

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ  
«ДНІПРОВСЬКА ПОЛІТЕХНІКА»



І.С. Лактіонов, В.В. Гнатушенко, В.Ю. Каштан, Г.Г. Дяченко

**ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ ТА  
КОМП'ЮТЕРНІ ТЕХНОЛОГІЇ ЗБОРУ ТА  
АНАЛІЗУ ДАНИХ АГРОМОНІТОРИНГУ**

Монографія

Дніпро  
2025

УДК 004.9; 631.1

I.73

*Рекомендовано Вченою радою Національного технічного університету «Дніпровська політехніка» як монографію (Протокол № 2 від 14.02.2025).*

Рецензенти:

*В.Б. Мокін*, д-р техн. наук, професор, завідувач кафедри системного аналізу та інформаційних технологій (Вінницький національний технічний університет, м. Вінниця);

*А.Л. Перекрест*, д-р техн. наук, професор, завідувач кафедри комп'ютерної інженерії та електроніки (Кременчуцький національний університет імені Михайла Остроградського, м. Кременчук);

*В.І. Корнієнко*, д-р техн. наук, професор, завідувач кафедри безпеки інформації та телекомунікацій (Національний технічний університет «Дніпровська політехніка», м. Дніпро).

Лактіонов І.С.

I.73 Інтелектуальні інформаційні та комп'ютерні технології збору та аналізу даних агромоніторингу: монографія / І.С. Лактіонов, В.В. Гнатушенко, В.Ю. Каштан, Г.Г. Дяченко; Міністерство освіти і науки України, НТУ «Дніпровська політехніка». – Дніпро: НТУ «ДП», 2025. – 235 с.

У монографії наведено результати досліджень і розробок, що присвячені вирішенню науково-прикладної проблеми розвитку теорії створення та використання інтелектуальних інформаційних і комп'ютерних технологій аграрного призначення завдяки обґрунтуванню й реалізації методів, моделей і засобів комплексного детектування, агрегування, мережевого обміну, трансформації та інтерпретації даних й інформації щодо впливу ґрунтокліматичних параметрів на ефективність вирощування сільськогосподарських культур у мінливих агрокліматичних умовах.

Монографія призначена для підготовки докторів філософії в галузях інформаційних технологій та електроніки, автоматизації й електронних комунікацій, а також буде корисною для практикуючих фахівців і наукових співробітників, які займаються проблемами розробки та використання сучасних інформаційних систем і комп'ютерних пристроїв.

УДК 004.9; 631.1

©Лактіонов І.С., Гнатушенко В.В.,  
Каштан В.Ю., Дяченко Г.Г.

©НТУ «Дніпровська політехніка», 2025

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	5
ВСТУП.....	8
РОЗДІЛ 1 СУЧАСНИЙ СТАН НАУКОВИХ ДОСЛІДЖЕНЬ І ПРАКТИЧНИХ РОЗРОБОК ІЗ ПОБУДОВИ ІНТЕЛЕКТУАЛЬНИХ ТЕХНОЛОГІЙ ДЛЯ СТАЛОГО ВИРОЩУВАННЯ СІЛЬСЬКОГОСПОДАРСЬКИХ КУЛЬТУР.....	12
1.1 Глобальні та вітчизняні тенденції сталого розвитку сільськогосподарської галузі.....	12
1.2 Технологічні засади цифровізації та інтелектуалізації сільськогосподарської галузі.....	23
1.3 Сучасні науково-прикладні досягнення з підвищення ефективності технологічних і виробничих процесів аграрної галузі....	47
1.4 Формулювання наукової проблеми та обґрунтування перспективних напрямів досліджень.....	61
1.5 Висновки до першого розділу.....	68
Список використаних джерел до першого розділу.....	70
РОЗДІЛ 2 СТРУКТУРНО-АЛГОРИТМІЧНА ОРГАНІЗАЦІЯ ТА АПАРАТНО-ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНИХ ТЕХНОЛОГІЙ АГРОТЕХНІЧНОГО ОНЛАЙН-МОНІТОРИНГУ ҐРУНТОКЛІМАТИЧНИХ ПАРАМЕТРІВ СІЛЬСЬКОГОСПОДАРСЬКИХ ВИРОБНИЦТВ.....	97
2.1 Комп'ютерно-орієнтована модель мережевої агрегації та периферійної обробки результатів моніторингу ґрунтокліматичних параметрів.....	97
2.2 Метод і комп'ютерні моделі обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування та прогнозування хвороб сільськогосподарських культур на основі алгоритмів машинного навчання.....	124

2.3	Метод і комп'ютерні моделі обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування та прогнозування хвороб сільськогосподарських культур на основі адаптивних нейро-нечітких мереж.....	140
2.4	Висновки до другого розділу.....	165
	Список використаних джерел до другого розділу.....	168
<b>РОЗДІЛ 3 ІНТЕЛЕКТУАЛЬНА ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ</b>		
<b>ОБРОБКИ ТА АНАЛІЗУ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ДЛЯ</b>		
<b>КАРТОГРАФУВАННЯ ЗЕМНОЇ ПОВЕРХНІ.....</b>		
		172
3.1	Метод попередньої обробки супутникових зображень із використанням згорткової нейронної мережі .....	172
3.2	Нейромережева сегментація для картографування земного покриву.....	183
3.3	Синергетична обробка багатоспектральних Sentinel-зображень із використанням згорткових нейронних мереж для підвищення точності виділення меж сільськогосподарських полів.....	196
3.4	Програмна реалізація інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні.....	214
3.5	Практичне застосування інформаційної технології для картографування зон затоплення земної поверхні.....	218
3.6	Висновки до третього розділу.....	221
	Список використаних джерел до третього розділу.....	223
<b>ЗАГАЛЬНІ ВИСНОВКИ.....</b>		
		232

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

AI	– штучний інтелект
AIoT	– штучний інтелект речей
ANN	– штучна нейронна мережа
ATPRK	– кернелізація регресії за площею
ATWT	– адаптивне зважене перетворення тональності
ATWT	– адитивне вейвлет-перетворення
AWLP	– адаптивне зважене лінійне прогнозування
BDS	– різниця яскравості на основі різниці насиченості
BLE	– bluetooth з низьким енергоспоживанням
BT	– перетворення Бровея
CC	– хмарні обчислення
CNN	– згорткова нейронна мережа
CS	– компонентна заміна
DL	– глибоке навчання
DM	– інтелектуальний аналіз даних
DRNN	– глибока рекурентна нейронна мережа
DSCK	– кернелізація з пониженням масштабу
EC	– граничні обчислення
ERGAS	– відносна безрозмірна глобальна похибка синтезу
ESA	– Європейське космічне агентство
FAO	– Продовольчий та сільськогосподарський комітет при ООН
FC	– туманні обчислення
FCN	– повністю зв'язана шарова мережа
FHB	– фузаріозна гниль
FNN	– нейронна мережа прямого поширення
FRNN	– швидка рекурентна нейронна мережа
FVI	– індекс вразливостей до повеней
GR	– наземні роботи
GRT	– геометричні та радіометричні перетворення

GS	– перетворення Грама-Шмідта
GSA	– адаптивне перетворення Грама-Шмідта
HPF	– високочастотна фільтрація
HSB	– модель тон–насиченість–яскравість
HSV	– модель тон–насиченість–значення
IHS	– модель інтенсивність–відтінок–насиченість
IoT	– промисловий Інтернет речей
IoT	– Інтернет речей
IT	– інформаційні технології
ITU	– Міжнародний союз електрозв’язку
IWF	– Всесвітній форум Інтернету речей
KED	– кернелізований зовнішній дрейф
KNN	– алгоритм k-найближчих сусідів
LoRa	– велика дальність
LPWAN	– енергоефективна мережа дальнього радіусу дії
LR	– лінійна регресія
LSTM	– довга короткострокова пам’ять
LTE	– довготривалий розвиток
LUT	– таблиця пошуку
MAE	– абсолютна похибка
MAPE	– середня абсолютна відсоткова похибка
MIoT	– масштабний Інтернет речей
ML	– машинне навчання
MRA	– аналіз із множинною роздільною здатністю
NCLB	– хвороба листя кукурудзи (північна)
NDVI	– нормалізований різницевий вегетаційний індекс
NIR	– ближній інфрачервоний діапазон довжин хвиль
OT	– операційні технології
OTVR	– оптичні технології у видимому діапазоні
PCA	– аналіз головних компонент
PD	– портативний пристрій

PRACS	– адаптивна заміна компонент із частковою заміною
PSNR	– пікове співвідношення сигнал/шум
R <sup>2</sup>	– коефіцієнт детермінації
RF	– випадковий ліс
RGB	– модель червоний–зелений–синій
RMSE	– середньоквадратична похибка
SCLB	– хвороба листя кукурудзи (південна)
SFIM	– фільтрація на основі модуляції інтенсивності
SGD-BP	– стохастичний градієнтний спуск зі зворотним поширенням
SM	– супутниковий моніторинг
SSIM	– коефіцієнт структурної схожості зображень
SVM	– метод опорних векторів
SWIR	– короткохвильовий інфрачервоний діапазон довжин хвиль
TIN	– триангулярна нерегулярна мережа
UAV	– безпілотний літальний апарат
WoT	– мережа речей
WSN	– бездротова мережа сенсорів
XAI	– пояснювальний штучний інтелект
БГД	– база геоданих
БЗ	– багатоканальне зображення
ГЕС	– гідроелектростанція
ГІС	– географічна інформаційна система
ДЗЗ	– дистанційне зондування Землі
ЗКЗ	– зона катастрофічного затоплення
ІККТ	– інфокомунікаційні та комп'ютерні технології
ПЗ	– панхроматичне зображення
с.к.в.	– середнє квадратичне відхилення
с/г	– сільське господарство
СУБД	– система управління базами даних

## ВСТУП

На сьогоднішній день у світовому та національному масштабах спостерігається негативна динаміка земельних ресурсів, які придатні для вирощування сільськогосподарських (с/г) культур. Цей факт обумовлено рядом факторів різного характеру, основними з яких є: урбанізація та індустріалізація територій; забруднення, деградація та виснаження ґрунтів; зміна клімату та погіршення екологічної ситуації; занепад зрошувальних систем та інше. На національному рівні все це негативним чином впливає на ефективність аграрного сектору під час формування національної економіки України, її продовольчу безпеку, експортний потенціал, а також інвестиційну привабливість с/г підприємств рослинництва у середньо- та довгостроковій перспективі. Отже, актуалізуються питання раціонального використання площ і ресурсів, а також підвищення питомої врожайності сільськогосподарських культур, що є можливим за рахунок ефективного і своєчасного планування та реалізації агротехнічних заходів протягом повного циклу їх вирощування в польових умовах.

У теперішній час інтелектуальні інформаційні та комп'ютерні технології, зокрема ті, що базуються на бездротових сенсорних мережах наземного моніторингу та засобах дистанційного (супутникового) зондування, а також методах штучного інтелекту й машинного навчання, є дієвим інструментом під час обґрунтування та реалізації шляхів вирішення проблем, що пов'язані з плануванням агротехнічних заходів під час повного циклу вирощування сільськогосподарських культур.

Науково-прикладна проблема, на вирішення якої спрямовано дослідження і розробки, які наведено в цій монографії, полягає в розвитку теорії створення, удосконалення й використання інтелектуальних інформаційних і комп'ютерних технологій аграрного призначення.

Об'єктом дослідження є нестационарні процеси агрегації, мережевого обміну та інтелектуалізованої інтерпретації розподілених вимірювальних даних

щодо ґрунтокліматичного стану сільськогосподарських підприємств рослинництва відкритого ґрунту.

Предметом дослідження є методи, комп'ютерні моделі та засоби інтелектуалізованого моніторингу ґрунтокліматичного стану агротехнічних об'єктів галузі рослинництва відкритого ґрунту.

Під час досліджень, результати яких викладено в цій монографії, використано підхід, що ґрунтується на комплексному вирішенні проблеми створення і практичного використання прикладних інтелектуалізованих інформаційних і комп'ютерних технологій. В процесі розробки відповідного програмно-апаратного забезпечення враховано сьогоденні досягнення в галузях Інтернету речей, Індустрії 4.0, супутникового моніторингу, штучного інтелекту та машинного навчання. Розроблені програмно-апаратні компоненти передбачають архітектурну інтеграцію запропонованих методів і засобів побудови фізичного, мережевого і програмно-обчислювального рівнів до єдиної інформаційної технології. Ключовою відмінністю від відомих на сьогоднішній день технологій є те, що не передбачається принципова зміна архітектури використовуваних на сьогоднішній день апаратних засобів моніторингу (супутниковий і бездротовий наземний). Дослідження цієї монографії спрямовано на розширення їх функціональних можливостей шляхом впровадження багатоетапного і мультизонального інтелектуального моніторингу з подальшою предикативною програмною трансформацією даних задля підвищення достовірності, прецизійності та оперативності під час автоматизованої підтримки прийняття рішень із забезпечення раціонального використання площ і ресурсів та, як наслідок, підвищення ефективності с/г підприємств рослинництва відкритого ґрунту.

Основний матеріал монографії представлено у вигляді вступу, трьох змістовних розділів та загальних висновків. Після кожного розділу подано відповідні висновки, що лаконічно відображають отримані кількісні та якісні результати в систематизованому вигляді, а також відповідний перелік посилань на використані джерела інформації.

Перший розділ монографії присвячено комплексному аналізу сучасного стану наукових досліджень і практичних розробок із побудови інтелектуальних технологій для сталого вирощування сільськогосподарських культур. Основними результатами цього розділу є: огляд і систематизація глобальних і вітчизняних тенденцій сталого розвитку сільськогосподарської галузі; критичний аналіз і узагальнення технологічних засад цифровізації та інтелектуалізації сільськогосподарської галузі; обґрунтування сучасних науково-прикладних досягнень із підвищення ефективності технологічних і виробничих процесів аграрної галузі; формулювання наукової проблеми, що склалась на теперішній час у сфері цифровізації та інтелектуалізації аграрних підприємств; обґрунтування перспективних напрямів досліджень.

У другому розділі наведено результати щодо досліджень і розробки структурно-алгоритмічної організації та апаратно-програмних компонент інтелектуальних наземних технологій агротехнічного онлайн-моніторингу ґрунтокліматичних параметрів с/г виробництв. Основними результатами цього розділу є: розроблена та протестована комп'ютерно-орієнтована модель мережевої агрегації та периферійної обробки результатів моніторингу ґрунтокліматичних параметрів; розроблені та валідовані метод і комп'ютерні моделі обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування й прогнозування хвороб с/г культур на основі алгоритмів машинного навчання та адаптивних нейро-нечітких мереж.

Третій розділ присвячено розробці інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні. Основними результатами цього розділу є: запропонований метод попередньої синергетичної обробки супутникових зображень із використанням згорткової нейронної мережі; нейромережева сегментація для картографування земного покриття (сільськогосподарські культури, дерева, будівлі та дороги); розроблені та протестовані програмні компоненти інформаційної технології інтелектуальної обробки та аналізу супутникових зображень для картографування земної поверхні.

Кількісні та якісні результати розробок, які наведено в монографії, отримано на основі експериментальних і теоретичних досліджень, що були взаємно доповнюваними й уточнюваними. Під час проведення експериментальних досліджень використано розроблені авторами лабораторні зразки функціональних вузлів інформаційної технології та сертифіковане контрольнo-вимірjувальне обладнання, а також спеціалізовані пакети прикладних програм для розробки і тестування програмних компонент і комп'ютерних моделей досліджуваних інформаційних і комп'ютерно-орієнтованих технологій. Під час теоретичних досліджень використано основні положення теорії математичного, структурного й інформаційного моделювання.

Внесок авторів під час написання монографії є таким:

- вступ і загальні висновки: всі автори;
- розділи 1, 2: Лактіонов І.С., Дяченко Г.Г.;
- розділ 3: Гнатушенко В.В., Каштан В.Ю.

Монографія є логічним узагальненням результатів досліджень колективу науковців НТУ «Дніпровська політехніка», які отримано під час виконання ряду науково-дослідних робіт і проєктів, зокрема, прикладної науково-дослідної роботи (0124U000289). Таким чином, вона призначена для підготовки докторів філософії в галузях інформаційних технологій та електроніки, автоматизації й електронних комунікацій, а також буде корисною для практикуючих фахівців і наукових співробітників, які займаються проблемами розробки та використання сучасних інформаційних систем і комп'ютерних пристроїв.

Автори висловлюють вдячність рецензентам д.т.н., проф. Мокіну В.Б., д.т.н., проф. Перекресту А.Л. та д.т.н., проф. Корнієнку В.І. за детальний розгляд рукопису, цінні коментарі, рекомендації та побажання щодо поліпшення змістовного наповнення, які були враховані під час доопрацювання й сприяли поліпшенню монографії.

# РОЗДІЛ 1

## СУЧАСНИЙ СТАН НАУКОВИХ ДОСЛІДЖЕНЬ І ПРАКТИЧНИХ РОЗРОБОК ІЗ ПОБУДОВИ ІНТЕЛЕКТУАЛЬНИХ ТЕХНОЛОГІЙ ДЛЯ СТАЛОГО ВИРОЩУВАННЯ СІЛЬСЬКОГОСПОДАРСЬКИХ КУЛЬТУР

### 1.1 Глобальні та вітчизняні тенденції сталого розвитку сільськогосподарської галузі

На сьогоднішній день у розрізі глобальних світових тенденцій науково-технічного розвитку сільське господарство стає дедалі більш наукомісткою галуззю, що відіграє важливу роль під час формування національних економік багатьох країн світу, зокрема й України. Сільське господарство на сучасному етапі розвитку стикається з багатьма проблемами, зокрема з тими, що пов'язані з негативною динамікою клімату, значною динамікою цін на посівний матеріал, добрива і матеріально-технічні ресурси, що забезпечують виконання агротехнічних заходів під час посівів, вирощування і збору врожаю, а також нестабільністю ланцюгів постачання та ринків збуту с/г продукції. Перед агрономами і фермерами постають певні виклики, які пов'язані з необхідністю приймати оперативні й комплексні рішення щодо планування й реалізації агротехнічних заходів зі забезпечення високих показників обсягів, темпів і якості вирощуваної с/г продукції під час повного циклу вирощування. Таким чином, практикуючі фахівці в галузі рослинництва повинні мати оперативний і надійний доступ до об'єктивної інформації, яка отримана на підставі автоматизованого збору й обробки значних масивів розосереджених даних, що всеосяжно характеризують технологічні процеси виробництва та реалізації с/г продукції [1], [2].

Цифровізація та інтелектуалізація виробничих і технологічних процесів с/г підприємств сприяє динамічному розвитку економічних, екологічних і соціальних аспектів стійкого розвитку глобального сільського господарства,

водночас стимулюючи позитивну динаміку інвестиційної привабливості та продовольчої безпеки відповідних країн. Інтеграція інфокомунікаційних і комп'ютерних технологій (ІККТ) до сільськогосподарської галузі є актуальним трендом розвитку на світовому [3] та національному рівнях [4], адже такий підхід є важливими і дієвим фактором під час досягнення глобальних цілей сталого розвитку.

Виходячи з цього на підставі логічного узагальнення та інформаційного аналізу предметної галузі провідними світовими організаціями FAO (продовольчий та сільськогосподарський комітет при ООН) та ITU (Міжнародний союз електров'язку) було обґрунтовано структурну схему, що визначає роль сучасних інфокомунікаційних та комп'ютерних технологій (ІККТ) у сталому розвитку сільського господарства, як показано на рисунку 1.1.

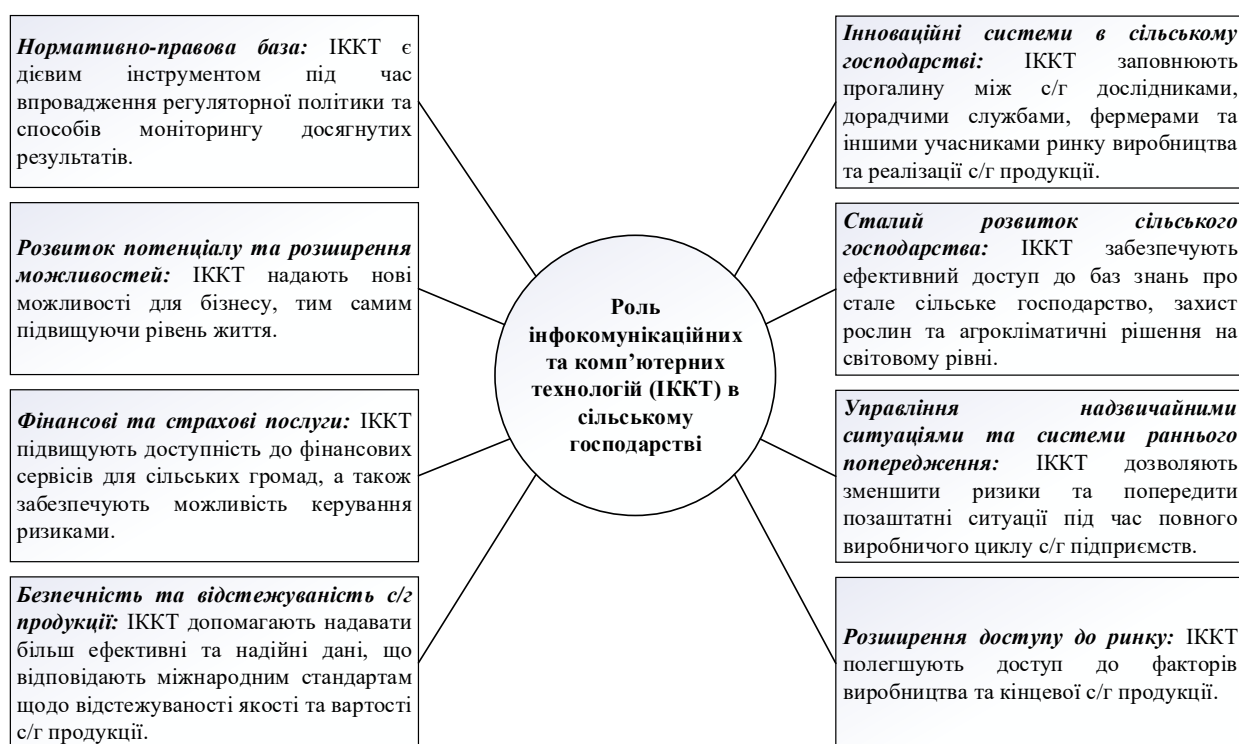


Рисунок 1.1 – Структурна схема ролі сучасних ІККТ у сталому розвитку сільського господарства за версією FAO та ITU [1]

Основною метою розробки та впровадження вискоєфективних ІККТ під час цифровізації та інтелектуалізації сільського господарства є стимулювання

розвитку аграрної галузі та сільських територій за рахунок модернізації програмно-технічної бази комплексного моніторингу й керування технологічними і виробничими процесами с/г підприємств. Концепція цифрового сільського господарства охоплює питання проектування, створення та впровадження інноваційних підходів під час використання ІККТ у сільськогосподарській практиці. В свою чергу, реалізація стратегії розвитку цифрового сільського господарства може забезпечити критично важливу підтримку для нормування ресурсів (фінансових, матеріальних і людських) з метою оптимізованого використання можливостей ІККТ с/г призначення для підприємств різних масштабів і форм власності.

На сьогоднішній день прикладні ІККТ є високоефективним інструментом моніторингу, контролю і діагностування поточного і прогнозованого стану агротехнічних процесів. Впровадження сучасних ІККТ до виробничих процесів сільськогосподарських підприємств рослинництва дозволяє значно підвищити їх ефективність завдяки онлайн моніторингу сукупності фізико-хімічних параметрів ґрунтокліматичних умов вирощування з подальшою автоматизованою підтримкою прийняття рішень на основі глибинного інтелектуального програмного аналізу вимірювальних даних.

Варто зазначити, що ІККТ агротехнічного призначення є розвиненими та високоефективними програмно-технічними системами, що базуються на різних підходах, методах і засобах детектування, збору, мережевого обміну та трансформації вимірювальних даних. Із обліком сталої динаміки площ для вирощування сільськогосподарських культур, а також обсягів вирощування, значної актуальності набувають питання, що пов'язані з удосконаленням існуючого та розробкою принципового нового програмно-апаратного забезпечення розподіленого ґрунтокліматичного моніторингу, що інтегруються в інфокомунікаційні мережі агротехнічного призначення.

Актуальність розробки, дослідження та впровадження прикладних ІККТ агротехнічного призначення підтверджується масштабністю світового рослинництва у розрізі задіяних площ, типів і обсягів вирощуваних культур, як

це показано на рисунках 1.2–1.4. Статистичні дані, які наведено на рисунках 1.2–1.4, отримано шляхом аналізу інформаційно-аналітичних ресурсів [5], [6], що узагальнені FAO з 2013 по 2022 рр. (дата останньої актуалізації даних).




Рисунок 1.2 – Динаміка оброблюваних сільськогосподарських площ у світі



Рисунок 1.3 – Динаміка врожайності у світі




Рисунок 1.4 – Динаміка питомої врожайності у світі

Шляхом аналізу статистичних даних (рис. 1.2–1.4) встановлено наступне:

– оброблювані площі, які задіяні в сільському господарстві в усьому світі постійно зростають: абсолютний приріст за останні 10 років становить 110 млн га, що у відносних одиницях складає +7,1 %;

– абсолютний (рис. 1.3) та питомий (рис. 1.4) приріст врожайності не носить сталого позитивного характеру та змінюється в діапазоні від 9388,6 млн т (6,07 т/га) у 2013 р. до 6823,5 млн т (4,12 т/га) у 2022 р. за умови збільшення оброблюваних с/г площ, що підтверджує факт значного впливу сукупності дестабілізуючих факторів різної природи (кліматичні, шкідники, своєчасність і адекватність агротехнічних заходів, соціально-економічні аспекти та інше) на обсяги вирощування різних типів с/г культур.

