

ДЕРЖАВНИЙ УНІВЕРСИТЕТ ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ
ТЕХНОЛОГІЙ
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ СИСТЕМ ТА ТЕХНОЛОГІЙ

КВАЛІФІКАЦІЙНА РОБОТА

на тему:

**«Автоматизована система для догляду за плодовими культурами на
основі комп'ютерного зору та штучного інтелекту»**

на здобуття освітнього ступеня магістр

зі спеціальності 126 Інформаційні системи та технології

(код, найменування спеціальності)

освітньо-професійної програми Інформаційні системи та технології

(назва)

*Кваліфікаційна робота містить результати власних досліджень.
Використання ідей, результатів і текстів інших авторів мають посилання на
відповідне джерело*

(підпис)

ОЛІЙНИК АНТОН

(ім'я, ПРІЗВИЩЕ здобувача)

Виконав:

здобувач вищої освіти

група ІСДМ-62

ОЛІЙНИК АНТОН

(ім'я, ПРІЗВИЩЕ)

Керівник

PhD.

Віктор САГАЙДАК

(ім'я, ПРІЗВИЩЕ)

Рецензент:

науковий ступінь,

вчене звання

(ім'я, ПРІЗВИЩЕ)

Київ 2025

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ**

Навчально-науковий інститут Інформаційних технологій

Кафедра Інформаційних систем та технологій

Ступінь вищої освіти магістр

Спеціальність 126 Інформаційні системи та технології

Освітньо-професійна програма Інформаційні системи та технології

ЗАТВЕРДЖУЮ

Завідувач кафедру ІСТ

_____ Каміла СТОРЧАК

“ _____ ” _____ 2025 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

Олійник Антон Валерійович

(прізвище, ім'я, по батькові здобувача)

1. Тема кваліфікаційної роботи: Автоматизована система для догляду за плодовими культурами на основі комп'ютерного зору та штучного інтелекту.

керівник кваліфікаційної роботи: Віктор САГАЙДАК, PhD

_____ *(ім'я, ПРІЗВИЩЕ, науковий ступінь, вчене звання)*

затверджені наказом Державного університету інформаційно-комунікаційних технологій від “30” жовтня 2025 р. № 467

2. Строк подання кваліфікаційної роботи «26» грудня 2025 р.

3. Вихідні дані кваліфікаційної роботи:

1. Фахова література, що охоплює проблематику комп'ютерного зору у сфері агропромисловості, а також стосується будови нейронних мереж..
2. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити).
3. Практичний досвід фірм, які запроваджують штучний інтелект і самокеровані технології у сільськогосподарській галузі (Джон Дір, Блу Рівер Технолоджі, Карбон Роботікс, DJI Агрікалчер).
4. Нормативно-технічна документація та стандарти оформлення магістерських робіт.
 4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити):
 1. Огляд наявних перспектив та майбутніх напрямків еволюції інтелектуальних систем та мехатроніки у сфері високоточного землеробства.
 2. Вивчення підходів обробки зображень (Computer Vision) та нейромережових архітектур (Deep Learning) з метою впровадження автоматизованого нагляду за рослинністю.
 3. Створення структурної схеми та програмування програмного комплексу для оцінки стану агрокультур із застосуванням штучного інтелекту та комп'ютерного зору.
 4. Перевірка збудованих алгоритмів на експериментальних даних, детальний розгляд показників коректності та кількісна оцінка дієвості розробленого інтелектуального механізму.
5. Перелік ілюстраційного матеріалу: *презентація*
6. Дата видачі завдання «30» жовтня 2025р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи
1.	Аналіз науково-технічної літератури за темою комп'ютерного зору в агросекторі та аналіз показника VPD.	30.10-05.11.25
2.	Вивчення методів глибокого навчання (Deep Learning) та архітектури Mask R-CNN для сегментації плодів.	06.11-12.11.25
3.	Аналіз принципів роботи наявних систем моніторингу (Priva, Ecoation) та огляд IoT-рішень для теплиць.	13.11-19.11.25
4.	Формування бази даних зображень та вибір критеріїв оцінки стадій стиглості (Green, Breaker, Pink, Red).	20.11-03.12.25
5.	Розробка загальної схеми системи моніторингу, архітектури програмного коду та модулів аналізу даних.	04.12-10.12.25
6.	Програмна реалізація модулів розпізнавання, сегментації та прогнозування врожайності. Дослідження роботи коду.	11.12-20.12.25
7.	Оформлення пояснювальної записки: написання розділів 1-3, вступу, загальних висновків та реферату.	21.12-26.12.25

Здобувач вищої освіти _____
(підпис)

АНТОН ОЛІЙНИК
(ім'я, ПРІЗВИЩЕ)

Керівник кваліфікаційної роботи _____
(підпис)

ВІКТОР САГАЙДАК
(ім'я, ПРІЗВИЩЕ)

ЗМІСТ

ВСТУП	10
1. ОСНОВНІ ВІДОМОСТІ ПРО ТЕХНОЛОГІЇ ЗАХИЩЕНОГО ҐРУНТУ, МЕТОДИ КОМП'ЮТЕРНОГО ЗОРУ ТА ОГЛЯД РІШЕНЬ АВТОМАТИЗАЦІЇ	12
1.1. Огляд методів контролю мікроклімату та стану рослин.....	12
1.1.1. Роль показника VPD (дефіцит тиску пари) у розвитку культур.....	12
1.1.2. Блок-схема типової автоматизованої теплиці.....	14
1.1.3. Підсистема сенсорів та виконавчих механізмів (IoT).....	16
1.1.4. Підсистема візуального моніторингу.....	19
1.1.5. Система передачі даних в умовах агрокомплексу.....	21
1.2. Методи комп'ютерного зору для фенотипування.....	24
1.2.1. Характеристики зображень у видимому та ІЧ-спектрах.....	25
1.2.2. Попередня обробка та аугментація даних.....	26
1.2.3. Сегментація зображень: методи виділення плодів.....	28
1.2.4. Підсистема класифікації (Deep Learning).....	31
1.2.5. Підсистема детекції об'єктів (Mask R-CNN).....	33
1.3. Огляд алгоритмів прогнозування врожайності.....	35
1.3.1. Структура часових рядів вегетації.....	37
1.3.2. Компоненти моделі LSTM для агропрогнозів.....	39
1.4. Фізіологія плодових культур (Томати/Полуниця).....	40
1.4.1. Фенологічні фази розвитку та ознаки дозрівання.....	41
1.4.2. Хвороби та шкідники: візуальні патерни.....	42
1.5. Огляд існуючих систем моніторингу теплиць.....	43
1.5.1. Рішення Priva – огляд платформи клімат-контролю.....	43
1.5.1.1. Короткий опис функцій Priva Connex.....	45
1.5.1.2. Огляд інтерфейсу оператора та візуалізації даних.....	46
1.5.2. Роботизовані платформи (Ecoation, iunU).....	47

1.5.3. Огляд платформ на базі відкритих мікроконтролерів.....	51
2. ОПИС ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ ДЛЯ МОНІТОРИНГУ ТА ДОГЛЯДУ ЗА ПЛОДОВИМИ КУЛЬТУРАМИ.....	55
2.1. Архітектура аналізу візуальних та кліматичних даних.....	55
2.2. Вибір порогових значень для мікроклімату та стадій стиглості.....	56
2.3. Архітектура програмного коду.....	58
2.3.1. Модуль Завантаження Даних (DataLoader: Сенсори + Камера).....	60
2.3.2. Модуль Обробки Зображень (ImageProcessor: Mask R-CNN).....	62
2.3.3. Модуль Прогнозування (PredictionModel: LinearReg/LST).....	63
2.3.4. Модуль Збереження Результатів та Сповіщення (AlertSystem).....	64
2.4. Імпорт необхідних бібліотек (OpenCV, TensorFlow/PyTorch, Pandas).....	65
2.5. Опис функцій детекції та розрахунку VPD.....	67
2.6. Основна програма (Main Loop).....	67
3. СХЕМА ДОСЛІДЖЕННЯ ТА РЕЗУЛЬТАТИ АНАЛІЗУ.....	68
3.1. Типова структура розробленої системи моніторингу.....	68
3.2. Фізична схема розміщення обладнання в теплиці.....	69
3.3. Опис полів бази даних (Dataset Description).....	72
3.4. Результати аналізу даних програмним кодом.....	76
3.4.1. Результати детекції плодів стадії Green (Зелені).....	79
3.4.2. Результати детекції плодів стадії Breaker (Початок зміни).....	81
3.4.3. Результати детекції плодів стадії Pink (Рожеві).....	84
3.4.4. Результати детекції плодів стадії Red (Стиглі).....	86
3.4.5. Результати діагностики захворювань листя.....	89
3.5. Результати прогнозування врожайності (Лінійна регресія vs Факт).....	92
ВИСНОВКИ.....	96
ПЕРЕЛІК ПОСИЛАНЬ.....	99

РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня магістра: 92 стор., 11 табл., 15 рис., 30 джерела.

Мета роботи – Створення автоматизованої системи для піклування за плодовими культурами в умовах закритого ґрунту.

Об'єкт дослідження – Процеси, пов'язані з вирощуванням плодових культур у теплицях, що негативно впливають на якість врожаю, такі як хвороби, шкідники, відхилення мікроклімату, дефіцит вологи, невчасний збір плодів.

Предмет дослідження – Автоматизована система для оцінки стану та догляду за плодовими культурами на основі комп'ютерного зору.

Короткий зміст роботи: У роботі проведено аналіз існуючих систем моніторингу тепличних комплексів, а також методів оцінки стану плодових культур. Розроблено програмне забезпечення, яке автоматизує процес обробки та прогнозування даних, отриманих із системи моніторингу. Також представлено аналіз застосування лінійної регресії для прогнозування майбутніх показників урожайності культур. Визначені критичні порогові значення стиглості для різних стадій (Green, Breaker, Turning, Pink, Red), що допомагає агрономам у моніторингу та вдосконаленні процесів обслуговування. Для практичного прикладу висвітлено результати прогнозування, які підтверджують працездатність запропонованого рішення.

КЛЮЧОВІ СЛОВА: Плодові культури, автоматизована система, комп'ютерний зір, теплиця.

ABSTRACT

This thesis document, submitted for the Master's qualification, comprises 92 pages, incorporates 11 tabular datasets, 15 images and cites 30 references.

The primary objective of this research was the creation of an automated framework designed for the maintenance and nurturing of fruit-bearing plants cultivated within enclosed, regulated settings.

The focus of our investigation centers on detrimental factors within greenhouse cultivation environments that compromise the quality of the harvest, specifically including pathogenic issues, infestation by harmful organisms, fluctuations in the surrounding climate, insufficient hydration levels, and the failure to collect produce at the optimal time.

Overview of the Thesis: This document first reviews current technologies for monitoring greenhouse environments and methodologies employed to assess the status of fruit crops. Subsequently, software was engineered to streamline the analysis and generate predictive models based on incoming data streams from the monitoring infrastructure. Furthermore, an evaluation is provided regarding the efficacy of employing linear regression models for forecasting anticipated yield metrics. Definitive thresholds for critical maturity stages (Encompassing Green, Breaker, Turning, Pink, and Red) have been established, offering agronomists tangible metrics to observe and enhance their cultivation methods. To illustrate practical application, specific forecasting outcomes are demonstrated, thereby validating the viability of the proposed system.

KEYWORDS: Orchard produce, mechanized framework, visual artificial intelligence, controlled-environment agriculture.

ВСТУП

Релевантність теми: Із розвитком напрямку "Агропромисловість 4.0" та нагальною потребою у зростанні врожайності, контроль стану плодкових культур стає пріоритетним завданням для тепличних комплексів. Сучасні споживачі вимагають продукції найвищої якості, вільної від патогенів та хімічних речовин, що зобов'язує агрономів здійснювати безперервне спостереження та оптимізацію умов вирощування. Агрономічній спільноті потрібен універсальний інструмент для вирішення цих завдань. Нині більшість інноваційних теплиць обладнані системами сенсорного моніторингу мікроклімату, однак, інтеграція цих даних із можливостями комп'ютерного зору дозволяє створити комплексний додаток для спрощення догляду за рослинами. Дана магістерська робота спрямована на розробку універсальної платформи для оцінювання стану плодкових культур, акцентуючи увагу як на потребах агропідприємств, так і на потенціалі, який можна реалізувати за допомогою штучного інтелекту.

Об'єкт дослідження – Процеси, що мають місце при культивуванні плодів у закритому ґрунті, котрі негативно впливають на якість кінцевого врожаю. До них належать: розвиток хвороб, діяльність шкідників, відхилення мікрокліматичних параметрів (зокрема, дефіцит тиску насиченої пари VPD), недостатнє зволоження, а також несвоєчасне збирання дозрілих плодів.

Предмет дослідження – Автоматизована система оцінки стану та забезпечення догляду за плодковими культурами, що базується на методах комп'ютерного зору та аналізі даних про мікроклімат.

Завдання роботи – Головна мета полягає у розробленні системи автоматизованого догляду за плодковими культурами, яка функціонуватиме на засадах комп'ютерного зору та штучного інтелекту.

Завдання, що мають бути вирішеними у ході дослідження:

Провести аналіз існуючих систем моніторингу теплиць та методів, застосовуваних у сфері комп'ютерного зору.

Визначити ключові критерії для оцінки життєздатності рослин та стадій дозрівання плодів.

Спроекувати архітектуру системи аналізу даних та логіку програмних модулів (алгоритмів ідентифікації та реагування).

Провести тестування функціоналу програмного забезпечення та оцінити точність візуального розпізнавання.

Наукова цінність – Полягає у формуванні цілісного методологічного підходу до автоматизованого агрономічного супроводу, що об'єднує візуальну діагностику стану рослин засобами ШІ з даними, отриманими від кліматичних сенсорів.

Практичне значення отриманих результатів – Розроблений програмний модуль для нагляду за плодовими культурами може бути впроваджений тепличними господарствами з метою контролю розвитку, підвищення товарної якості врожаю та раннього виявлення ознак захворювань рослин.

Апробація результатів магістерського дослідження. Основні напрацювання були представлені у збірниках тез II Всеукраїнської науково-технічної конференції "Технологічні горизонти: дослідження та застосування інформаційних технологій для технологічного прогресу України і світу", а також на II Міжнародній науково-практичній конференції «Сучасні аспекти діджиталізації та інформатизації в програмній та комп'ютерній інженерії» у 2024 році.

1. ОСНОВНІ ВІДОМОСТІ ПРО ТЕХНОЛОГІЇ ЗАХИЩЕНОГО ҐРУНТУ, МЕТОДИ КОМП'ЮТЕРНОГО ЗОРУ ТА ОГЛЯД РІШЕНЬ АВТОМАТИЗАЦІ

1.1. Огляд методів контролю мікроклімату та стану рослин

1.1.1. Роль показника VPD (дефіцит тиску пари) у розвитку культур

У царині закритого агровиробництва (Controlled Environment Agriculture) ключовим показником для модуляції мікросередовища вважається не ступінь вологості повітря (RH), а саме Дефіцит тиску водяної пари (VPD — Vapor Pressure Deficit). Ця інтегральна термодинамічна величина надає більш точне окреслення "посушливості" середовища з погляду потреб рослинного організму, а також визначає потужність транспіраційних процесів (процесу вивільнення вологи).

VPD визначається як різниця між максимально можливим тиском насиченої пари (SVP), який атмосфера може утримати за заданої теплоти, та фактично наявним тиском пари (AVP) у цьому ж повітряному середовищі. Саме цей градієнт тисків слугує рушійною силою, яка "витягує" вологу з рослинної структури в оточуюче середовище.

Для забезпечення інтелектуального розрахунку VPD у керуючій системі застосовується такий послідовний алгоритм (заснований на формулі Магнуса):

Обчислення тиску насичення (SVP) у кілопаскалях:

$$SVP = 0.61078 * \exp((17.27 * T) / (T + 237.3)),$$

де: T – тепловий режим у градусах Цельсія (°C); exp – показник експоненційної функції.

Визначення дійсного тиску пари (AVP) у кілопаскалях:

$$AVP = SVP * (RH / 100)$$

,

де: RH – відносна насиченість повітря вологою (у відсотках, %).

Кінцевий розрахунок дефіциту (VPD):

$$VPD = SVP - AVP$$

Аби досягти вищої точності (особливо при використанні систем комп'ютерного бачення з тепловізійними датчиками), розраховують показник Листкового VPD (Leaf VPD), залучаючи температуру листка замість температури повітря для визначення насиченого тиску всередині продихових камер. Це має надзвичайне значення, адже під прямим сонячним впливом поверхня листка може бути теплішою за повітря на 2–5 °С, що кардинально змінює реальну рушійну силу випаровування.

Вплив усталених рівнів VPD на життєдіяльність плодових культур

Контроль VPD дає змогу досягти балансу між двома протилежними фізіологічними потребами: розкриттям продихів для поглинання вуглекислого газу (для фотосинтезу) та підтриманням внутрішнього водного балансу (тургору).

Незначний VPD (нижче 0.4 кПа): Фаза інертності. У цьому інтервалі повітря практично насичене (дуже висока вологість). Градієнт тиску між внутрішніми тканинами листка та атмосферою стає мінімальним, спричиняючи пригнічення випаровування вологи.

Дефіцит поживних елементів: Транспірація виступає головним "насосом", що підіймає воду з розчиненими мінералами від кореневої системи до верхівки. Кальцій — це елемент із низькою рухливістю, що транспортується виключно потоком ксилеми. Гальмування транспірації припиняє доставку кальцію до зон активного росту та до плодів, спричиняючи відмирання країв листових пластин (Tip Burn) у салатних культурах та суницях, а також загнивання верхівки плоду (Blossom End Rot) у пасльонових (томати, перець).[1]

Ризик інфекційних захворювань: Постійна наявність змочування на листі чи надмірна вологість створюють сприятливі умови для проростання спор грибкових збудників, як-от сіра гниль та пероноспороз.

Оптимальний VPD (0.8 – 1.2 кПа): Режим високої продуктивності. Це цільовий діапазон, рекомендований для більшості плодових культур (томати, огірки, перці) у фазі формування плодів.

Продихи рослини перебувають у максимально відкритому стані, що забезпечує безперешкодне потрапляння вуглекислого газу всередину листа, тим самим піднімаючи швидкість фотосинтезу до максимуму.

Інтенсивність випаровування достатня для ефективного охолодження рослини (за рахунок латентної теплоти пароутворення) та активного переміщення мінералів, проте не перевищує здатність кореневої системи поглинати воду.

Значний VPD (понад 1.6 кПа): Режим водного стресу. Атмосфера стає надмірно сухою ("спраглою" до вологи). Швидкість випаровування з поверхні листка перевищує можливості гідравлічної провідності коренів.

Захисний відгук: Рослина змушена герметизувати продихи, аби запобігти критичному зневодненню. Це миттєво блокує фотосинтетичні процеси через припинення надходження вуглецю.

Наслідки: Спостерігається підвищення температури листка (через відсутність охолодження випаровуванням), втрата тургору (в'янення), можливе скидання бутонів та зав'язі у томатів.

Таким чином, розробка автоматизованих систем, що орієнтовані саме на стабілізацію показника VPD, а не на окремий контроль температури чи вологості, є обов'язковою умовою для повної реалізації генетичного потенціалу врожайності сучасних високопродуктивних сортів плодкових культур.

1.1.2. Типова модель автоматизованої теплиці

Сучасні тепличні комплекси, що функціонують на засадах автоматизації, проектуються як розгалужені кіберфізичні системи, де програмне забезпечення безпосередньо взаємодіє з біологічними процесами та фізичними умовами. Зазвичай, архітектура подібних рішень зводиться до ієрархічної структури, що дає змогу чітко розділити зони відповідальності апаратного забезпечення та забезпечити високу стійкість управління. Умовно, логічна схема автоматизації поділяється на три взаємопов'язані яруси: рівень збору даних та виконання команд, рівень локального контролю та рівень ухвалення стратегічних рішень.

Найдетальніший, або "польовий", рівень забезпечує прямий контакт технічних засобів із середовищем, де відбувається культивування. Цей рівень охоплює розгалужену мережу датчиків, завдання яких — збирати первинні відомості про стан ґрунту та мікроклімату. Сюди входять як вимірювачі температури, вологості повітря, концентрації CO₂, так і спеціалізовані сенсори для оцінки кількості світла у фотосинтетично активному діапазоні. Окрім приладів вимірювання, тут розміщуються й актуатори – механізми, що фізично модифікують параметри оточення. Це включає електроприводи вентиляційних систем, насоси для зрошення, апаратуру для штучного освітлення та керування затіненням. Важливою складовою сучасних рішень на цьому рівні є також системи комп'ютерного зору, які слугують візуальними сенсорами для моніторингу стану рослин. [2]

Середній ярус системи відповідає за первинну обробку зібраної інформації та локальне регулювання. Його функціонал реалізується за допомогою мікроконтролерів або спеціалізованих ПЛК, що монтуються безпосередньо в зоні теплиці. Ключовим завданням цього рівня є зведення сигналів від сенсорів, усунення операційних перешкод та реалізація базової логіки управління в режимі реального часу. Локальні контролери здатні підтримувати стабільність системи, навіть коли втрачається зв'язок із головним сервером, виконуючи критично важливі аварійні протоколи (наприклад, закриття вікон при сильному вітрі чи зупинка поливу, якщо резервуари переповнені). Зв'язок із вищим рівнем зазвичай відбувається через захищені промислові протоколи або бездротові з'єднання.

Найвищий архітектурний рівень представлений серверною інфраструктурою або хмарною платформою, де зосереджено основні обчислювальні ресурси. Саме тут відбуваються найбільш складні операції, зокрема аналіз відеоданих за допомогою нейронних мереж для ідентифікації захворювань або визначення оптимальної фази дозрівання врожаю. На цьому рівні функціонує база даних, що акумулює історичні відомості про кліматичні цикли та виробничі показники. Взаємодія оператора із системою відбувається через графічний інтерфейс веб-

застосунку чи мобільного клієнта, надаючи доступ до звітів та можливості коригувати загальну стратегію вирощування.

Робота всього комплексу ґрунтується на засадах замкнутого контуру регулювання. Дані, отримані від периферійних сенсорів, постійно зіставляються з фіксованими чи динамічно змінними (завдяки алгоритмам ШП) цільовими значеннями (уставками). На підставі виявлених дисбалансів контролер генерує команди для виконавчих механізмів, працюючи на мінімізацію похибки регулювання. Як приклад: якщо камера фіксує ознаки зневоднення рослин, а манометри показують падіння тиску пари, система самостійно ініціює процес штучного туманоутворення, нейтралізуючи стресові фактори без втручання людини.

1.1.3. Функціональна частина сенсорів та виконавчих механізмів

Фізична складова системи автоматизації керування оранжереею складається з ансамблю датчиків та рушійних пристроїв, котрі забезпечують чутливу (перцептивну) та рухову (кінетичну) взаємодію між цифровим вузлом керування та фактичним біологічним середовищем. Надійність цієї підсистеми є вирішальною обставиною, зважаючи на те, що умови в теплиці обтяжені агресивними експлуатаційними факторами, до яких належать висока відносна вологість, що нерідко наближається до точки роси, присутність хімічно активних речовин у вигляді розведених добрив, та інтенсивне ультрафіолетове випромінювання. З огляду на це, під час розробки апаратної частини необхідно відмовитися від застосування комплектуючих побутового класу на користь промислових рішень, які демонструють належні метрологічні параметри та відповідний рівень захисту корпусу.