Зазначені вище статистичні дані та встановлені проміжні висновки доводять актуальність розробки підходів, методів і програмно-технічних засобів, які орієнтовано на оптимізацію агротехнічних процедур шляхом підвищення стресостійкості польових культур за рахунок автоматизованого збору та інтелектуалізованого аналізу даних щодо ґрунтокліматичного стану с/г

об'єктів рослинництва під час повного циклу вирощування.

Особливої уваги в розрізі зазначеної прикладної проблеми заслуговує аналіз аналогічних до світових статистичних даних, які спостерігаються для с/г галузі рослинництва відкритого ґрунту в Україні. Такий аналіз дозволить оцінити негативний вплив бойових дій на території України шляхом порівняльного аналізу результатів с/г діяльності в період до широкомасштабних військових дій і під час повномасштабних військових дій в Україні.

Також локалізований аналіз сільськогосподарських показників доповнено статистикою вирощування в розрізі найбільш популярних і рентабельних с/г культур (пшениця, кукурудза та соняшник) [7], [8] для агрокліматичних умов України [6]. Результати статистичного аналізу загальних показників с/г діяльності в Україні за період із 2013 р. по 2022 р. наведено на рисунках 1.5–1.7, а локалізовані показники за відповідними с/г культурами – на рисунках 1.8–1.10.




Рисунок 1.5 – Динаміка оброблюваних сільськогосподарських площ в Україні




Рисунок 1.6 – Динаміка врожайності в Україні




Рисунок 1.7 – Динаміка питомої врожайності в Україні

Також на рисунку 1.11 представлено відносні осереднені показники с/г діяльності щодо вирощування пшениці, кукурудзи та соняшника в загальних

обсягах с/г діяльності в Україні за зазначений вище період, що доводить популярність і рентабельність даних с/г культур під час вирощування в агрокліматичних умовах в Україні.

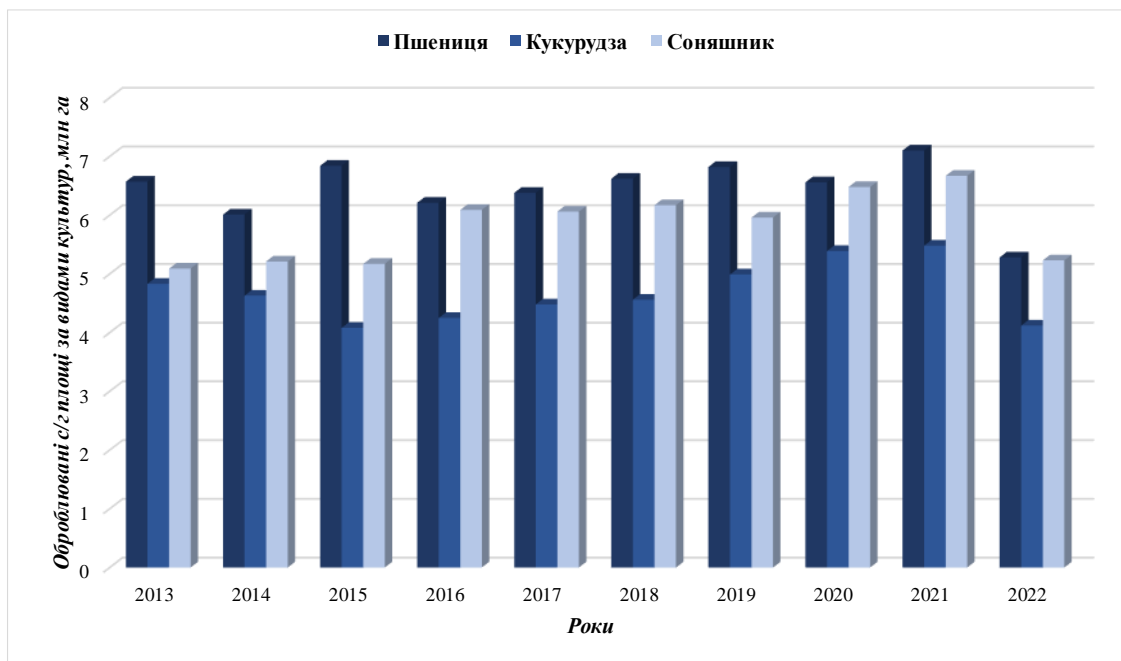


Рисунок 1.8 – Динаміка оброблюваних сільськогосподарських площ в Україні за видами сільськогосподарських культур

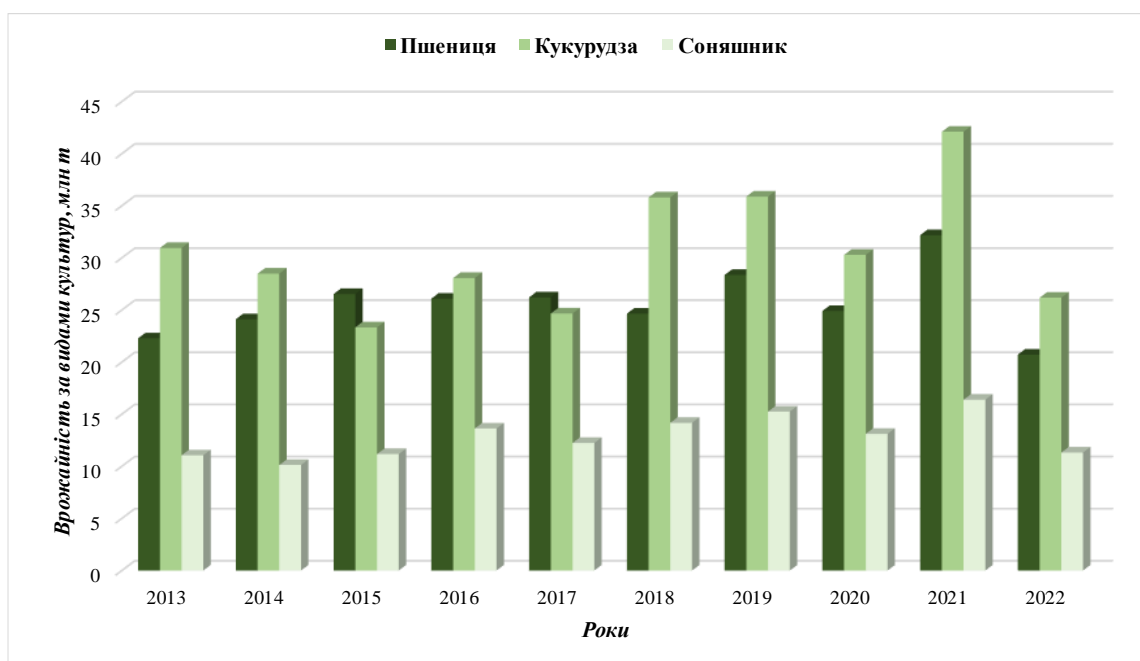


Рисунок 1.9 – Динаміка врожайності в Україні за видами сільськогосподарських культур

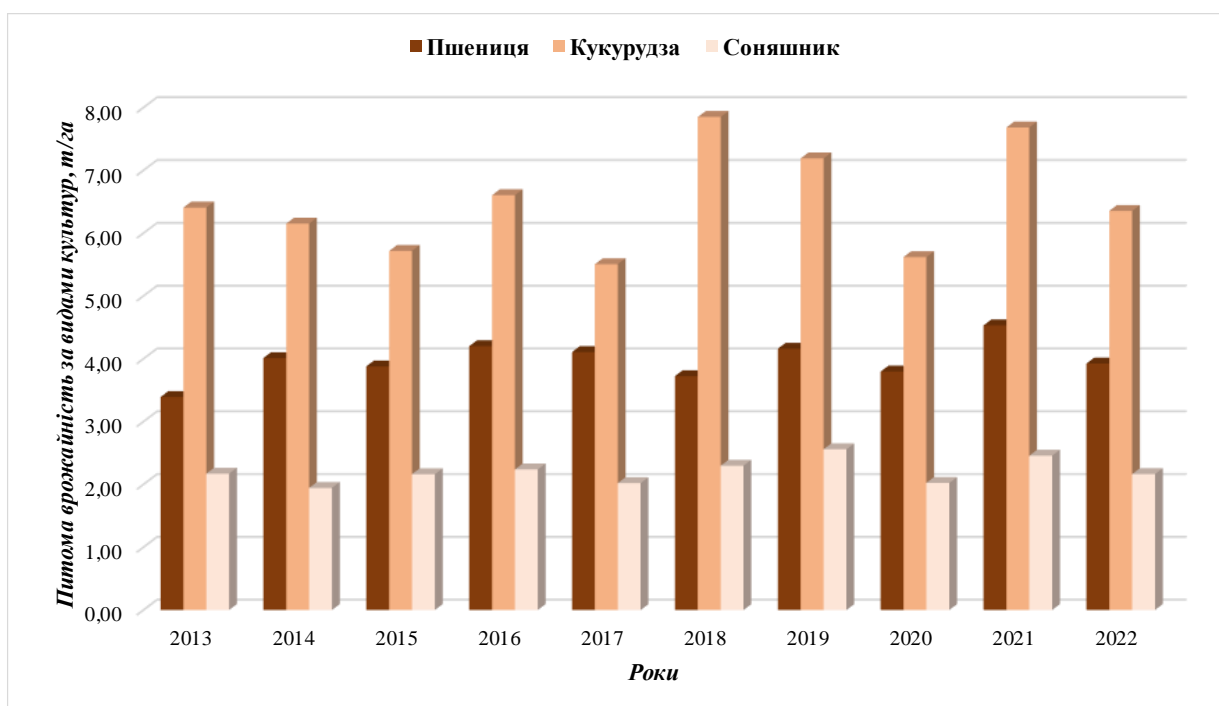

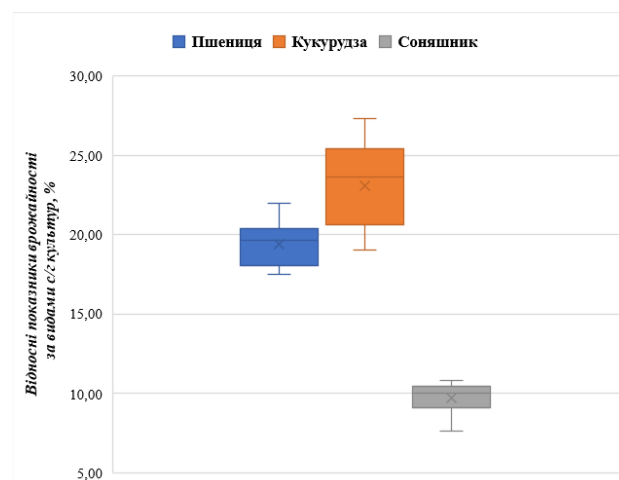


Рисунок 1.10 – Динаміка питомої врожайності в Україні за видами сільськогосподарських культур



а) оброблювані площі



б) врожайність

Рисунок 1.11 – Осереднені відносні показники провадження сільськогосподарської діяльності рослинництва відкритого ґрунту за видами вирощуваних культур за період 2013 – 2022 рр.

На підставі інформаційного аналізу статистичних даних, які наведено на рисунках 1.5 – 1.11, зроблено такі проміжні висновки:

– у період до широкомасштабних військових дій в Україні (2013 –

2021 рр.) тренди динаміки основних показників провадження с/г діяльності рослинництва відкритого ґрунту (оброблювані с/г площі та врожайність с/г культур) в Україні корелюють із загальносвітовими показниками. Середні відносні значення внеску за цими показниками для с/г діяльності України в загальносвітові масштаби становлять, відповідно: за показником оброблюваних с/г площ – 1,59 % та за показником врожайності – 1,63 %. Цей факт підтверджує важливість виробництва вітчизняної с/г продукції рослинництва під час забезпечення глобальної продовольчої безпеки, а також актуальність інтеграції сучасних світових стратегій цифровізації та інтелектуалізації с/г галузі до умов провадження с/г діяльності рослинництва відкритого ґрунту в Україні;

– під час широкомасштабних військових дій в Україні (2022 р.) показник оброблюваних с/г площ у загальносвітовому масштабі залишився майже без змін у порівнянні з 2021 р. (збільшився на 0,2 %), а в Україні аналогічний показник зменшився на 20,2 %. Показник врожайності с/г культур у загальносвітовому масштабі у 2022 р. зменшився на 13,7 % у порівнянні з 2021 р., а в Україні аналогічний показник зменшився на 26,8 %. Ці факти свідчать про значний негативний вплив військових дій на провадження с/г діяльності в Україні. Під час аналізу показників питомої врожайності було встановлено, що в загальносвітовому масштабі спостерігалось відносне зменшення на 13,8 %, а в масштабах України – зменшення на 8,1 %. Цей факт свідчить про кореляцію проблем щодо використовуваних технологій під час провадження рослинництва відкритого ґрунту в Україні зі загальносвітовими;

– з обліком негативної динаміки оброблюваних с/г площ та стратегічною значущістю вирощування зернових культур (пшениця: 25,2 % – від загально використовуваних с/г площ і 19,4 % – від загальних обсягів врожаю; кукурудза: 18,3 % – від загально використовуваних с/г площ і 23,1 % – від загальних обсягів врожаю; соняшник: 22,7 % – від загально використовуваних с/г площ і 9,7 % – від загальних обсягів врожаю) під час забезпечення національної продовольчої безпеки та конкурентоспроможного експортного потенціалу

України значно актуалізуються питання впровадження науково обґрунтованих підходів до раціонального використання земельних ресурсів с/г призначення, у тому числі тих, що постраждали внаслідок бойових дій, а також збереження врожаю протягом повного циклу вирощування с/г культур, що є можливим, у тому числі завдяки дослідженню та розробці з подальшим упровадженням інноваційних програмно-апаратних рішень інтелектуальних технологій комплексного моніторингу ґрунтокліматичного стану с/г виробництв із автоматизованою підтримкою прийняття рішень у режимі реального часу.

У теперішній час під час вирощування різних типів с/г культур у різних агрокліматичних зонах використовується широкий спектр цифрових та інформаційних технологій різного цільового призначення. На сьогоднішній день більшість із використовуваних технологій є інтелектуалізованими за рахунок інтеграції до них функціональних компонент, що базуються на методах і засобах машинного навчання та штучного інтелекту. З урахуванням значного теоретико-прикладного доробку в галузі інтелектуальних систем агротехнічного призначення, варто зазначити, що теорія розробки і використання інтелектуальних інформаційних технологій підтримки прийняття рішень щодо оптимізації й адаптації використання земельних ресурсів та формування превентивних агротехнічних заходів збереження врожаю с/г культур знаходиться в стадії активного розвитку й формування, що підтверджується результатами аналізу глобальних тенденцій цифровізації та інтелектуалізації сільськогосподарської галузі, які наведені в цьому підрозділі, а також узагальненням світових і вітчизняних наукових джерел [1]–[6], [9].

На підставі зазначеного вище можна стверджувати, що основний очікуваний соціально-економічний ефект досліджень цієї монографії полягає в підвищенні показників раціонального використання задіяних площ і ресурсів під час повного циклу вирощування с/г культур, що так само позитивно впливає на експортний потенціал, інвестиційну привабливість та продовольчу безпеку України.

## 1.2 Технологічні засади цифровізації та інтелектуалізації сільськогосподарської галузі

Сталий розвиток засад цифровізації та інтелектуалізації є одним із трендів, що стимулюють процеси раціонального використання ресурсів під час виробництва с/г продукції, а також забезпечення високих показників її якості та обсягів із обліком екологічних, економічних і соціальних аспектів [10]. Як зазначалось у попередньому підрозділі, на сучасному етапі розвитку сільське господарство є прикладною галуззю, до виробничих умов якої активно впроваджуються новітні досягнення в галузі комп'ютерних та інформаційних технологій, що обумовлює сукупність актуальних завдань із точки зору комплексного обліку технологічних засад цифровізації та інтелектуалізації с/г галузі, як показано на рисунку 1.12 [10]–[13].

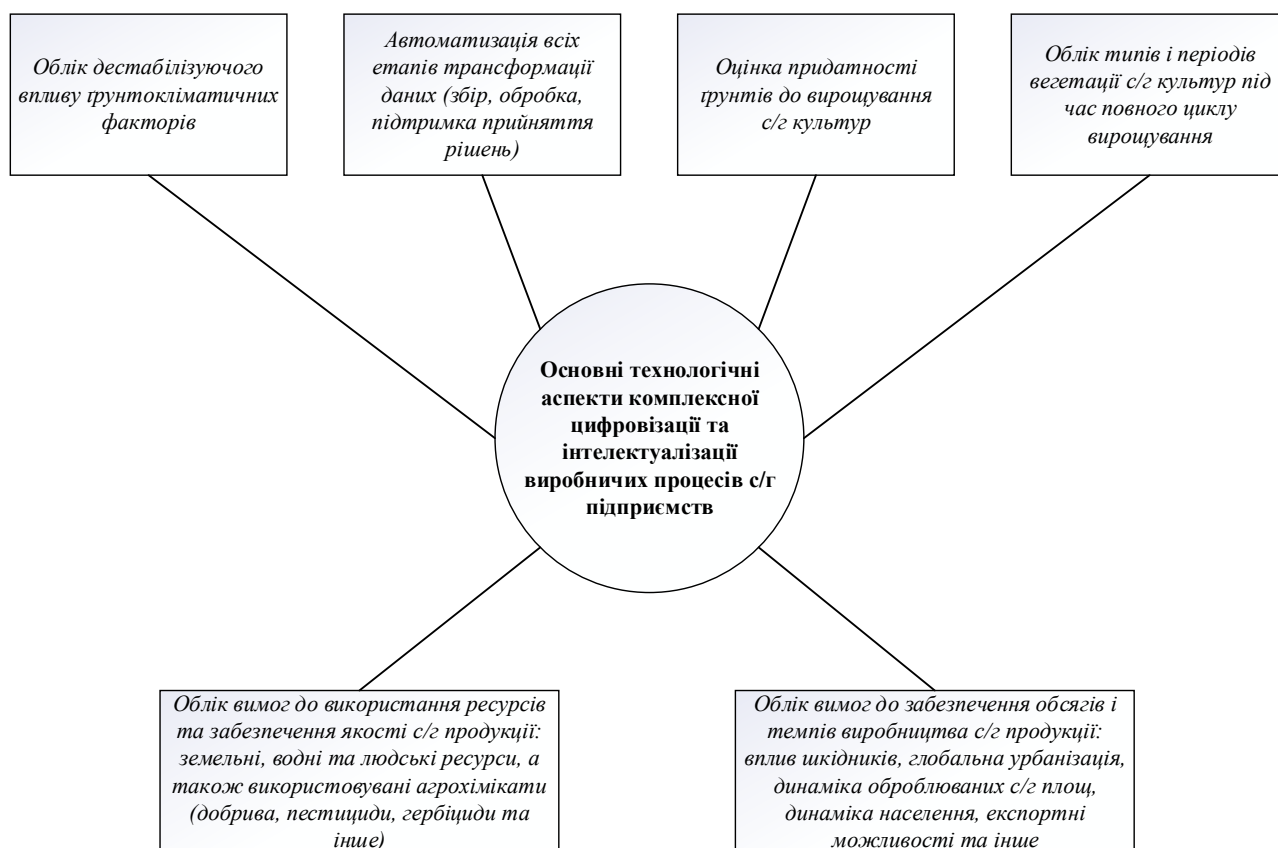


Рисунок 1.12 – Ключові фактори технологічної модернізації виробничих процесів сільськогосподарської галузі рослинництва

У сьогоденній практиці прийнято розглядати с/г виробництва рослинництва відкритого ґрунту як неоднорідні й динамічні об'єкти з точки зору впливу характеристик ґрунту, клімату, типів вирощуваних с/г культур, вірогідності виникнення різних видів хвороб у рослин та інше [14].

Технологічна реалізація засад цифровізації та інтелектуалізації сільського господарства дозволяє приймати оперативні рішення щодо оптимізованих агротехнічних процедур з обліком аспектів часової та просторової мінливості ґрунтокліматичних характеристик оброблюваних с/г площ, що так само стимулює підвищення якості та продуктивності виробництва с/г продукції рослинництва та позитивно впливає на навколишнє середовище.

Цифрові, інформаційні та комп'ютерно-інтегровані технології, використання яких передбачено концептуальними засадами «Agriculture 4.0», «Digital Agriculture», «Precision Farming» та «Organic Farming», здатні забезпечити адаптацію та оптимізацію процесів вирощування в умовах відкритого ґрунту шляхом оптимізації та адаптації внесення добрив, планування посівів, режимів зрошення ґрунту залежно від конкретних типів с/г культур у конкретні періоди вегетації на локалізованих ділянках полів у конкретних кліматичних умовах. Такий підхід провадження с/г діяльності рослинництва відкритого ґрунту з використанням сучасних цифрових та інтелектуальних технологій може бути описаний функціональною схемою, як показано на рисунку 1.13.

На сьогоднішній день концептуальні засади стратегії сталого розвитку сільськогосподарської галузі «Agriculture 4.0» та дотичних із нею передбачають виконання всіх етапів ведення агротехнічної діяльності на основі масштабного збору та інтелектуалізованого аналізу потоків розподілених у часі й просторі вимірювальних даних у режимі реального часу з автоматизованою підтримкою прийняттям рішень, що генеруються програмно-апаратними засобами інформаційних технологій [15], [16], як у графічному вигляді показано на рисунку 1.13.

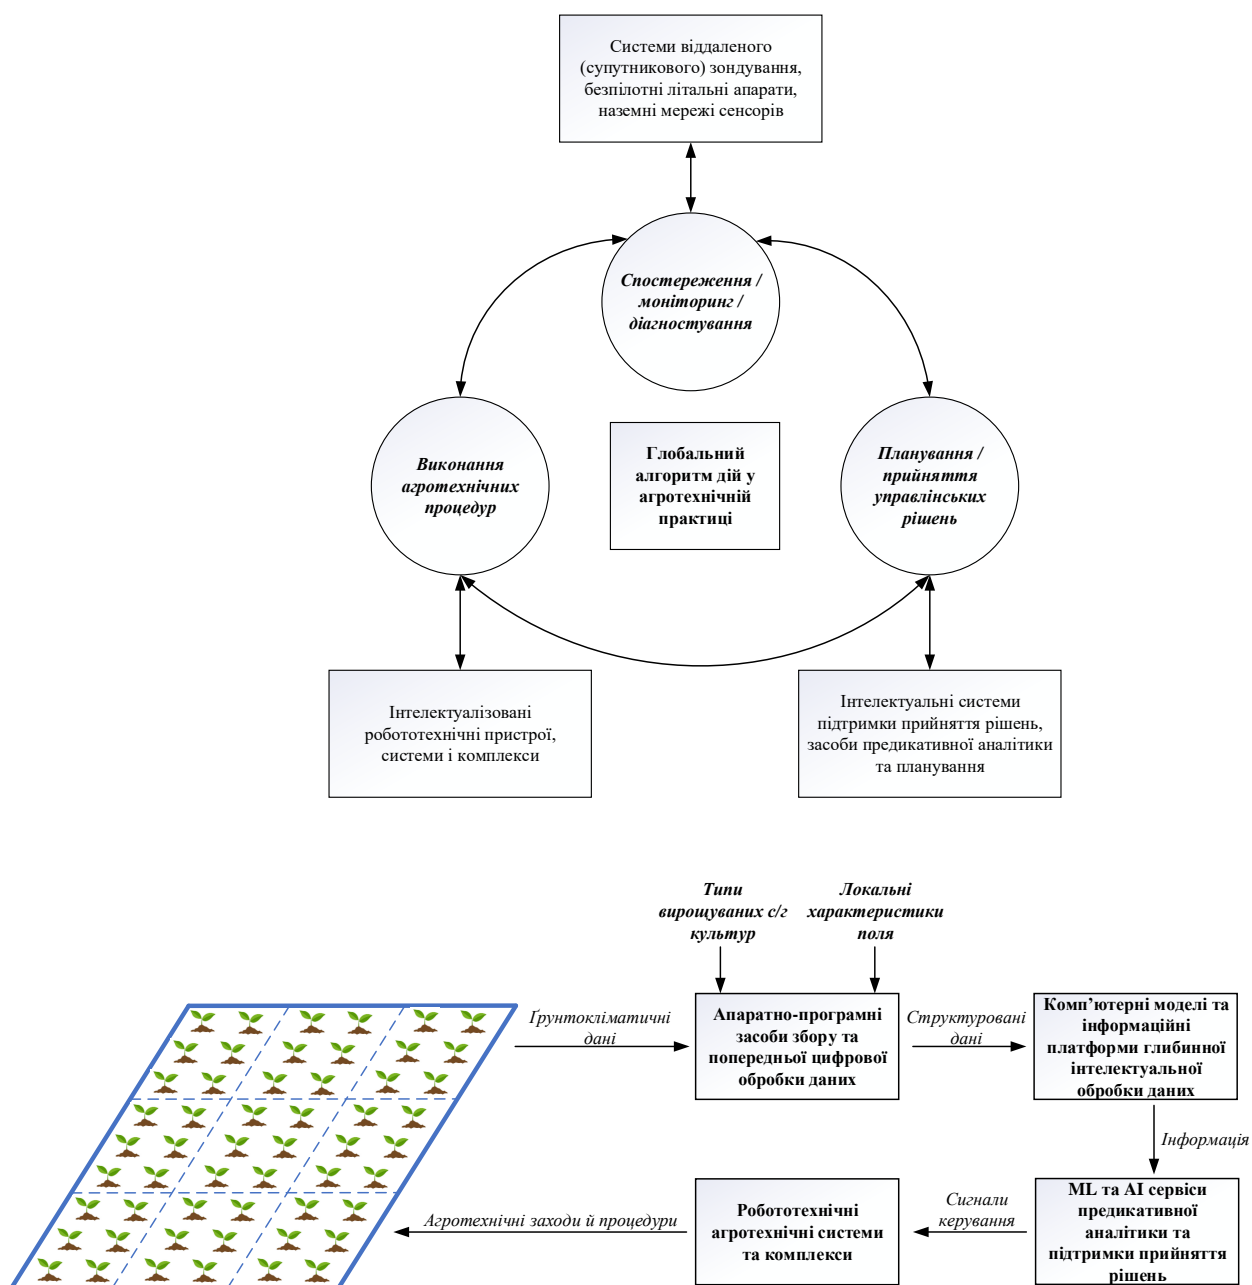


Рисунок 1.13 – Узагальнена функціональна схема інформаційно-орієнтованого підходу до провадження сільськогосподарської діяльності рослинництва відкритого ґрунту

Визначений підхід до цифровізації сільськогосподарської галузі на основі інформаційно-орієнтованого підходу (рис. 1.13) передбачає комплексну інтеграцію сучасних інфокомунікаційних, сенсорних, роботизованих, обчислювальних і програмних технологій в рамках єдиної архітектури програмно-апаратного комплексу. До сучасних інтелектуальних і цифрових

технологій, використання яких спроможне забезпечити таку архітектурну інтеграцію, відносяться: супутникове зондування, Інтернет речей, машинне навчання (ML) та штучний інтелект (AI), аграрні роботи та безпілотні літальні апарати, інфокомунікаційні технології бездротового обміну даними та інше.

Надалі в цьому підрозділі наведена узагальнена характеристика сучасних технологій, які на сьогоднішній день є використовуваними та характеризуються значними подальшими перспективами під час сталої цифровізації та інтелектуалізації с/г галузі рослинництва відкритого ґрунту в світовій практиці.

**Супутниковий моніторинг.** Використання технологій дистанційного зондування в сільському господарстві дозволяє подолати виклики, що пов'язані з отриманням масштабних даних про стан посівів протягом всього сезону, як наприклад: ідентифікація оптимальних сортів с/г культур для відповідних агрокліматичних умов, прогнозування обсягів виробництва с/г продукції, моніторинг показників землекористування й використання водних ресурсів та інше. Надалі наведено систематизовану інформацію щодо основних напрямів застосування технологій супутникового моніторингу с/г призначення (рис. 1.14), яку отримано на підставі аналізу актуального світового науково-практичного досвіду з обліком можливості їх адаптації та впровадження до вітчизняних с/г підприємств рослинництва відкритого ґрунту [17]–[21].

Також варто зазначити, що на сьогоднішній день доволі розвиненими є методи обробки даних, які базуються на використанні технологій супутникового моніторингу. Глобально ці методи можуть бути поділені на дві групи: суто емпіричні (регресійні) та механістичні. Принцип дії першої групи методів полягає у встановленні частинного виду градуєвальної залежності між однією або декількома інформативними фізичними (хімічними, біологічними) параметрами та сигналами дистанційного зондування або їх похідними, як наприклад: коефіцієнт відбиття та індекс листяного покриву, коефіцієнт зворотного розсіювання й зволоженість с/г культур та інше. Друга група методів базується на застосуванні сучасних підходів математичного та комп'ютерного моделювання, в тому числі, зі залученням засобів машинного

навчання та штучного інтелекту, а саме: ітераційні методи оптимізації; метод look-up-table (LUT), який полягає в обчисленні цільової функції на великому наборі даних, що складається з імітованого сигналу і відповідних вхідних параметрів моделі; методи машинного навчання зі залученням фізичних і цифрових моделей досліджуваних об'єктів [13].

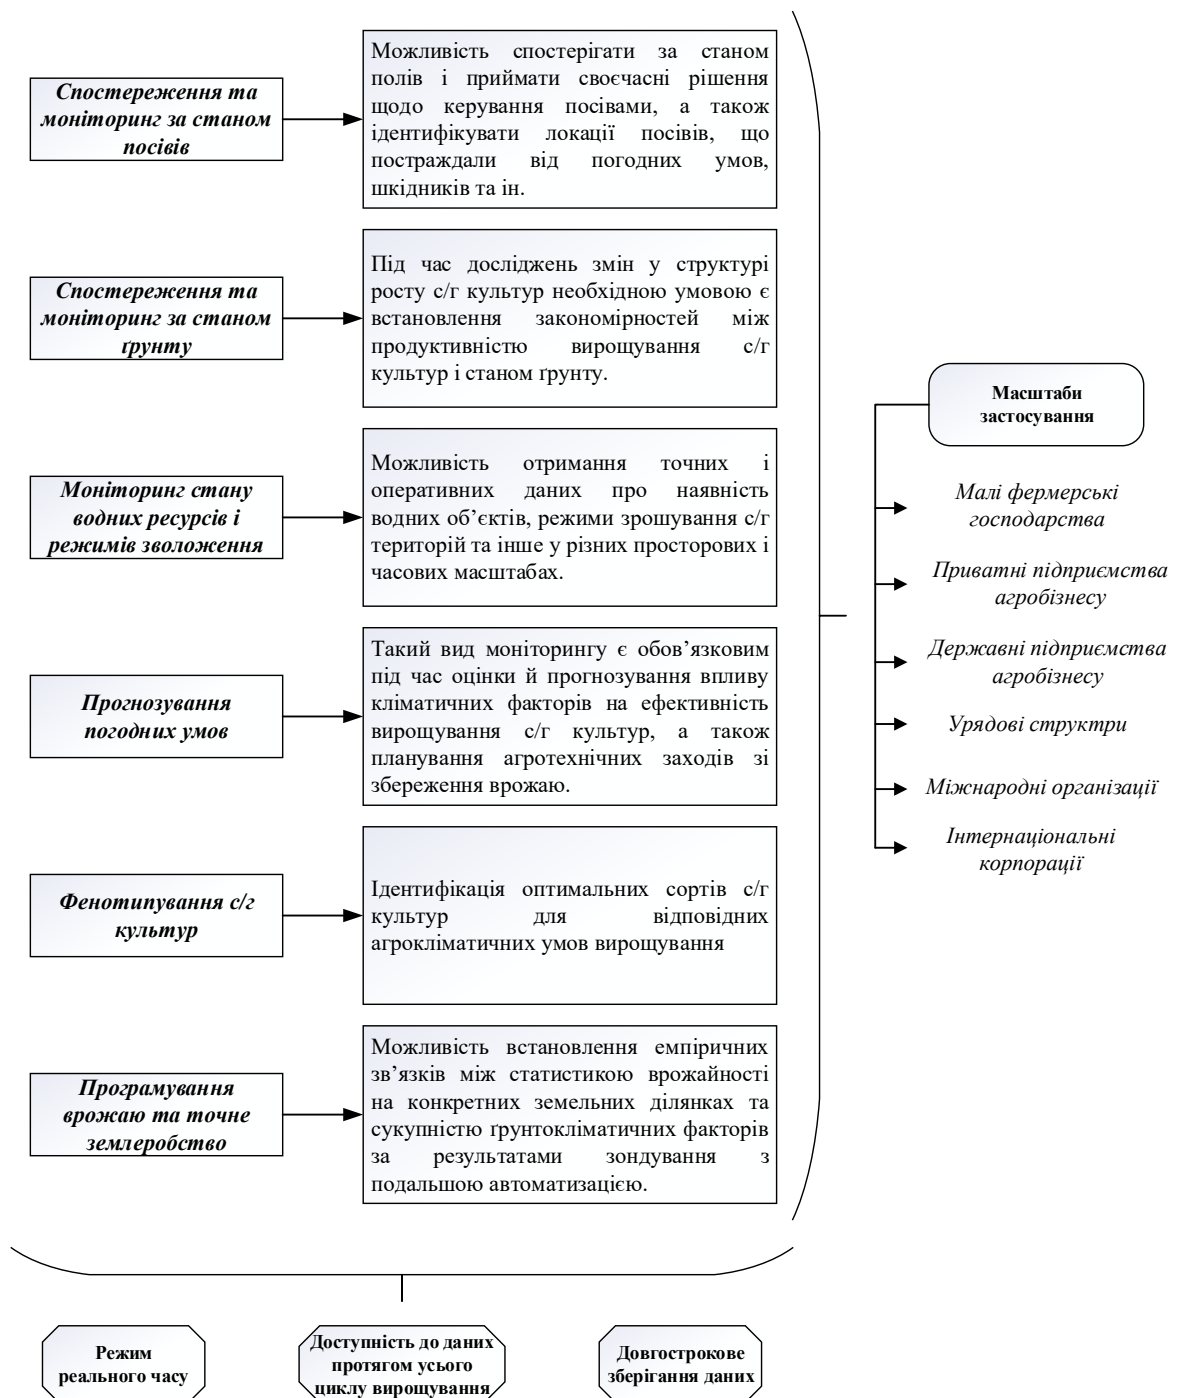


Рисунок 1.14 – Загальна характеристика прикладного застосування технологій супутникового моніторингу в агротехнічній практиці

На підставі проведеного аналізу характеристик прикладного застосування технологій супутникового зондування й моніторингу в сільськогосподарській галузі встановлено факт масштабності та адаптивності використання цієї технології під час побудови інтелектуалізованих систем для сталого вирощування с/г культур. Також локалізовано сукупність прикладного функціонального призначення віддаленого моніторингу агротехнічного призначення під час розробки та дослідження інформаційної технології комплексного інтелектуального ґрунтокліматичного моніторингу задля сталого вирощування сільськогосподарських культур в Україні у воєнний та повоєнний час, як показано на рисунку 1.15.

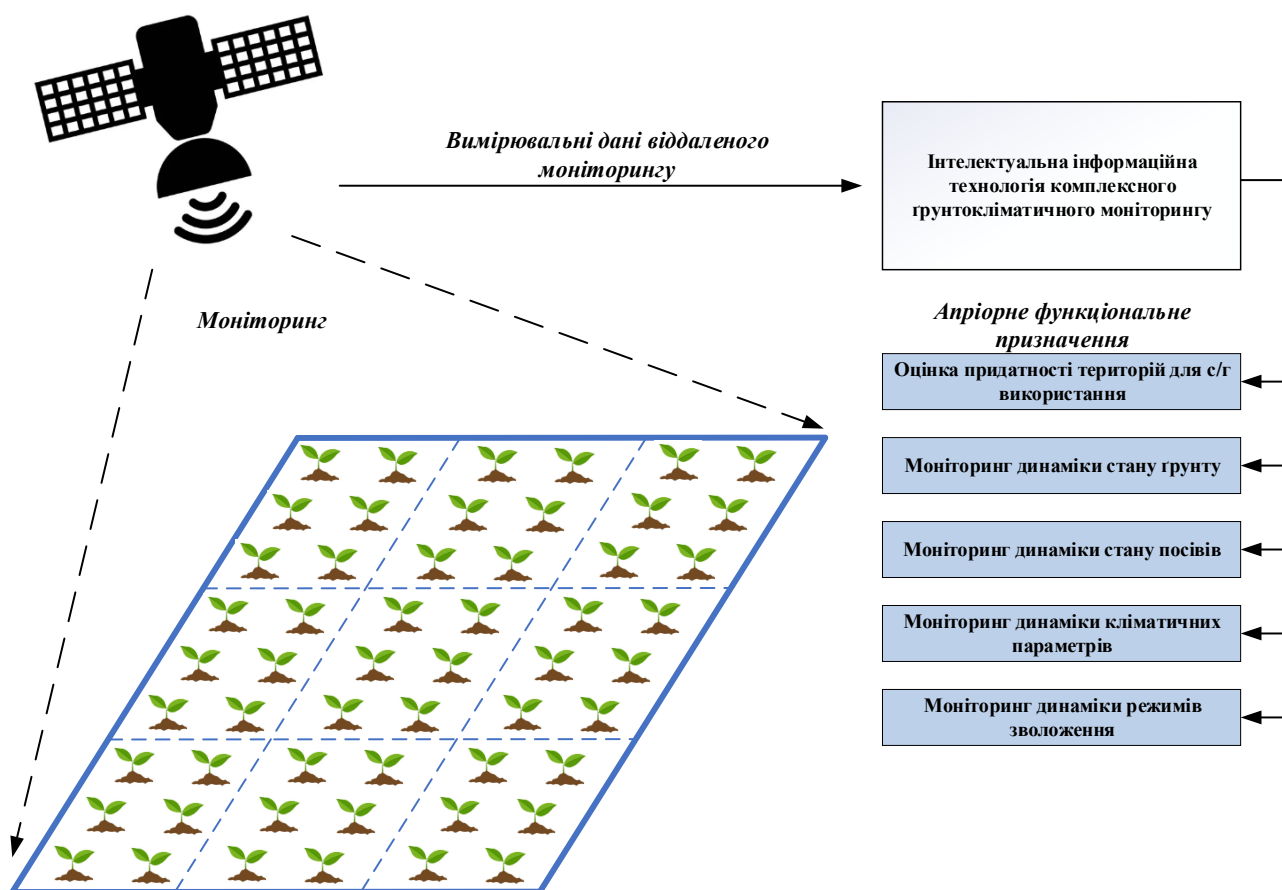


Рисунок 1.15 – Потенційне функціональне призначення супутникового моніторингу в досліджуваній інформаційній технології

Проте додатково варто зазначити, що вирішення науково-прикладних

задач інтеграції сучасного світового досвіду в галузі супутникового моніторингу агротехнічного призначення до агрокліматичних і технологічних умов с/г галузі України потребує проведення більш ґрунтового аналізу, а також додаткових досліджень і подальшого розвитку, зокрема під час розробки та впровадження геопросторових і комп'ютерних моделей моніторингу змін ґрунтокліматичних факторів із підтримкою прийняття рішення до програмно-апаратних комплексів інтегрального моніторингу стану технологічних процесів с/г виробництв рослинництва відкритого ґрунту.

**Інтернет речей.** Системи Інтернету речей (IoT) с/г призначення в загальному випадку являють собою багаторівневі мережеві апаратно-програмні рішення, в яких фізичні й біологічні об'єкти с/г діяльності, такі як рослини, тварини, виробничі процеси й механізми, що оснащені засобами генерування вимірювальних даних (інтелектуальні сенсори), з'єднані між собою за певними мережевими протоколами для здійснення обміну даними й інформацією в глобальній мережі Інтернет. Такий підхід має на меті реалізувати цифрову та інтелектуалізовану ідентифікацію, детектування, моніторинг та керування с/г об'єктами та процесами в режимі реального часу [22].

Прикладні апаратно-програмні рішення, які дозволяють реалізувати концептуальні засади Інтернету речей під час провадження с/г діяльності, відрізняються залежно від їх цільового спрямування, проте здебільшого відповідають типовій архітектурі, яка реалізує повний цикл процедур інтелектуальної трансформації вимірювальних даних (рис. 1.16): збір – локальна обробка – мережевий обмін – агрегування – глибинний інтелектуалізований аналіз – формування бази даних та знань – ергономічна візуалізація та сповіщення користувачів – генерування впливів керування с/г об'єктами та процесами [22]–[29]. Побудова IoT систем і мереж за зазначеною архітектурою дозволяє реалізувати двонаправлений рух вимірювальних даних / опрацьованої інформації: від с/г об'єктів (процесів) до кінцевих користувачів та в зворотному напрямку.

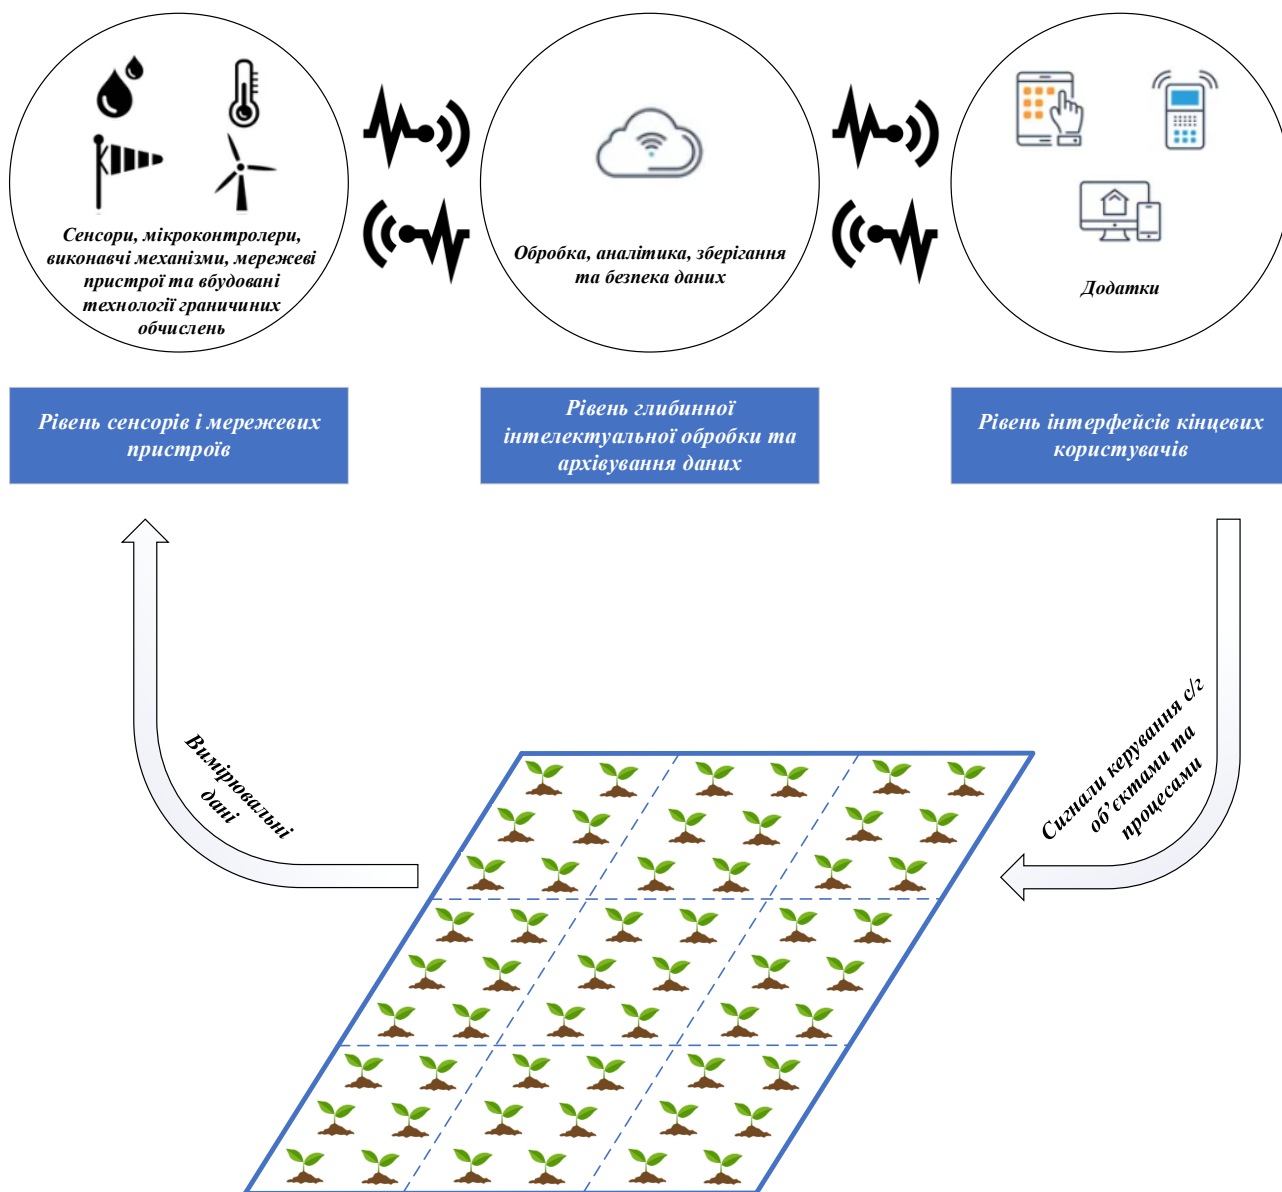


Рисунок 1.16 – Узагальнена структурно-алгоритмічна організація IoT систем і мереж сільськогосподарського призначення

Створенням і розвитком IoT технологій на сьогоднішній день займаються не тільки провідні фірми-виробники пристроїв, але й спеціалізовані організації, до яких відносяться: Міжнародний союз електрозв'язку (International Telecommunication Union, ITU), Консорціум промислового Інтернету (Industrial Internet Consortium, ІІС) та Інженерна рада Інтернету (Internet Engineering Task Force, IETF). На сьогоднішній день найбільшої популярності під час розробки та дослідження IoT систем різного прикладного призначення, в тому числі, й сільськогосподарського, набули дві еталонні моделі. Перша з них була

представлена та детально описана в рекомендаціях Y.2060 від Міжнародного союзу електрозв'язку (ITU). Така еталонна архітектура надає розробникам розуміння того, які функції мають бути реалізовані в IoT технологіях і яким чином вони мають взаємодіяти. На рисунку 1.17 наведена еталонна модель Інтернету речей від ITU, що складається з чотирьох основних ієрархічних рівнів (рівень пристроїв, рівень мережі, рівень підтримки послуг і підтримки додатків, рівень додатків), а також можливостей керування та безпеки, що діють між чотирма основними рівнями еталонної моделі Y.2060 [30].

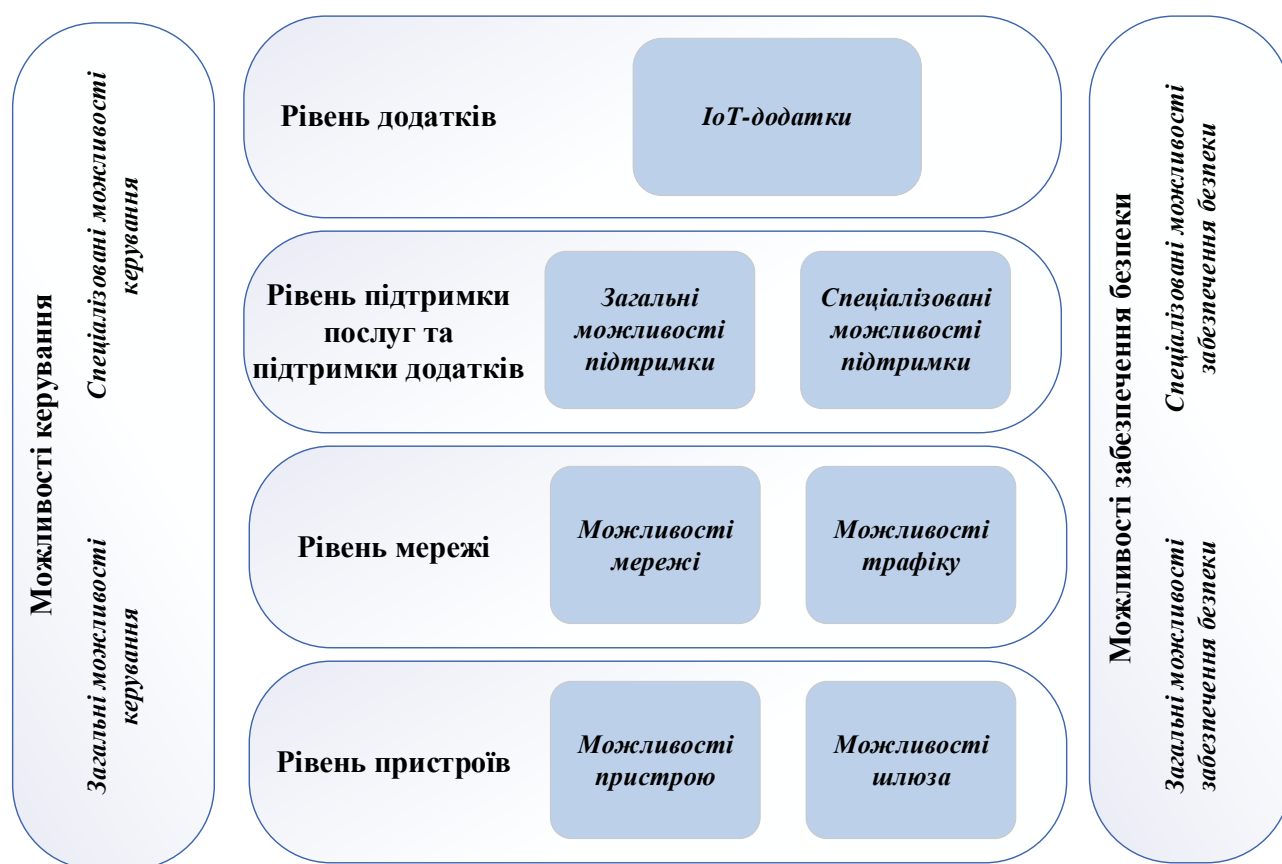


Рисунок 1.17 – Еталонна модель Інтернету речей Y.2060

Друга еталонна модель IoT була обґрунтована комітетом із питань архітектури інформаційних і цифрових технологій Всесвітнього форуму Інтернету речей (IWF), як показано на рисунку 1.18. Ця модель є загальним структурно-алгоритмічним рішенням, що покликано підвищити ефективність та швидкість розгортання програмно-апаратних рішень IoT. Така модель

призначена для обґрунтування шляхів зі створення відтворюваних, стандартизованих і уніфікованих технічних рішень IoT систем і мереж різного прикладного призначення, в тому числі агротехнічного. Ця еталонна модель є логічним доповненням до моделі Y.2060, яка була розроблена Міжнародним союзом електрозв'язку [31].