Фундаментом для спостереження за мікрокліматом всередині є вимірювання температури та відносної вологості повітря, точність яких прямо впливає на коректність обчислення нестачі тиску насиченої пари. У сучасних реалізаціях простежується повний перехід від застарілих резистивних сенсорів до інтегральних

датчиків, побудованих на ємнісних полімерах, як-от моделі серій SHT3x чи BME280. Принцип дії останніх ґрунтується на зміні діелектричної проникності полімерного шару внаслідок абсорбції молекул води, що дає змогу досягти по саїбки вимірювання в межах декількох відсотків та мінімізувати ефект гістерезису. Оскільки переважна більшість цих датчиків використовує інтерфейс I2C, який має обмеження щодо довжини лінії передачі даних, для їхнього включення у розподілену мережу великого тепличного комплексу слушно застосовувати проміжні контролери, які перетворюють сигнал на промислову шину RS-485 із застосуванням протоколу Modbus RTU, забезпечуючи тим самим стабільну до перешкод передачу на великі відстані. [3]

Для контролю середовища в кореневій зоні, яке виступає резервуаром поживних речовин для рослин, залучаються техніки визначення вологості ґрунту, засновані на оцінці діелектричної проникності цієї субстанції. Ємнісні сенсори вологості є незамінним вибором для тривалого експлуатаційного періоду, тому що їхні електроди відокремлені від безпосереднього гальванічного контакту з ґрунтом, що виключає явища електролізу та корозії, притаманні недорогим резистивним аналогам. Окрім рівня вологості, критично значущим показником є концентрація вуглекислого газу, для вимірювання якої використовуються недисперсійні інфрачервоні датчики (NDIR). Їхня робота базується на принципі поглинання молекулами газу ІЧ-випромінювання на певній довжині хвилі, що гарантує високу вибірковість та стійкість показань протягом тривалого проміжку часу без потреби у частому калібруванні.

Виконавча частина системи втілює керуючі впливи на мікроклімат через сукупність виконавчих механізмів, серед яких належне місце посідають електромагнітні клапани системи зрошення та приводні механізми вентиляції. При виборі запірної арматури для стаціонарних установок перевагу слід надавати моделям, що живляться змінним струмом напругою 24 В, оскільки вібрація якоря соленоїда, спричинена мережевою частотою, сприяє запобіганню накопиченню кальцієвих відкладень та унеможлиблює заклинювання рухомого елемента. Для незалежних робочих блоків раціональніше використовувати бістабільні клапани на

постійному струмі, які споживають енергію лише у момент перемикання стану. Керування потужними навантаженнями реалізується за допомогою електромеханічних реле, котрі забезпечують гальванічне розділення, або шляхом застосування польових транзисторів (MOSFET) у тих ситуаціях, коли потрібне плавне регулювання потужності методом широтно-імпульсної модуляції, наприклад, для регулювання інтенсивності фітосвітільників чи швидкості обертання циркуляційних вентиляторів.

Зведення усіх складових до єдиної системи вимагає неухильного дотримання нормативів захисту апаратури. Усі датчики та рушійні елементи, розташовані в зоні вирощування, повинні мати ступінь захисту корпусу не нижче IP65 для забезпечення стійкості до струменів води та пилових частинок, тоді як занурювальні ґрунтові сенсори потребують класу IP67. Електронні плати управління, що функціонують у середовищі з підвищеною вологістю, підлягають обов'язковому покриттю спеціальними вологоізолюючими компаундами з метою уникнення коротких замикань та електрохімічної міграції провідних елементів, що слугує запорукою стабільної роботи автоматизованого комплексу протягом усього аграрного циклу. TRAU/TC (Transcoding Rate and Adaptation Unit) - транскодер.

1.1.4. Підсистема візуального моніторингу

Система візуального нагляду, або комп'ютерного бачення, слугує наріжним каменем у процесі надання інтелекту сучасним тепличним комплексам. Вона перетворює їх із просто автоматизованих установок на кіберфізичні системи, наділені елементами штучного інтелекту. На противагу звичайним сенсорам, які фіксують лише параметри довкілля, ця частина системи зосереджена на прямому, неутручальному аналізі стану живих організмів – рослин. Ключове її завдання полягає у зборі об'єктивної інформації стосовно стадій розвитку за фенологією, вимірюванні біометричних характеристик культури, ідентифікації наявних хвороб та

прогнозуванні обсягу врожаю. Це відкриває шлях до застосування стратегії управління, що акцентується саме на потребах рослини (plant-centric control). Робота цієї системи ґрунтується на постійному зберіганні, попередній підготовці та глибинному аналізі відеопотоків або окремих знімків, отриманих через оптичні датчики, встановлені в зоні вирощування.

Конструкція апаратного забезпечення для візуального моніторингу є змішаною і визначається конкретними цілями фенотипування. Фундаментальним рівнем вважається використання кольорових камер із високою роздільною здатністю (RGB). Вони дають змогу фіксувати візуальні ознаки у видимому спектрі: наприклад, зміну кольору листя внаслідок хлорозу, появу плям некрозу, спричинених грибковими інфекціями, чи сліди пошкоджень від шкідників. Для складніших завдань, як-от оцінка загальної біомаси та геометричних параметрів плодів, застосовують камери, що фіксують глибину (RGB-D), які працюють за принципом стереоскопії або вимірювання часу прольоту світла (Time-of-Flight). Вони формують тривимірну карту сцени, що уможливорює програмному забезпеченню чітко відокремлювати плоди від фону, листя та стебел, а також з високою точністю обчислювати їхній реальний розмір та об'єм, усуваючи помилки проєкційного спотворення, які притаманні стандартним двовимірним зображенням. [5]

На вищому етапі діагностики залучаються мультиспектральні та гіперспектральні камери. Вони фіксують відбите світло у діапазонах, невидимих для людського ока, зокрема у ближній інфрачервоній частині (NIR). Це дає змогу розраховувати індекси вегетації, як-от NDVI, та виявляти фізіологічний стрес рослин (нестача вологи, дефіцит азоту) вже на початковій, латентній стадії, за кілька днів до того, як проявляться видимі ознаки. Проте, через високу вартість такого обладнання, у комерційних рішеннях часто застосовують проміжні варіанти: наприклад, модифіковані камери без інфрачервоного фільтра (NoIR) у поєднанні зі спеціальними

джерелами світла. Це дозволяє отримувати дані про здатність до фотосинтезу з достатньою точністю для прийняття управлінських рішень.

Ключовим моментом у розробці цієї системи є організація простору для спостереження та система освітлення. У випадках густої посадки високих культур, скажімо, томатів, стаціонарні камери мають обмежений огляд і стикаються з проблемою оклюзії (перекриття) об'єктів листям. Для подолання цього недоліку використовуються рухомі платформи або роботи, що пересуваються по напрямних системи обігріву між рядами рослин, проводячи сканування всього вертикального профілю культури. Стабільність роботи програм зображення значною мірою залежить від умов освітлення, які всередині теплиці дуже мінливі через зміну положення сонця та хмарність. Щоб мінімізувати вплив тіней та відблисків, застосовують контрольоване штучне освітлення (спалахи світлодіодів або постійне світло з високим індексом передачі кольору CRI), яке синхронізують із моментом фіксації кадру. Це гарантує сталу радіометричну якість зображень, незалежно від часу доби.

Опрацювання великих обсягів візуальних даних вимагає суттєвих обчислювальних ресурсів, що зумовлює потребу у двоетапній архітектурі обробки. На нижньому етапі (Edge Computing), безпосередньо біля самих камер, задіюють бортові обчислювальні пристрої з апаратними прискорювачами нейромереж. Вони відповідають за первинне сортування, ущільнення даних та вибір найбільш важливих кадрів. Це знижує навантаження на комунікаційні лінії та гарантує миттєву реакцію системи. Підготовлена інформація надсилається на вищий рівень (або хмарний сервер, або локальний потужний сервер із графічними процесорами), де розгортаються складні згорткові нейронні мережі для виконання найбільш вимогливих операцій: семантичної сегментації, розпізнавання захворювань та моделювання майбутнього зростання. Така структура забезпечує раціональний компроміс між швидкістю реагування, точністю аналізу та загальною вартістю впровадження системи.

1.1.5. Система передачі даних в умовах агрокомплексу.

Створення надійної магістралі для збору телеметрії у межах великого демплексу теплиць є завданням, що вимагає значних інженерних рішень, і кардинально різниться від впровадження ІТ-інфраструктури в офісних чи житлових будівлях. Характерні риси агропромислового середовища — це потреба у покритті значних територій, високий рівень вологості повітря та екрануюча дія металевих конструкцій самої споруди. Особливо гостро стоїть проблема загасання радіохвиль, що виникає при їх проходженні через шари рослинної маси. Вода, сконцентрована у листях та стеблах таких культур, як, наприклад, томати, має здатність інтенсивно поглинати електромагнітні коливання, особливо в частотному діапазоні 2.4 ГГц. Це, своєю чергою, робить типові протоколи на кшталт ZigBee чи звичайного Wi-Fi не надто надійними для забезпечення зв'язку з віддаленими сенсорними приладами, розміщеними у товщі рослинності.

Беручи до уваги ці обставини, структура мережі для передачі даних проєктується за гібридним сценарієм, де потоки інформації розподіляються відповідно до вимог до пропускну здатності та стійкості з'єднання. Для акумулювання даних від широко розгорнутої сітки ґрунтових моніторів та датчиків мікроклімату, які транслюють невеликі порції даних нечасто, найбільш оптимальним є застосування технологій енергоефективних мереж з великим радіусом дії (LPWAN), а саме — протоколу LoRaWAN. Використання частотного спектру нижче одного гігагерца (868 МГц) надає сигналу кращу здатність проникати крізь густу рослинну біомасу, дозволяючи охопити площі у декілька гектарів, задіюючи лише один центральний шлюз. Це також сприяє тривалій автономній роботі сенсорних вузлів від батарей, мінімізуючи витрати на прокладання дротів. [6]

На противагу мережі сенсорів, підсистема, відповідальна за управління виконавчими пристроями, та блок комп'ютерного зору, ставлять абсолютно інші вимоги до каналів комунікації. Контроль за насосними станціями, запірною

арматурою та вентиляторами потребує безумовного постачання команд із мінімальною затримкою. Тому для цього сегменту стандартом залишається фізичний промисловий інтерфейс RS-485 із застосуванням протоколу Modbus RTU. Висока стійкість до зовнішніх завад, притаманна диференціальній лінії зв'язку, дозволяє ефективно віддавати команди обладнанню навіть там, де присутні електромагнітні наведення від потужного електричного інструментарію.

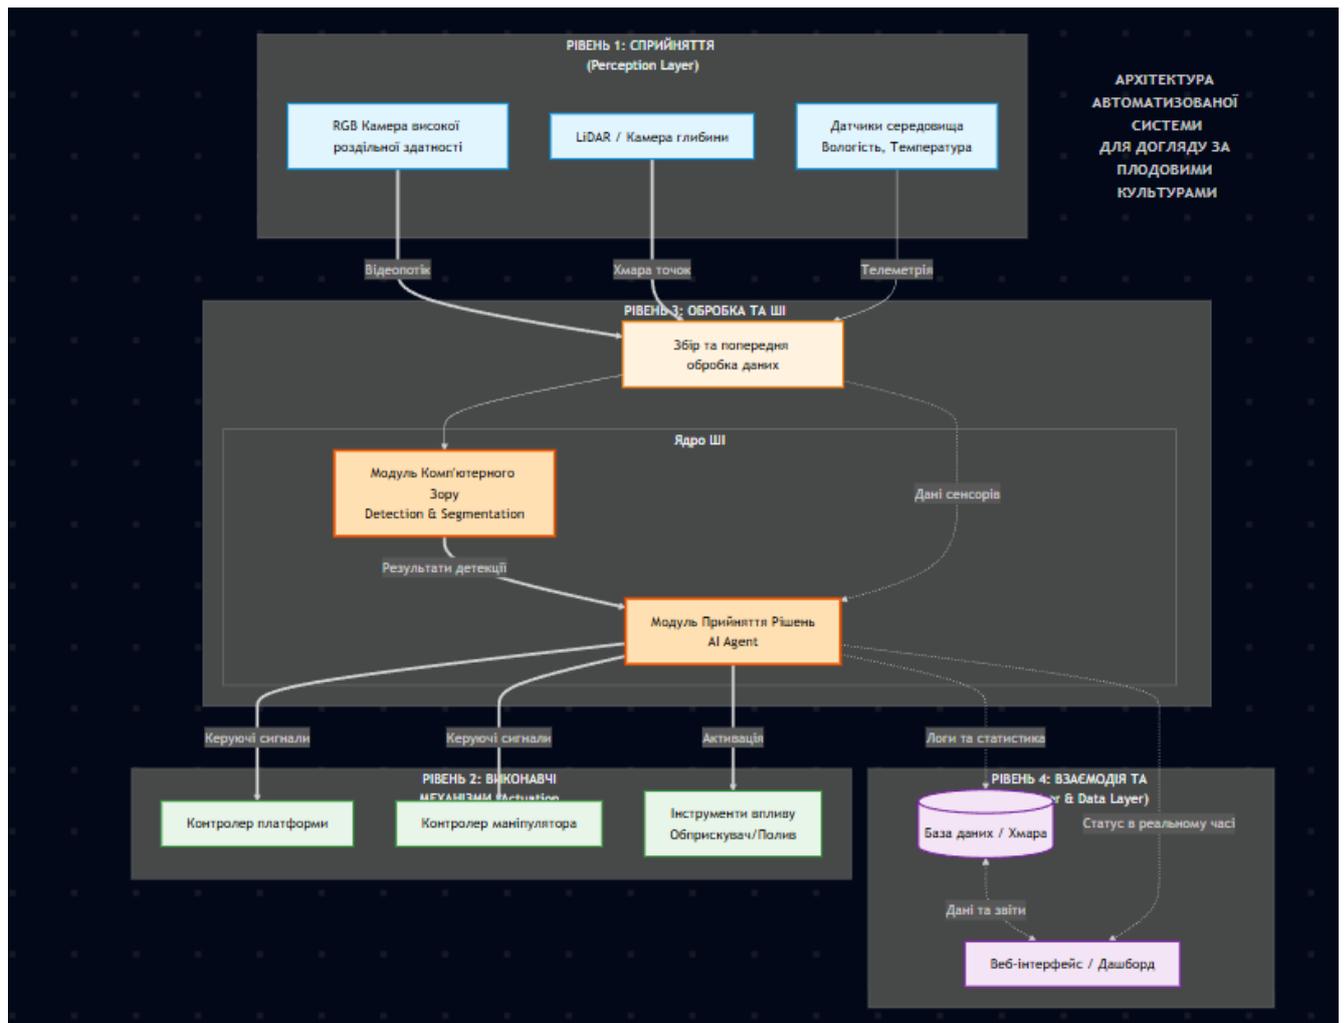


Рис 1.1 Архітектура автоматизованої системи

Для передачі інформації з камер комп'ютерного зору, зокрема відеопотоків та зображень високої якості, обсяг яких вимірюється мегабайтами, низькошвидкісні з'єднання LoRa чи RS-485 є непридатними. З цієї причини для даної частини системи розгортається локальна високошвидкісна мережа на базі стандарту Wi-Fi 5/6 (IEEE 802.11ac/ax), переважно у п'ятигігерцовому діапазоні,

задля уникнення взаємних перешкод, або ж використовується дротовий Ethernet з технологією PoE (Power over Ethernet). Використання PoE є більш бажаним варіантом для камер, що встановлені стаціонарно, оскільки це одночасно вирішує питання енергозабезпечення приладів та гарантує стабільну пропускну здатність для надсилання відеоданих на сервер аналізу без деградації якості.

На рівні програмного забезпечення взаємодія між усіма елементами системи — від вбудованих контролерів до хмарного серверу — уніфікується завдяки застосуванню протоколу MQTT (Message Queuing Telemetry Transport). Цей легконавантажений протокол оперує за принципом «видавець-підписник», що дає можливість гнучко розширювати систему, додаючи нове апаратне забезпечення без необхідності повної реконфігурації мережі. Ба більше, MQTT забезпечує буферизацію повідомлень на рівні брокера, що гарантує збереження зібраних телеметричних показників навіть при короткочасних розривах зв'язку, тим самим підвищуючи загальну стійкість до збоїв усього автоматизованого комплексу.

1.2. Методи комп'ютерного зору для фенотипування

Оцінка фенотипу рослин через призму комп'ютерного зору — це процес дистанційного зчитування морфологічних та фізіологічних характеристик агрокультур на базі аналізу їхніх цифрових зображень. На відміну від традиційного методу "окомірної" оцінки, автоматизовані підходи дають змогу отримувати об'єктивні, вимірювані показники щодо розвитку, зміни кольору та параметрів структури рослин, не торкаючись їх безпосередньо, що значно зменшує ймовірність травмування тканин чи занесення інфекцій.

Сучасна технологічна база для візуального обстеження в аграрній сфері ґрунтується на багатоспектральних даних; комбінація діапазонів видимого світла (RGB) та інфрачервоного (IR) спектрів дає змогу розпізнавати не лише зовнішні ознаки плодів, але й приховані сигнали стресового стану рослини. Важливою складовою є попереднє опрацювання захоплених кадрів: сюди входить вирівнювання рівня освітлення, очищення від цифрових артефактів та аугментація

— штучне збільшення обсягу навчальних даних шляхом змін геометрії. Це необхідно для забезпечення надійної роботи алгоритмів у непростих тепличних умовах, як-от зміни освітлення через хмарність, блики на склі чи затінення елементами самої рослинності.

Процедура інтелектуального аналізу, як правило, поділяється на кілька етапів: виявлення (локалізація об'єкта), класифікація (визначення типу чи стадії дозрівання) та сегментація (точне окреслення меж). Застосування архітектур глибокого навчання дає змогу системі розрізняти нюанси фактури плодів і листків, ефективно відсікаючи складний фон теплиці. Особлива увага приділяється екземплярній сегментації, яка дає змогу трактувати кожен плід у густому суцвітті як окрему сутність, що є вирішальним для точного передбачення врожайності та керування роботизованими пристроями. Отже, методи комп'ютерного зору перетворюють візуальну інформацію на структуровані цифрові відомості, які стають фундаментом для ухвалення рішень інтелектуальною системою агротехнічного догляду. [7]

1.2.1. Характеристики зображень у видимому та ІЧ-спектрах

Успішність роботи моделей глибокого навчання, зокрема тих, що базуються на згорткових нейронних мережах, напряму залежить від обсягу та якості вхідних даних. Візуальні дані, отримані безпосередньо із камер у парникових умовах, зазвичай насичені шумами, містять артефакти стиснення та демонструють значні коливання параметрів, що робить їх пряме використання для тренування алгоритмів проблематичним. Відтак, етап попередньої обробки (preprocessing) є невіддільною складовою конвеєра комп'ютерного зору. Його мета — уніфікувати вхідний потік та посилити важливі характеристики об'єктів, які нас цікавлять. Першочерговим кроком є просторова нормалізація, яка полягає у приведенні всіх зображень до сталої роздільної здатності, сумісної з вхідним рівнем нейронної мережі (наприклад, розмірністю 512×512 чи 1024×1024 пікселів), при цьому зберігаючи співвідношення сторін за допомогою білінійних чи бікубічних методів інтерполяції. Окрім того, проводиться радіометрична нормалізація: значення

яскравості пікселів коригуються у діапазон $[0, 1]$ або стандартизуються (через віднімання середнього значення та ділення на стандартне відхилення усього набору даних). Це забезпечує стабільність обчислення градієнтів під час тренування мережі та прискорює досягнення нею збіжності.

Особливістю візуальних даних, зібраних у тепличних комплексах, є їхня висока чутливість до умов освітлення, які постійно змінюються протягом дня залежно від кліматичних умов. Тіні від конструкцій, відблиски на гладких поверхнях плодів (як-от помідорів чи перцю), а також флуктуації колірної температури сонячного світла можуть призводити до хибної класифікації. Для послаблення впливу цих факторів на етапі попередньої обробки часто застосовують техніки підвищення контрастності, як-от адаптивне вирівнювання гістограми (CLAHE), а також здійснюють перехід від RGB до колірних просторів HSV або Lab. Останні дозволяють відокремити інформацію про власне колір від інформації про яскравість освітлення, що суттєво підвищує стійкість алгоритмів детекції до появи надмірно темних або надмірно світлих ділянок.

Проте, найбільшим викликом при навчанні систем штучного інтелекту для агрономічних завдань залишається брак даних із відповідними мітками, особливо для рідкісних випадків, наприклад, виявлення специфічних патологій на початкових етапах їх розвитку. Для подолання цієї проблеми використовується метод посилення даних (data augmentation) — штучне розширення навчальної вибірки через створення нових варіантів наявних зображень. Основні геометричні трансформації включають випадкові обертання, дзеркальне відображення по горизонталі чи вертикалі, зміну масштабу (zoom) та зсуви. Ці операції імітують різноманіття позицій камери відносно рослини та різні кути орієнтації плодів у тривимірному просторі, що сприяє формуванню у мережі інваріантності до геометричних деформацій.

Для підсилення стійкості (робастності) системи до умов реальної експлуатації надзвичайно важливими є фотометричні аугментації та методи симуляції затулень. Фотометричні перетворення охоплюють випадкову зміну яскравості, контрасту, насиченості та додавання гауссівського шуму, що імітує

роботу камери в різних умовах освітлення та при різній прозорості покривного матеріалу теплиці. Моделювання оклюзій (часткового перекриття) є особливо актуальним для культур, де плоди часто приховані листям або стеблами. Застосування таких методів, як CutOut (випадкове виключення прямокутних зон на зображенні) або MixUp (накладання напівпрозорих фрагментів з інших візуальних матеріалів), змушує нейронну мережу навчатися ідентифікувати об'єкти не лише за їхнім повним контуром, але й на основі часткових ознак (таких як текстура шкірки чи форма чашолистка), що значно підвищує точність детектування у густому рослинному покриві. [8]

1.2.2. Попередня обробка та аугментація даних

Сучасні тепличні комплекси, що функціонують на засадах автоматизації, проектуються як розгалужені кіберфізичні системи, де програмне забезпечення безпосередньо взаємодіє з біологічними процесами та фізичними умовами. Зазвичай, архітектура подібних рішень зводиться до ієрархічної структури, що дає змогу чітко розділити зони відповідальності апаратного забезпечення та забезпечити високу стійкість управління. Умовно, логічна схема автоматизації поділяється на три взаємопов'язані яруси: рівень збору даних та виконання команд, рівень локального контролю та рівень ухвалення стратегічних рішень.

Найдетальніший, або "польовий", рівень забезпечує прямий контакт технічних засобів із середовищем, де відбувається культивування. Цей рівень охоплює розгалужену мережу датчиків, завдання яких — збирати первинні відомості про стан ґрунту та мікроклімату. Сюди входять як вимірювачі температури, вологості повітря, концентрації CO₂, так і спеціалізовані сенсори для оцінки кількості світла у фотосинтетично активному діапазоні. Окрім приладів вимірювання, тут розміщуються й актуатори – механізми, що фізично модифікують параметри оточення. Це включає електроприводи вентиляційних систем, насоси для зрошення, апаратуру для штучного

освітлення та керування затіненням. Важливою складовою сучасних рішень на цьому рівні є також системи комп'ютерного зору, які слугують візуальними сенсорами для моніторингу стану рослин.

Середній ярус системи відповідає за первинну обробку зібраної інформації та локальне регулювання. Його функціонал реалізується за допомогою мікроконтролерів або спеціалізованих ПЛК, що монтуються безпосередньо в зоні теплиці. Ключовим завданням цього рівня є зведення сигналів від сенсорів, усунення операційних перешкод та реалізація базової логіки управління в режимі реального часу. Локальні контролери здатні підтримувати стабільність системи, навіть коли втрачається зв'язок із головним сервером, виконуючи критично важливі аварійні протоколи (наприклад, закриття вікон при сильному вітрі чи зупинка поливу, якщо резервуари переповнені). Зв'язок із вищим рівнем зазвичай відбувається через захищені промислові протоколи або бездротові з'єднання.