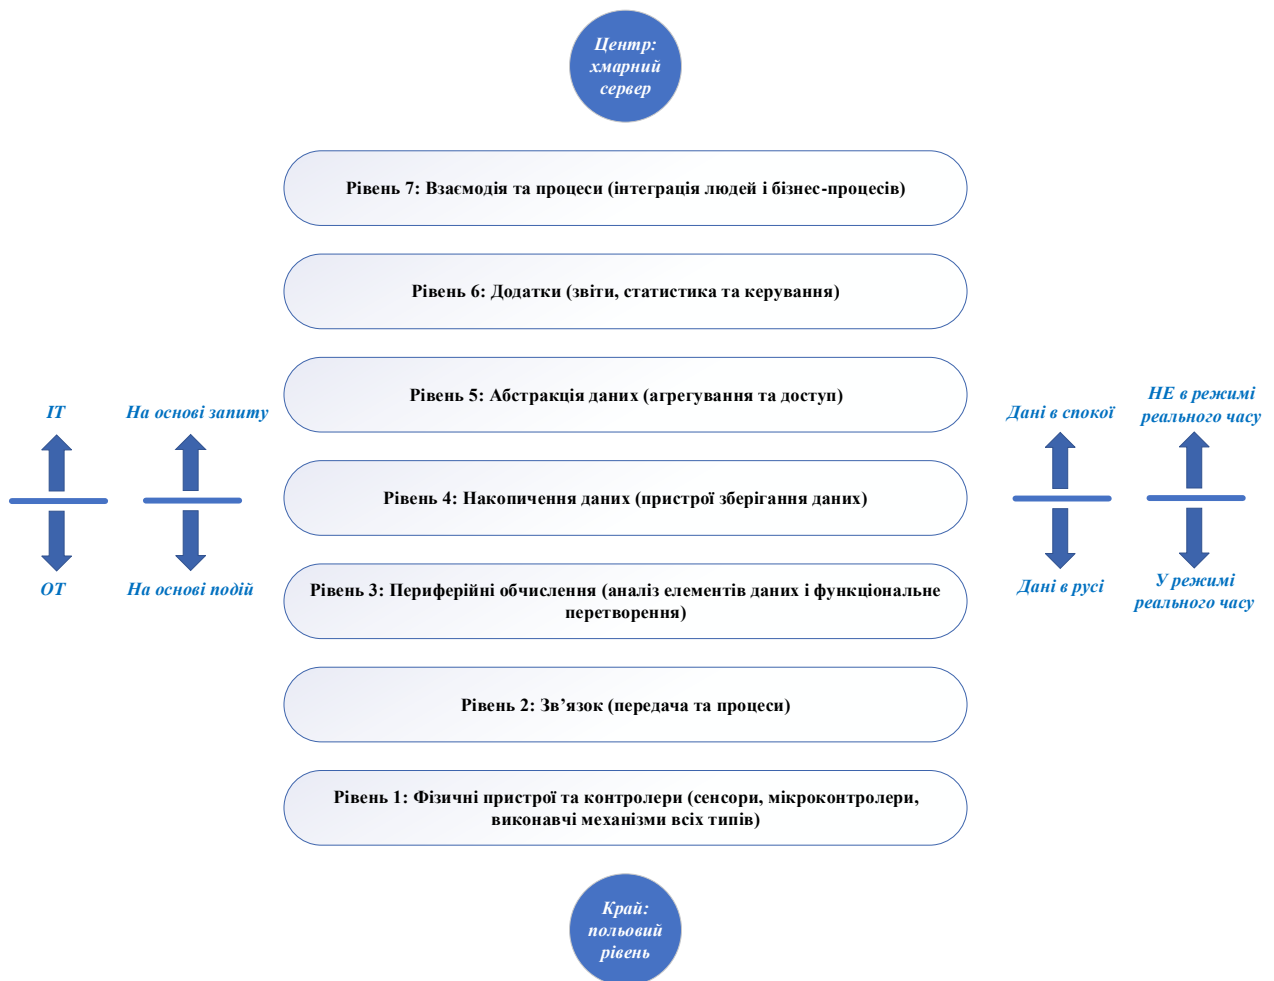


Рисунок 1.18 – Еталонна модель Інтернету речей від IWF

Головна відмінність цих моделей (IWF та Y.2060) полягає в тому, що рекомендації Y.2060 роблять головний акцент на нижніх рівнях пристроїв і шлюзу та найбільше уваги приділяють обґрунтуванню концепції підтримки розробки й впровадження стандартів взаємодії IoT пристроїв. У моделі, що була запропонована IWF, основна увага приділена питанням розробки додатків та програмного забезпечення IoT технологій, а також функцій і засобів

підтримки корпоративного Інтернету речей.

Варто зазначити, що на сучасному етапі розвитку IoT технологій значної популярності під час реалізації мережових апаратно-програмних рішень набула технологія Web of Things (WoT), яка відноситься до набору стандартів задля забезпечення сумісності, фрагментації та ергономічності використання різних прикладних рішень Інтернету речей (IoT). Таким чином, можна стверджувати, що WoT – це підмножина IoT технологій, яка побудована на основі таких стандартів програмного забезпечення, як REST, HTTP та URIs, що, в свою чергу, дозволяє оптимізувати механізми мережової взаємодії IoT пристроїв, як показано на рисунку 1.19 [32].

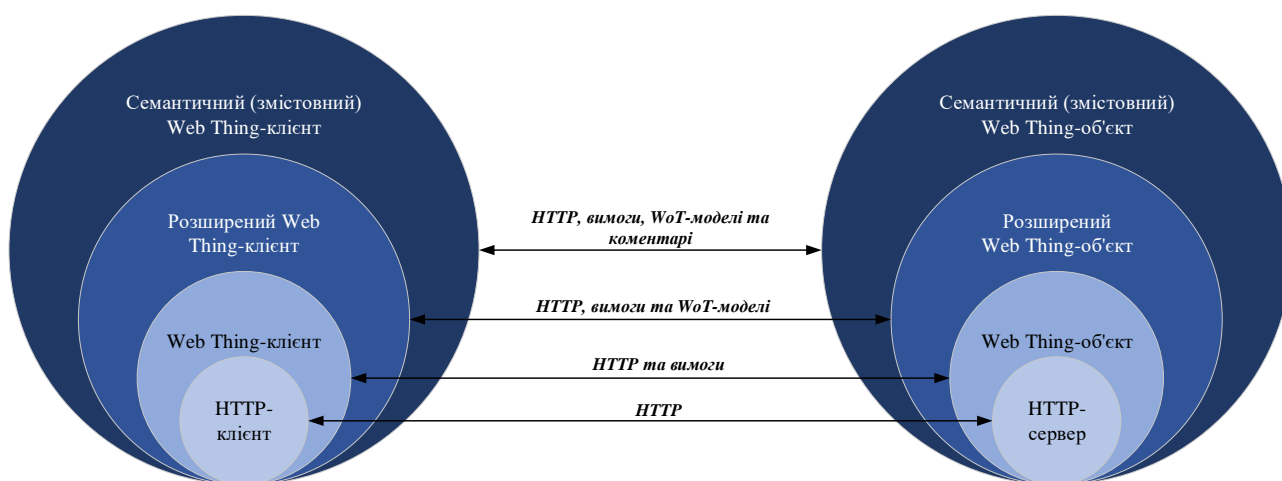


Рисунок 1.19 – Структурна схема взаємодії ієрархічних рівнів WoT мереж

Під час аналізу ключових засад створення та функціонування систем і мереж Web of Things було встановлено, що вони є дуже схожими на ті, які закладено до концепції Internet of Things. Це в основному пов'язано з тим, що головною метою WoT та IoT є реалізація підключення та обміну даними між пристроями в мережі Інтернет. Варто зазначити, що Web of Things працює як прикладний рівень та дозволяє встановлювати систематичні шляхи передачі інформації між мережевими пристроями, а також забезпечує сумісність генерування даних у мережі між клієнтами та об'єктами.

Основними обчислювальними технологіями, які на сьогоднішній день

використовуються під час побудови систем Інтернету речей с/г призначення різної архітектури, є хмарні, туманні та периферійні (граничні) обчислення. Ці технології не є конкуруючими, а призначені для взаємного доповнення функціональних можливостей одна одної. Такий підхід дозволяє реалізувати збір, обробку та аналітику вимірювальних даних ґрунтокліматичного моніторингу на різних ієрархічних рівнях IoT систем і мереж, що позитивно впливає на загальну оперативність, надійність та безпеку трансформації значних обсягів даних та інформаційних повідомлень, що генеруються апаратно-програмними засобами систем і мереж Інтернету речей. Графічну інтерпретацію такої взаємодії обчислювальних технологій у розрізі концептуальних рішень Інтернету речей наведено на рисунку 1.20 [33], [34].

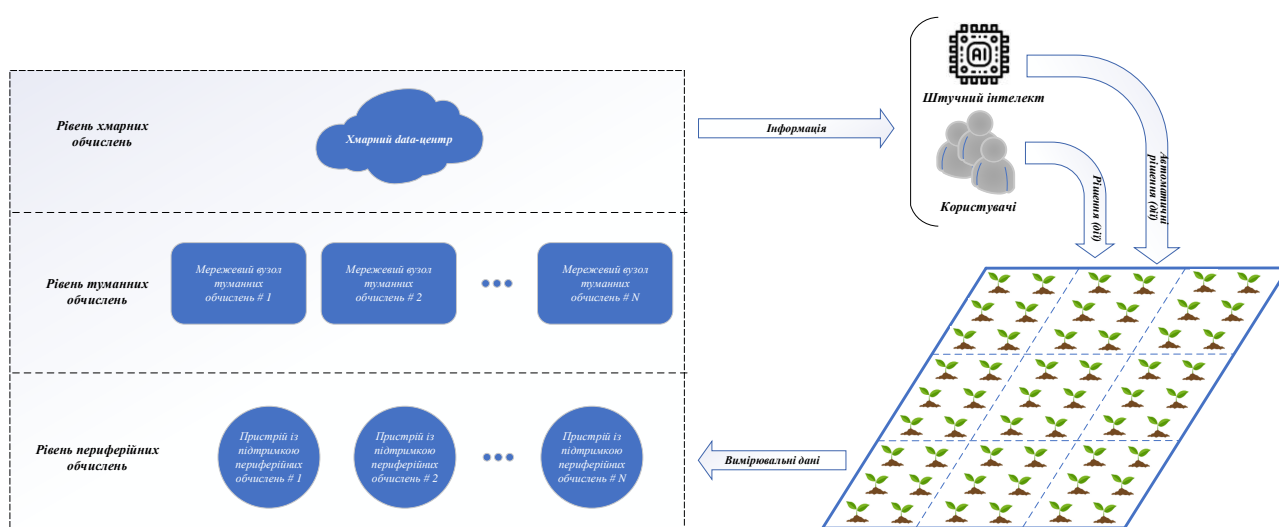


Рисунок 1.20 – Структурно-алгоритмічна організація багаторівневої мережевої трансформації даних ґрунтокліматичного моніторингу

У загальному випадку взаємодія обчислювальних технологій є такою, що розподілені граничні пристрої, які облаштовано засобами обробки даних, як наприклад, інтелектуальні сенсори, генерують значні обсяги вимірювальних даних щодо агротехнічних об'єктів і процесів, що попередньо обробляються на периферійному рівні. Після цього попередньо оброблені дані агрегуються, трансформуються та структуруються на рівні мережевих вузлів туманних

обчислень, наприклад, за допомогою IoT-шлюзів. На наступному етапі структуровані дані надходять до хмарних data-центрів із метою їх тривалого зберігання, інтелектуальної аналітики та надання до них віддаленого доступу користувачам у відповідності до їх прав і ролей.

Додатково варто зазначити, що на сьогоднішній день IoT є всеосяжної концепцією, що динамічно розвивається та трансформується з обліком сучасних світових досягнень цифрових, обчислювальних та інтелектуальних технологій. У результаті цього в окремі напрями виділяються похідні від IoT технології, основні з яких наведено в таблиці 1.1.

Таблиця 1.1 – Сучасні напрями розвитку технологій Інтернету речей

Технологія	Характерні особливості	Літературне джерело
Промисловий Інтернет речей (IIoT)	IIoT передбачає застосування IoT технологій у промислових умовах задля максимізації ефективності, зниження витрат і підвищення загальної продуктивності виробничих процесів. IIoT інтегрує в системні й мережеві рішення виробниче обладнання, пристрої та сенсорні технології в промисловому середовищі, дозволяючи збирати та аналізувати дані в режимі реального часу	[35], [36]
Масштабний Інтернет речей (MIoT)	MIoT являє собою промислову екосистему, яка використовує хмарні та периферійні обчислення, аналітику великих даних та штучний інтелект з метою зробити значні обсяги даних більш доступними та цінними для промисловості та бізнеса	[37], [38]
Штучний інтелект речей (AIIoT)	AIIoT являє собою системну інтеграцію технологій штучного інтелекту та інфраструктури Інтернету речей. Метою AIIoT є підвищення ефективності функціонування IoT систем за рахунок оптимізації людино-машинної взаємодії. У пристроях AIIoT штучний інтелект вбудований до апаратно-програмних компонент IoT із подальшим використанням інтерфейсів прикладного програмування задля забезпечення надійної взаємодії всіх апаратних, програмних і сервісних компонент без участі людини-користувача	[39], [40]

На підставі проведеного аналізу функціональних характеристик прикладного застосування IoT технологій з обліком характерних особливостей провадження с/г діяльності рослинництва відкритого ґрунту було встановлено

значну апріорну ефективність щодо застосування цієї технології під час побудови інтелектуалізованих систем для сталого вирощування с/г культур. Проте додатково необхідно зазначити, що вирішення науково-прикладних задач інтеграції сучасного світового досвіду в галузі IoT моніторингу до агрокліматичних і технологічних умов с/г галузі України потребує проведення більш ґрунтового аналізу, а також додаткових досліджень і подальшого розвитку, зокрема під час розробки та впровадження мережевих апаратно-програмних рішень, які мають функціонувати як компоненти інтелектуальних комплексів інтегрального моніторингу стану технологічних процесів с/г виробництв рослинництва відкритого ґрунту.

**Машинне навчання та штучний інтелект.** Інтеграція методів і засобів штучного інтелекту (AI) та алгоритмів машинного навчання (ML) до технологічних і виробничих процесів с/г підприємств дозволяє трансформувати аграрний сектор за рахунок оптимізації агротехнічних процедур та використання ресурсів. Розробка та впровадження підходів до керування виробничими процесами рослинництва на основі ML та AI методів і засобів містить у собі різнобічні аспекти, які є результатом системної інтеграції методів ведення сільського господарства щодо керування біологічним, хімічним і фізичним середовищем вирощування с/г культур з метою досягнення кількісних і якісних цілей цифрового землеробства [41]. Світовий досвід використання інтелектуалізованих підходів до моніторингу й керування агротехнічними процесами вирощування с/г культур під час всього періоду вирощування доводить високу ефективність і продуктивність використання апаратно-програмних рішень систем на основі ML та AI [42]–[47]. Такий ефект у першу чергу пов'язаний з тим, що ML та AI алгоритми дозволяють програмно-апаратними засобами врахувати комплексний вплив дестабілізуючих факторів різної природи (типи і періоди вегетації с/г культур, кліматичні умови, фізико-хімічний стан ґрунту, наявність і доступність джерел зволоження, ураженість шкідниками і хворобами та інше) під час підтримки прийняття рішень щодо агротехнічних процедур у режимі реального часу [48].

Графічну інтерпретацію результатів узагальнення основних напрямів використання систем на основі ML та AI у світовій с/г практиці наведено на рисунку 1.21.

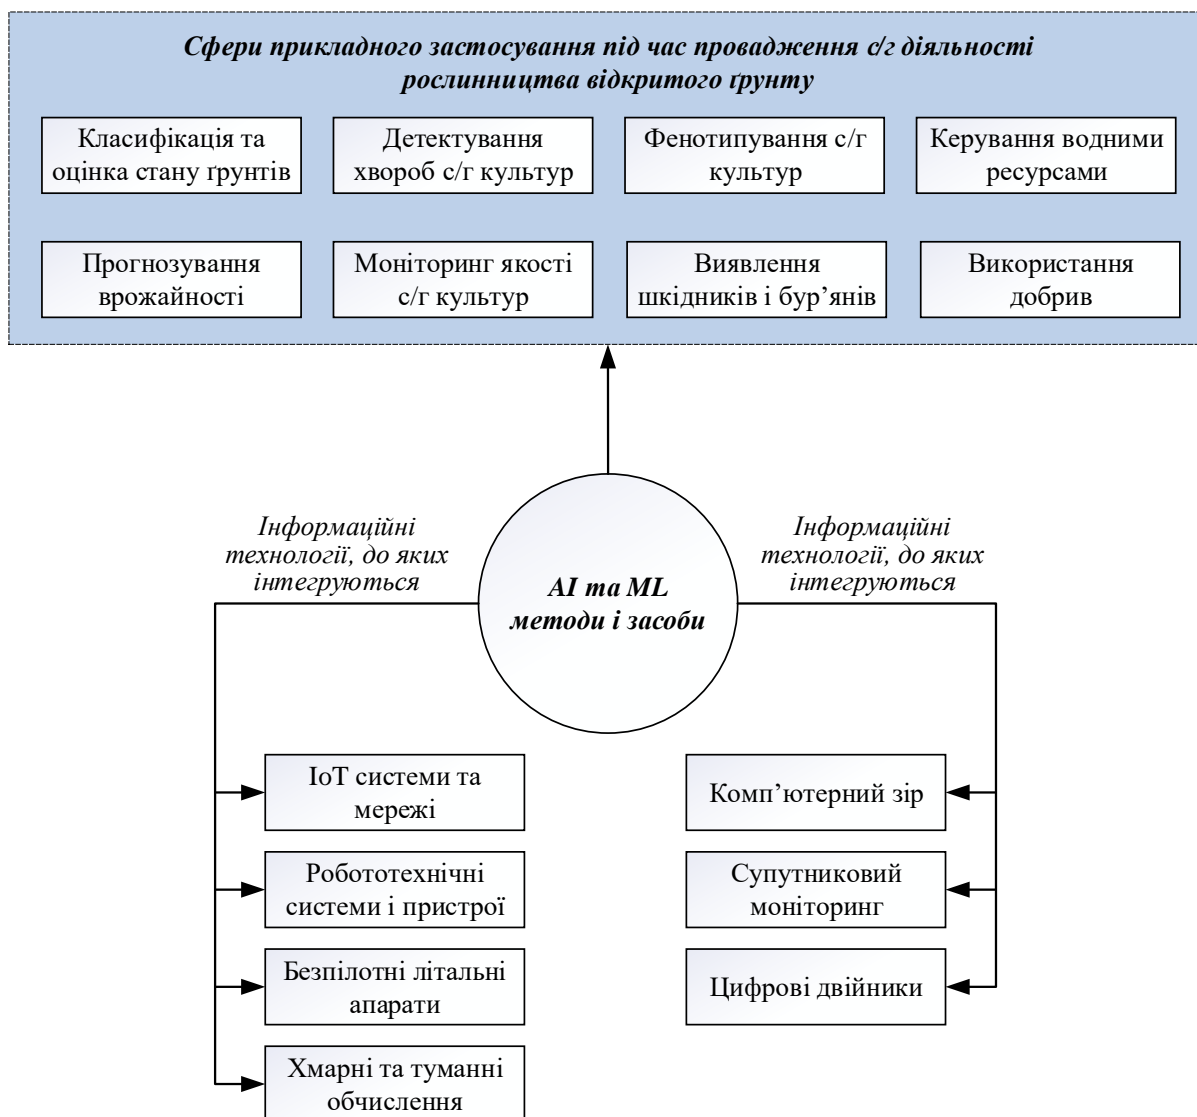


Рисунок 1.21 – Результати узагальнення основних напрямів використання систем на основі ML та AI у сільськогосподарській практиці рослинництва відкритого ґрунту

Аналіз типових підходів до розробки та розгортання інформаційних технологій на основі ML та AI алгоритмів у розрізі комплексного моніторингу різних технологічних процесів і об'єктів дозволив встановити такі положення [45], [49], [50]. Для узгодження детектованих розподілених у часі й

просторі вимірювальних даних із вимогами програмних компонент цифрової обробки необхідно обов'язково реалізувати попередню обробку даних, яка містить у собі такі операції: фільтрація, інтеграція від різних джерел, консолідація та агрегація за певними ознаками, а також нормалізація і дискретизація. У загальному випадку процедуру розробки та впровадження AI та ML алгоритмів до інформаційних технологій ґрунтокліматичного моніторингу, що містить у собі етапи навчання та тестування відповідних моделей, наведено на рисунку 1.22.

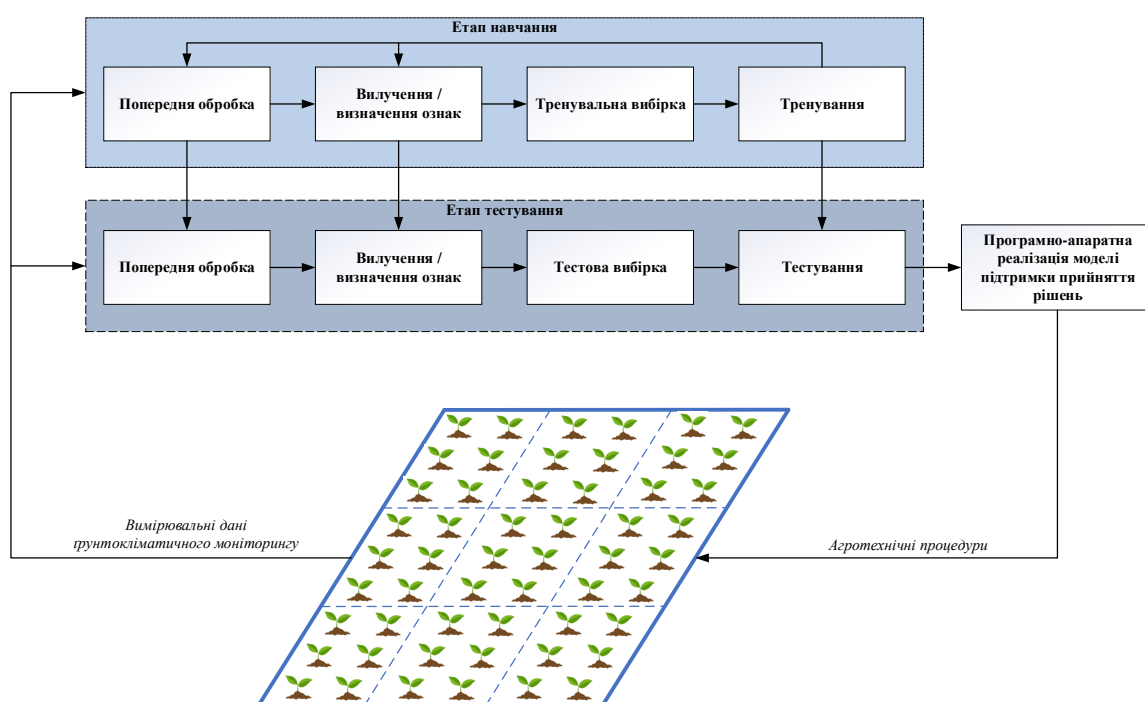


Рисунок 1.22 – Узагальнена процедура розробки та впровадження AI та ML алгоритмів до інформаційних технологій ґрунтокліматичного моніторингу

Після попередньої обробки (фільтрація, консолідація та нормалізація) вимірювальних даних неодмінним етапом розробки інтелектуальних методів та засобів ґрунтокліматичного моніторингу є функція вилучення / визначення ознак, яка дозволяє ідентифікувати найбільш інформативні дані (параметри вибірок даних) та встановити кореляційні зв'язки між впливними інформативними і дестабілізуючими факторами. Наявність зворотного зв'язку в такій моделі дозволяє коригувати отримані результати навчання та тестування

розроблюваної моделі в режимі реального часу під час її розробки та функціонування. На етапі тестування, на відміну від етапу навчання, до навченої моделі додаються вхідні вектори (масиви) з оновленою (розширеною) сукупністю даних. Фінальним етапом реалізації такого алгоритму, як показано на рисунку 1.22, є програмно-апаратна реалізація моделі підтримки прийняття рішень (вирішення задач класифікації, регресії, прогнозування та інше) щодо агротехнічних процедур залежно від цільового призначення розроблюваної технології (рис. 1.21).

Таким чином, на основі наведених вище результатів аналізу та логічного узагальнення сучасних світових досягнень щодо інтеграції ML та AI алгоритмів до апаратно-програмних рішень інформаційних технологій агротехнічного призначення було встановлено значущу ефективність їх використання під час побудови інтелектуалізованих систем моніторингу й керування агротехнічними процесами. Поруч із цим необхідно акцентувати увагу на тому, що вирішення науково-прикладних задач розробки та впровадження програмних компонент на основі ML та AI алгоритмів до системних рішень інформаційних технологій агротехнічного призначення потребує проведення більш ґрунтовного аналізу й подальших досліджень у цьому напрямку з точки зору прецизійності, надійності та оперативності реалізації повного циклу трансформації вимірювальних даних у складі польової ланки досліджуваних інтелектуалізованих інформаційних технологій з обліком агрокліматичних і технологічних характеристик с/г галузі України.

**Аграрні роботизовані системи та технології.** На сьогоднішній день під терміном «аграрний робот» прийнято розуміти мобільний, програмований, автономний, мехатронний пристрій (система, комплекс) з підтримкою прийняття рішень, що виконує завдання або їх сукупність під час с/г діяльності, в тому числі, рослинництва відкритого ґрунту під наглядом людини, але без її безпосередньої участі, а саме: підготовка ґрунту, посіви, боротьба зі шкідниками та бур'янами, збір врожаю та інше [16], [51], [52].

Узагальнену характеристику сучасних технологій, на яких базуються

аграрні роботизовані пристрої й системи, а також прикладних сфер їх застосування під час провадження с/г діяльності рослинництва відкритого ґрунту наведено на рисунку 1.23 [16], [53]–[57].

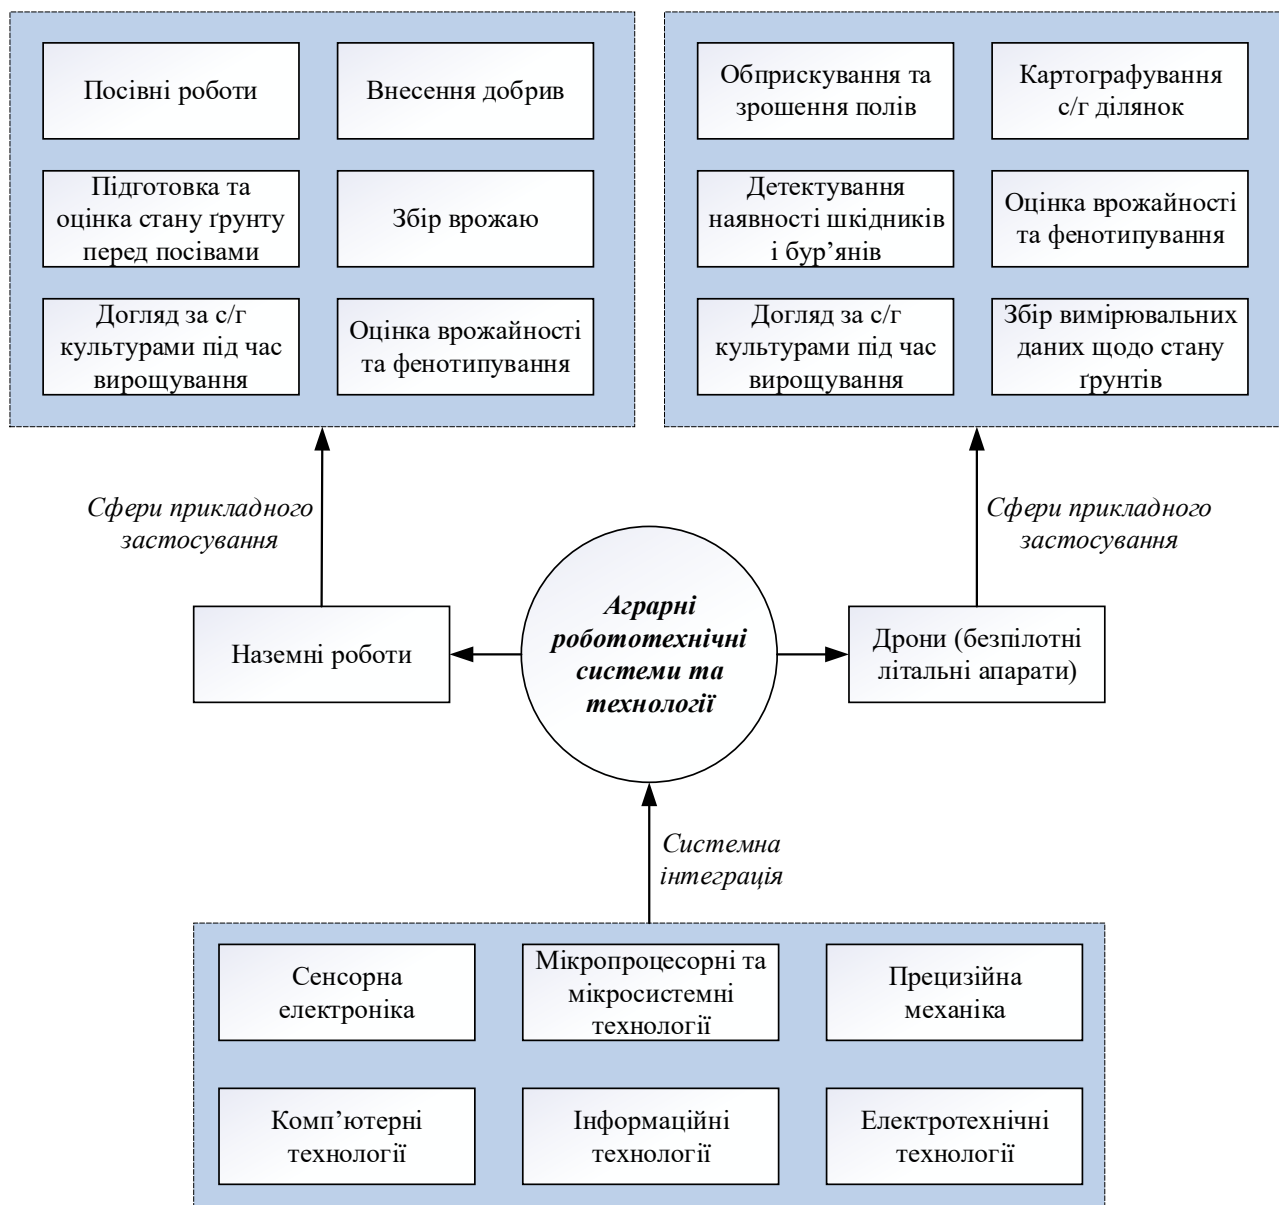


Рисунок 1.23 – Характеристика сучасного стану робототехнічних систем і технологій агротехнічного призначення

Сільськогосподарські об'єкти здебільшого в сьогodenній практиці є неструктурованим через значну динаміку інформативних і дестабілізуючих факторів, що впливають на ефективність агротехнічних процесів, що обумовлює наявність науково-прикладних проблем невизначеності операційних

та системних налаштувань роботехнічних пристроїв і систем. Варто зазначити, що на сьогоднішній день значна кількість роботехнічних технологій (наземні та UAV) задля реалізації широкого спектру агротехнічних процедур (рис. 1.23) перебуває на стадії досліджень, а лише незначна їх частина знаходиться на комерційній стадії серійного випуску та використання в реальних умовах. Це обумовлено структурою фермерських господарств у світі, адже майже 90 % с/г виробництв відносяться до категорій малого та середнього бізнесу [58]. Отже, наразі одним із основних трендів розвитку робототехнічних систем є їх апаратно-програмна реалізація з обліком багатofункціонального застосування.

Таким чином, представлені вище результати аналізу й узагальнення сучасного стану розробки й використання робототехнічних систем і технологій у аграрній галузі дозволили апріорно встановити їх потенційне цільове призначення під час синтезу комплексної структурно-алгоритмічної організації інформаційної технології інтелектуального ґрунтокліматичного моніторингу під час сталого вирощування сільськогосподарських культур в Україні у воєнний та повоєнний час, як у графічному вигляді показано на рисунку 1.24.

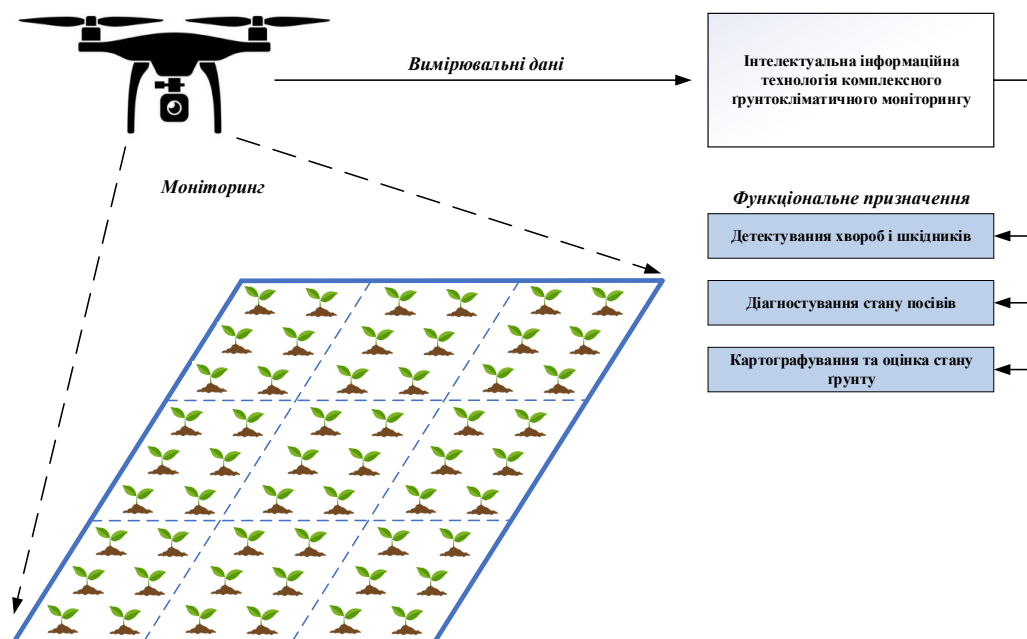


Рисунок 1.24 – Потенційні функціональне призначення робототехнічних пристроїв у досліджуваній інформаційній технології

Додатково необхідно зазначити той факт, що під час системної інтеграції робототехнічних пристроїв до досліджуваної інтелектуальної інформаційної технології комплексного ґрунтокліматичного моніторингу виникає необхідність у вирішенні низки задач дослідного характеру, які пов'язані з програмною та апаратною сумісністю, а також синхронізованою взаємодією функціональних компонент розроблюваної технології з обліком агрокліматичних і технологічних характеристик с/г галузі України.

**Інфокомунікаційні технології бездротового обміну даними.** В сьогоденній практиці під час розробки систем моніторингу й керування агротехнічними процесами широкого впровадження набувають мережеві рішення, що дозволяють обмінюватись даними та інформаційними повідомленнями апаратно-програмним компонентам систем у режимі machine-to-machine (device-to-device), а також надійно та оперативно агрегувати вимірювальні дані на віддалених хмарних середовищах. Виходячи з цього значного поширення набули бездротові технології обміну даними та відповідні інфокомунікаційні протоколи, на яких вони функціонують. Мережевий рівень інформаційних технологій забезпечує рух даних та інформації крізь ієрархічну будову таких систем від краю (апаратні засоби генерування вимірювальних даних) до центру (хмарні сервери аналітики даних), а також в зворотному напрямку [59]. Дані та / або інформація в цих технологіях можуть передаватися з використанням радіохвиль, інфрачервоного або лазерного випромінювання.

На теперішній час розроблено й упроваджено значну кількість бездротових технологій та відповідних їм апаратно-програмних рішень, наприклад, Wi-Fi, ZigBee, Bluetooth, LoRa WAN, NB-IoT та інше. Кожна з таких бездротових технологій має певні техніко-функціональні характеристики, які визначають сферу її застосування. До ключових параметрів і характеристик бездротових технологій відносяться дальність передачі сигналу, енергоефективність, швидкість передачі даних, проникаюча здатність сигналу (спроможність долати перешкоди), затримка передачі сигналу (час між генеруванням сигналу на виході сенсора та отриманням оброблених даних

користувачем / оператором), кількість базових станцій, що необхідні для покриття певної місцевості, продуктивність базової станції (кількість одночасно підтримуваних абонентів). На рисунку 1.25 наведено класифікацію бездротових мереж за критерієм зони покриття, а також зазначено приклади бездротових інфокомунікаційних технологій, які відносяться до відповідних категорій мереж [60], [61].

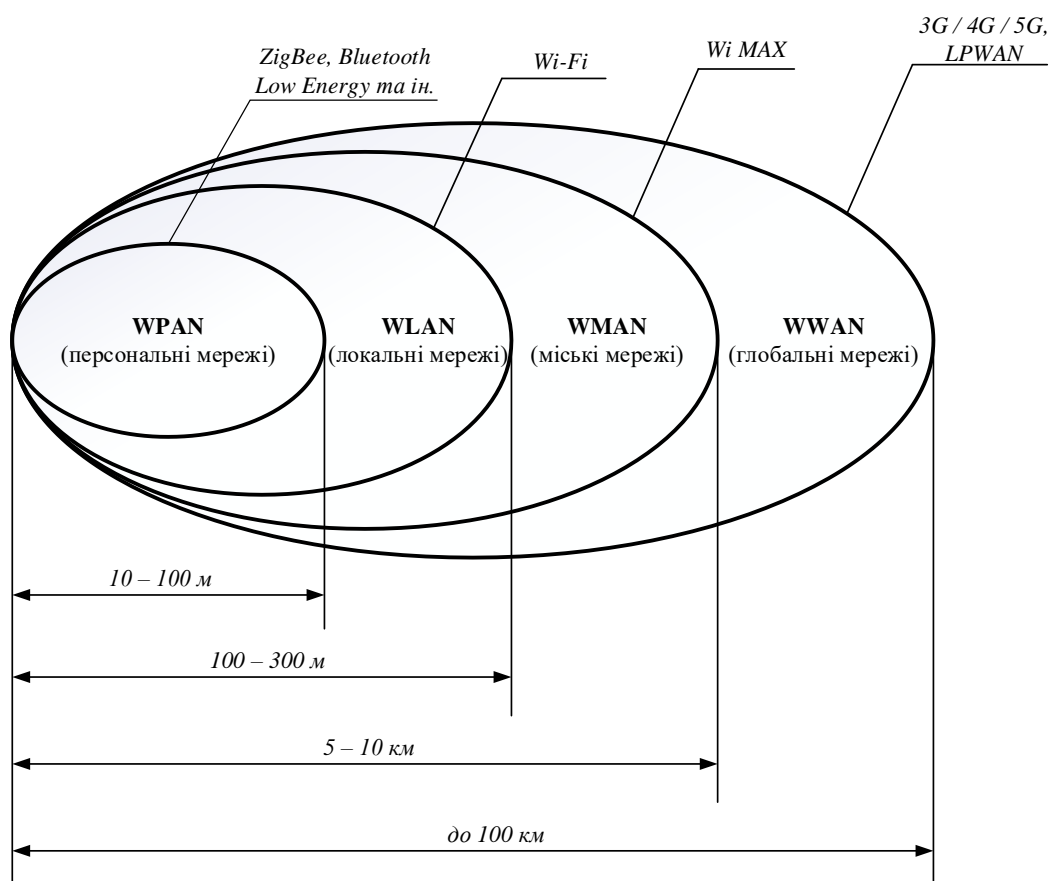


Рисунок 1.25 – Класифікація бездротових інфокомунікаційних технологій за зоною покриття

У сучасній агротехнічній практиці під час ґрунтокліматичного моніторингу найбільшого поширення набули технології, що відносяться до категорій WPAN, WLAN та WWAN. Така тенденція обумовлена специфікою побудови мережевих рішень агротехнічного моніторингу: у межах одного поля в основному використовуються WPAN і WLAN технології, а для об'єднання декількох полів у єдину мережу – WWAN технології.

Порівняльну характеристику основних техніко-функціональних параметрів бездротових технологій WPAN і WLAN, які набули широкого впровадження під час проектування програмно-апаратних системних рішень у галузі с/г моніторингу та керування технологічними процесами, наведено в таблиці 1.2 [62]–[65].

Таблиця 1.2 – Результати порівняння бездротових мережевих технологій категорій WPAN і WLAN

<b>Характеристика технології (стандарту)</b>	<b>ZigBee (IEEE 802.15.4)</b>	<b>WI-FI (IEEE 802.11b)</b>	<b>Bluetooth (BLE) (IEEE 802.15.1)</b>
Частотний діапазон, ГГц		від 2,4 до 2,483	
Пропускна здатність, Кбіт/с	250	11000	723,1
Розмір стека протоколу, Кбайт	від 32 до 64	понад 1000	понад 250
Час безперервної автономної роботи від акумулятора, дні	від 100 до 1000	від 0,5 до 5	від 1 до 10
Максимальна кількість вузлів у мережі	65536	10	7
Діапазон дії, м	від 10 до 100	від 20 до 300	від 10 до 100

У сьогоденній агротехнічній практиці широкого розповсюдження набули бездротові технології, що відносяться до категорії WWAN, а саме, LPWAN (LoRa, NB-IoT і Sigfox) [66], [67]. Додатково під терміном LPWAN розуміється протокол передачі даних у мережах із множиною вузлів, що побудовані за топологією «зірка» або «зірка зірок», як це показано на рисунку 1.26. Порівняльну характеристику основних техніко-функціональних параметрів різновидів бездротових технологій LPWAN, які набули широкого впровадження під час проектування програмно-апаратних мережевих рішень, наведено в таблиці 1.3.

Варто зазначити також той факт, що під час побудови мережевих рішень інформаційних технологій комплексного ґрунтокліматичного моніторингу характерним є системна інтеграція бездротових пристроїв, що відносяться до різних категорій (WPAN, WLAN і WWAN). Такий підхід дозволяє реалізувати засади масштабування та підвищення надійності програмно-апаратних рішень

моніторингу й керування технологічними та виробничими процесами с/г підприємств.

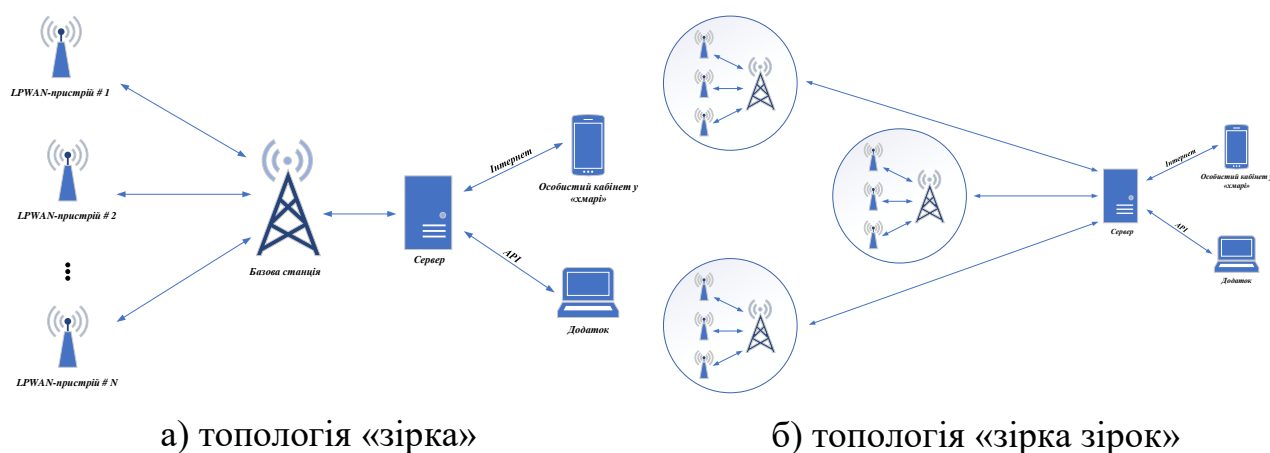


Рисунок 1.26 – Структура типових LPWAN мереж

Таблиця 1.3 – Порівняльна характеристика технологій LPWAN

Технологія	<i>LoRa</i>	<i>NB-IoT</i>	<i>Sigfox</i>
Характеристика			
Метод модуляції	CSS	QPSK	BPSK
Діапазон частот	Неліцензовані діапазони ISM (Європа – 868 МГц, Північна Америка – 915 МГц, Азія – 433 МГц)	Ліцензовані діапазони LTE	Неліцензовані діапазони ISM (Європа – 868 МГц, Північна Америка – 915 МГц, Азія – 433 МГц)
Пропускна здатність	125 КГц і 250 КГц	200 КГц	100 Гц
Гранична швидкість передачі даних	50 Кбіт/с	200 Кбіт/с	100 Кбіт/с
Підтримка двонаправленого зв'язку	Так / напівдуплексний	Так / напівдуплексний	Обмежений / напівдуплексний
Максимальна кількість повідомлень на добу	Необмежено	Необмежено	140 (UL), 4 (DL)
Граничний об'єм корисного навантаження	243 байти	1600 байт	12 байт (UL), 8 байт (DL)
Орієнтовна дальність передачі без втрати даних	5 км (міський), 20 км (сільський)	1 км (міський), 10 км (сільський)	10 км (міський), 40 км (сільський)
Наявність шифрування та аутентифікації	Так (AES 128 біт)	Так (AES 128 біт)	Не підтримується
Підтримка адаптивної швидкості передачі даних	Так	Ні	Ні
Наявність дозволу на приватні мережі	Так	Ні	Ні
Стандартизація	LoRa-Alliance	3GPP	Sigfox разом із ETSI

Також під час розгортання мережевих рішень інформаційних технологій моніторингу й керування технологічними й виробничими процесами, що відповідають концептуальним засадам «Industry 4.0» та «Agriculture 4.0», набули широкого впровадження відповідні мережеві протоколи [68]–[70]. Систематизований перелік найбільш ефективних і популярних мережевих протоколів, які використовуються у світовій практиці під час створення й розгортання інфокомунікаційних мереж, що дозволяють реалізувати засади machine-to-machine взаємодії, наведено в таблиці 1.4.

Таблиця 1.4 – Порівняльна характеристика інфокомунікаційних протоколів

Протокол	Типова сфера застосування	Виконувані операції	Характерні особливості
MQTT	Мережі зі значною кількістю розподілених пристроїв і брокером	Обробка телеметричних даних, публікацій та підписки	Підтримка механізму черг і різних класів якості обслуговування
DDS	Мережі, в яких необхідно забезпечити розподіл навантаження	Отримання й відправка даних	Реалізація прямого шинного зв'язку на основі реляційної моделі даних
CoAP	Мережі з обмеженими обчислювальними й швидкісними ресурсами	Отримання й запис конкретних показників і параметри	Являє собою спрощену бінарну версію протоколу HTTP
XMPP	Невеликі персональні мережі	Запит інформації, отримання та оновлення даних	Наявна можливість забезпечення швидкого асинхронного обміну даними
SOAP	Розподілені обчислювальні мережі	Запит параметрів та віддалений виклик методів / функцій	Підтримка декількох механізмів доступ та сумісність із різними платформами
STOMP	Мережі з можливістю комбінування декількох різних протоколів із передачею повідомлень через брокера	Обробка мережевих публікацій та підписки	Сумісність зі значною кількістю мов програмування та інфокомунікаційних платформ
AMQP	Мережі, в яких необхідно забезпечити високу якість та безпеку обміну даними	Моніторинг інформаційних повідомлень та одночасне надсилання повідомлень декільком користувачам	Функціонування в асинхронному режимі та швидка реакція сервера на запити, налагодження взаємодії між різними системами

Таким чином, на основі проведеного аналізу та логічного узагальнення характерних особливостей та тренду розвитку інфокомунікаційних технологій обміну даними в розрізі їх прикладного використання під час побудови комплексних програмно-апаратних рішень інформаційних мереж було встановлено доцільність використання підходу комбінованої інтеграції бездротових технологій різних категорій (WPAN, WLAN і LPWAN) на основі відповідних мережевих протоколів. Одночасно із цим необхідно акцентувати увагу на тому, що такий підхід обумовлює необхідність проведення додаткового аналізу світових науково-прикладних розробок щодо ефективності використання бездротових технологій та інфокомунікаційних протоколів під час створення мережевих програмно-апаратних рішень моніторингу й керування, саме, в умовах с/г підприємств рослинництва відкритого ґрунту, що дозволить локалізувати перспективні завдання подальших досліджень і розробки з обліком агрокліматичних і технологічних характеристик аграрної галузі України.

### **1.3 Сучасні науково-прикладні досягнення з підвищення ефективності технологічних і виробничих процесів аграрної галузі**

На підставі проведеного інформаційного аналізу та логічного узагальнення сучасних напрямів і тенденцій розвитку прикладних інтелектуальних інформаційних технологій моніторингу й керування технологічними й виробничими процесами було встановлено, що у теперішній час актуалізується потреба аграрних підприємств у динамічній та високоефективній цифровізації й інтелектуалізації завдяки впровадженню високопрецизійних, оперативних і надійних мережевих програмно-апаратних рішень таких технологій. З одного боку, це обумовлено значною наукомісткістю проблеми, а з іншого, – значним впливом на успіх вирішення низки економіко-соціальних задач, які мають безпосередній зв'язок із розвитком цифрових і інформаційних технологій: підвищення економічної

ефективності та інвестиційної привабливості вітчизняних с/г підприємств, забезпечення населення якісною с/г продукцією власного виробництва, формування позитивного експортного іміджу України та похідні від них.