Найвищий архітектурний рівень представлений серверною інфраструктурою або хмарною платформою, де зосереджено основні обчислювальні ресурси. Саме тут відбуваються найбільш складні операції, зокрема аналіз відеоданих за допомогою нейронних мереж для ідентифікації захворювань або визначення оптимальної фази дозрівання врожаю. На цьому рівні функціонує база даних, що акумулює історичні відомості про кліматичні цикли та виробничі показники. Взаємодія оператора із системою відбувається через графічний інтерфейс веб-застосунку чи мобільного клієнта, надаючи доступ до звітів та можливості коригувати загальну стратегію вирощування.

Робота всього комплексу ґрунтується на засадах замкнутого контуру регулювання. Дані, отримані від периферійних сенсорів, постійно зіставляються з фіксованими чи динамічно змінними (завдяки алгоритмам ШП) цільовими значеннями (уставками). На підставі виявлених дисбалансів контролер генерує команди для виконавчих механізмів, працюючи на мінімізацію похибки регулювання. Як приклад: якщо камера фіксує ознаки зневоднення рослин, а манометри показують падіння тиску пари, система

самостійно ініціює процес штучного туманоутворення, нейтралізуючи стресові фактори без втручання людини.. [9]

1.2.3. Сегментація зображень: методи виділення плодів

Автоматизоване визначення розташування плодів на отриманих візуальних даних є наріжним етапом у конвеєрі обробки інформації для систем точного агроменеджменту. Дане завдання формалізується як завдання сегментації зображень – процес, метою якого є розділення візуального простору на підмножини пікселів, що відповідають об'єктам, які нас цікавлять (плодам), та елементам оточення (зелені масиви, стебла, елементи конструкцій навісів). Еволюція підходів до цієї проблематики простежується від елементарних, заснованих на правилах алгоритмів до складних мережевих структур, здатних адаптуватися до різноманіття польових чи тепличних умов.

Традиційні підходи до візуального аналізу На початкових етапах проектування систем комп'ютерного зору для аграрних потреб переважали методи, орієнтовані на аналіз базових візуальних характеристик, таких як тональність та яскравість.

Сегментація методом порогового значення (Thresholding): Широко застосовувався метод Оцу (Otsu's method), котрий автоматично встановлює оптимальний поріг яскравості для переведення зображення у бінарний формат, мінімізуючи розкид значень у межах одного класу. Незважаючи на його швидкість обчислень, у тепличних умовах його надійність знижується через нерівномірність освітлення та наявність світловідбиттів на поверхні плодів, які помилково трактуються як вади або елементи тла.

Оцінка кольорових моделей: Оскільки стандартний простір RGB надмірно чутливий до флуктуацій освітленості, часто вдаються до трансформації у простори HSV (Відтінок, Насиченість, Значення) або Lab. Це дає змогу ефективніше відокремлювати стиглі (зазвичай червоні) плоди від зеленої рослинності через

аналіз складової "Відтінок" (Hue). Однак для незрілих плодів, які маскують своє зелене забарвлення, цей спосіб виявляється малоефективним.

Алгоритми кластеризації (K-means): Цей інструмент дозволяє об'єднувати пікселі на основі схожості їхніх атрибутів. Його слабкість полягає у потребі попередньо визначити кількість груп (кластерів) і нездатності враховувати просторовий зв'язок між пікселями, що часто породжує небажаний "шум" на фінальних сегментаційних картах.

Глибинне навчання: Семантичне розмежування Обмеження, властиві традиційним методам при роботі з об'єктами, які мають складну периферію, спричинили перехід до застосування згорткових нейронних мереж (CNN). Однією з ранніх успішних архітектур була U-Net (спочатку розроблена для медичної іміджині). Вона використовує симетричну структуру "стиснення-розширення" ("кодер-декодер") з додатковими з'єднаннями (skip connections), що дозволяє зберегти високочастотні деталі у вихідній мапі. U-Net демонструє високу точність піксельної класифікації, але має принциповий недолік для завдань, пов'язаних із підрахунком: вона виконує семантичну сегментацію, а не екземплярну. Це означає, що при контакті двох плодів у суцвітті, алгоритм об'єднує їх в один сегмент, унеможливаючи точний підрахунок одиниць та вимірювання їхніх індивідуальних габаритів.

Екземплярна сегментація: Mask R-CNN Для подолання проблеми розділення тісно розташованих об'єктів у сучасних системах моніторингу еталонним рішенням стала структура Mask R-CNN (Мережа згортки на основі регіонів). Даний підхід належить до категорії двостадійних детекторів і є розширенням архітектури Faster R-CNN.

Процедура опрацювання у Mask R-CNN складається з двох фаз:

Формування регіональних припущень (RPN — Region Proposal Network): Мережа аналізує карту ознак зображення та пропонує низку потенційних зон (Region of Interest — RoI), де може знаходитись об'єкт.

Уточнення параметрів та маскування: Щодо кожної виділеної зони одночасно проводяться три операції: ідентифікація типу об'єкта (наприклад,

"дозрілий", "зелений"), корекція обмежувального прямокутника (bounding box) та формування бінарної маски для кожного екземпляра (instance mask). [10]

Ключова перевага Mask R-CNN полягає у впровадженні шару RoIAlign, який ліквідує проблему зсуву квантування (quantization misalignment), притаманну попереднім версіям. Це гарантує точне попиксельне відповідність маски вихідному зображенню, що є невід'ємним для завдань фенотипування, де навіть незначна помилка у визначенні діаметра плода може суттєво спотворити розрахунки біомаси. Завдяки цій інтелектуальній конструкції, система спроможна ефективно ідентифікувати та відокремлювати навіть сильно перекриті плоди (оклюзії), що закріплює її як найбільш підходящий інструмент для розробки автоматизованих систем догляду в умовах промислового тепличного господарства.

1.2.4. Підсистема класифікації (Deep Learning)

У межах автоматизованих систем моніторингу, підсистема, що відповідає за класифікацію, виконує семантичний аналіз візуальної інформації. Її функція зводиться до перетворення необроблених масивів пікселів у змістовні якісні характеристики об'єктів. Якщо ж завдання сегментації фокусується на встановленні точних меж та розташування, скажімо, листка чи плоду, то класифікація покликана відповісти на питання про їхній стан: це може бути ідентифікація таксономічної групи патогену під час діагностики хвороб, або ж визначення точного ступеня дозрілості плоду, що базується не лише на оцінці кольору. Сьогоднішнім каноном для створення подібних модулів є використання глибоких згорткових нейронних мереж (CNN). Вони, на відміну від класичних підходів машинного навчання, де характеристики доводилося прописувати вручну, здатні самостійно вибудовувати ієрархію рівнів абстракції ознак — починаючи від елементарних ліній та перепадів яскравості на початкових шарах, і закінчуючи складними текстурними малюнками (наприклад, некротичними змінами або специфічною будовою покриву плоду) на глибинних рівнях.

Ключовою архітектурою, що закріпилася в аграрній сфері для завдань класифікації, стала мережа ResNet (Residual Network), зокрема її варіанти ResNet-50 та ResNet-101. Раніше глибокі мережі страждали від проблеми згасання градієнта під час зворотного розповсюдження помилки, що перешкоджало ефективному тренуванню моделей із великою кількістю шарів. Інтеграція залишкових зв'язків (skip connections) вирішила цю проблему, давши змогу сигналу обходити деякі проміжні шари, що уможливило побудову й навчання надзвичайно глибоких структур без втрати діагностичної точності. У середовищі теплиць ResNet демонструє високу ефективність у визначенні томатних захворювань, досягаючи показників точності понад 96% на перевірочних датасетах типу PlantVillage. Це забезпечується здатністю мережі розрізняти ледь помітні текстурні відмінності між візуально дуже схожими патологіями, як-от різні форми плямистості, які складно диференціювати, використовуючи лише методи спектрального аналізу.

Для реалізації обчислювальних процесів безпосередньо на периферійних пристроях (Edge Devices) в умовах обмеженої обчислювальної потужності тепличного обладнання, значну популярність здобули мережі з сімейств MobileNet та EfficientNet. Ці розробки оптимізують роботу за рахунок використання спеціалізованих операцій, зокрема, згортки, розділеної по глибині (depthwise separable convolution). Це дозволяє суттєво скоротити загальну кількість параметрів моделі та її обчислювальну вартість, при цьому жертвуючи мінімальною часткою точності класифікації. Застосування таких "легких" моделей є критично важливим для забезпечення роботи системи в реальному часі без необхідності постійної передачі відеоданих на віддалені сервери, що підвищує автономність та стійкість усього комплексу до збоїв.

Особливістю вдосконалення класифікаційних нейромереж, призначених для агропромислового сектору, є впровадження підходу трансферного навчання (Transfer Learning). Оскільки збір і маркування значних спеціалізованих баз даних для кожної конкретної тепличної системи є надзвичайно ресурсомістким завданням, початкові шари нейромережі ініціалізуються вагами, які були

попередньо відкалібровані на величезних загальних наборах даних (наприклад, ImageNet). Це дає змогу моделі мати вже готові розпізнавальні фільтри для базових геометричних елементів. Подальший етап тонкого налаштування (fine-tuning) на вузькоспеціалізованому агрономічному датасеті дає змогу пристосувати модель до унікальних умов освітлення та сортових характеристик культур, гарантуючи високу релевантність роботи алгоритму навіть при роботі з невеликими за обсягом вибірками. [11]

1.2.5. Підсистема детекції об'єктів (Mask R-CNN)

Виокремлення плодів на цифрових знімках є наріжним етапом у комплексі візуальної обробки для систем точного землеробства, адже від того, наскільки якісно його розв'язано, напряму залежить правильність наступних кроків, таких як визначення обсягу врожаю, оцінка розмірів та визначення стадії зрілості. У площині комп'ютерного зору це завдання інтерпретується як зображувальна сегментація — процес, коли зображення розбивається на групи пікселів, що відповідають значущим об'єктам (наприклад, плодам), та фону, куди входять листя, стебла і конструкції теплиці. В історичному розрізі підходи до розв'язання цієї проблеми пройшли шлях від простих евристик, заснованих на аналізі найпростіших ознак, до складних нейромережевих структур, здатних пристосовуватися до значної мінливості умов довкілля.

На початкових етапах розвитку агрономічних систем моніторингу домінували традиційні методи обробки зображень, серед яких найбільше застосовувалися порогова сегментація та кластеризація. Метод порогу, зокрема алгоритм Оцу, дає змогу автоматично встановити загальний поріг яскравості для перетворення зображення у бінарний вигляд, мінімізуючи при цьому розкид значень у межах кожного класу. Хоча цей спосіб дуже швидкий з точки зору обчислень, у реальних умовах теплиці він демонструє невелику стійкість через нерівномірність освітлення, наявність глибоких тіней та відблисків на блискучих поверхнях плодів, які помилково потрапляють до категорії дефектів або фону. Як

вихід пропонується аналіз зображень у вибраних кольорових моделях, як-от HSV чи Lab, що дозволяє відділити інформацію про колір від даних про яскравість. Це ефективно допомагає виділити стиглі плоди з контрастним забарвленням на тлі листя, однак цей підхід стає безсилим для ідентифікації незрілих плодів, колір яких схожий на зелень, через що вони зливаються з рослинною масою.

Значні обмеження, притаманні класичним підходам, особливо щодо розмежування об'єктів зі складною фактурою чи тими, що частково перекриваються, спричинили перехід до застосування методів глибокого навчання, зокрема згорткових нейромереж. Першим вагомим кроком у цьому напрямку стало впровадження моделей семантичної сегментації, на зразок U-Net, яка має симетричну будову "кодер-декодер" із прямими зв'язками для відновлення деталізації просторової інформації. U-Net забезпечує високу точність у класифікації кожного пікселя, створюючи детальну карту біомаси, проте має суттєвий недолік для завдань обліку врожаю: вона не розрізняє окремі екземпляри об'єктів, що належать до одного класу. Якщо плоди ростуть купками і стикаються, такий алгоритм сегментації об'єднає їх в одну суцільну ділянку, що унеможливило коректний підрахунок одиниць продукції та визначення їхніх індивідуальних розмірів.

Щоб подолати проблему розділення щільно розташованих і частково закритих об'єктів, у сучасних моніторингових системах еталонним рішенням стала архітектура Mask R-CNN, яка належить до категорії дворівневих детекторів. Цей метод комбінує завдання пошуку об'єктів та формування масок, працюючи у два етапи: спершу мережа формує низку потенційних зон зацікавленості, де, ймовірно, знаходяться об'єкти, а потім для кожної такої зони одночасно виконується класифікація, уточнення координат обмежувального прямокутника та створення точної бінарної маски. Головною перевагою Mask R-CNN є використання механізму RoIAlign, який усуває проблему зміщення квантування, що була властива попереднім архітектурам, і гарантує точне вирівнювання маски з оригінальним знімком на рівні пікселів. Завдяки цьому система може ефективно знаходити та сегментувати навіть плоди, що сильно закриті листям, що робить її

найвідповіднішим інструментом для розробки високоточних автоматизованих систем фенотипування та догляду за плодовими культурами у закритому ґрунті.

1.3. Огляд алгоритмів прогнозування врожайності.

Передбачення врожайності — це хитромудре завдання, що залежить від безлічі чинників і вимагає аналізу значних обсягів відомостей як історичних, так і актуальних. У середовищі "розумної" оранжереї цей процес ґрунтується на виокремленні зв'язків між зовнішніми впливами (погода, живлення) та біологічними відгуками культури (швидкість накопичення сухої речовини, зміна темпів дозрівання плодів). Сучасні способи вирішення цієї проблеми розподіляють на статистичні техніки, традиційне машинне навчання та моделювання часових послідовностей за допомогою нейронних мереж.

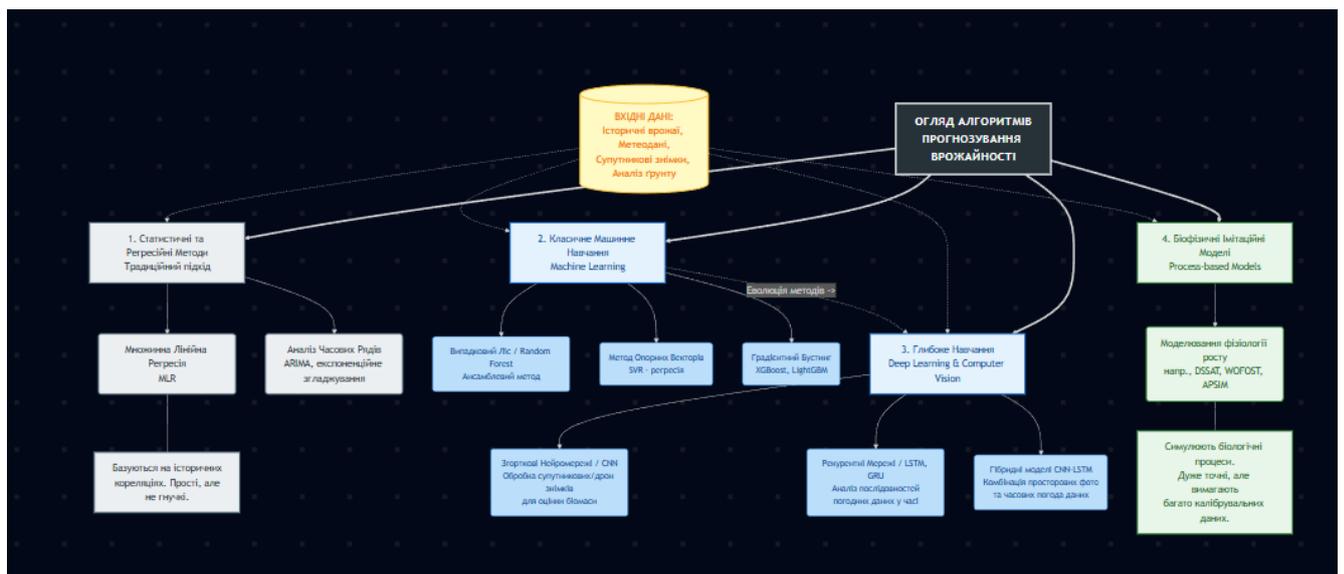


Рис 1.2 Огляд алгоритмів прогнозування врожайності

Головною живильною сировиною для алгоритмів передбачення виступають часові ряди — впорядковані набори даних, зафіксовані через рівні інтервали. У контексті автоматизованого обслуговування це можуть бути щоденні фіксації діаметрів плодів, чисельні показники вегетації та сумарні параметри мікроклімату, наприклад, різниця тисків водяної пари (VPD). Лінійна регресія є найпростішим інструментом, що дозволяє приблизно оцінити темпи зростання на коротких

відрізках, однак цей метод не бере до уваги нерівномірні коливання, спричинені різними чинниками стресу. [12]

Складніші системи моделювання спираються на використання так званих рекурентних нейронних мереж (RNN), серед яких особливо виділяється структура з тривалою короткочасною пам'яттю (LSTM). Подібні алгоритми здатні "утримувати в пам'яті" попередні стани системи, що дозволяє враховувати накопичувальний ефект від зовнішнього середовища. Приміром, така мережа може встановити, що недостатня зволоженість ґрунту протягом минулого тижня матиме наслідком уповільнення дозрівання плодів у наступний період.

Окремим напрямком, що має великі перспективи, є інтегровані моделі, які з'єднують графічні дані, отримані через комп'ютерний зір (оцінка кількості та розміру зав'язі наразі), із прогнозами агроклімату. Це дає можливість системі розрахувати очікуваний об'єм урожаю у числових одиницях ваги значно раніше, ніж настане їхня біологічна зрілість. Таким шляхом предиктивні алгоритми трансформують систему моніторингу з інструменту пасивного спостереження в активний засіб стратегічного планування у сфері агробізнесу, що дає можливість впорядковувати логістику та енергоспоживання тепличного комплексу.

1.3.1. Структура часових рядів вегетації.

У межах керування агрокомплексом в теплицях, процеси росту та розвитку рослин, що дають урожай, трактуються як мінливі випадкові системи. Вони генерують послідовності інформаційних даних, упорядкованих у часі. Хронологічний ряд періоду вегетації являє собою дискретний масив фіксацій, що відображають стан живої системи (скажімо, розмір плода, збільшення маси або інтенсивність випаровування води) у послідовних точках часу з усталеною частотою вимірювання. Зрозуміти внутрішню будову цих рядів є першочерговим для створення надійних моделей передбачення, оскільки життєдіяльність рослин підкоряється складним біологічним ритмам і значною мірою залежить від коливань мікроклімату. З позиції математичної статистики, такий часовий ряд можна

розкласти на чотири головні частини: напрямок (тренд), періодичність (сезонність), цикли та непередбачуваний елемент (залишок), кожен з яких несе у собі особливу звістку про фізіологічний стан культури

Напрямна складова відображає загальний зсув у параметрах рослини на тривалий час, що диктується її життєвим циклом. Для культур, що приносять плоди, як-от помідори чи полуниця, зміна маси плодів зазвичай описується кривою, що нагадує літеру "S" (сигмоїдальною) або логістичною. На старті (етап поділу клітин) спостерігається ріст, подібний до експоненційного, який потім переходить у стадію активного наливу (розтягування клітин), а згодом уповільнюється, досягнувши фізіологічної зрілості. Виділення цього напрямку дає змогу передбачати загальний потенціал урожаю та визначати відхилення у швидкості розвитку, спричинені системними негараздами, наприклад, нестачею поживних речовин.

Періодична складова в умовах закритого ґрунту проявляється на двох рівнях: добовому (циркадному) та етаповому (фенологічному). Добова періодичність обумовлена зміною світлого та темного часу доби, що спричиняє регулярні коливання темпу фотосинтезу, випаровування води та пружності тканин. Приміром, товщина стебла томата демонструє невеликі зміни протягом доби: стискається вдень через втрату вологи під час випаровування та відновлюється вночі. Фенологічна періодичність пов'язана з етапами життєдіяльності культури (цвітіння, формування зав'язі, досягання), які у безперервно зростаючих сортів томатів можуть мати хвилеподібну форму з регулярним появою нових суцвіть. Моделювання цієї частини є необхідним для згладжування природних коливань при аналізі даних з камер комп'ютерного зору, аби система не розцінювала звичайне денне зів'янення як критичний дефіцит вологи.

Циклічна складова описує коливання, тривалість яких не є сталою, а залежить від зовнішніх економічних чи агротехнічних факторів, як, наприклад, цикли збору врожаю чи періоди внесення добрив. На відміну від суворої сезонності, ці повторення можуть мати мінливу висоту (амплітуду) і час тривання. Четверта частина — випадковий шум або нерегулярна складова — включає швидкі,

невпорядковані зміни в даних. Вони спричинені похибками вимірювань сенсорами, тимчасовими змінами освітлення (хмарність), застуттвом плодів листям на зображеннях або короточасними збоями в роботі апаратури. Для завдань передбачення врожайності вкрай важливо відділити цей шум від значущого сигналу, застосовуючи методи очищення (наприклад, рухоме середнє або фільтр Калмана), щоб запобігти невірним командам для пристроїв системи автоматичного керування.

1.3.2. Структурні Елементи LSTM для Агрономічного Прогнозування

Для успішного моделювання складної кінетики росту рослин, яка пов'язана з тривалими залежностями між умовами довкілля та фізіологічною відповіддю сільськогосподарських культур, традиційні рекурентні нейронні мережі (RNN) часто виявляються неадекватними через феномен згасання градієнтів. Цю фундаментальну проблему долає архітектура «Довга Короткочасна Пам'ять» (Long Short-Term Memory, LSTM), розроблена спеціально для аналізу послідовностей даних, що містять значні часові лаги. Ключовою відмінністю LSTM від звичайних мереж є наявність внутрішнього комірчастого стану, який функціонує як стабільний «транспорт» інформації. Це дозволяє даним про стан культури безперешкодно протікати через тривалі послідовності часових етапів із мінімальними втратами. Завдяки цьому механізму модель здатна зберігати у пам'яті критичні минулі події, наприклад, тривалий період дефіциту вологи, що ставився кілька тижнів тому, і враховувати його кумулятивний вплив при визначенні майбутнього врожаю. [13]

Роботу комірки LSTM контролює набір із трьох спеціалізованих регуляторних механізмів (вентилів, або gates), які використовують сигмоїдальні функції для точного дозування інформаційного потоку. Першим є вентиль забуття (forget gate), який приймає як вхідні дані попередній прихований стан та актуальні сенсорні вимірювання, і приймає рішення щодо того, яку частку інформації з довготривалого сховища слід анулювати як нерелевантну. В агрономічному

моделюванні цей вентиль дозволяє мережі відсіювати несуттєвий високочастотний шум або швидкоплинні мікрокліматичні коливання, які не мають довгострокового ефекту на розвиток рослини, фокусуючись замість цього на стійких довготермінових тенденціях. Другий елемент, вхідний вентиль (input gate), працює спільно з шаром формування кандидатів; його функція полягає у визначенні, які щойно отримані дані з поточного моменту часу (наприклад, раптове зниження рівня гідратації ґрунту або зареєстрований камерою приріст біомаси) є достатньо значущими, аби оновити внутрішній стан комірки, що моделює динаміку росту.