Під час аналізу відомих результатів теоретичних і експериментальних досліджень та практичних розробок у заявленій предметній області (пп. 1.1 і 1.2) було встановлено, що одним із найбільш перспективних підходів до вдосконалення технологічних і виробничих процесів с/г підприємств є створення й упровадження інтелектуальних інформаційних і комп'ютерних технологій моніторингу інтегрального ґрунтокліматичного стану с/г підприємств рослинництва відкритого ґрунту на підставі метрологічно задовільного збору, надійного мережевого обміну та функціонально придатного аналізу вимірювальних даних щодо розподілених фізико-хімічних параметрів у режимі реального часу з автоматизованою підтримкою прийняття рішень, адже ефективність та інформативність протікання технологічних процесів в умовах с/г підприємств істотно залежить від точності, оперативності, надійності, системності та комплексності генерування, агрегування, обробки, передачі, аналізу й інтерпретації вимірювальних даних.

Приймаючи до уваги той факт, що на сьогоднішній день проблемам розробки, дослідження й упровадження програмно-апаратних рішень інтелектуальних інформаційних систем агротехнічного спрямування присвячено значний обсяг публікацій, подальші результати аналізу відомих науково-прикладних досягнень у цій сфері систематизовано у відповідності до таких критеріїв: функціональне призначення досліджуваних систем і мереж, типи структурно-алгоритмічної організації, прикладний ефект досліджень, використовувані методи і підходи досліджень та інше.

Результати критичного аналізу та логічного узагальнення актуальних світових науково-прикладних розробок інформаційних технологій моніторингу й керування технологічними й виробничими процесами с/г підприємств рослинництва за критерієм їх функціонального призначення наведено в таблиці 1.5.

Таблиця 1.5 – Результати аналізу та узагальнення агротехнічних інформаційних технологій за критерієм їх функціонального призначення

<b>Функціональне призначення</b>	<b>Базові технології</b>		
	Супутниковий моніторинг	Безпілотні літальні апарати	Наземні IoT технології
Оцінка придатності та картографування територій для с/г використання	[71]–[78]	[79]–[82]	[83]–[85]
Моніторинг динаміки стану ґрунту	[86]–[90]	[91]–[96]	[97]–[100]
Моніторинг динаміки стану посівів	[101]–[105]	[105]–[109]	[110], [111]
Моніторинг динаміки кліматичних параметрів	[112]–[116]	[117]–[119]	[120]–[126]
Моніторинг динаміки режимів зволоження	[127]–[131]	[132]–[135]	[136]–[139]
Детектування хвороб с/г культур, шкідників і бур'янів	[140]–[142]	[143]–[150]	[151]–[155]

Додатково варто зазначити, що на підставі аналізу наукових джерел (табл. 1.5) було встановлено, що актуальним і перспективним напрямом щодо синтезу архітектурних рішень інфокомунікаційних систем агротехнічного призначення є комбіноване використання різних технологій, як наприклад: безпілотні літальні апарати та наземні IoT мережі [156], супутниковий моніторинг та безпілотні літальні апарати [157], [158], а також усі три вищезазначені технології [159]. Такий підхід дозволяє значно розшири та адаптувати функціонал відповідних програмно-апаратних рішень інтелектуальних систем ґрунтокліматичного моніторингу під час вирішення значного спектру прикладних завдань (рис. 1.15, 1.21 і 1.24).

Результати критичного аналізу та логічного узагальнення актуальних світових науково-прикладних розробок щодо комплексного використання інтелектуалізованих інформаційних і цифрових технологій моніторингу й керування технологічними й виробничими процесами с/г підприємств рослинництва за критерієм їх структурно-алгоритмічної організації та відповідних програмно-апаратних рішень наведено в таблиці 1.6.

Таблиця 1.6 – Результати бібліографічного аналізу агротехнічних IoT технологій за критерієм їх структурно-алгоритмічної організації

Об'єкт дослідження	Науково-прикладний ефект	Обчислювальні технології та алгоритми	Апаратні технології	Детектовані процеси, параметри та явища	Джерело
IoT система моніторингу с/г призначення з інтегрованими функціями глибинного навчання	Запропоновано новий метод побудови систем моніторингу посівів, що використовує UAV та функціонал класифікації на основі машинного навчання	CNN, DRNN	IoT, UAV, SM	Аномалії в посівах та кліматичні параметри	[159]
Архітектура комплексного програмно-апаратного рішення для точного землеробства	Розроблено та експериментально валідовано комплексне апаратно-програмне рішення точного землеробства, що дозволяє фермерам керувати та контролювати стан виноградників	Веб інтерфейс для аналізу NDVI на основі AI алгоритмів	WSN, IoT, UAV	Параметри клімату і ґрунту, аерокосмічні зображення посівів	[160]
Багаторівнева архітектура IoT системи збору та аналізу ґрунтокліматичних даних для точного землеробства з оптимізованими показниками енергоефективності	Обґрунтовано апаратні, програмні та мережеві компоненти побудови системи на кожному архітектурному рівні. Розроблено IoT систему та доведено її ефективність під час вирощування шафрану в Греції	RF під час аналізу показників росту та наявності хвороб с/г культур	IoT, WSN, UAV	Параметри клімату і ґрунту та аерокосмічні зображення стану посівів	[161]
Програмно-апаратне рішення IoT системи керування поливом с/г культур зі залученням техніки хмарних обчислень	Розроблено рішення віддаленого моніторингу та автоматичного керування поливом с/г культур на основі веб-технологій та бюджетної компонентної бази	KNN	IoT, WSN, CC	Параметри ґрунту	[162]
Методи та засоби розробки цифрових двійників щодо прогнозування хвороб с/г культур	Розширюване рішення, що базується на використанні широкого спектру інформаційних і сенсорних технологій моніторингу стану земельних ресурсів та посівів с/г культур	DL на основі мультимодальних технологій злиття даних від різних джерел	IoT, UAV, SM	Параметри клімату і ґрунту та аерокосмічні зображення стану посівів	[163]
Процес предикативного моніторингу стану посівів у віддаленій місцевості з низькими показниками обробки ґрунту та з урахуванням динаміки кліматичних параметрів	Розроблено та досліджено нову систему моніторингу посівів, що використовує класифікацію даних, які отримано за допомогою комбінування технологій (UAV, IoT, SM) на основі алгоритмів ML	CNN, FRNN, SGD-BP	IoT, UAV, SM	Кліматичні параметри та аерокосмічні зображення стану посівів	[164]

Продовження табл. 1.6

Високочастотний режим моніторингу с/г виробництв та спільного використання послуг і управлінських ресурсів	Обґрунтовано підхід до комбінованого інтелектуального моніторингу с/г виробництв, що включає: розпізнавання культур і стадії їх зростання, оцінку врожайності, детектування хвороб і шкідників, генерування рекомендацій щодо внесення добрив, управління с/г технікою	CNN	WSN, UAV, SM, PD, GR	Кліматичні параметри, характеристики ґрунту, аерокосмічні зображення стану посівів	[165]
Методи, засоби та підходи до синтезу архітектури систем інтелектуалізованого моніторингу сільськогосподарських виробництв	Розроблено структурно-алгоритмічну організацію системи для smart-землеробства, що враховує локації збору та обробки даних на основі ґрунтового аналізу значної кількості реалізованих прикладних проєктів	Edge-AI, CNN	IoT, SM	Аерокосмічні зображення стану посівів і ґрунту, кліматичні параметри, наявність шкідників	[166]
Методи і технології застосування засобів штучного інтелекту щодо підвищення ефективності аналізу супутникових зображень під час досліджень динаміки стану ґрунту	Представлено результати всебічного аналізу та логічного узагальнення сучасних науково-прикладних результатів інтеграції технологій дистанційного зондування та штучного інтелекту щодо моніторингу за станом динаміки земельних ресурсів	XAI, DL	SM	Аерокосмічні зображення стану ґрунту	[167]
Прикладні аспекти та сценарії застосування технології 5G під час проєктування IoT мереж агротехнічного призначення	Проведено аналіз і логічне узагальнення технологічних засад побудови IoT систем агротехнічного призначення на основі технології 5G	AI, ML	5G-IoT, CC, FC, EC, GR	Графічні зображення та потоки відео стану посівів і ґрунту, кліматичні параметри	[168]
Методи та засоби отримання та обробки знімків високої роздільної здатності на основі глибинного машинного навчання	Розроблено підхід до уточнення супутникових знімків, що базується на методі глибинного навчання, який використовує інформацію зі знімків високої роздільної здатності, отриманих від мультиспектральних сенсорів БПЛА	ML, DL	UAV, SM	Аерокосмічні зображення стану посівів і ґрунту	[169]

У результаті аналізу та логічного узагальнення інформації [159]–[169], яку наведено в таблиці 1.6, можна зазначити, що на сьогоднішній день спостерігається стрімка динаміка розвитку технологій, які базуються на комбінуванні різних апаратних засобів за принципом дії та функціональними засадами обчислювальних технологій і відповідних програмних компонент на основі штучного інтелекту та машинного навчання. Зазначений підхід дозволяє значно підвищити ефективність розподіленого в часі й просторі збору, мережевого обміну та багаторівневої обробки вимірювальних даних (ЕС, FC та СС) різної фізичної природи (вихідні сигнали давачів, графічні й аерокосмічні зображення та потоки відео). Ще одним перспективним трендом структурно-алгоритмічної організації інформаційних технологій агромоніторингу є розгортання комплексних програмних компонент, що реалізують різні AI (XAI) та ML алгоритми на єдиній апаратній платформі. Все це, в свою чергу, дозволяє підвищити надійність та об'єктивність автоматичного генерування рекомендацій щодо агротехнічних процедур із планування посівів і збереження врожаю протягом повного циклу вирощування с/г культур. Додатково варто зазначити, що в таблиці 1.6 наведено не повний перелік сучасних досягнень щодо синтезу структурно-алгоритмічних організацій інформаційних технологій агромоніторингу, а лише певна частина, яка відображає тренд розвитку та підтверджує актуальність побудови зазначених систем і мереж шляхом комбінованого використання різних апаратних платформ із інтегрованими програмними компонентами інтерпретації вимірювальних даних із автоматизованою підтримкою прийняття рішень.

З метою локалізації перспективних дослідних завдань цього проекту було проведено додатковий аналіз сучасних досягнень у галузі інтелектуалізованих інформаційних технологій розподіленого в часі й просторі збору та обробки вимірювальних даних, що потенційно можуть бути використані під час агротехнічного моніторингу. Систематизовані результати зазначеного аналізу за критерієм отриманого техніко-функціонального ефекту відповідних науково-прикладних результатів наведено в таблиці 1.7.

Таблиця 1.7 – Результати аналізу прикладних інформаційних технологій за критерієм отриманого техніко-функціонального ефекту

Отриманий ефект	Опис ефекту	Джерело
<b>Метрологічні характеристики</b>	Покращення якості вихідних сигналів бюджетних сенсорів IoT системи екологічного моніторингу за рахунок інтеграції методів агрегації даних та ANN та LR алгоритмів	[170]
	Підвищення точності IoT системи моніторингу якості повітря за рахунок інтеграції алгоритму цифрової фільтрації на основі фільтру Калмана до мікрокомп'ютерної ланки обробки сигналів на базі Raspberry Pi	[171]
	Підвищення точності системи бездротового IoT моніторингу в додатках для розумних міст за рахунок реалізації багатоступеневого алгоритму вимірювань. Одночасно з цим підвищується енергоефективність засобів вимірювань	[172]
	Покращення точності класифікації даних у IoT сенсорних мережах, які засновані на хмарній архітектурі, що позитивно впливає на підвищення точності прогнозування та зменшення вірогідності помилкових спрацьовувань IoT систем. Одночасно з цим досягається ефект покращення показника захисту даних завдяки реалізації підходу виявлення втручань до мультимедійних IoT систем на основі DL алгоритмів	[173]
	Підвищення оперативності мережевого обміну даними між граничними пристроями та хмарним сервером, що входять до IoT систем розподіленого моніторингу. Цей ефект досягнуто завдяки підвищенню продуктивності рівня мікроконтролерів шляхом побудови цього рівня на основі кластерної архітектури з інтеграцією алгоритмів паралельних обчислень	[174]
	Підвищення точності аналізу даних дистанційного моніторингу щодо зрошення сільськогосподарських територій на основі методу посткласифікаційної корекції аерокосмічних зображень, що отримуються за допомогою безпілотних літальних апаратів	[175]
	Обґрунтування методів підвищення точності аналізу супутникових знімків із високою роздільною здатністю щодо оцінки стану посівів сільськогосподарських культур. Встановлено, що калібрування фенологічних параметрів симулятора с/г виробничих систем (APSIM) на основі показника мінливості врожайності з подальшим ансамблевим навчанням з урахуванням показників біомаси та постійного індексу врожайності підвищує продуктивність масштабованого картографа врожайності с/г культур на основі супутникових знімків (SCYM)	[176]
<b>Надійність</b>	Підхід до підвищення надійності IoT систем за рахунок інтеграції методів підвищення ефективності наступних техніко-функціональних компонент таких систем: підвищення продуктивності мережевого зв'язку, реалізація автоматичного відновлення та локального резервного копіювання даних, впровадження автоматизованого тестування програмного забезпечення та реалізація механізмів системної безпеки	[177]

	Підвищення відмовостійкості та інтегральної надійності гетерогенних IoT систем на основі нової архітектурної моделі програмного забезпечення, що реалізує обмін інтелектуальними блоками обробки даних між функціональними компонентами таких систем	[178]
	Підвищення надійності IoT додатків, що розгортаються на основі протоколу MQTT, за рахунок виявлення та зменшення аномалій у режимах функціонування таких систем завдяки інтеграції алгоритмів кореляційного аналізу зі залученням методів машинного навчання	[179]
	Покращення інтегральної надійності програмно-апаратних рішень IoT мереж завдяки аналізу й обліку поточного стану всіх компонент систем задля динамічної заміни функціональних вузлів і пристроїв, що вийшли з працездатного стану. Одночасно з цим досягається ефект підвищення енергоефективності систем завдяки обліку функціональних зв'язків непрацездатних компонент із мережевими пристроями	[180]
	Підвищення інтегральної надійності програмно-апаратних рішень IoT систем агротехнічного моніторингу за рахунок оптимізації топологічних моделей бездротових сенсорних мереж ґрунтокліматичного моніторингу. Одночасно з цим досягається ефект оптимізації зони мережевого покриття під час бездротового обміну даними за рахунок комбінованого використання різних за радіусом дії технологій	[124]
<b>Достовірність прийняття рішень</b>	Удосконалення підходів до керування процесом підтримки прийняття рішень пристроями та сервісами IoT на основі техніки оцінювання за сукупністю атрибутів даних та використання рекурентних нейронних мереж типу LSTM. У запропонованому підході багатоатрибутне оцінювання використовується для розрахунку ступеня довіри, а LSTM алгоритм – під час виявлення змін у поведінці системи на основі граничного значення довіри	[181]
	Підвищення показника достовірності прийняття рішень у IoT системах за рахунок реалізації методу, який базується на багатокритеріальному підході, який враховує показники кібер-ризиків, легкості доступу та інтегрального рівня безпеки, а також реалізує динамічне оновлення показників довіри протягом усього терміну функціонування пристрою	[182]
	Покращення показника достовірності прийняття рішень у IoT системах для закладів охорони здоров'я за рахунок реалізації та впровадження нового протоколу на основі оцінки ступеня довіри обміну інформацією між IoT пристроями медичного призначення задля створення бази знань. Розроблений IoT протокол ґрунтується на трифакторному (класифікація ризиків, надійність та ймовірність втрати здоров'я) аналізі даних та є стійким до даних вимірювального моніторингу з високим рівнем шумової складової	[183]
	Підвищення достовірності процесу підтримки прийняття рішень в умовах інтелектуалізованих технологічних процесів виробництва завдяки інтеграції методів DM шляхом оперативного кореляційного аналізу даних на основі різномірних критеріїв	[184]

	Підвищення ефективності детектування вірогідності виникнення хвороб сільськогосподарських культур під час повного циклу вирощування за рахунок програмно-апаратної реалізації системи моніторингу ґрунтокліматичних параметрів на основі WSN та XAI	[154]
<b>Енергетична ефективність</b>	Підвищення енергетичної ефективності та інтегральної продуктивності IoT мереж завдяки подовженню терміну автономної роботи вузлів WSN на основі оптимізованих методів маршрутизації мережевого трафіку із використанням протоколів адаптивної ієрархічної кластеризації з низьким енергоспоживанням	[185]
	Систематизація відомих методів і підходів до оптимізації режимів енергоспоживання WSN, що розгортаються на основі LPWAN технологій, завдяки реалізації метаевристичних методів оптимізації на базі багатофакторного аналізу	[186]
	Підвищення ефективності структурно-алгоритмічної організації IoT систем на основі оптимізації за критеріями мінімального енергоспоживання вузлів WNS та максимальної продуктивності цієї IoT мережі. Цей ефект було досягнуто шляхом розробки та впровадження протоколу Energy Harvesting MAC зі залученням методів машинного навчання	[187]
	Оптимізація режимів енергоспоживання мережевих організацій пристроїв, що входять до складу IoT систем, на основі впровадження механізмів забезпечення якості обслуговування (QoS-EO), які розгорнуто на рівні туманної мережі	[188]
<b>Захист даних</b>	Підвищення ефективності IoT мереж за критерієм кіберзахисту даних на основі розробки і впровадження схеми з полегшеною блокчейн технологією через реорганізацію лінійних блоків блокчейн у структуру бінарного дерева, що оптимізує процеси автентифікації мережевих пристроїв і захисту дани	[189]
	Покращення механізмів автентифікації та контролю доступу в IoT мережах, що базуються на WSN технологіях із підтримкою 5G. Запропоновані підходи до підвищення кіберзахисту IoT мереж охоплюють рівні мережі, додатків і підтримки	[190]
	Підвищення рівня кіберзахисту IoT систем за рахунок інтеграції механізмів симетричного шифрування / дешифрування разом із криптографічною хеш-функцією. Мережева модель, що використовувалась, базувалась на рівнях сенсорних вузлів, мережевого шлюза та вузлів головного кластера	[191]
	Підвищення інтегрального рівня кіберзахисту IoT систем і мереж завдяки розробці й використанню протоколу автентифікації, принцип дії якого базується на агрегації ступенів довіри до кожного мережевого пристрою, що обчислюються на основі алгоритмів машинного навчання	[192]
	Аналіз і систематизація сучасних підходів до підвищення інтегрального рівня кіберзахисту IoT систем і мереж агротехнічного призначення зі зазначенням прикладних сфер їх застосування і отриманого ефекту	[193]

Результати критичного аналізу та систематизації прикладних інформаційних технологій за критерієм отриманого техніко-функціонального ефекту, які наведено в таблиці 1.7, дозволили встановити актуальні світові тренди розвитку таких технологій з точки зору підвищення ефективності та інформативності моніторингу та керування агротехнічними процесами, а саме: покращення метрологічних показників (точність і швидкодія), підвищення надійності апаратно-програмних системних рішень та достовірності прийняття рішень, а також забезпечення оптимальних значень енергоспоживання та захисту даних. Основним трендом, який спостерігається та активно розвивається в світовій науковій практиці, є синтез структурно-алгоритмічних організацій IoT систем і мереж за критерієм одночасного удосконалення декількох техніко-функціональних характеристик, як наприклад, точність обробки даних та енергоспоживання [172] та точність опрацювання вимірювальних даних і кіберзахист системи [173]. Ще одним актуальним і дієвим підходом до підвищення ефективності IoT систем, в тому числі й агротехнічного призначення, є інтеграція інтелектуальних програмних компонент аналізу вимірювальних даних [154], [170], [176], [181], [183], [187], [189] на різних ієрархічних рівнях таких систем. Додатково варто зазначити, що в таблиці 1.7 наведено не повний перелік відомих науково-практичних рішень із удосконалення техніко-функціональних характеристик прикладних інформаційних технологій, а лише їх систематизацію за найбільш перспективними напрямками розвитку та досягнутим ефектом.

З метою оцінки ефективності використовуваних на сьогоднішній день підходів до планування й реалізації досліджень на різних етапах розробки прикладних інформаційних технологій агротехнічного моніторингу та підтримки прийняття рішень було проаналізовано та систематизовано відомі актуальні результати теоретичних і експериментальних досліджень у зазначеній предметній галузі. Результати щодо використовуваних методів і підходів до досліджень зі зазначенням відповідного ефекту, що був отриманий авторами відповідних наукових робіт, наведено в таблиці 1.8.

Таблиця 1.8 – Результати аналізу прикладних інформаційних технологій за критерієм використовуваних методів і підходів до теоретико-експериментальних досліджень

Методи та підходи до досліджень	Отриманий ефект	Джерело
<b>Систематизація відомих результатів (бібліографічні дослідження)</b>	Проаналізовано та описано комплексний підхід до цифровізації сільського господарства з обліком перспективних напрямків розвитку IoT, WSN та інших інфокомунікаційних технологій. Обґрунтовано перелік рекомендацій щодо системної інтеграції сучасних досягнень у галузі сенсорних, мережевих та інфокомунікаційних технологій під час цифровізації та інтелектуалізації виробничих процесів аграрних підприємств	[194]
	Представлено результати багатофакторного аналізу передових технологій та поточних досягнень у сфері інтелектуалізації сільського господарства на основі IoT технологій, а також наведено огляд комерційних продуктів на основі Інтернету речей, що були розроблені й впроваджені під час розумного землеробства. На основі проведеного огляду й аналізу визначено ключові виклики і перспективні напрями досліджень у цій галузі	[195]
	Детально описано та проаналізовано існуючі технології дистанційного (супутникового) зондування під час моніторингу виробничих процесів із вирощування польових культур на основі спектральних зображень, а також висвітлено об'єктивні переваги і недоліки кожної технології з точки зору перспектив їх прикладного використання в агротехнічних цілях	[196]
	Оцінено та детально описано ефективність використання методів мультимодального дистанційного зондування під час моніторингу сільськогосподарських культур задля оцінки якісних показників їх вирощування протягом повного циклу вегетації	[197]
	Детально проаналізовано й описано прикладний ефект підвищення стійкості та продуктивності сільськогосподарських виробництв завдяки впровадженню застосунків на основі ML, DL та AI під час вирішення задач точного землеробства	[198]
	Розглянуто та детально описано перспективні тенденції розвитку та ефективні приклади щодо розробки і застосування безпілотних літальних апаратів під час вирішення широкого спектру задач у сільськогосподарській практиці	[199]
<b>Математичне моделювання</b>	Обґрунтовано значущість методів математичного моделювання під час дослідження складних процесів у галузі сільськогосподарської інженерії. Також проаналізовано приклади розробки математичних моделей процесів вирощування с/г культур, зрошення ґрунту, моніторинг впливу кліматичних параметрів, детектування шкідників і внесення добрив до ґрунту	[200]

	Обґрунтовано методами математичного моделювання підхід до оптимального розміщення функціональних вузлів і пристроїв підсистеми польового збору вимірювальних даних під час дистанційного моніторингу агротехнічних процесів на основі IoT технологій	[201]
	Методами математичного моделювання оцінено та проаналізовано кількісні та якісні характеристики систем автоматичного контролю агротехнічного призначення на основі обліку процесів, що протікають в середовищі «сільськогосподарська культура – ґрунт», а також техніко-функціональні характеристики контрольно-вимірювальних приладів і виконавчих механізмів	[202]
	Розроблено предикативну математичну модель щодо оцінки втрат продукції в агротехнічній практиці галузі рослинництва, яка дозволяє визначати потенційні втрати продукції через несвоєчасне виконання агротехнічних робіт, що дає змогу локалізувати критичні агротехнічні процедури та, як наслідок, обґрунтувати відповідні управлінські рішення	[203]
	Методами математичного моделювання досліджено динамічні характеристики сільськогосподарських культур задля прогнозування їх продуктивності й врожайності на основі результатів дистанційного моніторингу агроєкосистем	[204]
	Розроблено та досліджено математичну модель процесу підтримки прийняття рішень щодо вдосконалення процедури дозування поживних речовин та пестицидів під час вирощування сільськогосподарських культур в умовах малих фермерських господарств.	[205]
	Досліджено засобами математичного моделювання на основі чисельних методів динамічні закономірності впливу шкідників, факторів навколишнього середовища та агротехнічних процедур зі збереження врожаю на ефективність вирощування сільськогосподарських культур за критерієм щільності їх біомаси	[206]
<b>Комп'ютерний експеримент</b>	Розроблено систему моніторингу технологічних процесів сільськогосподарських підприємств на основі IoT технологій із використанням LoRaWAN і ThingSpeak, а також виконано дослідження цієї системи методами комп'ютерного моделювання та лабораторних випробувань	[207]
	Досліджено системну платформу агротехнічного моніторингу, що базується на технологіях IoT, хмарних обчислень та інтелектуального аналізу даних. Методами комп'ютерного моделювання з подальшими експериментальними випробуваннями доведено можливість оптимізації показників надійності, безпеки та вартості розроблюваної системи	[208]