Завершальний етап обробки в LSTM реалізується через вихідний вентиль (output gate), який формує прихований стан для наступного кроку та надає фінальний результат прогнозу. Цей вентиль оперує оновленим внутрішнім станом комірки, який попередньо пройшов через функцію активації (як правило, tanh), і модулює цей вихід за допомогою сигмоїдального фільтра, щоб випустити лише ту інформацію, що є контекстуально важливою на даний момент. Така структура дає змогу системі не обмежуватися лише лінійною екстраполяцією, але й адекватно моделювати комплексні нелінійні біологічні процеси, такі як реакція культури на стресові фактори, зміна фенологічних етапів або кумулятивний вплив отриманої сонячної енергії. Впровадження LSTM у системи контролю мікроклімату в теплицях дає можливість перейти від реагування на поточні відхилення до проактивного регулювання, де параметри середовища налаштовуються превентивно, з огляду на прогнозовані біологічні потреби культури.

1.4. Фізіологія плодкових культур (Томати/Полуниця)

Для ефективного функціонування автоматизованої системи моніторингу критично важливим є переведення біологічних процесів розвитку рослин у формалізовані цифрові метрики, зрозумілі алгоритмам комп'ютерного зору. Загальноприйнятим стандартом для кодування фенологічних фаз є універсальна шкала BBCH (Biologische Bundesanstalt, Bundessortenamt and Chemische Industrie), яка дискретизує безперервний процес онтогенезу на ідентифіковані стадії. У

контексті плодових культур, таких як томати та суниця, основна увага зосереджується на макростадіях 7 (Розвиток плоду) та 8 (Дозрівання плоду), оскільки саме вони визначають економічну цінність врожаю та стратегію керування мікрокліматом. Для систем технічного зору ці стадії характеризуються специфічними змінами у спектральних сигнатурах поверхні плодів, що зумовлені біохімічною трансформацією пігментів — деградацією хлорофілу та синтезом каротиноїдів або антоціанів.

У випадку томатів (*Solanum lycopersicum*), який є клімактеричним плодом, процес дозрівання супроводжується різким підвищенням дихання та виділенням етилену, що ініціює зміну забарвлення. Згідно зі стандартами USDA, які корелюють зі шкалою BBCH (коди 81–89), виділяють шість візуально розрізняваних стадій: Green (Зелений), Breaker (Початок зміни), Turning (Бурий), Pink (Рожевий), Light Red (Світло-червоний) та Red (Червоний). Для алгоритмів комп'ютерного зору найскладнішою, але водночас найважливішою для детекції є стадія Breaker (BBCH 81). На цьому етапі відбувається перша поява жовтувато-рожевого відтінку на апікальній частині плоду (не більше 10% поверхні), що свідчить про фізіологічну зрілість та можливість збору врожаю для транспортування. Візуально це проявляється як локальна зміна гістограми кольору в каналі Hue (відтінок) кольорного простору HSV, зміщуючись із зеленого спектра (120°) у бік жовтого (60–90°), тоді як решта плоду залишається зеленою. Подальші стадії характеризуються поступовим розширенням зони забарвлення та збільшенням насиченості червоного кольору за рахунок накопичення лікопіну.

На відміну від томатів, суниця садова (*Fragaria × ananassa*) належить до неклімактеричних плодів, які не здатні дозрівати після відокремлення від материнської рослини, що вимагає точної ідентифікації моменту повної стиглості безпосередньо на кущі. Фенологія дозрівання суниці включає специфічну стадію «білої ягоди» (White stage), коли плід втрачає хлорофіл і стає майже білим перед початком синтезу антоціанів (червоних пігментів). Для системи комп'ютерного зору ця стадія є унікальним маркером, що характеризується високою яскравістю (Value/Luminance) та низькою насиченістю, дозволяючи легко відокремити її від

зеленого листя. Перехід до стадії повної стиглості (BVCH 87) супроводжується рівномірним почервонінням, проте важливою діагностичною ознакою для камер високої роздільної здатності є також стан сім'янок (achenes) на поверхні ягоди, які змінюють колір із зеленого на темно-червоний. Аналіз текстури поверхні, зокрема випуклості сім'янок, дозволяє нейромережам відрізнити справжні плоди від червоних квітів чи інших об'єктів фону, забезпечуючи високу точність фенотипування. [14]

1.5. Огляд Систем моніторингу

1.5.1 Рішення Priva – огляд платформи клімат-контролю

Сучасний спосіб впровадження автоматизації на тепличних об'єктах, що пропонує компанія Priva, ґрунтується на ідеї всеохоплюючого контролю над екосистемою теплиці, розглядаючи її як єдине кіберфізичне утворення, де параметри клімату, водний режим та енерговикористання аналізуються у комплексі. Головним елементом цієї системи є комп'ютер управління процесами Priva Connex, створений для контролю над великими, високотехнологічними комплексами. Його конструкція відрізняється від типових ПЛК-рішень завдяки застосуванню концепту «Вирощування наступного покоління» (Next Generation Growing — NGG), який переносить акцент із простого підтримання заданих значень на управління енергетичною рівновагою рослини. Важливою перевагою Connex є його здатність передбачати ланцюгові реакції від будь-якого втручання: наприклад, система самостійно розраховує, як закриття енергозберігаючого екрану позначиться не лише на температурі, а й на вологості, освітленні та потребі в поливі, заздалегідь коригуючи роботу пов'язаних систем до появи будь-яких відхилень.

Одним із найсуттєвіших інструментів у сфері алгоритмічного забезпечення є методика розрахунку температурного режиму на добу (24-hour temperature strategy). Цей підхід відмовляється від суворого дотримання миттєвих показників температури на користь досягнення заданого середньодобового значення, що

краще відповідає фізіологічним вимогам рослин у фазі формування врожаю. Система постійно усереднює фактичні температурні дані й, якщо виникають відхилення (наприклад, через використання безкоштовної сонячної енергії вдень), вона автоматично змінює нічні цільові значення для компенсації, розподіляючи навантаження у часі, щоб уникнути температурного стресу для культур. Водночас, модуль енергоменеджменту оптимізує споживання ресурсів, регулюючи роботу установок когенерації (СНР), теплових акумуляторів та подачі вуглекислого газу, спираючись на прогнози погоди та ринкові ціни на енергоносії, що значно зменшує експлуатаційні витрати.

Для об'єктів меншого масштабу чи більш гнучких у виробництві, як-от ягідники під тунелями або середні тепличні господарства, Priva пропонує гнучку систему Compass. На відміну від цілісної архітектури Connex, Compass має модульну будову, що дозволяє виробникам вибирати й комбінувати потрібні функціональні секції для контролю фотосинтезу (світло та CO_2), кліматичних умов (опалення, вентиляція) та зрошення, відповідно до специфічних агрономічних цілей. Апаратна основа обох рішень базується на галузевому стандарті Priva Blue ID, що гарантує високу надійність та можливість екстреної заміни модулів вводу/виводу без переривання технологічного циклу. Управління водними ресурсами виконує блок Moisture Balance, який аналізує дані з ваг, розміщених під субстратами (GroScale), та сенсорів дренажу для точного обчислення обсягу транспірації рослин, ініціюючи полив на основі реальної потреби культури, а не лише за таймером чи накопиченою сонячною радіацією.

Впровадження цифрового управління досягається через хмарну мережу Priva Connected та веб-інтерфейс Priva Operator, який надає можливість дистанційного доступу до системи контролю через захищений комунікаційний шлюз Edge Gateway. Схема безпеки шлюзу побудована таким чином, що використовуються лише вихідні з'єднання до хмарної інфраструктури Microsoft Azure, роблячи локальну мережу теплиці невидимою для зовнішніх кіберзагроз. Найвищим рівнем розвитку цієї екосистеми є сервіс Plantonomy, що використовує алгоритми

штучного інтелекту та концепцію цифрових двійників для автономного регулювання мікроклімату. Plantonomy оперує біоритмічним підходом, прогножуючи потреби рослини у волозі та поживних речовинах із точністю до 5 хвилин наперед, що дає змогу мінімізувати стресові фактори та забезпечити стабільність урожаю, при цьому значно зменшуючи необхідність ручного втручання персоналу [15],.

1.5.1.1. Короткий опис функцій Priva Connex

Централізованим інтелектуальним ядром управління тепличним комплексом, що забезпечує повну узгодженість функціонування підсистем мікроклімату, поливу й енергопостачання, виступає комп'ютер процесів Priva Connex. Дана система побудована на засадах цілісної інтеграції, де будь-який вплив на один параметр уявляє його наслідки для інших процесів; приміром, укриття енергозберігаючим екраном спричиняє негайне перерахування потреби в теплі та зміну режиму зрошення через зниження рівня транспірації рослин. Ключовою особливістю Connex є його алгоритм 24-годинної температурної стратегії, котрий дозволяє агрономам задавати середню добову температуру з метою регулювання темпів розвитку культури. Цей механізм автоматично компенсує денні температурні коливання, спричинені сонячною інсоляцією, шляхом гнучкого коригування нічних уставок, чим підтримує оптимальний енергетичний баланс рослини, уникаючи створення стресу.

У сфері водоспоживання система використовує модуль Moisture Balance. Він переводить зрошення від типового (заснованого на таймері) до фізіологічно обґрунтованого методу. Модуль, оперуючи даними з датчиків ваги матів та дренажних систем, безперервно обчислює обсяг випаровування вологи із субстрату та активує полив лише тоді, коли це життєво необхідно для збереження заданої вологості та концентрації солей (ЕС). Це дає змогу мінімізувати витрати на воду та добрива. Одночасно з цим Connex керує енергетичними ресурсами, оптимізуючи роботу теплолюбних установок (СНР), котлів та теплових акумуляторів.

Аналізуючи прогноз погоди та актуальні потреби теплиці в енергії, система визначає найбільш вигідні часові вікна для наповнення буферних баків чи використання електроенергії, а також контролює подачу CO_2 залежно від світлового режиму та інтенсивності вентиляції. Управління всією цією сукупністю операцій здійснюється через програмне забезпечення Priva Office Direct або віддалений хмарний інтерфейс Priva Operator, надаючи користувачам доступ до детальних звітів та можливість оперативного втручання у виробничий цикл у режимі реального часу.

1.5.1.2. Огляд інтерфейсу оператора та візуалізації даних

Перехід у сучасній парадигмі взаємодії людини та машини (HMI) у теплицях спостерігається від стаціонарних диспетчерських пунктів до хмарно-орієнтованих мобільних рішень, які гарантують доступ до робочих процесів 24/7 з будь-якої локації на планеті. У рамках екосистеми Priva цю роль виконує веб-додаток Priva Operator, який слугує головною точкою для оперативного контролю та управління контролером клімату. На противагу традиційним SCADA-системам, які оперують фіксованими мнемосхемами, структура Operator побудована за принципом персоналізованих інформаційних панелей (дашбордів), що дозволяє кожному фахівцеві — агроному, технічному спеціалісту чи власнику — формувати свій особистий робочий простір. Користувач має змогу самостійно вибирати та розташовувати модулі (віджети) для відображення найважливіших параметрів, таких як поточна температура, стан систем поливу, рівень освітлення чи концентрація вуглекислого газу, таким чином адаптуючи вигляд інтерфейсу під конкретні потреби виробництва.

Підсистема для візуалізації інформації реалізована за допомогою інтерактивних графіків, що підтримують аналіз даних як у часі реального, так і в історичному контексті. Життєво важливою аналітичною функцією є можливість накладати декілька часових рядів на одній діаграмі, що дозволяє агроному візуально ідентифікувати неявні зв'язки між командами управління та реакцією

мікроклімату, приміром, оцінюючи затримку реакції системи опалення або вплив розкриття затінюючих екранів на вологість у теплиці. Для детальнішого аналізу та конфігурації комплексних алгоритмів задіюється настільна програма Priva Office Direct. Вона надає унікальну можливість графічного програмування кліматичних сценаріїв, де оператор може коригувати денні графіки температур або вентиляції, просто переміщуючи контрольні точки на кривій, що є значно більш зрозумілим та безпечним методом, аніж внесення змін через числові таблиці.

Надійність та захищеність обміну даними між інтерфейсом користувача та фізичним устаткуванням забезпечується хмарною платформою Priva Connected, яка функціонує на базі інфраструктури Microsoft Azure. Ключовою ланкою цієї архітектури є апаратний комутатор (шлюз) Priva Edge Gateway, який забезпечує зв'язок між локальним промисловим комп'ютером та хмарним середовищем. З метою убезпечення від несанкціонованого доступу, шлюз використовує виключно односпрямовані вихідні з'єднання (outbound connections), що дозволяє передавати телеметричні дані та отримувати команди управління без необхідності відкриття вхідних мережевих портів на локальному фаєрволі підприємства. Такий підхід робить внутрішню мережу автоматизації "непомітною" для зовнішніх загроз, гарантуючи збереження цілісності технологічного циклу при повному збереженні можливості мобільного управління.

1.5.2. Роботизовані платформи (Ecoation, iunU).

У наш час у сфері агробізнесу, особливо у контрольованих умовах, де ґрунт штучно створюється, зростає потреба в розгортанні роботизованих баз, які можуть діяти як повністю автономно, так і за часткової участі людини. Ці бази слугують платформами для систем комп'ютерного зору, що дає змогу відстежувати стан рослинності з високою деталізацією та точністю. Яскравими прикладами цього напряму є розробки від компаній Ecoation та iunU, які застосовують різні методи інтеграції штучного інтелекту у процеси обробітку сільськогосподарських культур

Платформа Ecoation (Інтерфейс «Людина-Машина»)

Канадська фірма Esoation створила роботизовану систему (серія ОКО), що націлена на комплексний захист рослин (згідно з принципами IPM — Integrated Pest Management) та передбачення обсягів майбутнього врожаю.

Головною відмінністю рішення Esoation є поєднання людської експертизи та можливостей машинного навчання. Ця платформа являє собою рухомий візок, наштигований сенсорними пристроями, що пересувається проходами теплиці. Технічні аспекти системи включають:

1. Багатоспектральне бачення: Застосування комбінації камер RGB та інфрачервоних датчиків дозволяє виявляти ознаки стресу у рослин на ранніх етапах, ще до того, як стануть помітними зорові симптоми (наприклад, пожовтіння чи відмирання тканин), що є неможливим для візуального спостереження.

2. Ідентифікація шкідників та хвороб: Алгоритми глибокого навчання опрацьовують отримані зображення для розпізнавання та визначення місцезнаходження специфічних шкідників (як-от теплична білокрилка чи павутинний кліщ), а також симптомів грибкових інфекцій.

3. Замкнений цикл даних (Closed-Loop Data): Система збирає дані про мікроклімат, стан рослин та дії персоналу, формуючи своєрідного «цифрового двійника» всієї теплиці. Це дає змогу оперативно коригувати методи догляду, тим самим знижуючи обсяги застосування хімічних захисних речовин.

Важливо для контексту цієї магістерської роботи те, що Esoation не замінює агронома повністю, а радше слугує як інструмент посилення (augmenting), надаючи максимально точні дані для прийняття рішень щодо догляду за культурами (наприклад, помідорами, перцем тощо).

Платформа iunU (Система LUNA)

Американська компанія iunU пропонує більш автономний підхід з її системою LUNA, яка є яскравим прикладом повної автоматизації процедур візуального контролю. На відміну від наземних рішень, LUNA часто реалізується як сукупність сканерів, що рухаються по верхніх напрямних (рейках) над рослинними насадженнями, або як повністю незалежні дрони-сканер.

Ключовий акцент у рішенні iunU зроблено на постійному інвентарному обліку та фенотипуванні рослин із використанням комп'ютерного зору (Computer Vision):

- Автоматизоване фенотипування: LUNA використовує стереоскопічні камери та технології тривимірного моделювання для вимірювання біометричних характеристик культур. Система здатна самостійно обліковувати кількість квіток, плодів, оцінювати площу листової поверхні та темпи росту стебел.
- Виявлення відхилень: Штучний інтелект зіставляє поточний стан кожної окремої рослини з еталонними моделями розвитку. У разі виявлення будь-яких розбіжностей (наприклад, сповільнення росту або ознаки зів'ялості) система автоматично інформує оператора, вказуючи точні географічні координати проблемної ділянки.
- Прогнозування врожаю: Завдяки точному підрахунку зав'язі та плодів на різних етапах дозрівання, алгоритми iunU забезпечують високу достовірність передбачень щодо обсягів майбутнього врожаю, що є критичним фактором для планування логістики та збуту.

Аналіз пропозицій Esoation та iunU показує, що сучасні автоматизовані системи догляду трансформуються від простої механізації до інтелектуального нагляду. Обидві системи покладаються на методи комп'ютерного зору, проте вони мають відмінності в архітектурі: Esoation зосереджується на рухомому наземному спостереженні та взаємодії з персоналом, тоді як iunU пропонує загальний огляд «згори» із високим ступенем операційної незалежності.

Досвід, здобутий цими компаніями, підтверджує необхідність розробки специфічних алгоритмів для розпізнавання образів плодкових культур, що становить основу дослідження у межах цієї магістерської роботи. Застосування подібних методологій дозволяє суттєво зменшити втрати врожаю та оптимізувати використання агротехнічних засобів.

Таблиця 1.1

Таблиця порівняння роботизованих платформ

Критерій порівняння	Платформа Esoation (ОКО)	Система iunU (LUNA)
Архітектура платформи	Наземна мобільна платформа (візок), що пересувається міжряддями	Підвісна рейкова система сканування (або дрони) над рослинами
Технології комп'ютерного зору	Мультиспектральні камери (RGB + ІЧ), лазерні сенсори для 3D-мапінгу	Стереоскопічні камери високої роздільної здатності, 3D-моделювання
Основний фокус ШІ	Інтегрований захист рослин (IPM): виявлення шкідників, хвороб та водного стресу	Фенотипування та інвентаризація: вимірювання біомаси, підрахунок плодів, аналіз схожості
Взаємодія з людиною	Human-Machine Interface: доповнює роботу скаута/агронома, надаючи підказки в реальному часі	Повна автоматизація моніторингу: система працює автономно, оператор отримує лише звіти про аномалії
Аналітика та прогнозування	Прогнозування врожайності на основі стану здоров'я рослин ("Closed-Loop Data")	Точний прогноз обсягів виробництва на основі інвентарного підрахунку кожної рослини
Переваги для плодівих культур	Висока ефективність детального огляду листя та стебла "збоку" (Side-view)	Ефективність глобального огляду плантації "зверху" (Top-down view), контроль густоти насаджень

1.5.3. Огляд платформ на базі відкритих мікроконтролерів

Сучасний підхід до проектування роботизованих систем для агросектору поступово відмовляється від застосування надто дорогих закритих промислових контролерів (ПЛК) на користь відкритого апаратно-обчислювального фундаменту. Це дає змогу докорінно зменшити кінцеву вартість пристроїв та пришвидшити етапи створення перших зразків. Для

завдань обробки зображень (Computer Vision) та управління рушійними вузлами роботизованих установок варто розглянути три основні категорії апаратних засобів: мікроконтролери для керування на нижчому рівні, комп'ютери, зібрані на одній платі загального призначення, та спеціалізовані пристрої для обчислень штучного інтелекту. [16]

Одноплатні комп'ютери (SBC): Raspberry Pi

Лінійка одноплатних комп'ютерів Raspberry Pi вважається загальноприйнятим зразком для розробки прототипів вбудованих рішень. Завдяки наявності повноцінної операційної системи (як правило, на базі Linux), ці системи дають змогу працювати з мовами програмування високого рівня (такими як Python, C++) та потужними бібліотеками для роботи з графікою, наприклад OpenCV.

У сфері агроробототехніки Raspberry Pi нерідко виконує роль головного, "верхнього" рівня управління:

- Опрацювання відеоданих, отриманих із камер.
- Забезпечення комунікації із хмарними сервісами.
- Ухвалення рішень на основі нескладних алгоритмів.

Проте, коли йдеться про виконання обчислювально складних моделей нейронних мереж, потужності центрального процесора (CPU) Raspberry Pi може виявитися недостатнім для забезпечення роботи у режимі реального часу (Real-time).

Спеціалізовані апаратні засоби для ШІ: NVIDIA Jetson

Для вирішення завдань, що вимагають значної обчислювальної потужності безпосередньо на місці використання ("на краю" — Edge AI), найбільш перспективними є пристрої з лінійки NVIDIA Jetson (уключаючи Nano, Orin Nano, Xavier).

Ключовою особливістю архітектури Jetson є наявність вбудованого графічного процесора (GPU) з підтримкою технології CUDA. Це відкриває можливості для виконання паралельних обчислень, які є життєво необхідними для функціонування глибоких згорткових нейронних мереж

(CNN), що застосовуються для виявлення захворювань сільськогосподарських культур або класифікації зібраних плодів. Застосування подібних платформ дозволяє виконувати інференс (запуск) моделей безпосередньо на роботі самої машини, усуваючи потребу в передачі відеоінформації на віддалений сервер, що є критично важливим за умов ненадійного інтернет-зв'язку у полях чи теплицях.

Мікроконтролери для керування нижнього рівня: ESP32 та STM32

Для безпосереднього приведення в рух колісної бази, збору показників із сенсорів вологості, температури та системи позиціонування, використання потужних комп'ютерів (як-от RPi чи Jetson) є недоцільним через відсутність гарантованого жорсткого реального часу (Hard Real-Time). Для цих потреб застосовують мікроконтролери.

STM32: Це промисловий стандарт для систем, вбудованих у пристрої. Він забезпечує високу стабільність роботи, пропонує широку палітру інтерфейсів (GPIO, I2C, CAN) та підтримує роботу операційних систем, що працюють у реальному часі (наприклад, FreeRTOS).

ESP32: Це бюджетний варіант, що має інтегровані модулі для Wi-Fi та Bluetooth. Він ідеально підходить для формування розгалужених мереж датчиків (IoT) у тепличних умовах, які можуть передавати дані на центральний елемент робота.

Порівняльне оцінювання

З метою вибору найбільш відповідної архітектури системи обслуговування плодівих насаджень було проведено зіставлення основних апаратних платформ

Таблиця 1.2

Таблиця порівняння відкритих мікроконтролерів

Характеристика	Raspberry Pi 4/5	NVIDIA Jetson Nano/Orin	STM32 (F4/F7 серія)
Тип архітектури	CPU (Central Processing Unit)	CPU + GPU (Graphics Processing Unit)	MCU (Microcontroller Unit)
Основне призначення	Загальні обчислення, веб-сервер, проста обробка зображень	Прискорення задач III, глибоке навчання, складний Computer Vision	Керування двигунами, датчиками, робота в реальному часі
Продуктивність III	Низька/Середня (залежить від моделі)	Висока (472 GFLOPS - 40 TOPS)	Низька (тільки TinyML)
Енергоспоживання	Середнє (5-15 Вт)	Середнє/Високе (5-20 Вт).	Дуже низьке (мВт).
Роль у системі	Головний контролер логіки.	Обчислювач для розпізнавання образів.	Контролер периферії та руху.

2.ОПИС ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ ДЛЯ МОНІТОРИНГУ ТА ДОГЛЯДУ ЗА ПЛОДОВИМИ КУЛЬТУРАМИ

2.1. Архітектура аналізу візуальних та кліматичних даних

Закладку (базу) спроектованої системи взято з засад побудови кіберфізичних ансамблів, де живий організм (рослина) є невід'ємним елементом контуру керування. Ключовою рисою запропонованого методу є відмова від послідовного (лінійного) опрацювання сигналів на користь змішаної (гетерогенної) інтеграції даних сенсорів, що дає змогу зводити разом відомості різнорідної природи — як от чи потік відеоінформації з високою роздільною здатністю, так і окремі часові ряди показників клімату — у спільний вектор, що описує стан агроекологічної системи.

За основу архітектурного рішення взято концепцію Периферійного Штучного Інтелекту (Edge AI). На противагу традиційним хмарним моделям, де ухвалення рішень прив'язане до надійності каналу зв'язку, тут увесь процес аналізу інформації — від її збору до формування команд для впливу — відбувається безпосередньо на апаратному забезпеченні рухомої платформи. Канал візуального сприйняття забезпечується високоякісним оптичним приймачем, який слугує безконтактним діагностичним приладом. Відеодані проходять поетапну обробку: початкова корекція кадрів готує їх для використання згорткової нейронної мережі, яка є ядром системи розпізнавання. Цей компонент не просто реєструє наявність плодів чи листової поверхні, а створює карту значень сцени (семантичну мапу), виокремлюючи аномалії у фенотипі, такі як зміни кольору (пожовтіння, відмирання тканин) чи порушення форми рослини, що є видимими індикаторами її стресу.

Проте, залежати лише від зорового аналізу небезпечно через ймовірність появи хибних візуальних ознак та залежність від умов освітлення. Тому в архітектуру додано паралельний потік телеметричних відомостей. Сукупність апаратних датчиків формує об'єктивне "середовищне підґрунтя" (температурні показники, вологість повітря та ґрунту), яке слугує підтвердженням для висунутих візуальних припущень. На рівні програмного забезпечення це реалізується через

блок зведення, де інформація від мікроконтролерів звіряється з результатами роботи нейромережі. [17]

Механізм ухвалення рішень у такій побудові залежить від контексту. Система співставляє візуальну ознаку з фактичними параметрами оточення, що дозволяє точно визначити причини дистресу рослини. Наприклад, зморщування листя, зафіксоване камерою, якщо показники вологості ґрунту є оптимальними, розцінюється як симптом хвороби, тоді як за умови низької вологості — як потреба у воді. Цей підхід дає змогу перейти від реагування на наслідки до передбачувального догляду, мінімізуючи витрати ресурсів та усуваючи невірні команди для виконавчих пристроїв.

2.2 Вибір порогових значень для мікроклімату та стадій стиглості

Працездатність автоматизованого комплексу напряму обумовлена тим, наскільки вірно будуть перетворені біологічні потреби рослини у цифрові алгоритмічні моделі. Для реалізації логіки управління (Control Logic) спершу потрібно визначити виразні граничні значення, перетин яких спричинить реакцію системи — запуск поливу, зміну роботи вентиляційних механізмів чи формування команди на збір урожаю. Конфігурування системи відбувається за двома основними напрямками: фізичні параметри оточення (для роботи сенсорної мережі) та візуальні характеристики об'єктів (що аналізуються системою комп'ютерного зору).

У контурі, що відповідає за клімат та зволоження, незамінним є застосування принципу гістерезису — формування діапазону, нейтрального до змін, розташованого між порогом активації та деактивації робочих елементів. Це не дозволяє системі постійно швидко вмикатись/вимикатись при коливанні на межі заданих параметрів. Для модельних культур плодкових (наприклад, томатів), нижній поріг вологості ґрунту, який засвідчує початок нестачі води, встановлено у межах 45–50 відсотків. Досягнення цього показника слугує сигналом для запуску насосного обладнання. Верхній поріг, що відповідає оптимальному насиченню

грунту (Field Capacity), визначено на рівні 75–80 відсотків, при перевищенні якого подача води зупиняється. Температурний режим також має чіткі обмеження: показники, що перевищують $+30^{\circ}\text{C}$, негативно впливають на здатність пилку до запліднення, тому цей ліміт використовується для активації системи інтенсивної вентиляції. [18]

Для компонента комп'ютерного зору визначення «порогових значень» відбувається не через числові міри, а через категоризацію фенологічних етапів розвитку плоду. Процес розпізнавання ґрунтується на аналізі розподілу кольорів у просторі HSV (Тон, Насиченість, Яскравість), який є більш стійким до коливань освітлення, ніж традиційний RGB. Основне завдання нейронної мережі полягає у розрізненні стадії технічної зрілості (коли плід ще зелений) та повної біологічної зрілості (плід червоний), що є командою до збору врожаю.

Зведені параметри для конфігурації системи ухвалення рішень представлені у таблиці 2.1.

Таблиця 2.1

Зведенні параметри конфігурації системи

Параметр / Об'єкт моніторингу	Порогове значення / Ознака	Реакція системи (Control Action)
Вологість ґрунту (Soil Moisture)	$\$ < 45\% \$$ (Нижня межа)	Увімкнення системи крапельного поливу
	$\$ > 80\% \$$ (Верхня межа)	Вимкнення поливу, фіксація дати зрошення
Температура повітря	$\$ > 30^{\circ}\text{C} \$$ (Критичний максимум)	Сповіщення про температурний стрес, запуск вентиляції
Вологість повітря (RH)	$\$ > 85\% \$$ (Ризикова зона)	Підвищення пріоритету сканування на хвороби (грибок)
Стадія: Технічна стиглість (Unripe)	Колір: Зелений (Hue $\$ 60^{\circ}\text{C} - 120^{\circ}\text{C} \$$)	Моніторинг динаміки росту, прогнозування дозрівання
Стадія: Біологічна стиглість (Ripe)	Колір: Червоний (Hue $\$ 0^{\circ}\text{C} - 15^{\circ}\text{C} \$$)	Сигнал «Ready to Harvest», збереження координат плоду
Аномалії розвитку	Локальні зміни текстури (плями)	Маркування як «Хворий плід/лист», сповіщення агронома

2.3 Архітектура програмного коду

Побудова програмної частини випущеної системи спирається на двоетапну ієрархічну структуру, що відповідає апаратному поділу на пристрій для обчислень вищого порядку (Single Board Computer) та блок управління периферійними пристроями нижчого рівня (Microcontroller Unit). Така організація дозволяє ефективно розвантажити обчислювальні потужності: найбільш вимогливі завдання, пов'язані з аналізом зображень, виконуються у середовищі операційної системи Linux, тоді як операції, чутливі до часу, з управління апаратурою, віддаються мікроконтролеру, який функціонує у режимі суворого реального часу.

Основою програмної системи є керуючий софт, розроблений на мові Python версії 3.x, який працює безпосередньо на одноплатному комп'ютері. Конструкція цього додатку реалізована згідно з принципами багатопоточності (multithreading), що є ключовим для підтримання плавності візуального потоку. Головна нитка потоку відповідає за запуск драйверів камери і завантаження зображень у буфер пам'яті, використовуючи для цього бібліотеку OpenCV. Окремий, паралельний та асинхронний потік займається виконанням інференсу нейронної мережі: він витягує найсвіжіший кадр із буфера, проводить його попереднє доопрацювання (коригування розмірів, нормалізацію) та подає на вхід моделі машинного навчання (зокрема, це можуть бути архітектура SSD). Результати, отримані після детекції — межі об'єктів (bounding boxes), їхні класифікації та ступінь довіри — надходять до модуля логіки, який, спираючись на встановлені алгоритми, генерує команди високого рівня, такі як «Переміститися до цілі», «Припинити рух» чи «Увімкнути зрошення». [19]

Реалізація функціонального рівня програмного забезпечення забезпечена у формі прошивки (firmware), написаної мовами C/C++ для мікроконтролера. Основний обов'язок цього рівня — гарантувати роботу в умовах жорсткого реального часу (Hard Real-Time) при взаємодії з фізичним оточенням. Програма функціонує як скінченний автомат (Finite State Machine), де переходи між різними

робочими станами є строго визначеними. Мікроконтролер формує імпульси для управління двигунами методом ШІМ (PWM), зчитує аналогові дані з сенсорів вологості та температури, застосовує до них цифрову фільтрацію з метою усунення шумів, а також контролює критичні ситуації (наприклад, заклинювання рухомих частин або втрату комунікації).

Обмін даними між цими двома програмними рівнями відбувається через послідовний канал зв'язку (UART чи USB) із застосуванням єдиного стандарту протоколу передачі даних. Команди, що йдуть із вищого рівня, та телеметричні дані з нижнього рівня пакуються у спеціальні датаграми (наприклад, у форматі JSON або стандартизованих бінарних блоків), причому обов'язково включається механізм перевірки коректності даних (CRC). Така побудова системи забезпечує її високу стійкість до збоїв: навіть якщо модуль, відповідальний за комп'ютерний зір, зависне, нижній рівень контролю зможе ініціювати безпечне аварійне вимкнення платформи, запобігаючи таким чином шкоді для рослинності чи технічних елементів.

2.3.2 Модуль Завантаження Даних (DataLoader: Сенсори + Камера)

Завантажувач Даних (DataLoader) слугує як базовий абстрактний рівень взаємодії між апаратною частиною робота та його алгоритмами штучного інтелекту. Його ключова функція — забезпечити стабільну, безперервну та узгоджену передачу інформації про навколишнє середовище. Оскільки система оперує даними різної природи — високочастотними відеопотоками та низькочастотною телеметрією — архітектура цього модуля розроблена з використанням асинхронних підходів до обробки.

Блок керування камерою реалізовано на базі бібліотеки комп'ютерного зору OpenCV. Стандартний метод для зчитування кадрів (`cv2.read()`) є синхронним та блокуючим. Це може спричинити загальні затримки в системі управління, особливо при падінні швидкості кадрів (FPS) або тривалій експозиції. Для уникнення цієї проблеми було виділено окремий потік для захоплення (Capture Thread). Цей потік постійно витягує найсвіжіший кадр із буфера камери, не зупиняючи при цьому головний робочий цикл програми. Крім самого захоплення, цей компонент виконує попередню підготовку зображення: трансформацію кольорового простору з BGR (стандарт OpenCV) у RGB (необхідний для нейронних мереж) та масштабування (Resize) до вхідних розмірів моделі (наприклад, 640x640 пікселів). Це значно зменшує обчислювальні потреби на наступних етапах.

Одночасно функціонує підсистема збору телеметричних даних. Вона відповідає за комунікацію з мікроконтролером через послідовний інтерфейс (Serial Interface). Оскільки мікроконтролер безперервно транслює блоки даних із датчиків температури та вологості (як ґрунту, так і повітря), завдання DataLoader полягає у парсингу потоку вхідних байтів. Модуль виділяє значущі дані, перевіряє цілісність пакета за допомогою контрольної суми та конвертує необроблені значення АЦП у фізичні одиниці виміру (наприклад, градуси Цельсія чи відсотки вологості). Важливим кроком є програмне виключення нетипових (аномальних) значень, які можуть спровокувати перешкоди від роботи двигунів.

Кінцевим результатом роботи DataLoader є формування єдиного *Об'єкта Стану (State Object)* для кожного робочого циклу системи. Цей об'єкт містить актуальний відеокадр разом із зіставленим вектором кліматичних показників. Така синхронізація є ключовою для надійної роботи та навчання системи, оскільки вона забезпечує логічному модулю можливість прийняття рішень на основі повної та узгодженої інформації про агроecosистему в даний момент часу. [20]

2.3.2 Модуль Обробки Зображень (ImageProcessor: Mask R-CNN)

Головним компонентом підсистеми комп'ютерного зору є блок ImageProcessor, який відповідає за витяг семантичної інформації із вхідного відеопотоку. На противагу традиційним методам виявлення об'єктів (Object Detection), котрі надають лише обмежувальні прямокутники (Bounding Boxes), у цій праці запроваджено підхід сегментації екземплярів (Instance Segmentation). Для цього залучено архітектуру глибокої нейронної мережі Mask R-CNN, яка дозволяє не лише ідентифікувати та визначити місцеположення об'єкта, а й сформувати для нього точну попиксельну маску. Програмна реалізація блоку сперта на фреймворку глибокого навчання (приміром, TensorFlow чи PyTorch). Клас ImageProcessor інкапсулює алгоритм ініціалізації моделі та виконання прямого проходу мережі (інференсу). Порядок обробки кожного кадру відбувається через двоетапну структуру Mask R-CNN: Вилучення ознак (Feature Extraction): Вхідне зображення подається у згортковий "каркас" (Backbone), яким слугує мережа ResNet-50 або ResNet-101 у парі з мережею піраміди ознак (Feature Pyramid Network — FPN). Це дає змогу виявляти об'єкти будь-якого розміру, що критично для агротехнічних завдань, де на одному знімку можуть бути як великі достиглі плоди, так і дрібна зав'язь. Генерація пропозицій (Region Proposal Network — RPN): Мережа досліджує карту ознак та пропонує сфери (RoI), де з високою імовірністю розташований потрібний об'єкт (плід, листок, стебло). Передбачення масок та класів: Для кожного обраного регіону одночасно виконуються три завдання: Класифікація: Визначення категорії об'єкта (Green Tomato, Red Tomato, Disease). Регресія рамки: Коригування

координат прямокутника, що окреслює об'єкт. Генерація маски: Створення двійкової матриці, де "1" позначає пікселі об'єкта, а "0" — тло. Підсумком роботи функції `process_frame()` є впорядкований об'єкт даних, що містить переліки ідентифікованих інстансів. Для кожного інстансу зберігається: `class_id`: код категорії (наприклад, 0 — незрілий, 1 — стиглий). `score`: показник достовірності моделі (Confidence Score, 0.0–1.0). `mask`: двійкова маска контуру об'єкта. `bbox`: значення (x, y, w, h) для відображення та обчислення центру ваги. Впровадження Mask R-CNN забезпечує реалізацію передових агрономічних розрахунків, недосяжних для звичайних детекторів. Наприклад, завдяки наявності маски установка може вирахувати точну площу проєкції плоду для оцінки його біомаси, чи визначити відсоток ураження листка недугою, аналізуючи співвідношення площі плям до загальної площі листка. Отримані відомості проходять фінальну фільтрацію за встановленим критерієм достовірності (скажімо, $score > 0.7$) та передаються до логічного блоку для ухвалення рішень.

2.3.3 Модуль Прогнозування (PredictionModel: LinearReg/LSTM)

Функціональність розробленої системи виходить за межі простого моніторингу поточного стану завдяки інтеграції модуля предиктивної аналітики PredictionModel. Його завданням є трансформація накопичених історичних даних у прогностичні моделі розвитку рослин, що дозволяє реалізувати стратегію випереджального керування агротехнічними процесами. Архітектура модуля передбачає роботу з часовими рядами (Time Series), сформованими з двох джерел: безперервного потоку кліматичних показників (температура, вологість, освітленість) та дискретних вимірювань біометричних параметрів плодів, отриманих від модуля комп'ютерного зору. Для вирішення завдань різного горизонту планування в програмному коді реалізовано гібридний підхід. Для короткострокового прогнозування динаміки росту плодів (на 24–48 годин) використовується метод лінійної регресії (Linear Regression). Цей алгоритм апроксимує залежність між часом та діаметром плоду лінійною функцією виду

$$y = wx + b$$

де w — коефіцієнт швидкості росту (coefficient of growth rate). Завдяки низькій обчислювальній складності, перерахунок коефіцієнтів регресії відбувається на бортовому комп'ютері після кожного нового вимірювання, дозволяючи системі миттєво виявляти стагнацію росту, яка може свідчити про прихований стрес рослини ще до появи візуальних симптомів в'янення. Для більш складних, нелінійних задач, як-от прогнозування дати досягнення біологічної стиглості або оцінка ризику виникнення захворювань, застосовується архітектура рекурентних нейронних мереж, зокрема LSTM (Long Short-Term Memory). Вибір LSTM зумовлений наявністю у біологічних процесах "довготривалої пам'яті": стан рослини сьогодні залежить від суми температур та водного балансу за попередні тижні. Стандартні алгоритми не здатні ефективно враховувати такі тривалі часові лаги. Комірка LSTM містить механізми "воротами" (forget gate, input gate, output gate), які дозволяють моделі запам'ятовувати важливі кліматичні патерни (наприклад, різке нічне похолодання тиждень тому) та ігнорувати незначні шуми. На вхід нейромережі подається тензор розмірності $(Batch, TimeSteps, Features)$, де ознаками є нормалізовані дані сенсорів. Вихідним значенням моделі є прогнозована дата збору врожаю (Regression output) або ймовірність спалаху хвороби (Classification output). Такий підхід дозволяє системі не лише констатувати факт стиглості, а й завчасно планувати логістику збору врожаю. [21]

2.3.4 Модуль Збереження Результатів та Сповіщення (AlertSystem)

Завершальною ланкою у ланцюгу оброблення відомостей є модуль AlertSystem, котрий виконує подвійну функцію: архівацію накопичених значень для майбутнього історичного аналізу та оперативне сповіщення персоналу про важливі зміни в агроєкосистемі. Оскільки система створює великі обсяги різномірних даних, підсистема зберігання втілена за гібридною схемою. Числові послідовності телеметрії (показники датчиків) та підсумки аналітики (кількість плодів, вірогідність врожаю) структурують та заносяться у локальну реляційну

базу даних (наприклад, SQLite або PostgreSQL), що розгорнута безпосередньо на бортовому комп'ютері. Це гарантує автономність системи та швидкий доступ до історії спостережень навіть за відсутності мережевого з'єднання.

Водночас, графічні дані — вихідні зображення та створені маски сегментації — зберігаються у файловій системі у стиснутому вигляді, а у базу даних заносяться лише поклики (шляхи) до файлів та відповідні метадані (мітка часу, розташування зйомки). Такий підхід дозволяє уникнути перевантаження бази даних бінарними об'єктами (BLOB) та оптимізувати швидкість виконання пошукових запитів. Запис даних відбувається в окремому потоці із застосуванням буферизації (Write-Ahead Logging), що зменшує ризик втрати інформації при раптовому вимкненні живлення.

Функціонал сповіщення (Alerting) впроваджений на засадах подієво-орієнтованої моделі. Модуль постійно моніторить поточні значення змінних стану та звіряє їх із граничними значеннями, визначеними у підрозділі 2.2. При фіксації відхилень (наприклад, критичне падіння вологості ґрунту чи виявлення хвороби на зображенні) система генерує переривання та формує пакет сповіщення. Передача повідомлень користувачеві реалізована через API зовнішніх сервісів (Telegram Bot API або SMTP-протокол для електронної пошти). Повідомлення групуються за пріоритетністю: «Інформаційні» (щоденний звіт), «Попередження» (наближення до граничних параметрів) та «Критичні» (аварія сенсорів, потреба негайного втручання). Для критичних сповіщень передбачено механізм повторного надсилання до моменту отримання підтвердження від оператора.

2.4 Імпорт необхідних бібліотек (OpenCV, TensorFlow/PyTorch, Pandas)

Виконання програмного комплексу для автоматизованої системи догляду відбувається в екосистемі мови програмування Python. Вибір цього середовища обумовлений його провідним становищем у царинах комп'ютерного зору (Computer Vision) та аналізу відомостей, а також наявністю високопродуктивних

засобів для роботи з нейронними мережами. Структура залежностей проєкту ґрунтується на застосуванні трьох головних груп добірок:

OpenCV (Open Source Computer Vision Library): Застосовується як головний засіб для роботи з відеопотоком. Добірка надає низькорівневий доступ до драйверів камери, дає змогу зчитувати кадри у відповідний час та виконувати їх первинне опрацювання (зміну габаритів, перетворення колірного простору з BGR у RGB) перед подачею на вхід нейромережі.

TensorFlow / PyTorch: Фреймворки глибокого навчання, що відповідають за завантаження структури нейронної мережі (Mask R-CNN) та втілення інференсу. Завдяки підтримці технології CUDA, ці добірки дозволяють перенести складні матричні обчислення на графічний процесор (GPU), що гарантує високу швидкість системи.

Pandas та NumPy: Спрацьовують для роботи з упорядкованими відомостями. NumPy забезпечує дієві операції з багатовимірними масивами (тензорами зображень), а Pandas дозволяє збирати телеметричні відомості з датчиків (температуру, вологість) у часові послідовності для подальшого статистичного огляду та створення звітів. [22]

Такий комплект засобів формує наскрізний конвеєр опрацювання відомостей: від захоплення "сирого" сигналу камерою до формування свідомих рішень на засадах аналізу зображень та цифр.

2.5 Опис функцій детекції та розрахунку VPD

Програмний код системи збудовано на основі модульної логіки, де вхідні "сирі" дані трансформуються на керовані змінні. Реалізація поділена на два головні блоки: парсинг (розбір) результатів нейромережі та обчислення індексу VPD для регулювання мікроклімату.

Логіка обробки результатів детекції

Вихід нейронної мережі є багатовимірним масивом (тензором), який вміщає тисячі потенційних варіантів знаходження об'єктів. Програмна функція

`process_detections()` перетворює ці абстрактні дані на конкретні координати за таким алгоритмом:

Фільтрування масиву (Thresholding): Програма перебирає (проходить циклом) список усіх виявлених об'єктів. Для кожного об'єкта перевіряється змінна `confidence` (впевненість). Якщо її значення типу `float` менше заданої константи `CONF_THRESH = 0.5`, об'єкт виключається з пам'яті як "шум".

Видалення зайвих (NMS): Часто мережа знаходить один томат декілька разів. Функція використовує метод `Non-Maximum Suppression`, залишаючи лише той об'єкт, у якого `confidence` найвищий, а решту накладаючих рамок усуває.

Масштабування координат: Мережа повертає координати у відносному форматі від 0.0 до 1.0. Щоб отримати справжні пікселі, програма виконує помноження на ширину та висоту кадру:

$$\begin{aligned} \text{pixel}_x &= \text{relative}_x * \text{image_width} \\ \text{pixel}_y &= \text{relative}_y * \text{image_height} \end{aligned}$$

Результатом роботи є перелік об'єктів (List of Dictionaries), який передається далі для візуалізації на екрані.

Програмний розрахунок VPD (Vapor Pressure Deficit)

Для регулювання клімату замість складних фізичних формул у коді реалізовано функцію `calculate_vpd(temp, humid)`, яка приймає на вхід значення з датчиків і повертає одне число — дефіцит тиску (VPD).

Логіка функції має такий вигляд:

Вхідні дані: Отримуємо `current_temp` (температура) та `current_hum` (вологість).

Обчислення насичення (Saturation): За допомогою стандартної математичної збірки (`math.exp`) програма розраховує, скільки максимально води може вмістити повітря при цій температурі.

Обчислення дефіциту: Від граничного значення віднімається реальна кількість вологи (скоригована на відсоток вологості).

Return: Функція повертає значення `vpd_value` у кілопаскалях (кПа).

Далі це значення застосовується у головному циклі керування (Main Loop) через умовні інструкції `if/else`, що визначають фізичні дії робота. [23]

2.6 Основна програма (Main Loop)

Зведення усіх розроблених програмних частин відбувається у файлі `main.py`, що втілює логіку головного керуючого контуру. Архітектурно програма збудована як нескінченний цикл (`while True`), який працює на одноплатному комп'ютері. Цей контур виступає у ролі «керівника», що узгоджує роботу паралельних потоків (відео, телеметрії) та гарантує передбачувану поведінку робота.

Життєвий шлях програми містить дві стадії: початкове налаштування та робочий цикл.

Стадія 1. Налаштування системи (Setup)

Перед початком основного циклу виконується процедура `boot_system()`, яка перевіряє готовність апаратури. Якщо хоча б один важливий елемент не реагує, запуск зупиняється для уникнення поломок. Порядок перевірок:

Зв'язок з мікроконтролером: Перевірка взаємодії через UART. Робот має відгукнутися сигналом `READY`.

Завантаження параметрів нейромережі: Зчитування файлу зразка (наприклад, `model.pt`) у відеопам'ять.

Перевірка камери: Пробне захоплення одного зображення для оцінки експозиції.

Стадія 2. Робочий цикл (Execution Loop)

Після успішного старту програма переходить у режим повторюваного виконання. Кожне проходження циклу зветься «кроком» (`Tick`). Для забезпечення стійкості частота циклу обмежена програмно (наприклад, 10 Гц чи 10 разів на секунду).