	Розроблено та досліджено методами комп'ютерного моделювання з експериментальними випробуваннями систему моніторингу с/г призначення на основі IoT, що реалізує алгоритми виявлення, оцінки, перевірки стиглості та ідентифікації інфікованих овочевих культур	[209]
	Обґрунтовано вимоги до оптимізації структурно-алгоритмічної організації систем ґрунтокліматичного IoT моніторингу сільськогосподарського призначення методами комп'ютерного експерименту з використанням пакетів прикладних програм Arduino IDE, Proteus, Matlab & Simulink та CupCarbon	[124], [126], [210]
	Проведено дослідження та проаналізовано результати впровадження комп'ютерних моделей електронного сільського господарства в країнах, що розвиваються, на основі передових практик Європейських країн у галузі інформаційних і комп'ютерних технологій	[211]
	Досліджено нові підходи до класифікації IoT технологій с/г призначення на основі багатофакторного аналізу з обліком метрик продуктивності стаціонарних і мобільних мережеских сценаріїв на основі стандарту 6LowPAN. Результати отримано методами комп'ютерного експерименту з використанням симулятора COOJA	[212]
<b>Натурні експериментальні випробування</b>	Проведено експериментальні випробування IoT технології с/г моніторингу, яка базується на інтелектуальних давачах, приводах керування технологічними процесами та хмарному сервері. Розроблена система базується на модульному принципі з підтримкою прийняття рішень на основі критеріїв оптимального використання енергії та ресурсів	[213]
	Запропоновано серійний інфокомунікаційний модуль із низьким енергоспоживанням, великим радіусом дії та низькою вартістю, що використовується під час вирішення задач агротехнічного моніторингу на великих відстанях. Запропонована структурно-алгоритмічна організація є масштабованою завдяки реалізації деревовидної архітектури	[214]
	Розроблено надійний фреймворк, до якого інтегровано підходи IoT, методи інтелектуального аналізу даних і хмарні технології, що дало змогу експериментально підтвердити ефективність розробки під час підвищення продуктивності агротехнічних процесів, покращення керування водними ресурсами та прогнозування врожаю в режимі реального часу	[215]
	Розроблено комп'ютеризовану метеостанцію агротехнічного моніторингу на основі бюджетної компонентної бази з можливістю онлайн детектування сукупності інформативних ґрунтокліматичних параметрів на основі технології туманних обчислень. Проведено довготривалі експериментальні випробування системи, що дозволило обґрунтувати та програмно реалізувати алгоритми підвищення надійності мережевого обміну даними	[125], [216]

Результати аналізу прикладних інформаційних технологій за критерієм використовуваних методів і підходів до теоретико-експериментальних досліджень, які наведено в таблиці 1.8, дозволили підтвердити масштабність та актуальність досліджень із розробки та впровадження системних і мережових рішень цифрових, інфокомунікаційних і комп'ютерно-орієнтованих технологій до агротехнічної галузі під час наукового обґрунтування шляхів підвищення ефективності виробничих процесів із вирощування сільськогосподарських культур. Також було доведено значну популярність та високу ефективність застосування методів комп'ютерного експерименту під час проектування інформаційних технологій ґрунтокліматичного моніторингу для умов сільськогосподарських підприємств рослинництва відкритого ґрунту незалежно від апаратних і програмних компонент, на яких ці технології реалізуються. Це дозволяє оптимізувати структурно-алгоритмічну організацію та відповідні програмно-апаратні рішення таких технологій на ранніх етапах проектування. Додатковим трендом, який був встановлений у результаті проведеного аналізу, є стрімке зростання кількості наукових публікацій, що присвячені бібліографічним дослідженням сучасних досягнень у галузі апаратних і програмних рішень агротехнічного моніторингу на окремих ієрархічних рівнях (сенсорний, мережовий, застосунки для обробки та візуалізації даних) із їх подальшою мережевою інтеграцією. Це свідчить про сталу динаміку розвитку компонентної бази та відриває широкі можливості під час їх системної інтеграції у рамках єдиної архітектури, але й одночасно з цим обумовлює значні виклики дослідного характеру щодо оптимізованого розподілу функціоналу та забезпечення сумісності всіх ієрархічних рівнів таких інформаційних систем і мереж.

Також необхідно зазначити, що в таблиці 1.8 наведено не повний перелік відомих науково-прикладних рішень інформаційних технологій за критерієм використовуваних методів і підходів щодо їх теоретико-експериментальних досліджень, а лише відповідну систематизацію за потенційними напрямками використання в цьому дослідженні.

Результати критичного аналізу та логічного узагальнення сучасних науково-прикладних досягнень із підвищення ефективності технологічних і виробничих процесів аграрної галузі, які наведено в цьому підрозділі, дозволили зробити висновок щодо актуальності й необхідності проведення подальших досліджень із обґрунтування структурно-алгоритмічної організації інформаційної технології ґрунтокліматичного моніторингу на основі комплексної архітектурної інтеграції сучасних апаратно-програмних рішень наземних і супутникових вимірювань зі залученням методів штучного інтелекту та машинного навчання під час агрегування й обробки даних, а також автоматизованої підтримки прийняття рішень щодо оптимізації агротехнічних процедур, що дозволить підвищити ефективність і продуктивність технологічних процесів аграрних виробництв під час повного циклу вирощування сільськогосподарських культур в умовах відкритого ґрунту.

#### **1.4 Формулювання наукової проблеми та обґрунтування перспективних напрямів досліджень**

На підставі проведених бібліографічних і аналітичних досліджень щодо сучасного стану наукових досліджень і практичних розробок зі створення інтелектуальних інформаційних технологій для сталого вирощування сільськогосподарських культур встановлено, що у теперішній час спостерігається стала світова динаміка з розробки системних і мережевих рішень цифровізації та інтелектуалізації технологічних і виробничих процесів аграрних підприємств завдяки інтеграції високопрецизійних, надійних і оперативних комп'ютерно-орієнтованих, інфокомунікаційних, програмних та сенсорних технологій. З одного боку, це обумовлено значною наукомісткістю проблеми синтезу архітектури апаратно-програмних рішень комплексного ґрунтокліматичного моніторингу з обліком значної кількості інформативних параметрів і дестабілізуючих факторів, а з іншого, – значним потенціальним впливом на успіх вирішення низки соціально-економічних завдань, таких як

підвищення економічної та екологічної ефективності сільськогосподарських виробництв, забезпечення достатнього рівня продовольчої безпеки, формування інвестиційної привабливості аграрних підприємств та інше.

Прикладні аспекти застосування інформаційних технологій, як наукоємність і масштабність сучасного рослинництва відкритого ґрунту, які задекларовано всесвітньовизнаною організацією FAO на підставі узагальнення багаторічного експертного досвіду, диктують тенденції до вирішення методологічних питань зі синтезу структурно-алгоритмічних організації та реалізації інтелектуальних програмно-апаратних рішень комплексного мережевого ґрунтокліматичного моніторингу стану аналізованих середовищ із підтримкою прийняття рішень щодо обґрунтування підходів до оптимізації використання земельних ресурсів під час посівів і планування агротехнічних процедур із підвищення стресосійкості вирощуваних с/г культур під час повного циклу їх вирощування. У такому випадку відомі результати наукових досліджень і прикладних розробок потребують подальшого розвитку в контексті обґрунтування теорії якісного переходу від детектування розподілених фізико-хімічних параметрів і фрагментарного аналізу окремих фізичних і біологічних процесів, що протікають під час вирощування с/г культур, до комплексного мережевого моніторингу ґрунтокліматичного стану сільськогосподарських територій із автоматизованою підтримкою прийняття рішень на основі апаратно-програмних засобів і комп'ютерних моделей інтелектуальної трансформації даних. Все це обумовлює певний дисбаланс між теорією та практикою, що полягає у фрагментарності відомих результатів наукових досліджень по відношенню до актуальних вимог прикладного застосування інформаційних технологій агротехнічного призначення.

Отже, науково-прикладна проблема, на вирішення якої спрямовано дослідження цієї монографії, є актуальною і полягає в розвитку теорії створення й використання програмно-апаратних рішень інтелектуальних інформаційних і комп'ютерно-орієнтованих технологій сільськогосподарського призначення завдяки розробці методів та реалізації комп'ютерних моделей і

засобів комплексного агрегування, мережевого обміну, трансформації та інтерпретації розподілених вимірювальних даних щодо впливу ґрунтокліматичних параметрів на ефективність вирощування с/г культур у режимі реального часу з підтримкою прийняття рішень на основі концептуальних положень Інтернету речей, супутникового моніторингу, штучного інтелекту та машинного навчання, що дозволить підвищити показники раціонального використання задіяних площ та стресостійкості сільськогосподарських культур під час повного циклу їх вирощування, що, в свою чергу, позитивно впливає на продовольчу безпеку України, її експортний потенціал та інвестиційну привабливість вітчизняного аграрного сектору.

Деталізація вищезазначеної науково-прикладної проблеми може бути виконана шляхом опису обмежень відомих наукових і практичних результатів щодо побудови програмно-апаратних мережевих рішень моніторингу ґрунтокліматичного стану сільськогосподарських підприємств рослинництва відкритого ґрунту, які описано вище, а саме:

– побудова відомих програмно-апаратних рішень систем моніторингу агротехнічного призначення за принципом фрагментарності без обліку комплексного підходу до реалізації процедур агрегації, мережевого обміну та інтелектуальної трансформації вимірювальних даних, що генеруються різними технологіями (супутниковий і наземний моніторинг);

– обмеженість результатів об'єктивного розподілу функціоналу між структурними та алгоритмічними компонентами програмно-апаратних рішень комплексного моніторингу ґрунтокліматичного стану сільськогосподарських підприємств із урахуванням їх інтегральної сервісної взаємодії, а саме: первинна оцінка придатності ґрунтів до вирощування с/г культур під час планування посівів, предикативний моніторинг показників стресостійкості с/г культур під час повного циклу їх вегетації та детектування наявності хвороб і шкідників в режимі реального часу під час оперативного планування агротехнічних заходів зі збереження врожаю;

– недостатній ступінь проробленості питань щодо впливу динаміки

грунтокліматичних показників на ефективність ідентифікації та розробки комп'ютерних моделей оцінки та прогнозування стану сільськогосподарських об'єктів рослинництва відкритого ґрунту;

– недостатній ступінь обґрунтованості формалізованого опису впливу сукупності ґрунтокліматичних параметрів на прогнозування вірогідності виникнення специфічних видів хвороб сільськогосподарських культур під час повного циклу їх вирощування;

– недостатність теоретико-методологічного обґрунтування мережевої взаємодії сенсорних, мікропроцесорних та інфокомунікаційних технологій під час реалізації наземного IoT моніторингу розподілених у часі й просторі ґрунтокліматичних параметрів з обліком критерію масштабованості сучасних с/г підприємств рослинництва відкритого ґрунту;

– недостатній ступінь проробленості питань інтеграції програмних компонент інтелектуальної трансформації даних із підтримкою прийняття рішень щодо інтегрального впливу ґрунтокліматичних параметрів на ефективність вирощування с/г культур до ланки низького рівня (периферійні мікропроцесорні пристрої), що, в свою чергу, обмежує прикладні засади впровадження інформаційних технологій на основі туманної архітектури до виробничих процесів аграрних підприємств.

Таким чином, основні техніко-функціональні засади, що мають бути враховані під час створення програмно-апаратних рішень і комп'ютерних моделей інтелектуальних інформаційних технологій ґрунтокліматичного моніторингу агротехнічного призначення, є таким: системність і функціонально-метрологічна задовільність агрегації розподілених у часі й просторі вимірювальних даних (бездротові сенсорні мережі та засоби дистанційного супутникового зондування); надійність і оперативність мережевого обміну даними; адаптивність і предикативність обробки результатів моніторингу; прецизійність і достовірність підтримки прийняття рішень; апаратна та програмна сумісність розроблюваних функціональних компонент із використовуваними на сьогоднішній день технологіями в

агротехнічній практиці; масштабованість і адаптивність застосування до різних агрокліматичних зон.

Отже, основна мета цієї роботи полягає в розробці програмно-апаратного забезпечення та комп'ютерних моделей інтелектуальних інформаційних технологій онлайн моніторингу ґрунтокліматичного стану с/г виробництв рослинництва відкритого ґрунту з автоматизованою підтримкою прийняття рішень, що можуть бути використані під час обґрунтування науково-прикладних положень із раціонального використання площ і ресурсів та підвищення стресостійкості с/г культур під час повного циклу їх вирощування.

Об'єктом дослідження є нестационарні процеси агрегації, мережевого обміну та інтелектуалізованої інтерпретації розподілених вимірювальних даних щодо ґрунтокліматичного стану с/г підприємств рослинництва відкритого ґрунту.

Предметом дослідження є методи, комп'ютерні моделі та засоби інтелектуалізованого моніторингу ґрунтокліматичного стану агротехнічних об'єктів галузі рослинництва відкритого ґрунту.

Таким чином, на підставі проведеного аналізу з урахуванням локалізації науково-прикладної проблеми, мети, об'єкта і предмета досліджень цієї монографії було встановлено необхідність подальшого розвитку й удосконалення теоретичних засад і прикладних підходів із обґрунтування інформаційно-вимірювального, програмно-апаратного і алгоритмічного забезпечення під час побудови комплексних системних рішень інтелектуальних технологій із автоматизованою підтримкою прийняття рішень для сталого вирощування сільськогосподарських культур в умовах відкритого ґрунту. На підставі вищесказаного, а також з обліком актуальних світових тенденцій розвитку інформаційних і комп'ютерно-орієнтованих технологій, які були детально проаналізовані й систематизовані в цьому розділі, було обґрунтовано концептуальний підхід до вирішення заявленої науково-прикладної проблеми, як показано нижче на рисунку 1.27.

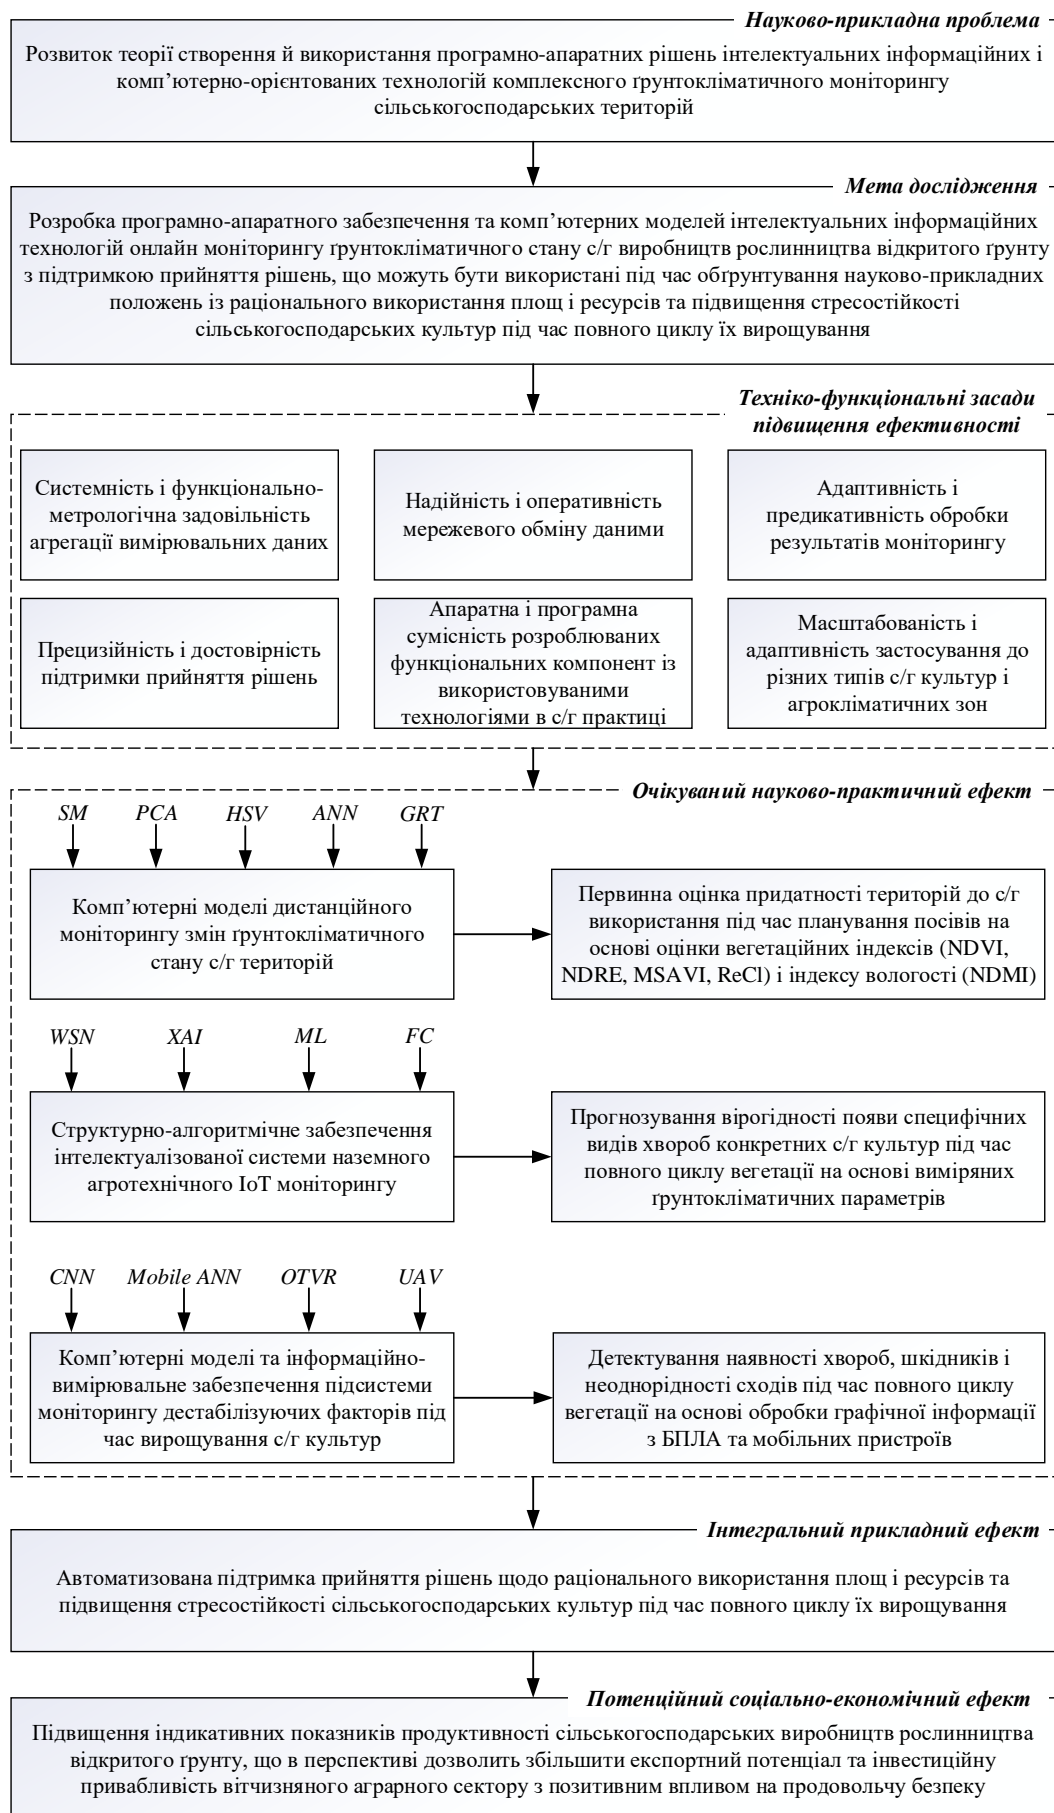


Рисунок 1.27 – Концепція вирішення заявленої науково-прикладної проблеми

Відповідно до обґрунтованих вище напрямів перспективних досліджень і запропонованого концептуального підходу (рис. 1.27) сформульовано такі дослідницькі завдання:

– провести бібліографічний огляд, критичний аналіз і логічне узагальнення сучасного стану та тенденцій розвитку інтелектуальних інформаційних технологій ґрунтокліматичного моніторингу та дотичних із ними, з точки зору, впливу їх техніко-функціональних характеристик на ефективність вирощування сільськогосподарських культур;

– обґрунтувати компоненту базу та базові функції мережевого рішення системи ґрунтокліматичного моніторингу агротехнічного призначення на основі інтеграції різних технологій (супутниковий і наземний моніторинг);

– розвинути науково-прикладні положення зі структурно-алгоритмічного синтезу програмно-апаратного забезпечення інтелектуальних технологій агротехнічного онлайн-моніторингу ґрунтокліматичних параметрів сільськогосподарських виробництв рослинництва відкритого ґрунту;

– розробити й валідувати комп'ютерні моделі та програмне забезпечення предикативної аналітики щодо впливу ґрунтокліматичних факторів на ефективність вирощування сільськогосподарських культур;

– розробити метод цифрової обробки сигналів під час мережевого обміну та агрегування результатів вимірювань ґрунтокліматичних параметрів;

– розробити геопросторові методи та комп'ютерну модель моніторингу змін ґрунтокліматичних факторів із підтримкою прийняття рішення щодо первинної придатності територій до сільськогосподарського використання;

– реалізувати макетний зразок і провести експериментальні випробування інтелектуалізованої інформаційної технології ґрунтокліматичного моніторингу, а також довести ефективність запропонованих програмно-апаратних рішень та обґрунтувати перспективні напрями з їх упровадження і подальшого розвитку.

Задля досягнення поставленої мети та вирішення зазначеної науково-прикладної проблеми дослідження цього проєкту мають бути проведені на основі принципу декомпозиції дослідного завдання: на першому етапі мають

бути розроблені та досліджені методи, моделі й засоби ґрунтокліматичного моніторингу на окремих технологічних рівнях наземного й супутникового моніторингу, а на другому – обґрунтовані теоретико-прикладні засади інтеграції результатів першого етапу в рамках єдиної інтелектуалізованої інформаційної технології. В основу науково-прикладних досліджень цього проекту покладено підхід, що ґрунтується на комплексному вирішенні проблеми створення і системної інтеграції прикладних інтелектуальних інформаційних і комп'ютерно-орієнтованих технологій сільськогосподарського призначення з обліком сьогоденних світових досягнень у сферах Інтернету речей, аналізу великих даних, штучного інтелекту, нечіткої логіки, цифрових методів аналізу супутникових даних, прогнозування часових рядів результатів спостережень і машинного навчання. Реалізація такого підходу дозволить підвищити інтегральну достовірність, прецизійність і оперативність підтримки прийняття рішень щодо раціонального використання ресурсів та підвищення стресостійкості польових культур під час повного циклу їх вирощування.

## **1.5 Висновки до першого розділу**

1. Проаналізовано світові та вітчизняні тенденції сталого розвитку сільськогосподарської галузі рослинництва відкритого ґрунту. На підставі цього встановлено глобальний тренд динамічного зростання оброблюваних сільськогосподарських територій та значного дестабілізуючого впливу сукупності факторів і процесів на показники врожайності сільськогосподарських культур. Також визначено орієнтовні кількісні оцінки негативного впливу війни в Україні на скорочення площ оброблюваних сільськогосподарських територій (зменшення на 20,2 % у 2022 р. у порівнянні з 2021 р.) та, як наслідок, різкого зниження врожайності стратегічних зернових культур (пшениця, соняшник і кукурудза) на 26,8 % у 2022 р. у порівнянні з 2021 р. Обґрунтовано загальні тенденції використання сучасних інфокомунікаційних та комп'ютерних технологій під час сталого розвитку

сільського господарства в глобальному контексті.

2. Проведено систематизований аналіз технологічних засад цифровізації та інтелектуалізації сільськогосподарської галузі. На підставі цього визначено ключові фактори модернізації виробничих процесів аграрної галузі рослинництва та обґрунтовано узагальнену функціональну схему інформаційно-орієнтованого підходу до провадження діяльності рослинництва відкритого ґрунту. Встановлено основні техніко-функціональні характеристики сучасних технологій ґрунтокліматичного моніторингу (супутниковий, наземний IoT та роботизовані пристрої), що дозволило обґрунтувати їх функціональне призначення в архітектурі досліджуваної інформаційної технології.

3. Детально проаналізовано та логічно узагальнено сучасні науково-прикладні досягнення з підвищення ефективності технологічних процесів аграрної галузі на основі критеріїв функціонального призначення, структурно-алгоритмічної організації, техніко-функціонального ефекту та використовуваних методів і підходів щодо досліджень. Це дозволило обґрунтувати базові теоретико-прикладні засади досліджень із розробки структурно-алгоритмічної організації інформаційної технології ґрунтокліматичного моніторингу на основі архітектурної інтеграції програмно-апаратних рішень наземних і супутникових вимірювань із залученням методів штучного інтелекту та машинного навчання під час агрегування й обробки даних, а також автоматизованої підтримки прийняття рішень щодо оптимізації агротехнічних процедур, що дозволить підвищити ефективність технологічних процесів аграрних виробництв під час вирощування польових культур.

4. Обґрунтовано перспективні напрями досліджень із подальшого розвитку інтелектуалізованих інформаційних технологій комплексного моніторингу ґрунтокліматичного стану сільськогосподарських підприємств рослинництва. У результаті цього сформульовано науково-прикладну проблему, основну мету, об'єкт, предмет і завдання досліджень, які спрямовано на обґрунтування шляхів досягнення важливого соціально-економічного ефекту підвищення рівня продовольчої безпеки України у воєнний і повоєнний час.