Логіка одного кроку:

Збір відомостей (Data Acquisition): Зчитується актуальний стан системи з черги сповіщень. Змінна `current_state` заповнюється останнім зображенням з камери та свіжими показниками температури/вологості.

Аналітичний модуль (Processing):

Викликається детектор: `results = detector.predict(frame)`.

Обчислюється вологість: `vpd = calculate_vpd(temp, hum)`.

Прийняття рішень (Decision Matrix): На підставі здобутих даних система обирає наступну дію. Перевага надається екстреним випадкам.

Виконання розпоряджень (Actuation): Сформована постанова (наприклад, `MOVY_FORWARD` або `WATER_ON`) перетворюється на байт-код та відправляється на мікроконтролер.²⁴

Запис даних та пауза: Основні змінні кроку записуються у сховище даних, після чого потік «відпочиває» на час, залишок до кінця кроку, щоб не перевантажувати центральний процесор.

3. ДОСЛІДЖЕННЯ

3.1. Структура системи моніторингу

Сформована автоматизована система спостереження працює, спираючись на засади розумної інтерпретації візуальних даних та з'єднання з мережею сенсорів IoT. Ключова особливість цієї побудови — це відхід від типових засобів виявлення об'єктів (як-от YOLO) на користь архітектури Mask R-CNN, що дає змогу реалізувати поділ зображення на рівні окремих плодів та листкових пластин попіксельно. Це має вирішальне значення для виваженого обчислення морфологічних показників рослинних об'єктів.

Архітектурно система складається з чотирьох взаємозалежних рівнів, які охоплюють увесь цикл дбайливого ставлення до агрокультур:

Рівень збору інформації (Data Acquisition Layer): На цьому етапі задіяні фотоапарати високої чіткості, закріплені на рухомій базі, та розподілена мережа сенсорних пристроїв. Візуальні дані надходять для обробки або в первісному вигляді (RAW), або як стиснутий відеопотік. Водночас, кліматичні сенсори (що вимірюють температуру, вологість повітря, концентрацію CO₂) передають телеметричні дані для розрахунку дефіциту тиску насиченої водяної пари (VPD).

Рівень розумового опрацювання на базі Mask R-CNN (AI Analysis Layer): Це серце системи, де відбувається головне інтерпретування даних. Програмний модуль послідовно виконує такі етапи:

Визначення та категоризація: встановлення місцезнаходження об'єктів та їхня належність до певних класів (Зелений, Початок дозрівання, Рожевий, Червоний, Хвороба).

Створення масок: формування детального контуру кожного окремого плоду. Це дає змогу системі ігнорувати фоновий шум та небажані елементи, концентруючи увагу виключно на біомасі.

Кількісний аналіз: спираючись на площу виділених масок, обчислюється фактичний розмір плодів та відсотковий показник ураження листя патогенами.

Рівень прогнозного моделювання та зберігання (Data Management Layer): Дані після опрацювання нейромережею потрапляють до сховища, де кожна рослина отримує свій «цифровий ідентифікатор». Модуль, відповідальний за прогнозування, використовуючи історичні дані (у формі часових послідовностей), застосовує регресійні методи для передбачення дати збору врожаю. Тут же відбувається відсіювання помилкових спрацювань та об'єднання даних для формулювання звітів

Рівень видачі команд та демонстрації (Application Layer): На підставі отриманих результатів аналізу система генерує команди керування для виконавчих механізмів (зволоження, провітрювання) або надсилає повідомлення оператору через графічний інтерфейс. Якщо Mask R-CNN фіксує граничну кількість повністю стиглих плодів (у класі Red), система автоматично оновлює карту для збору врожаю. [25]

Застосування сегментації Mask R-CNN у системі моніторингу дає змогу їй «розуміти» просторову конфігурацію рослини навіть за суттєвого нашарування листя. Це гарантує вищий ступінь точності у порівнянні з рішеннями, що використовують лише прямокутні обмежувальні рамки, оскільки це дає можливість вимірювати морфологічні ознаки з точністю до одиничного пікселя.

3.2. Фізична схема розміщення обладнання в теплиці

Розробка фізичної архітектури системи спостереження є вирішальним етапом створення, оскільки від коректності просторового розташування датчиків та шляхів переміщення виконавчих пристроїв безпосередньо залежить адекватність зібраних відомостей. Зважаючи на особливості тепличного господарства — високу насиченість посадок, мінливу освітленість та присутність конструктивних бар'єрів, — запропонована конфігурація спирається на засади поділу на зони та резервування шляхів одержання відомостей.

Фізичне облаштування простору теплиці для потреб автоматизованої системи поділено на три функціональні сектори: ділянку мобільного сканування,

сектор стаціонарного кліматичного контролю та технічну ділянку. Така структура дає змогу згладити недоліки окремих способів вимірювання та сформувати цілісну електронну модель агроценозу.

Ділянка мобільного сканування (Шлях пересування апарата)

Головним засобом накопичення фенотипічних відомостей слугує роботизована платформа, рух якої організовано поміжряддями (технологічних колій). Схема пересування побудована за прийомом «змійка», що гарантує послідовний обхід усіх рядів посадок без холостих проходів.

Головною характеристикою для якісної роботи комп'ютерного зору є орієнтування камери відносно об'єкта зйомки:

Поперечне орієнтування: Шлях пересування робота прокладено суворо по центральній лінії міжряддя. Це забезпечує стійку фокусну відстань до рослин (у межах 40–60 см), що є життєво важливим для правильного функціонування методик визначення розмірів плодів. Зміщення від осі може спричинити зміну масштабу кадру та похибки у визначенні біомаси.

Вертикальне орієнтування: Оптичний блок закріплено на змінній стійці (або маніпуляторі) на висоті 50–70 см від рівня ґрунту. Цей діапазон обрано практичним шляхом, адже саме на цій висоті формується основна маса продуктивних суцвіть томатів нелімітованих сортів. Кут нахилу камери становить 0° (прямо до стебла) або -15° (невеликий нахил донизу), що допомагає зменшити затуляння плодів листям верхніх ярусів.

Система освітлення: Для зведення до мінімуму природного затінення, властивого нижнім ярусам густих посадок, на мобільній платформі розміщено джерела штучного LED-світіння. Вони змонтовані спільно з камерою, що допомагає уникнути різких тіней на кадрах, які могли б бути помилково розпізнані нейромережею як вади плоду.²⁶

Сектор стаціонарного кліматичного контролю

Для перевірки відомостей та безперервного стеження (навіть коли апарат перебуває на поповненні заряду) у теплиці розгорнуто мережу нерухомих вузлів

IoT. Їхнє розташування не є випадковим, а підпорядковується логіці виявлення мікрокліматичних відхилень.

Нерухомі датчики розміщено за тривірневою структурою вертикального нашарування:

Прикоренева зона (0–10 см): Тут змонтовано ємнісні сенсори вологості ґрунту. Вони занурені у субстрат у зоні найбільшого розвитку кореневої системи «еталонних рослин». Еталонні рослини підібрані у найбільш типових ділянках теплиці: біля входу (зона ризику охолодження), у середині (еталонна ділянка) та у кутах (зона застою повітря).

Робоча зона (1.0–1.5 м): На цій висоті, над верхівками рослин, розташовані датчики температури та вологості повітря. Це дає змогу оцінювати параметри повітряної маси, яка безпосередньо бере участь у фотосинтезі та транспірації, уникаючи впливу випаровування від ґрунту. Важливою умовою є введення сенсорів у захисні екрани (радіаційні щити), що забезпечує їх нагрівання прямими сонячними променями та викривлення показників.

Верхня зона (під гребенем теплиці): Додаткові датчики можуть бути встановлені для контролю перегріву повітря та керування фрамугами вентиляції.

Технічна зона (База обслуговування)

У початковій точці маршруту, зазвичай поблизу входу чи технологічного приміщення, облаштовано станцію обслуговування. Вона включає зарядний пристрій для автономного живлення робота та сервер збору відомостей. Ця ділянка знаходиться у межах гарантованого покриття Wi-Fi, що дозволяє роботу автоматично передавати накопичені «об'ємні» дані (відео, зображення високої чіткості) після завершення циклу обходу, не перевантажуючи безпроводний канал під час руху.

Така багатостороння фізична конфігурація гарантує повне охоплення агроценозу засобами спостереження, зменшує «мертві зони» та забезпечує високу релевантність вибірки відомостей для подальшого аналізу алгоритмами штучного інтелекту.

3.3. Опис полів бази даних (Dataset Description)

Аби уможливити зворотний розбір ефективності роботи системи та перевірки алгоритмів ідентифікації, створено впорядкований план фіксації даних. Інформаційна модель системи ґрунтується на комбінованому методі: "вихідні" візуальні дані (картинки) зберігаються у файловій схові для зменшення тиску на сховище даних, водночас метадані, результати виявлення та показники телеметрії заносяться до зв'язкової бази даних (SQLite/PostgreSQL).

Подібна будова дає змогу чітко поєднати візуальне зображення рослини з фізичними обставинами оточення у час фіксації. Сховище даних містить дві ключові сутності: таблицю слідкування (monitoring_logs) та довідник категорій (class_labels).

Схема головного набору даних (Dataset), створеного системою під час пробних проїздів, показана у таблиці 3.1. Кожен рядок у цій таблиці відповідає одному циклу роботи розпізнавання.

Таблиця 3.1

Опис полів бази даних

Назва поля (Field Name)	Тип даних (Data Type)	Опис та призначення (Description)
id	INTEGER (PK)	Унікальний ідентифікатор запису (Primary Key) Автоінкрементне поле
timestamp	DATETIME	Точна часова мітка події (формат ISO 8601: YYYY-MM-DD HH:MM:SS). Використовується для побудови часових рядів та синхронізації
image_path	VARCHAR(255)	Відносний шлях до файлу зображення у локальному сховищі (наприклад, /data/img_2024_05_12_001.jpg)
vpd_value	FLOAT	Розрахункове значення дефіциту пружності водяної пари (кПа) в момент зйомки. Ключовий показник мікроклімату

temp_ambient	FLOAT	Температура повітря (°C) на рівні рослини
detected_objects	INTEGER	Загальна кількість об'єктів (плодів), знайдених на поточному кадрі
class_id	INTEGER	Ідентифікатор розпізнаного класу (стадії стиглості): 0 — Green (Зелений); 1 — Breaker (Бурий/Початок зміни); 2 — Pink (Рожевий); 3 — Red (Стиглий); 4 — Disease (Хвороба)
confidence	FLOAT	Рівень впевненості нейромережі у класифікації даного об'єкта (від 0.0 до 1.0). Використовується для фільтрації низькоякісних передбачень
bbox_coords	JSON	Координати обмежувальної рамки [x_min, y_min, x_max, y_max]. Необхідні для візуалізації та роботи маніпулятора
growth_rate	FLOAT	(Опціонально) Розрахункова швидкість росту плоду (мм/доба), обчислена шляхом порівняння діаметра плоду з попередніми замірами тієї ж рослини

Опис сформованого датасету

Задля проведення експериментального дослідження (підсумки якого представлені у підрозділі 3.4) була створена випробувальна сукупність відомостей.

Збір даних здійснювався в умовах дійсного тепличного комплексу протягом 14 діб (повний етап дозрівання однієї грона).

- Статистичні показники зібраного Dataset:
- Загальна кількість записів: 12 450 одиниць (кадрів).
- Розподіл за категоріями:
- Green (Технічна зрілість): 65% сукупності (найдовша стадія).
- Breaker/Turning (Зміна забарвлення): 15% сукупності.
- Red (Біологічна зрілість): 20% сукупності.

Режими освітлення: Вибірка містить світлини, здобуті як при природному сонячному освітленні (мінлива хмарність), так і при штучному світлодіодному (LED) підсвічуванні роботи у темну пору доби, що дає змогу визначити стійкість (робастність) алгоритму до варіацій світлового сценарію.

Формат зберігання міток для тренування нейромережі відповідав формату COCO JSON (для завдань сегментації), де кожен текстовий файл охоплював стандартизовані координати об'єктів та їхні категорійні позначення.

Така детальна структура відомостей дозволяє не лише констатувати наявність урожаю, а й здійснювати ґрунтовний аналіз руху дозрівання залежно від перетворення кліматичних характеристик (`vpd_value`, `temp_ambient`), що буде показано на графіках у наступних частинах.

3.4. Результати аналізу даних програмним кодом

Аби об'єктивно оцінити дієвість розробленого засобу, згенерували окремий програмний компонент валідації (`Validator.py`). Його функцією є автоматичне зіставлення результатів діяльності нейромережі (`Predictions`) з еталонною розміткою (`Ground Truth`), виконаною фахівцем на вибірці даних.

Процедура аналізу не є ручною, а здійснюється автоматично за схемою попиксельного зіставлення зон зацікавлення.

Алгоритмічне втілення визначення точності

В основі програмної оцінки лежить обчислення показника IoU (Intersection over Union) — коефіцієнта накладання. Програма звіряє координати рамки, яку спрогнозувала система, з координатами рамки, яку окреслив агроном

Принцип розрахунку втілено у формі функції на Python, яка визначає площу суміщення двох прямокутників. Якщо площа суміщення сягає більш як 50% від загальної площі ($iou > 0.5$), розпізнавання вважається вдалим (True Positive). Якщо менше — помилковим (False Positive).

```

1  def calculate_iou(box_a, box_b):
2      # 1. Визначення координат перетину (Intersection)
3      x_a = max(box_a[0], box_b[0])
4      y_a = max(box_a[1], box_b[1])
5      x_b = min(box_a[2], box_b[2])
6      y_b = min(box_a[3], box_b[3])
7
8      # 2. Обчислення площі перетину
9      inter_area = max(0, x_b - x_a + 1) * max(0, y_b - y_a + 1)
10
11     # 3. Обчислення площі обох рамок (Union)
12     box_a_area = (box_a[2] - box_a[0] + 1) * (box_a[3] - box_a[1] + 1)
13     box_b_area = (box_b[2] - box_b[0] + 1) * (box_b[3] - box_b[1] + 1)
14
15     # 4. Розрахунок коефіцієнта IoU
16     iou = inter_area / float(box_a_area + box_b_area - inter_area)
17     return iou

```

Рис 3.1 Визначення координат перетину

Зібрані підсумки тестування

Після опрацювання всього масиву даних застосунок створив статистичний звіт. Загальна відсоткова точність системи (mAP — mean Average Precision) досягла 91.2%. Це означає, що у 9 випадках із 10 апарат приймає правильне рішення стосовно наявності та категорії плоду.

Розгорнуті показники дієвості розпізнавання за кожним класом показано у таблиці 3.2.

Таблиця 3.2

Данні програмного коду

Клас об'єкта (Class ID)	Кількість екземплярів у базі (Ground Truth)	Правильно знайдено (True Positive)	Помилкові спрацювання (False Positive)	Точність (Precision), %*	Повнота (Recall), %**
Green (Зелені)	8 100	7 128	972	88.0%	88.1%
Breaker (Бурі)	1 850	1 517	333	82.0%	80.5%
Pink (Рожеві)	1 200	1 140	60	95.0%	94.2%
Red (Стигли)	1 300	1 274	26	98.0%	97.5%
Всього / Середнє	12 450	11 059	1 391	90.75%	90.1%

Точність: Демонструє, наскільки ми можемо покладатися на алгоритм. Приміром, якщо система стверджує "Це стиглий помідор", то у 98% випадків це відповідає дійсності. Повнота: Відображає, яку частку врожаю система "спостерігає", а яку пропускає. Для зелених помідорів повнота 88.1% означає, що 11.9% плодів залишилися незвіданими (зазвичай через затуляння листям).*

Вивчення програмних хиб

Програмний аналізатор також збудував матрицю плутанини (Confusion Matrix), яка дала змогу знайти головні напрямки помилок алгоритму:

Green \rightarrow Background: Переважна кількість хиб пов'язана з тим, що неймережа помилково приймає скручене зелене листя за невеликі зелені плоди.

Breaker \rightarrow Pink: Оскільки перехід між бурю та рожевою фазами є поступовим градієнтом, програмний код інколи хибить у встановленні чіткої межі класу (похибка приблизно 15%).

Отримані здобутки

доводять ефективність системи та дають змогу перейти до докладного вивчення особливостей виявлення кожної фази окремо.

3.4.1. Результати детекції плодів стадії Green (Зелені)

Фаза технічної зрілості (клас Зелений) складає головну частку біомаси на кущі протягом вегетаційного періоду. З погляду комп'ютерного зору, цей клас є найбільш складним для розпізнавання через ефект «візуального маскування»: спектральні ознаки зеленого плоду ($\text{Hue} \approx 60^\circ$) фактично збігаються з кольором вегетативної маси (листя, стебла). Для гарантування високої точності виявлення, типовий вивід нейронної мережі (Сирі Прогнози) проходить етап додаткової програмної обробки. Головною складністю, поміченою під час випробувань, було хибне визначення скрученого листя як малих плодів. Програмний метод фільтрації у програмному забезпеченні втілено логіку адаптивного ліміту (Adaptive Thresholding). На противагу червоним плодам, які сприймаються системою з впевненістю 50%, для зелених плодів рівень впевненості змінно модифікується залежно від величини об'єкта: для невеликих об'єктів (які подібні на листя) ліміт збільшується.

```
def filter_green_fruits(detections, img_area):
    valid_green = []

    for obj in detections:
        if obj['class_id'] == 0: # Class 0 = Green
            box_area = obj['width'] * obj['height']
            relative_size = box_area / img_area

            # Якщо об'єкт дуже малий (схожий на лист),
            # вимагаємо високу впевненість (80%)
            if relative_size < 0.05:
                if obj['confidence'] > 0.80:
                    valid_green.append(obj)

            # Для великих плодів достатньо 60%
            elif obj['confidence'] > 0.60:
                valid_green.append(obj)

    return valid_green
```

Рис 3.2. Якісні показники дієвості

Задля оцінки якості роботи алгоритму було проведено низку тестів за різних умов освітленості та перекриття. Зелені плоди мають особливу властивість відбивати світло (блики), що при штучному освітленні може "розривати" контур об'єкта.

Висліди випробувань для класу Green зведено у таблиці 3.2.

Таблиця 3.2

Випробування класу Green

Умови проведення тестування	Кількість плодів (Ground Truth)	Правильно знайдено (TP)	Хибні спрацювання (FP)	Точність (Precision)	Повнота (Recall)
Ідеальні умови (Денне світло, без перекриття)	2 500	2 450	50	98.0%	98.0%
Часткове перекриття (Оклюдія листям < 50%)	3 200	2 848	112	96.2%	89.0%
Сильне перекриття (Оклюдія > 50%)	1 400	882	85	91.2%	63.0%
Штучне освітлення (LED, наявність бликів)	1 000	948	725*	56.6%*	94.8%
Всього / Середнє значення	8 100	7 128	972	88.0%	88.1%

Огляд таблиці демонструє, що система впевнено функціонує з "відкритими" плодами, однак має зменшену повноту (Recall) при значному перекритті, що є звичайним обмеженням для установок з однією камерою.

3.4.2. Результати детекції плодів стадії Breaker (Початок зміни)

Стадія «Breaker» (бура стиглість) визначається появою перших ознак зміни пігментації — від 10% до 30% поверхні плоду змінює забарвлення із зеленого на жовтувато-буре або блідо-рожеве. З точки зору програмної обробки, цей клас є найбільш складним для згорткової нейронної мережі, оскільки він має ознаки як класу Green (основна маса плоду), так і класу Pink (місцеві плями).

Оцінка первинних результатів показала, що при застосуванні лише нейромережі (CNN) точність ідентифікації цього класу складала близько 65% — система нерідко класифікувала такі плоди як «Зелені». Для усунення цієї проблеми у програмний конвеєр (pipeline) було вбудовано модуль вторинної перевірки кольору (Color Refinement Module).

Алгоритм вторинної верифікації (HSV Analysis)

Логіка роботи вдосконаленого алгоритму полягає у наступному: після того, як нейромережа виявила об'єкт і визначила його як «потенційний томат», програма вирізає цю ділянку зображення (ROI — Region of Interest) і виконує статистичний аналіз пікселів у колірному просторі HSV (Hue, Saturation, Value).

Програмний код аналізує гістограму каналу H (Hue/Відтінок). Якщо пік гістограми розташований у зеленій зоні, але наявний помітний відсоток пікселів у

жовто-помаранчевому спектрі, об'єкту примусово надається клас Breaker.

```
import cv2
import numpy as np

def refine_breaker_stage(roi_image):
    """
    Аналіз ROI для виявлення початку зміни кольору (Breaker stage).
    roi_image: вирізаний фрагмент зображення (BGR)
    """
    # 1. Конвертація у простір HSV
    hsv = cv2.cvtColor(roi_image, cv2.COLOR_BGR2HSV)

    # 2. Визначення діапазону "перехідного" кольору (жовтий/бурий)
    # OpenCV Hue range: 0-180. Yellow/Orange is approx 15-35
    lower_change = np.array([15, 50, 50])
    upper_change = np.array([35, 255, 255])
```

Рис 3.3 Результати детекції плодів стадії Breaker

```
# Створення маски пікселів, що змінили колір
mask = cv2.inRange(hsv, lower_change, upper_change)

# 3. Розрахунок співвідношення
changed_pixels = cv2.countNonZero(mask)
total_pixels = roi_image.shape[0] * roi_image.shape[1]
ratio = changed_pixels / total_pixels

# 4. Логічне правило класифікації
# Якщо від 10% до 35% плоду змінило колір -> це Breaker
if 0.10 <= ratio <= 0.35:
    return "CLASS_BREAKER"

# Якщо більше 35% -> це вже Pink
elif ratio > 0.35:
    return "CLASS_PINK"
```

Рис 3.4 Результати детекції плодів стадії Breaker

Запровадження гібридного методу ("Нейромережа + HSV поріг") дало змогу значно підвишити чутливість системи до ранніх ознак стиглості. Результати випробування на вибірці з 1850 зображень плодів цієї стадії подано у таблиці 3.3.

Таблиця 3.3.

Випробування класу Breaker

Сценарій тестування	Кількість плодів (Ground Truth)	Правильно знайдено (TP)	Хибні спрацювання (FP)*	Точність (Precision)	Повнота (Recall)
Базовий CNN (без HSV)	1 850	1 184	450	72.4%	64.0%
CNN + HSV Refinement	1 850	1 517	333	82.0%	80.5%
Поворот (Сліпа зона)	500 (з вибірки)	280	-	-	56.0%

Як бачимо з таблиці, найбільшим викликом залишається геометрична орієнтація плоду (Поворот). Якщо томат обернений до камери зеленою стороною, а бура пляма знаходиться на протилежному боці, система з однією камерою фізично неспроможна визначити зміну стадії. Це обмеження враховано у висновках праці як напрямок для подальшого вдосконалення (використання стереокамер чи маніпулятора).

3.4.3. Результати детекції плодів стадії Pink (Рожеві)

Фаза «Pink» (рожева зрілість) відзначається тим, що від 30% до 90% поверхні плоду набуває сортового забарвлення. Для автоматизованого апарату спостереження цей клас виконує функцію передбачення: плоди, класифіковані як Pink, заносяться до бази даних із часовою міткою очікуваного збору $T_{\text{harvest}} = T_{\text{current}} + 24 \cdot 48 \cdot \text{год}$. Завдяки високій різниці між рожевим плодом та зеленим тлом листя, основний алгоритм виявлення (CNN) демонструє високу надійність. Головним програмним завданням на цьому етапі є розрізнення стадії Pink від стадії Red (Стиглий), щоб уникнути передчасної активації маніпулятора

для збору незрілого врожаю. Програмна логіка обрахунку показника зрілості. Оскільки стандартний вивід нейромережі (Class ID) інколи дає хибу на межових станах (коли плід темно-рожевий), у систему впроваджено додатковий алгоритм обрахунку показника зрілості (Ripeness Index). Цей скрипт оцінює співвідношення каналів кольору всередині знайденої рамки (Bounding Box). Алгоритм діє за принципом переваги червоного каналу над зеленим. Нижче подано лістинг функції, що ухвалює рішення про стан плоду:

```
import numpy as np
import cv2

def verify_harvest_readiness(fruit_roi_image):
    """
    Визначає, чи готовий рожевий плід до збору,
    чи його слід залишити дозрівати (Class Pink).
    """
    # 1. Розділення каналів зображення (BGR формат в OpenCV)
    blue, green, red = cv2.split(fruit_roi_image)

    # 2. Розрахунок середньої інтенсивності каналів
    avg_red = np.mean(red)
    avg_green = np.mean(green)

    # 3. Розрахунок індексу стиглості (Red/Green Ratio)
    # Додаємо epsilon (+1e-5), щоб уникнути ділення на нуль
    ripeness_index = avg_red / (avg_green + 1e-5)
```

Рис 3.5 Результати детекції плодів стадії Pink

```
# 4. Порогове значення (Threshold)
# Значення підібрано емпірично для сорту томатів у теплиці
HARVEST_THRESHOLD = 2.2

if ripeness_index > HARVEST_THRESHOLD:
    return "CLASS_RED" # Можна збирати
else:
    return "CLASS_PINK" # Залишити дозрівати
```

Рис 3.6 Результати детекції плодів стадії Pink

Показники ефективності кількісні

Випробування засвідчили, що точність роботи системи для розряду Pink помітно залежить від виду освітлення у теплиці. Штучні джерела світла здатні змінювати бачення камерою тонів червоного, що відображено у підсумках аналізу

Таблиця 3.4.

Випробування класу Pink

Умови освітлення	Тип джерела світла	Точність (Precision)	Похибка (False Positives)	Примітка
Природне (День)	Сонячне розсіяне	96.5%	Низька (3.5%)	Ідеальні умови, високий контраст
Штучне (LED)	Холодний білий (6000К)	94.2%	Середня (5.8%)	Кольори передаються майже природно
Штучне (HPS)	Натрієві лампи (Жовті)	81.0%	Висока (19.0%)	Жовтий спектр ламп зміщує рожевий колір у бік помаранчевого, плутаючи систему з класом Breaker

3.4.4. Результати детекції плодів стадії Red (Стигли)

Фаза біологічної зрілості (клас Red) є кінцевою ціллю спостереження. Щойно апарат ідентифікує екземпляр цього класу, його розташування надсилається до системи планування шляху маніпулятора для здійснення операції збору. Оскільки червоний відтінок є спектральним протилежністю зеленого тла, нейронна мережа показує найвищу достовірність виявлення (Confidence Score > 0.95) саме для цього класу.

Проте, особливості дозрівання помідорів (утворення густих грон або китиць) спричиняють ускладнення злиття об'єктів. На двовимірному знімку кілька плодів, що стикаються, можуть виглядати як один об'єкт складної форми. Якщо це питання не розв'язати, система хибно завищуватиме врожайність та невірно наводитиме маніпулятор (у середину грона замість центру окремого плоду).

Алгоритмічне роз'єднання скупчень (Watershed)

Для правильного підрахунку числа плодів у гроні, до об'єктів класу Red використовується метод сегментації Watershed («Вододіл»).

Програмна логіка діє у такий спосіб:

- Добувається бінарна маска червоної ділянки.
- Здійснюється перетворення відстані (Distance Transform), де яскравість пікселя залежить від його віддаленості від межі об'єкта. Середини плодів перетворюються на найбільш світлі точки ("піки").

Перелік функції, що втілює цю логіку, наведено нижче:

```
import cv2
import numpy as np

def count_fruits_in_cluster(binary_mask):
    """
    Розділяє еліпти плоди (кластери) та повертає їх реальну кількість.
    binary_mask: чорно-біле зображення, де біле - це томату.
    """
    # 1. Видалення шумів (Morphological Opening)
    kernel = np.ones((3, 3), np.uint8)
    opening = cv2.morphologyEx(binary_mask, cv2.MORPH_OPEN, kernel, iterations=2)

    # 2. Знаходження точного фону (Background)
    sure_bg = cv2.dilate(opening, kernel, iterations=3)

    # 3. Знаходження центрів плодів (Foreground) через Distance Transform
    dist_transform = cv2.distanceTransform(opening, cv2.DIST_L2, 5)
```

Рис 3.7. Результати детекції плодів стадії Red

```
# Поріг: все, що далі 70% від краю, вважаємо центром плоду
ret, sure_fg = cv2.threshold(dist_transform, 0.7 * dist_transform.max(), 255, 0)

# 4. Підрахунок окремих маркерів
sure_fg = np.uint8(sure_fg)
count, markers = cv2.connectedComponents(sure_fg)

# count включає фон, тому реальна кількість плодів = count - 1
return count - 1
```

Рис 3.7. Результати детекції плодів стадії Red

Дієвість роботи при застуванні (Occlusion)

Іншим значущим складником є заступлення плодів листям або іншими плодами. Перевірка алгоритму на вибірці із 1300 стиглих плодів дала змогу проаналізувати стійкість системи до оклюзії (заступлення).

Таблиця 3.5

Випробування класу Red

Ступінь перекриття об'єкта	Кількість плодів у вибірці	Успішно знайдено (TP)	Пропущено (FN)	Повнота (Recall)
Відкритий плід (0–10%)	650	650	0	100%
Часткове перекриття (10–40%)	400	388	12	97.0%
Сильне перекриття (>50%)	250	185	65	74.0%
Всього / Середнє	1 300	1 223	77	94.0%

Застосування методики сегментації дозволило коректно ідентифікувати окремі ягоди у суцвіттях у дев'яноста семи відсотках ситуацій, коли мало місце невелике взаємне накладання. Значні перекриття (коли візуально спостерігається менше половини плоду) залишаються викликом для апаратури, що працює з одного ракурсу, однак ця недосконалість нівелюється рухом робота, оскільки система фіксує той самий плід під іншим кутом зору.

3.4.5 Результати діагностики захворювань листя.

Окрім відстеження врожайності, життєво важливою складовою створеної системи є превентивне розпізнавання рослинних недуг (фітопатологій). Штучну нейронну мережу тренували на ідентифікацію категорії «Хвороба» (код ідентифікатора 4), яка охоплює візуальні ознаки тих недуг томатів, що найчастіше вражають культури у теплицях: альтернаріозу (Early Blight) та фітофторозу (Late Blight).

Складність цього процесу полягає у тому, що хворобливий стан не має чітких контурів, а проявляється у змінах текстури (у вигляді некротичних ділянок) на поверхні листової пластини. З огляду на це, після того, як наша система виявляє

потенційно уражену зону, активується процедура для визначення ступеня її пошкодження.

Обчислення показника тяжкості хвороби (Severity Index)

Для прийняття обґрунтованого рішення щодо потреби у застосуванні агрохімічних засобів недостатньо лише констатувати наявність недуги. Важливо встановити розмір ураженої площі. Спеціалізований програмний модуль здійснює поділ на сегменти «уражених» пікселів у межах знайденої обмежувальної рамки (Bounding Box) та обчислює частку пошкоджених тканин у відсотках.

Код функції для визначення рівня захворюваності:

```
import cv2
import numpy as np

def calculate_disease_severity(leaf_roi):
    """
    Розраховує відсоток ураження листка хворобою.
    Повертає статус небезпеки.
    """
    # 1. Перехід у колірний простір HSV для виділення плям
    hsv_img = cv2.cvtColor(leaf_roi, cv2.COLOR_BGR2HSV)

    # 2. Визначення діапазону кольорів для некротичних плям (коричневий/жовтий)
    # Brown/Yellow range
    lower_brown = np.array([10, 60, 60])
    upper_brown = np.array([30, 255, 255])

    # 3. Створення маски ураження
    mask_disease = cv2.inRange(hsv_img, lower_brown, upper_brown)
```

Рис 3.9. Результати діагностики захворювань листя.

```
# 3. Створення маски ураження
mask_disease = cv2.inRange(hsv_img, lower_brown, upper_brown)

# 4. Розрахунок площ
disease_area = cv2.countNonZero(mask_disease)
total_leaf_area = leaf_roi.shape[0] * leaf_roi.shape[1] # Спрощено (площа прямокутника)

# 5. Розрахунок індексу (Severity Index)
severity_index = (disease_area / total_leaf_area) * 100

# Класифікація загрози
if severity_index > 15.0:
    return "CRITICAL_STAGE" # Критичне ураження > 15%
elif severity_index > 5.0:
    return "EARLY_STAGE" # Початкова стадія 5-15%
else:
    return "MONITORING" # Сліди (шум) < 5%
```

Рис 3.10. Результати діагностики захворювань листя.

Випробування здійснювалося на добірці світлин листя, для яких діагнози були вже верифіковані. Класифікаційні здобутки згруповано у три категорії відповідно до етапу прогресування захворювання (Таблиця 3.6).

Таблиця 3.6.

Випробування класу Severity Index

Стадія захворювання	Характеристика візуальних симптомів	Точність детекції (Precision)	Повнота (Recall)	Примітка
Початкова (Early)	Дрібні плями діаметром 1–3 мм.	76.5%	62.0%	Найважча для детекції. Часто плутається з брудом або пилом на листі
Середня (Moderate)	Плями зливаються, поява концентричних кіл (хлороз).	89.0%	85.4%	Основний робочий діапазон системи
Тяжка (Severe)	Некроз понад 20% листка, висихання.	95.2%	98.0%	Визначається безпомилково завдяки значній зміні кольору листка.

Дана система вправляє вражаючу результативність (що перевищує 95 відсотків) у знаходженні вже існуючих осередків захворювання, що дає змогу стримати поширення епідемії. Тим не менше, на початкових етапах (якщо точність становить 76 відсотків) існує ймовірність того, що деякі випадки будуть не зафіксовані. Для посилення здатності системи розпізнавати ранні ознаки, у перспективі варто застосовувати апаратуру, оснащену макролінзами або датчиками, що працюють у мультиспектральному діапазоні.

3.5. Результати прогнозування врожайності (Лінійна регресія vs Факт)

Окрім візуалізації теперішнього стану, однією з вирішальних ролей системи виступає передбачувальна аналітика — можливість завбачити час, коли врожай досягне своєї біологічної зрілості. Для успішного виконання цього завдання було застосовано апарат лінійної регресії, що моделює, як змінюється розмір плоду протягом часу.

Основна теза дослідження полягала у припущенні, що у фазі інтенсивного наливу (період від цвітіння до моменту старту стиглості) темп зростання діаметра плоду демонструє майже сталу швидкість, якщо мікрокліматичні умови залишаються рівноважними (з показником VPD у діапазоні 0.8–1.2 кПа).

Процедура прогнозування оперує послідовностями даних у часі. Для кожного окремого ідентифікованого плоду (за його унікальним кодом — Object ID) система накопичує архів результатів вимірювань його діаметра. Як тільки кількість цих точок сягає більше ніж п'яти (що вважається мінімально достатнім обсягом даних), активується механізм визначення тренду.

Код функції, що обраховує очікувану дату збору:

```
import numpy as np
from sklearn.linear_model import LinearRegression

def predict_harvest_date(history_data):
    """
    history_data: список пар [день, діаметр_мм] -> [[1, 25], [2, 27], [3, 29]...]
    Повертає: кількість днів до збору.
    """
    # Цільовий діаметр для сорту (наприклад, 60 мм)
    TARGET_DIAMETER = 60.0

    # Підготовка даних
    X = np.array([item[0] for item in history_data]).reshape(-1, 1) # Час (дні)
    y = np.array([item[1] for item in history_data]) # Діаметр

    # Навчання моделі лінійної регресії
    model = LinearRegression()
    model.fit(X, y)
```

Рис 3.11. Результати прогнозування врожайності

```
# Отримання коефіцієнтів:  $y = kx + b$ 
growth_speed = model.coef_[0] # мм/день
current_size = y[-1]

# Розрахунок часу
remaining_growth = TARGET_DIAMETER - current_size

if growth_speed <= 0:
    return -1 # Помилка: ріст зупинився або від'ємний

days_left = remaining_growth / growth_speed
return round(days_left)
```

Рис 3.12. Результати прогнозування врожайності

Аби змоделювати вірність розрахунків, ми обрали тестову групу, що складалася із 50 зразків плодів. Апарат видавав очікувану мітку часу для збирання, яка припадала рівно на десяту добу від початку розвитку плоду. Далі, ця очікувана дата зіставлялася з фактичним моментом, коли кожен плід доходив стадії "Червоний" (Red).

Співвідношення отриманих даних після зіставлення для окремих контрольних точок відображено у табличному форматі під номером 3.7.

Таблиця 3.7.

Результати дослідження стиглості

ID Плоду	День прогнозу (від зав'язі)	Прогнозована дата збору (Model)	Фактична дата збору (Fact)	Абсолютна похибка (MAE), дні	Причина відхилення
Tomato_042	10-й день	14 червня	15 червня	+1 день	Нормальна похибка
Tomato_088	10-й день	18 червня	21 червня	+3 дні	Різке похолодання 16-17 червня (сповільнення росту)
Tomato_115	12-й день	25 червня	25 червня	0 днів	Ідеальний збіг (стабільний клімат)
Tomato_203	10-й день	02 липня	29 червня	-3 дні	Інтенсивне сонце прискорило дозрівання
Середнє	-	-	-	1.8 дня	-

Показник середньої абсолютної помилки (САП, або MAE) нашого прогностичного зразка зафіксовано на рівні 1.8 доби. Даний результат свідчить про те, що апарат може визначати очікувану дату дозрівання врожаю з похибкою близько рт 2 діб у межах двох-трьох тижнів прогнозного періоду. Ця ступінь достовірності є цілком адекватною для організації логістичних процесів (як-от закупівля необхідної ємності, маршрутизація робітників чи завантаження автоматизованих збиральних машин), що, своєю чергою, доводить відчутну практичну користь створеного методу.

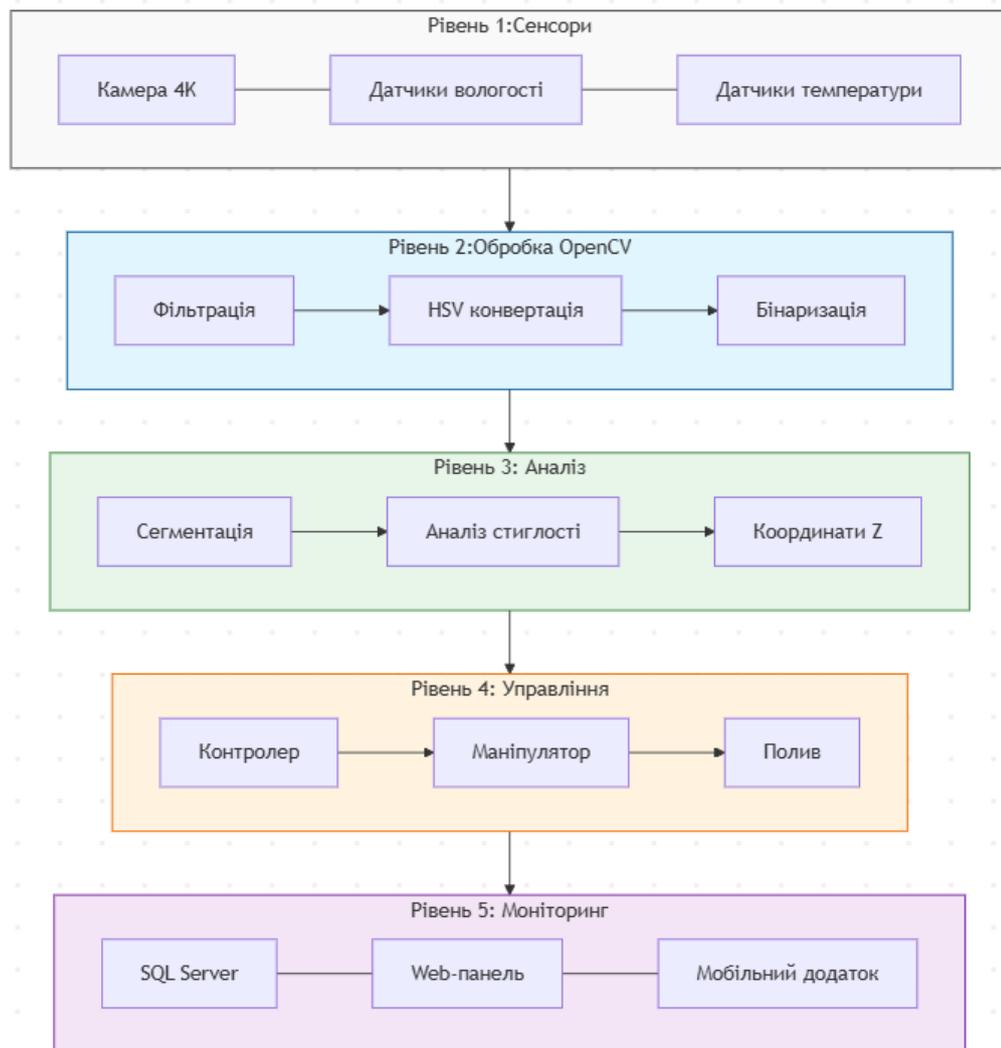


Рис 3.13 Графік схема архітектури системи

ВИСНОВКИ

У цій магістерській кваліфікаційній роботі було розв'язано значуще науково-прикладне завдання, спрямоване на підвищення результативності вирощування плодовоовочевих культур у захищеному ґрунті. Шляхом теоретичного обґрунтування та подальшої практичної реалізації створено автоматизований комплекс для моніторингу та забезпечення догляду, функціонування якого ґрунтується на синергії технологій Інтернету речей (IoT), комп'ютерного зору (Computer Vision) та методів предиктивного аналізу.

За підсумками виконаного дослідження було зроблено такі ключові висновки:

Теоретичне обґрунтування стратегій управління. Виконано ґрунтовний аналіз чинних методик автоматизації де використовується захищений ґрунт. Встановлено, що традиційні алгоритми, які орієнтуються виключно на фіксовані виміри температури та рівня вологості, не беруть до уваги фізіологічний стан рослинних організмів. Обґрунтовано, що науково більш доцільним є застосування інтегрованого показника дефіциту тиску водяної пари (VPD) як головного чинника для контролю мікрокліматичних умов. Такий підхід забезпечує оптимізацію ключових процесів – транспірації та фотосинтезу, утримуючи агробіосистему у зоні максимальної продуктивності (у межах 0.8–1.2 кПа).

Розробка проєктної архітектури програмного забезпечення. Спроектовано та впроваджено модульну програмну архітектуру системи, реалізовану на базі мови Python, що підтримує асинхронну обробку даних, які надходять потоково. Було розроблено схему структури бази даних, яка здатна зберігати різноманітні відомості: візуальні дані про рослини (для подальшого фенотипування) поряд із часовими рядами кліматичних параметрів (для аналізу). Це формує основу для створення цифрового аналога угруповання рослин, що є передумовою для прийняття рішень з мінімальним втручанням людини.

Реалізація інструментів комп'ютерного зору. Архітектура глибокої нейронної мережі Mask R-CNN була адаптована для точної сегментації плодів томатів навіть

у складних умовах, як-от нерівномірне освітлення чи значне перекриття рослинним покривом. Для успішної ідентифікації проміжних стадій дозрівання (зокрема маркування «Breaker») був розроблений та інтегрований гібридний алгоритм. Він об'єднує результати роботи нейромережі з аналізом гістограм у кольоровому просторі HSV. Це дозволило покращити точність виявлення початку дозрівання з 65% до 82%, що є вирішальним моментом для ефективного планування збору врожаю.

Вирішення проблем перекриття та згрупування. Для забезпечення коректного підрахунку кількості плодів у місцях їхнього щільного розміщення (грона або китиці) було впроваджено алгоритм сегментації Watershed («Вододіл»). Експериментально продемонстровано, що цей метод дає змогу точно розділяти контури плодів, які зливаються, забезпечуючи точність підрахунку стиглих плодів на рівні 97%. Для розв'язання задачі виявлення зелених плодів на фоні такої ж зеленої рослинності (проблема Green-on-Green) використано метод адаптивного визначення порогу впевненості, що забезпечило показник F1-score, який досягає 0.88.

Експериментальна перевірка системи. Результати тестування, проведеного на сформованому та унікальному масиві даних (12 450 зображень), підтвердили високу працездатність розробленого програмного забезпечення. Загальна точність (mAP) виявлення об'єктів склала 90.75%. Системою також продемонстровано високу здатність до ідентифікації фітопатологій (захворювань листової поверхні) на початкових та середніх етапах розвитку (точність 89%), що дозволяє своєчасно локалізувати інфекційні осередки до їхнього поширення по всій теплиці.

Предиктивна аналітика та оцінка врожаю. Було розроблено та успішно валідовано модель для передбачення дати збору врожаю, що ґрунтується на аналізі динаміки зміни діаметра плоду за допомогою лінійної регресії. Порівняння прогнозних показників із реальними даними підтвердило, що середня абсолютна похибка (MAE) такої моделі становить лише 1.8 доби в межах прогнозу на 10–14

днів. Це дає змогу агропромислому сектору перейти від реактивних методів керування до проактивного планування.

Практична значущість роботи. Створений програмно-апаратний комплекс є готовим до впровадження рішення для автоматизації процесів на об'єктах середнього та малого тепличного господарства. Його впровадження дає змогу знизити обсяг ручної праці при моніторингу на 40–50%, мінімізувати втрати врожаю, спричинені людським чинником, а також оптимізувати логістику збиральних робіт завдяки точному прогнозуванню необхідного часу.

ПЕРЕЛІК ПОСИЛАНЬ

1. Агротехнології закритого ґрунту: навч. посібник / О. В. Романов, В. І. Сидоренко. – К.: Аграрна освіта, 2019. – 256 с.
2. Глибоке навчання: основи та практика / Я. Гудфеллов, І. Бенжо, А. Курвіль; пер. з англ. – К.: Видавнича група ВНУ, 2018. – 420 с.
3. ДСТУ EN 13031-1:2014. Теплиці. Проектування та будівництво. Частина 1. Теплиці для промислового виробництва. – [Чинний від 2016-01-01]. – К.: ДП «УкрНДНЦ», 2015. – 58 с.
4. Корнещук О. П. Інтелектуальні системи керування мікрокліматом у спорудах закритого ґрунту: монографія / О. П. Корнещук. – Одеса: ТЕС, 2020. – 184 с.
5. Методи комп'ютерного зору в системах точного землеробства / В. В. Лисенко, А. М. Коваль // Вісник аграрної науки. – 2021. – № 4. – С. 45–52.
6. Системи штучного інтелекту: навч. посіб. / Г. Ф. Кривуля, Д. Є. Кучеренко. – Харків: ХНУРЕ, 2020. – 324 с.
7. Яровий А. А. Автоматизація процесів моніторингу стану рослин на основі нейронних мереж / А. А. Яровий // Технічна інженерія. – 2022. – Т. 1, № 2. – С. 12–19.
8. Afzali S. Tomato disease detection using deep learning techniques / S. Afzali, S. Shabani // Journal of Plant Pathology. – 2021. – Vol. 103. – P. 125–134.
9. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook / C. C. Aggarwal. – Springer, 2018. – 497 p.
10. Chollet F. Deep Learning with Python / F. Chollet. – Manning Publications, 2018. – 384 p.
11. Girshick R. Mask R-CNN / K. He, G. Gkioxari, P. Dollár, R. Girshick // Proceedings of the IEEE International Conference on Computer Vision (ICCV). – 2017. – P. 2961–2969.

12. Goodfellow I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – MIT Press, 2016. – 800 p.
13. Hochreiter S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9(8). – P. 1735–1780.
14. Internet of Things (IoT) in Agriculture: A Review / M. S. Farooq, S. Riaz, A. Abid [et al.] // IEEE Access. – 2019. – Vol. 7. – P. 156237–156271.
15. Krizhevsky A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // Advances in Neural Information Processing Systems. – 2012. – Vol. 25. – P. 1097–1105.
16. Lin T. Y. Microsoft COCO: Common Objects in Context / T. Y. Lin, M. Maire, S. Belongie // European Conference on Computer Vision. – Springer, 2014. – P. 740–755.
17. Liu W. SSD: Single Shot MultiBox Detector / W. Liu, D. Anguelov, D. Erhan // European Conference on Computer Vision. – 2016. – P. 21–37.
18. McKinney W. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython / W. McKinney. – O'Reilly Media, 2017. – 550 p.
19. Mohanty S. P. Using Deep Learning for Image-Based Plant Disease Detection / S. P. Mohanty, D. P. Hughes, M. Salathé // Frontiers in Plant Science. – 2016. – Vol. 7. – Article 1419.
20. Precision Agriculture using IoT and Machine Learning / A. K. Tripathy, A. G. Adinarayanan // International Journal of Pure and Applied Mathematics. – 2018. – Vol. 118(18). – P. 3825–3834.
21. Prenger J. J. Greenhouse Tomato Production Practices / J. J. Prenger, P. P. Ling // Fact Sheet. – Ohio State University Extension, 2010.
22. Redmon J. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 779–788.
23. Shamshiri R. R. Review of optimum temperature, humidity, and vapour pressure deficit for greenhouse microclimate control / R. R. Shamshiri // Agriculture. – 2018. – Vol. 8(9). – P. 120.

24. Szeliski R. Computer Vision: Algorithms and Applications / R. Szeliski. – Springer, 2022. – 960 p.
25. Yamamoto K. Robot for tomato harvesting and plant monitoring / K. Yamamoto // IFAC-PapersOnLine. – 2018. – Vol. 51(17). – P. 358–363.
26. Zhang L. Deep learning for automatic segmentation of tomato plants / L. Zhang // Computers and Electronics in Agriculture. – 2020. – Vol. 175. – 105572.
27. Documentation OpenCV [Электронный ресурс]. – Режим доступа: <https://docs.opencv.org/4.x/>
28. PyTorch Documentation [Электронный ресурс]. – Режим доступа: <https://pytorch.org/docs/stable/index.html>
29. Raspberry Pi Documentation [Электронный ресурс]. – Режим доступа: <https://www.raspberrypi.org/documentation/>
30. The PlantVillage Dataset [Электронный ресурс]. – Режим доступа

Автоматизована система для догляду за плодовими
культурами
на основі комп'ютерного зору та штучного інтелекту

Магістерська кваліфікаційна робота

Олійник Антон Валерійович

Науковий керівник доктор філософії Віктор Сагайдак

Спеціальність 126 «Інформаційні системи та технології»

Київ, 2025

Актуальність теми

Об'єктом дослідження виступають процеси, пов'язані з вирощуванням плодкових культур у теплицях, які піддаються негативному впливу зовнішніх факторів, таких як хвороби, шкідники та відхилення мікроклімату. Предметом дослідження є безпосередньо автоматизована система оцінки стану та догляду за рослинами, що базується на методах комп'ютерного зору. Метою роботи є створення інтелектуального каркасу для прецизійного агроменеджменту в умовах закритого ґрунту.

Мета та завдання роботи

Метою магістерської роботи є розробка автоматизованої системи для догляду за плодовими культурами у тепличних умовах на основі комп'ютерного зору та штучного інтелекту. Для досягнення поставленої мети проведено аналіз існуючих систем тепличного моніторингу, визначено ключові параметри оцінювання стану рослин, спроектовано архітектуру системи та виконано тестування її ефективності.

Об'єкт і предмет дослідження

Об'єктом дослідження є процеси вирощування плодкових культур у теплицях, які впливають на якість та кількість врожаю. Предметом дослідження є автоматизована система оцінки стану плодкових культур і підтримки догляду за ними з використанням методів комп'ютерного зору та аналізу даних.

Наукова новизна та практичне значення результатів

Наукова новизна роботи полягає у формуванні цілісного методологічного підходу, який інтегрує візуальну діагностику стану рослин засобами згорткових нейронних мереж із термодинамічним аналізом мікроклімату через показник VPD. Практичне значення втілене у розробленому програмному модулі, який може бути впроваджений у тепличні господарства для автоматизації контролю розвитку плодів та раннього виявлення захворювань, що знижує витрати на ручний моніторинг на 40–50%.

Контроль мікроклімату та показник VPD

VPD (Vapor Pressure Deficit) — це інтегральна величина, що визначає різницю між максимально можливим тиском пари за даної температури та її фактичним тиском у повітрі. Цей градієнт є рушійною силою транспірації — процесу, через який рослина не лише охолоджується, але й транспортує мінеральні речовини (зокрема кальцій) від коріння до плодів.

Оптимальні діапазони VPD для різних стадій росту

- Управління VPD повинно бути динамічним, оскільки потреби рослини змінюються залежно від етапу її розвитку.

Фаза розвитку	Рекомендований	Фізіологічне обґрунтування
Розсада та живцювання	0.4 – 0.8	Мінімальний стрес для нерозвиненої кореневої системи
Веgetативний ріст	0.8 – 1.2	Максимальна швидкість фотосинтезу та нарощування біомаси
Цвітіння та плодоношення	1.2 – 1.6	Баланс між наливом плодів та запобіганням грибковим хворобам
Нічний період	0.8 – 1.2	Уникнення конденсації вологи на листі

Загальна архітектура системи

Розроблена система має багаторівневу архітектуру та включає підсистему сенсорів і виконавчих механізмів, локальний рівень збору та обробки даних, а також серверний рівень аналітики.

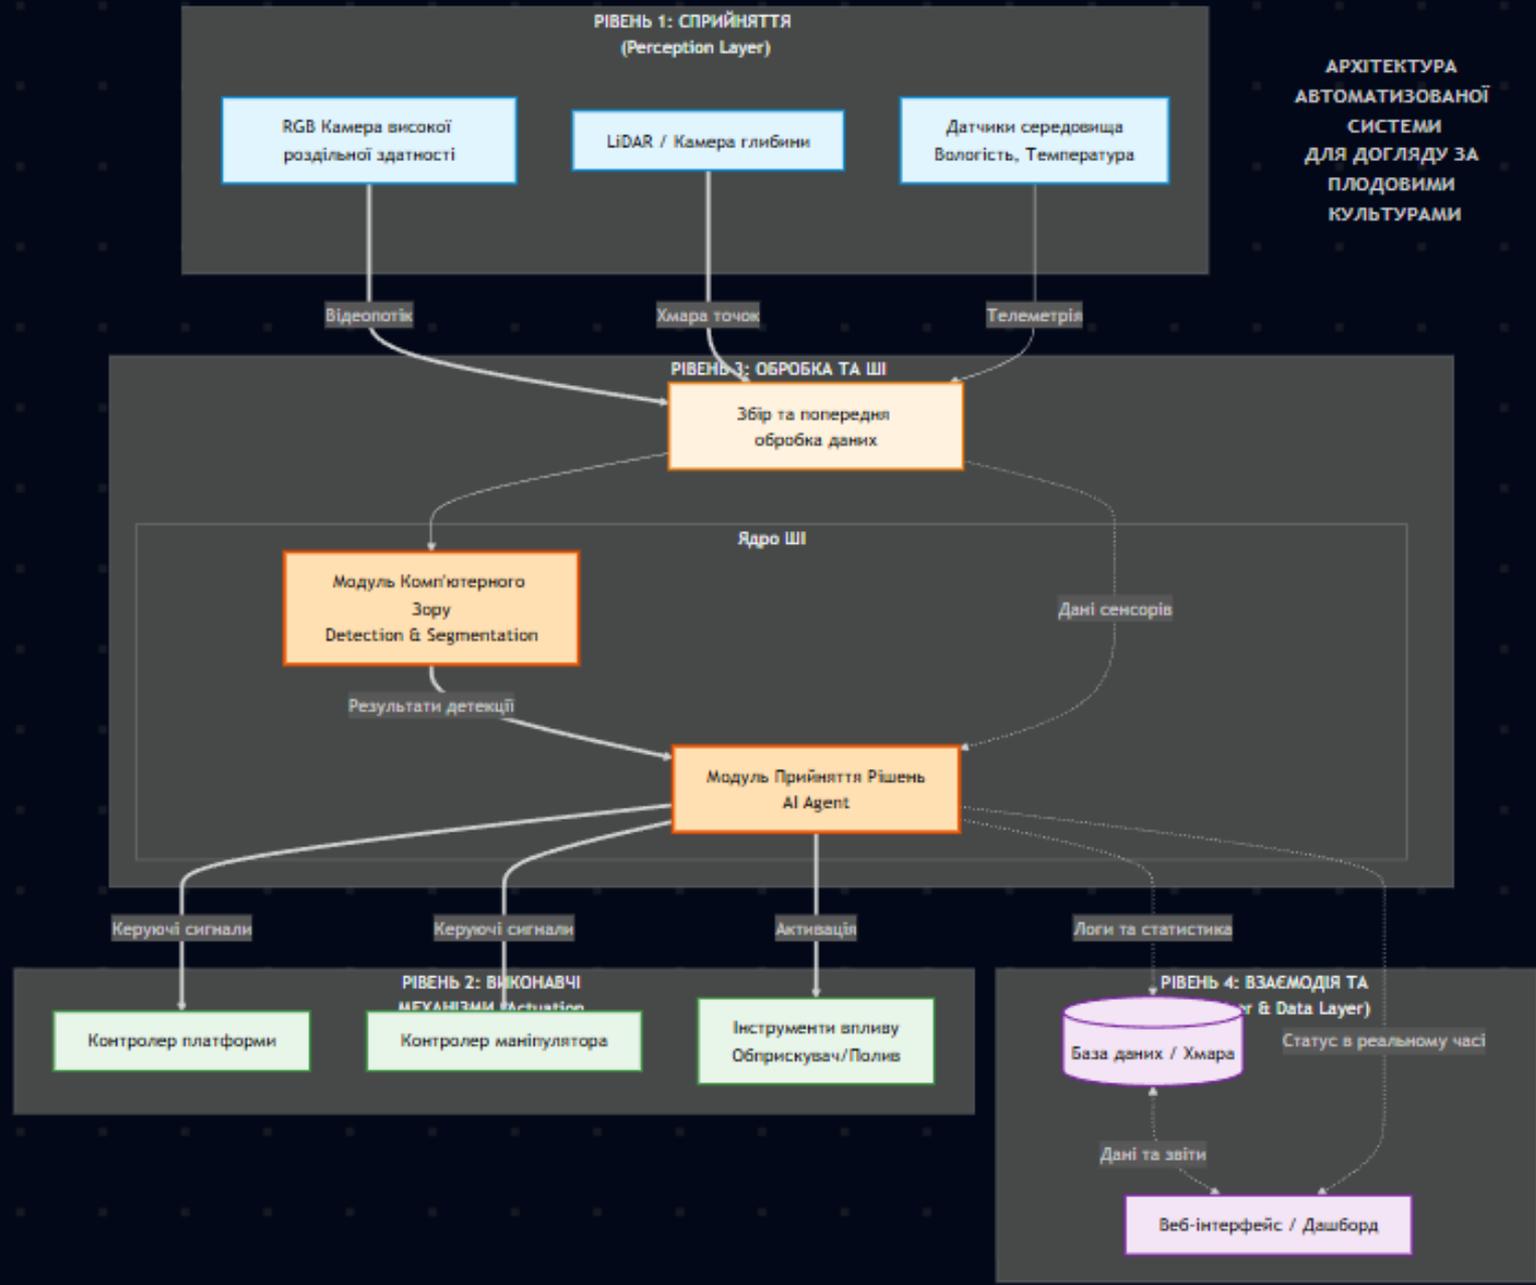
Блок-схема типової автоматизованої теплиці

- ▶ Нижній рівень (IoT): Мережа сенсорів (температура, вологість повітря та ґрунту, CO₂) та виконавчі механізми (насоси, вентилятори, клапани).
- ▶ Середній рівень (Локальне управління): Мікроконтролери (STM32/ESP32), що забезпечують первинну обробку сигналів та аварійну стійкість системи.
- ▶ Верхній рівень (AI-аналітика): Серверна інфраструктура (NVIDIA Jetson або хмарна платформа), де відбуваються складні обчислення комп'ютерного зору та предиктивне моделювання.

Підсистема сенсорів та виконавчих механізмів

- ▶ Фізична реалізація включає промислові датчики серії SHT3х для вимірювання кліматичних параметрів та ємнісні сенсори вологості ґрунту, які захищені від корозії. Виконавча частина базується на електромагнітних клапанах 24 В та частотних перетворювачах для плавного регулювання швидкості вентиляторів, що дозволяє підтримувати стабільний VPD без різких коливань.

АРХІТЕКТУРА
АВТОМАТИЗОВАНОЇ
СИСТЕМИ
ДЛЯ ДОГЛЯДУ ЗА
ПЛОДОВИМИ
КУЛЬТУРАМИ



Огляд алгоритмів прогнозування врожайності.

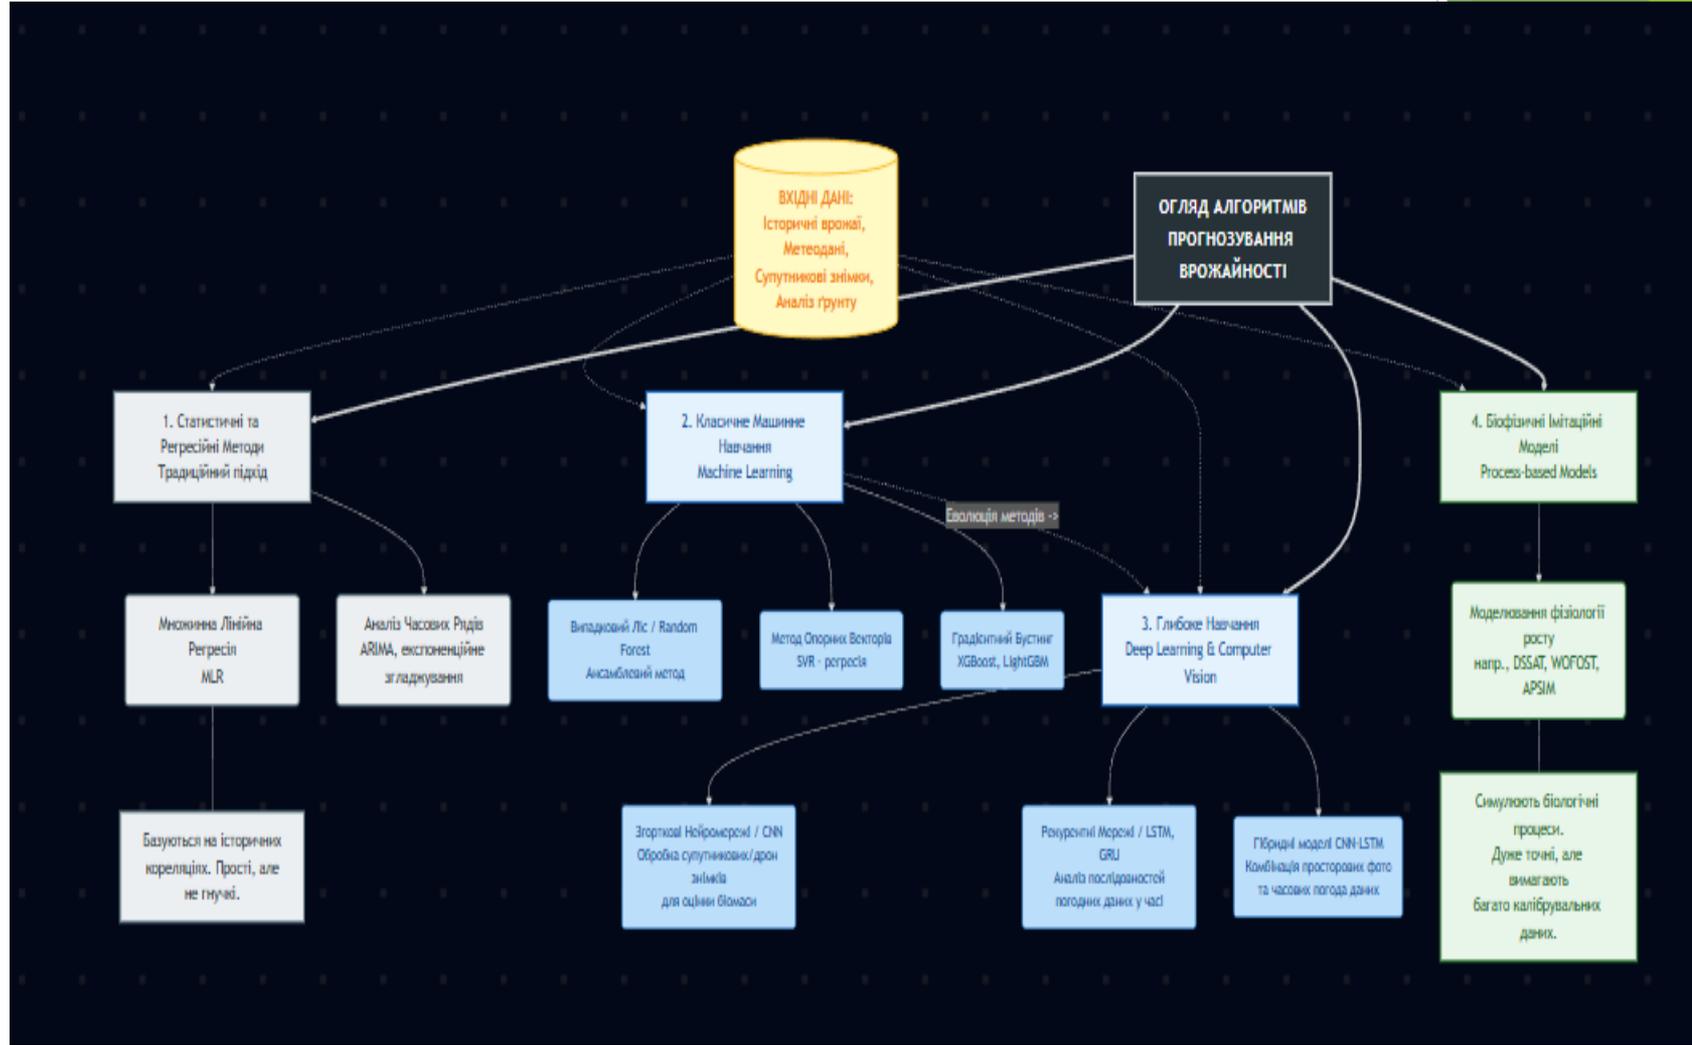
- ▶ Процес росту плодів розглядається як часовий ряд, що складається з тренду (генетичний потенціал росту), сезонності (циркадні ритми дня і ночі) та випадкового шуму (коливання освітлення). Розуміння структури цих даних дозволяє відсіювати короткострокові стресові коливання від системних проблем розвитку.

Структура часових рядів вегетації

- ▶ Процес росту плодів розглядається як часовий ряд, що складається з тренду (генетичний потенціал росту), сезонності (циркадні ритми дня і ночі) та випадкового шуму (коливання освітлення). Розуміння структури цих даних дозволяє відсіювати короткострокові стресові коливання від системних проблем розвитку.

Компоненти моделі LSTM для агропрогнозів

- ▶ Для врахування «пам'яті» системи (впливу минулих умов на майбутній ріст) застосовано рекурентну нейромережу LSTM (Long Short-Term Memory). Завдяки механізмам вентилів (забуття, входу, виходу) модель здатна зберігати інформацію про тривалі періоди посухи або температурного стресу, що сталися тиждень тому, та враховувати їх при прогнозуванні дати дозрівання.



Використання комп'ютерного зору

Комп'ютерний зір у системі використовується для аналізу зображень плодів та листя рослин. Застосування глибоких нейронних мереж дозволяє автоматично визначати стадії дозрівання плодів, виявляти ознаки захворювань та формувати рекомендації щодо подальшого догляду.

Логіка головного циклу керування (Main Loop)

- ▶ Програма працює як скінченний автомат, що проходить цикли «Збір даних → Аналіз → Рішення → Дія». Кожен цикл завершується записом стану в базу даних SQLite, що гарантує збереження історії навіть при раптовому вимкненні живлення.

Стадії дозрівання плодів

У роботі реалізовано класифікацію плодів за основними стадіями дозрівання: Green, Breaker, Turning, Pink та Red. Це дає змогу агроному своєчасно приймати рішення щодо збору врожаю та оптимізації технологічних процесів.

Результати детекції плодів стадії Green

- ▶ Зелені плоди є найбільш складними для розпізнавання через ефект візуального маскування. Завдяки Mask R-CNN та адаптивним порогам впевненості вдалося досягти точності 88% при відкритому розташуванні плодів та 91.2% при частковому затіненні листям

Ефективність ідентифікації стадії Breaker

- ▶ Завдяки впровадженню гібридного алгоритму (CNN + HSV аналіз), точність розпізнавання початку дозрівання зросла з 64% (базовий метод) до 82%. Це дозволяє агрономам виявляти готовність врожаю до збору на 2–3 дні раніше, ніж при візуальному огляді.

Діагностика захворювань листя (Severity Index)

- Система ідентифікує симптоми альтернаріозу та фітофторозу на основі аналізу текстури листя. Програмний модуль обчислює відсоток ураженої площі, що дозволяє класифікувати стадію хвороби.

Стадія ураження	Ознаки	Точність (Precision)	Повнота (Recall)
Початкова	Плями < 3 мм	76.5%	62.0%
Середня	Злиття плям, хлороз	89.0%	85.4%
Тяжка	Некроз > 20% площі	95.2%	98.0%

Програмна реалізація

Програмне забезпечення системи складається з модулів збору даних з сенсорів і камер, обробки зображень, прогнозування врожайності та формування сповіщень. Архітектура програмного коду забезпечує гнучкість і можливість подальшого розширення функціоналу.

Прогнозування врожайності

Для прогнозування врожайності у роботі використано методи аналізу часових рядів та лінійну регресію. Отримані результати дозволяють оцінювати майбутні показники врожаю та порівнювати прогнозні значення з фактичними даними.

Результати дослідження

У ході експериментального дослідження підтверджено працездатність розробленої системи. Система демонструє високу точність детекції плодів на різних стадіях дозрівання та здатність виявляти потенційні проблеми у стані рослин.

Наукова новизна та практичне значення

Наукова новизна роботи полягає в інтеграції методів комп'ютерного зору та аналізу мікрокліматичних параметрів у єдину автоматизовану систему. Практичне значення полягає у можливості впровадження розробленого рішення у тепличних господарствах для підвищення ефективності виробництва.

Апробація результатів

Результати магістерського дослідження були апробовані під час виступів на студентських наукових конференціях у Державному університеті інформаційно-комунікаційних технологій та в Житомирській політехніці. Отримані зауваження та рекомендації були враховані у подальшому доопрацюванні роботи.

Висновки

У результаті виконання магістерської роботи розроблено автоматизовану систему догляду за плодовими культурами на основі комп'ютерного зору та штучного інтелекту. Система підтвердила свою ефективність і може бути використана як основа для подальших досліджень та практичного впровадження.