## Список використаних джерел до першого розділу

1. ITU and FAO. Status of Digital Agriculture in 18 countries of Europe and Central Asia: Geneva, 2020. 79 p. URL: <https://fao.org/3/ca9578en/CA9578EN.pdf>
2. Ceccarelli, T., Chauhan, A., Rambaldi, G., Kumar, I., Cappello, C., Janssen, S., McCampbell, M. Leveraging automation and digitalization for precision agriculture: Evidence from the case studies. Background paper for The State of Food and Agriculture 2022. FAO Agricultural Development Economics Technical Study No. 24: Rome, FAO, 2022. 120 p. <https://doi.org/10.4060/cc2912en>
3. EU Science Hub: Agricultural monitoring. Retrieved from: [https://joint-research-centre.ec.europa.eu/scientific-activities-z/agricultural-monitoring\\_en](https://joint-research-centre.ec.europa.eu/scientific-activities-z/agricultural-monitoring_en) (accessed on October 10, 2024).
4. National Economic Strategy 2030. (in Ukrainian). Retrieved from: <https://nes2030.org.ua/> (accessed on October 12, 2024).
5. FAO: Agricultural production statistics 2000–2021, 2022: Rome, 2022. 17 p. URL: <https://www.fao.org/3/cc3751en/cc3751en.pdf>
6. FAOSTAT: Food and agriculture organization of the united nations. Retrieved from: <https://www.fao.org/faostat/en/#data/QCL> (accessed October 12, 2024).
7. AgroNews. (in Ukrainian). Retrieved from: <https://agronews.ua/news/nazvano-nayrentabelnishi-polovi-kultury-iaki-varto-vyroshchuvaty-v-ukraini/> (accessed on October 14, 2024).
8. Agrospray: The most popular crops for sowing. (in Ukrainian). Retrieved from: <https://agrospray.in.ua/ua/a474421-samye-vostrebovannye-kultury.html> (accessed on October 14, 2024).
9. European Commission: European industrial strategy. Retrieved from: [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/europe-fit-digital-age/european-industrial-strategy\\_en](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/europe-fit-digital-age/european-industrial-strategy_en) (accessed on October 10, 2024).
10. Dhanaraju, M., Chenniappan, P., Ramalingam, K., Pazhanivelan, S., Kaliaperumal, R. Smart Farming: Internet of Things (IoT)-Based Sustainable

Agriculture. *Agriculture*, 2022, Vol. 12 (10):1745. P. 1–26. <https://doi.org/10.3390/agriculture12101745>

11. Bruinsma, J.. *World agriculture: towards 2015/2030: an FAO perspective*: London, Earthscan Publications Ltd., 2003. 432 p. URL: <https://fao.org/3/y4252e/y4252e.pdf>.

12. *Our World in Data: Population Growth*. Retrieved from: <https://ourworldindata.org/population-growth> (accessed on October 15, 2024).

13. Hernandez-Ochoa, I.M., Gaiser, T., Kersebaum, K.-C., Webber, H., Seidel, S.J., Grahmann, K., Ewert, F. Model-based design of crop diversification through new field arrangements in spatially heterogeneous landscapes. A review. *Agron. Sustain.*, 2022, Dev. 42 (74). P. 1–25. <https://doi.org/10.1007/s13593-022-00805-4>

14. Jang, G., Kim, D.-W., Kim, H.-J., Chung, Y.S. Short Communication: Spatial Dependence Analysis as a Tool to Detect the Hidden Heterogeneity in a Kenaf Field. *Agronomy*, 2023, Vol. 13 (2):428. P. 1–8. <https://doi.org/10.3390/agronomy13020428>

15. Karunathilake, E.M.B.M., Le, A.T., Heo, S., Chung, Y.S., Mansoor, S. *The Path to Smart Farming: Innovations and Opportunities in Precision Agriculture*. *Agriculture*, 2023, Vol. 13 (8):1593, 1–26. <https://doi.org/10.3390/agriculture13081593>

16. Santos Valle, S., Kienzle, J. *Agriculture 4.0 – Agricultural robotics and automated equipment for sustainable crop production*. *Integrated Crop Management 24*: Rome, FAO, 2020. 40 p. URL: <https://www.fao.org/3/cb2186en/cb2186en.pdf>

17. *Dragonfly Aerospace: 7 Applications of Remote Sensing in Agriculture*. Retrieved from: <https://dragonflyaerospace.com/remote-sensing-in-agriculture-what-are-some-applications/> (accessed on October 16, 2024).

18. Weiss, M., Jacob, F., Duveiller, G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 2020, Vol. 236. P. 1–19. <https://doi.org/10.1016/j.rse.2019.111402>

19. Atzberger, C. *Advances in Remote Sensing of Agriculture: Context*

Description, Existing Operational Monitoring Systems and Major Information Needs. *Rem. Sens.*, 2013, Vol. 5 (2). P. 949–981. <https://doi.org/10.3390/rs5020949>

20. Adhikary, S., Biswas, B., Kumar Naskar, M., Mukherjee, B., Pratap Singh, A., Atta, K. *Remote Sensing for Agricultural Applications*. IntechOpen, 2023. 116 p. <https://doi.org/10.5772/intechopen.106876>

21. Borgogno-Mondino, E., Tarantino, E., Capolupo, A. *Remote Sensing in Agriculture: State-of-the-Art*. MDPI Books, 2022. 220 p. <https://doi.org/10.3390/books978-3-0365-5484-6>

22. Xu, J., Gu, B., Tian, G. Review of agricultural IoT technology. *Artificial Intelligence in Agriculture*, 2022. Vol. 6. P. 10–22. <https://doi.org/10.1016/j.aiia.2022.01.001>

23. Ndjuluwa, L.N.P, Adebisi, J.A., Dayoub, M. *Internet of Things for Crop Farming: A Review of Technologies and Applications*. *Commodities*, 2023, Vol. 2 (4). P. 367–381. <https://doi.org/10.3390/commodities2040021>

24. Pathmudi, V.R., Khatri, N., Kumar, S., Abdul-Qawy, A.S.H., Kumar Vyas, A. A systematic review of IoT technologies and their constituents for smart and sustainable agriculture applications. *Scientific African*, 2023, Vol. 19. P. 1–14. <https://doi.org/10.1016/j.sciaf.2023.e01577>

25. Abu, N.S., Bukhari, W.M., Ong, C.H., Kassim, A.M., Izzuddin, T.A., Sukhaimie, M.N., Norasikin, M.A., Rasid, A.F.A. *Internet of Things Applications in Precision Agriculture: A Review*. *Journal of Robotics and Control*, 2023, Vol. 3 (3). P. 338–347. <https://doi.org/10.18196/jrc.v3i3.14159>

26. Sujatha, P., Sheeba, S. *IOT Based Agriculture – A Review*. *Int. J. Curr. Microbiol. App. Sci.*, 2020, Vol. 9 (7). P. 708–713. <https://doi.org/10.20546/ijcmas.2020.907.081>

27. Kim, W.S., Lee, W.S., Kim, Y.J. A Review of the Applications of the Internet of Things (IoT) for Agricultural Automation. *J. Biosyst. Eng.*, 2020, Vol. 45. P. 385–400. <https://doi.org/10.1007/s42853-020-00078-3>

28. Ping H., Wang J.H., Ma Z.H., Du Y.F. Mini-review of application of IoT technology in monitoring agricultural products quality and safety. *Int. J. Ag. & Biol.*

Eng., 2018, Vol. 11 (5). P. 35–45. <https://doi.org/10.25165/j.ijabe.20181105.3092>

29. Pullo, S., Pareschi, R., Piantadosi, V., Salzano, F., Carlini, R. Integrating IOTA's Tangle with the Internet of Things for Sustainable Agriculture: A Proof-of-Concept Study on Rice Cultivation. *Informatics*, 2024, Vol. 11 (1):3. P. 1–20. <https://doi.org/10.3390/informatics11010003>

30. Recommendation ITU-T Y.2060. Retrieved from: [https://www.itu.int/rec/dologin\\_pub.asp?lang=s&id=T-REC-Y.2060-201206-I!!PDF-E&type=items](https://www.itu.int/rec/dologin_pub.asp?lang=s&id=T-REC-Y.2060-201206-I!!PDF-E&type=items) (accessed on November 19, 2024).

31. El Hakim, A. Internet of Things (IoT) System Architecture and Technologies. White Paper, 2018. P. 1–5. <https://doi.org/10.13140/RG.2.2.17046.19521>

32. Sciullo, L., Gigli, L., Montori, F., Trotta, A., Felice, M.D. A Survey on the Web of Things. *IEEE Access*, 2022, Vol. 10. P. 47570–47596. <https://doi.org/10.1109/ACCESS.2022.3171575>

33. Del-Pozo-Punal, E., Garcia-Carballeira, F., Camarmas-Alonso, D. A scalable simulator for cloud, fog and edge computing platforms with mobility support. *Future Generation Computer Systems*, 2023, Vol. 144. P. 117–130. <https://doi.org/10.1016/j.future.2023.02.010>

34. Digiteum: Difference between Cloud, Fog and Edge Computing in IoT. Retrieved from: <https://www.digiteum.com/cloud-fog-edge-computing-iot/> (accessed on November 22, 2024).

35. Jaidka, H., Sharma, N., Singh, R. Evolution of IoT to IIoT: Applications & Challenges. In: *Proceedings of the International Conference on Innovative Computing & Communications*, 2020. P. 1–6. <http://dx.doi.org/10.2139/ssrn.3603739>

36. Goundar, S., Bhardwaj, A., Nur, S. S., Kumar, S. S., Harish, R. Industrial Internet of Things: Benefit, Applications, and Challenges. In: *Innovations in the Industrial Internet of Things (IIoT) and Smart Factory*, 2021. P. 133–148. <https://doi.org/10.4018/978-1-7998-3375-8.ch010>

37. Perekrest, A., Mamchur, D., Zavaleev, A., Vadurin, K., Malolitko, V., Bakharev, V. Web-Based Technology of Intellectual Analysis of Environmental Data

of an Industrial Enterprise. In: 2023 IEEE 5th International Conference on Modern Electrical and Energy System, 2023. P. 1–7. <https://doi.org/10.1109/MEES61502.2023.10402523>.

38. Gao, Z., Ke, M., Qiao, L., Mei, Y. Massive IoT Access for 6G: Singapore, Springer Nature, 2022. 174 p. <https://doi.org/10.1007/978-981-19-2704-1>

39. Ghosh, A., Chakraborty, D., Law, A. Artificial intelligence in Internet of things. CAAI Trans. Intell. Technol., 2028, Vol. 3. P. 208–218. <https://doi.org/10.1049/trit.2018.1008>

40. Mokin, V.B., Pradivliannyi, M.G. Machine Learning, Intelligent Data Analysis and Artificial Intelligence of Things: electronic textbook [Electronic resource]. Vinnytsia: VNTU, 2024. 230 p. URL: <https://ir.lib.vntu.edu.ua/handle/123456789/43780>

41. Yvoz, S., Petit, S., Biju-Duval, L., Cordeau, S. A framework to type crop management strategies within a production situation to improve the comprehension of weed communities. European Journal of Agronomy, 2020, Vol. 115. P. 1–10. <https://doi.org/10.1016/j.eja.2020.126009>

42. Oliveira, R.C.d., Silva, R.D.d.Se. Artificial Intelligence in Agriculture: Benefits, Challenges, and Trends. Applied Sciences, 2023, Vol. 13 (13):7405. P. 1–17. <https://doi.org/10.3390/app13137405>

43. Singh, P., Kaur, A. Chapter 2 – A systematic review of artificial intelligence in agriculture. In: Cognitive Data Science in Sustainable Computing, Deep Learning for Sustainable Agriculture, 2022. P. 57–80. <https://doi.org/10.1016/B978-0-323-85214-2.00011-2>

44. Veeragandham, S., Santhi, H. A Review on the Role of Machine Learning in Agriculture. Scalable Computing: Practice and Experience, 2020, Vol. 21 (4). P. 583–589. <https://doi.org/10.12694/scpe.v21i4.1699>

45. Benos, L., Tagarakis, A.C., Dolias, G., Berruto, R., Kateris, D., Bochtis, D. Machine Learning in Agriculture: A Comprehensive Updated Review. Sensors, 2021, Vol. 21 (11):3758. P. 1–55. <https://doi.org/10.3390/s21113758>

46. Liakos, K.G., Busato, P., Moshou, D., Pearson, S., Bochtis, D. Machine

Learning in Agriculture: A Review. *Sensors*, 2018, Vol. 18 (8):2674. P. 1–29. <https://doi.org/10.3390/s18082674>

47. Attri, I., Awasthi, L.K., Sharma, T.P., Rathee, P. A review of deep learning techniques used in agriculture. *Ecological Informatics*, 2023, Vol. 77. P. 1–22. <https://doi.org/10.1016/j.ecoinf.2023.102217>

48. Elavarasan, D., Vincent, D.R., Sharma, V., Zomaya, A.Y., Srinivasan, K. Forecasting yield by integrating agrarian factors and machine learning models: A survey. *Computers and Electronics in Agriculture*, 2018, Vol. 155. P. 257–282. <https://doi.org/10.1016/j.compag.2018.10.024>

49. Anagnostis, A., Papageorgiou, E., Bochtis, D. Application of Artificial Neural Networks for Natural Gas Consumption Forecasting. *Sustainability*, 2020, Vol. 12 (16):6409. P. 1–29. <https://doi.org/10.3390/su12166409>

50. Zheng, A., Casari, A. *Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists*: Sebastopol, O'Reilly Media Inc., 2020. 215 p. URL: <https://www.oreilly.com/library/view/feature-engineering-for/9781491953235/>

51. Lowenberg-DeBoer, J., Huang, I.Y., Grigoriadis, V., Blackmore, S. Economics of robots and automation in field crop production. *Precision Agriculture*, 2020, Vol. 21. P. 278–299. <https://doi.org/10.1007/s11119-019-09667-5>

52. Bechar, A., Vigneault, C. Agricultural robots for field operations. Part 2: Operations and systems. *Biosystems Engineering*, 2020, Vol. 153. P. 110–128. <https://doi.org/10.1016/j.biosystemseng.2016.11.004>

53. Bac, C.W., Hemming, J., Tuijl, B.A.J., Barth, R., Wais, E., Henten, E.J. Performance Evaluation of a Harvesting Robot for Sweet Pepper. *J. Field Robotics*, 2017, Vol. 34. P. 1123–1139. <https://doi.org/10.1002/rob.21709>

54. Degieter, M., De Steur, H., Tran, D., Gellynck, X., Schouteten, J.J. Farmers' acceptance of robotics and unmanned aerial vehicles: A systematic review. *Agr. Journal*, 2023, Vol. 115. P. 2159–2173. <https://doi.org/10.1002/agj2.21427>

55. Megalingam, R.K., Kuttankulangara Manoharan, S., Mohan, S.M., Vadivel, S.R.R., Gangireddy, R., Ghanta, S., Kotte, S., Perugupally, S.T.,

Sivanantham, V. Amaran: An Unmanned Robotic Coconut Tree Climber and Harvester. *EEE/ASME Transactions on Mechatronics*, 2020, Vol. 26 (1). P. 288–299. <https://doi.org/10.1109/TMECH.2020.3014293>

56. Roldan, J.J., Cerro, J. del, Garzon-Ramos, D., Garcia-Aunon, P., Garzon, M., Leon, J. de, Barrientos, A. Robots in Agriculture: State of Art and Practical Experiences: InTech, 2018. 174 p. <https://doi.org/10.5772/intechopen.69874>

57. Oliveira, L.F.P., Moreira, A.P., Silva, M.F. Advances in Agriculture Robotics: A State-of-the-Art Review and Challenges Ahead. *Robotics*, 2021, Vol. 10 (2):52. P. 1–31. <https://doi.org/10.3390/robotics10020052>

58. FAO: Family Farming Knowledge Platform. Retrieved from: <https://www.fao.org/family-farming/themes/small-family-farmers/en/> (accessed on November 25, 2024).

59. Patel, N.R., Kumar, S., Singh, S.K. Energy and Collision Aware WSN Routing Protocol for Sustainable and Intelligent IoT Applications. *IEEE Sensors Journal*, 2021, Vol. 21 (22). P. 25282–25292. <https://doi.org/10.1109/JSEN.2021.3076192>

60. Rackley, S. *Wireless Networking Technology: From Principles to Successful Implementation*: Oxford, Elsevier, 2007. 425 p. <https://doi.org/10.1016/B978-0-7506-6788-3.X5028-8>

61. Salazar, J. *Wireless networks*: Czech Technical University of Prague Faculty of electrical engineering, 2017. 37 p. URL: [https://upcommons.upc.edu/bitstream/handle/2117/110811/LM01\\_F\\_EN.pdf](https://upcommons.upc.edu/bitstream/handle/2117/110811/LM01_F_EN.pdf)

62. Sadowski, S., Spachos, P. Wireless technologies for smart agricultural monitoring using internet of things devices with energy harvesting capabilities. *Computers and Electronics in Agriculture*, 2020, Vol. 172. P. 1–8. <https://doi.org/10.1016/j.compag.2020.105338>

63. CSA: ZigBee. Retrieved from: <https://csa-iot.org/all-solutions/zigbee/> (accessed on November 26, 2024).

64. Bluetooth. Retrieved from: <https://www.bluetooth.com/> (accessed on November 26, 2024).

65. Wi-Fi Alliance. Retrieved from: <https://www.wi-fi.org/> (accessed November 26, 2024).

66. Mekki, K., Bajic, E., Chaxel, F., Meyer, F. A comparative study of LPWAN technologies for large-scale IoT deployment. *ICT Express*, 2019, Vol. 5 (1). P. 1–7. <https://doi.org/10.1016/j.ict.2017.12.005>

67. Raza, U., Kulkarni, P., Sooriyabandara, M. Low Power Wide Area Networks: An Overview. *IEEE Communications Surveys & Tutorials*, 2017, Vol. 19 (2). P. 855–873. <https://doi.org/10.1109/COMST.2017.2652320>

68. Mansour, M., Gamal, A., Ahmed, A.I., Said, L.A., Elbaz, A., Herencsar, N., Soltan, A. Internet of Things: A Comprehensive Overview on Protocols, Architectures, Technologies, Simulation Tools, and Future Directions. *Energies*, 2023, Vol. 16 (8):3465. P. 1–39. <https://doi.org/10.3390/en16083465>

69. Aboubakar, M., Kellil, M., Roux, P. A review of IoT network management: Current status and perspectives. *Journal of King Saud University – Comp. and Inf. Sc.*, 2020, Vol. 34 (7). P. 4163–4176. <https://doi.org/10.1016/j.jksuci.2021.03.006>

70. Kanellopoulos, D., Sharma, V.K., Panagiotakopoulos, T., Kameas, A. Networking Architectures and Protocols for IoT Applications in Smart Cities: Recent Developments and Perspectives. *Electronics*, 2023, Vol. 12 (11):2490. P. 1–63. <https://doi.org/10.3390/electronics12112490>

71. AL-Taani, A., Al-husban, Y., Farhan, I. Land suitability evaluation for agricultural use using GIS and remote sensing techniques: The case study of Ma'an Governorate, Jordan. *The Egyptian Journal of Remote Sensing and Space Science*, 2021, Vol. 24 (1). P. 109–117. <https://doi.org/10.1016/j.ejrs.2020.01.001>

72. Elsheikh, R., Shariff, A.R.B.M., Amiri, F., Ahmad, N.B. Balasundram, S.K., Soom, M.A.M. Agriculture Land Suitability Evaluator (ALSE): A decision and planning support tool for tropical and subtropical crops. *Computers and Electronics in Agriculture*, 2013, Vol. 93. P. 98–110. <https://doi.org/10.1016/j.compag.2013.02.003>

73. Kashtan, V., Hnatushenko, V., Zhir, S. Information Technology Analysis

of Satellite Data for Land Irrigation Monitoring: Invited Paper. In: 2021 IEEE International Conference on Information and Telecommunication Technologies and Radio Electronics, 2021. P. 1–4.  
<https://doi.org/10.1109/UkrMiCo52950.2021.9716592>

74. Olaniyi, A.O., Ajiboye, A.J., Abdullah, A.M., Ramli, M.F., Sood, A.M. Agricultural Land Use Suitability Assessment in Malaysia. *Bulgarian Journal of Agricultural Science*, 2015, Vol. 21 (3). P. 560–572. URL: <https://www.agrojournal.org/21/03-14.pdf>

75. Kashtan, V.Yu., Hnatushenko, V.V. Deep Learning Technology for Automatic Burned Area Extraction Using Satellite High Spatial Resolution Images. In: *Lecture Notes in Computational Intelligence and Decision Making. ISDMCI 2022. Advances in Intelligent Systems and Computing*, 2023, Vol. 1246. P. 664–685. [https://doi.org/10.1007/978-3-031-16203-9\\_37](https://doi.org/10.1007/978-3-031-16203-9_37)

76. AbdelRahman, M.A.E., Natarajan, A., Hegde, R. Assessment of land suitability and capability by integrating remote sensing and GIS for agriculture in Chamarajanagar district, Karnataka, India. *The Egyptian Journal of Remote Sensing and Space Science*, 2026, Vol. 19 (1). P. 125–141. <https://doi.org/10.1016/j.ejrs.2016.02.001>

77. Ivanov, D.V., Hnatushenko, V.V., Kashtan, V.Yu., Garkusha, I.M. Computer modeling of territory flooding in the event of an emergency at Seredniodniprovska Hydroelectric Power Plant. *Nauk. Visn. Nats. Hirnychoho Universytetu*, 2022, Vol. 6. P. 123–128. <https://doi.org/10.33271/nvngu/2022-6/123>

78. Binte Mostafiz, R., Noguchi, R., Ahamed, T. Agricultural Land Suitability Assessment Using Satellite Remote Sensing-Derived Soil-Vegetation Indices. *Land*, 2021, Vol. 10 (2):223. P. 1–26. <https://doi.org/10.3390/land10020223>

79. El Hoummaidi, L., Larabi, A., Alam, K. Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, 2021, Vol. 7 (10). P. 1–14. <https://doi.org/10.1016/j.heliyon.2021.e08154>

80. Deng, L., Mao, Z., Li, X., Hu, Z., Duan, F., Yan, Y. UAV-based multispectral remote sensing for precision agriculture: a comparison between

different cameras. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, Vol. 46. P. 124–136. <https://doi.org/10.1016/j.isprsjprs.2018.09.008>

81. FAO. The usage of unmanned aerial vehicle technology in participatory land use planning and mapping: Naypyidaw, 2020. 22 p. URL: <https://www.fao.org/3/ca8990en/ca8990en.pdf>

82. Kim, J., Kim, S., Ju, C., Son, H.I. Unmanned Aerial Vehicles in Agriculture: A Review of Perspective of Platform, Control, and Applications. *IEEE Access*, 2019, Vol. 7. P. 105100–105115. <https://doi.org/10.1109/ACCESS.2019.2932119>

83. Aguiar, A.S., dos Santos, F.N., Cunha, J.B., Sobreira, H., Sousa, A.J. Localization and Mapping for Robots in Agriculture and Forestry: A Survey. *Robotics*, 2020, Vol. 9 (4):97. P. 1–23. <https://doi.org/10.3390/robotics9040097>

84. Fasiolo, D.T., Scalera, L., Maset, E., Gasparetto, A. Towards autonomous mapping in agriculture: A review of supportive technologies for ground robotics. *Robotics and Autonomous Systems*, 2023, Vol. 169. P. 1–34. <https://doi.org/10.1016/j.robot.2023.104514>

85. Milella, A., Reina, G., Nielsen, M. A multi-sensor robotic platform for ground mapping and estimation beyond the visible spectrum. *Precision Agriculture*, 2019, Vol. 20. P. 423–444. <https://doi.org/10.1007/s11119-018-9605-2>

86. Cui, X., Han, W., Zhang, H., Dong, Y., Ma, W., Zhai, X., Zhang, L., Li, G. Estimating and mapping the dynamics of soil salinity under different crop types using Sentinel-2 satellite imagery. *Geoderma*, 2023, Vol. 440. P. 1–14. <https://doi.org/10.1016/j.geoderma.2023.116738>

87. Dewitte, O., Jones, A., Elbelrhiti, H., Horion, S., Montanarella, L. Satellite remote sensing for soil mapping in Africa: An overview. *Progress in Physical Geography: Earth and Environment*, 2012, Vol. 36 (4). P. 514–538. <https://doi.org/10.1177/0309133312446981>

88. Endsley, K.A., Kimball, J.S., Reichle, R.H., Watts, J.D. Satellite monitoring of global surface soil organic carbon dynamics using the SMAP Level 4

Carbon product. *Journal of Geophysical Research: Biogeosciences*, 2020, Vol. 125. P. 1–18. <https://doi.org/10.1029/2020JG006100>

89. Pasichnyk, N., Shvorov, S., Gunchenko, Y., Miroshkin, O., Zakharchenko, E., Opryshko, O. Prospects for Satellite Spectral Monitoring for Automation of Processes for Assessing Agricultural Soil Use. In: II International Scientific and Practical Conference «Intellectual Systems and Information Technologies», 2021. P. 1–8. URL: <https://ceur-ws.org/Vol-3126/paper48.pdf>

90. Zhang, M.-W., Wang, X.-Q., Ding, X.-G., Yang, H.-L., Guo, Q., Zeng, L.-T., Cui, Y.-P., Sun, X.-L. Monitoring regional soil organic matter content using a spatiotemporal model with time-series synthetic Landsat images. *Geoderma Regional*, 2023, Vol. 34. P. 1–13. <https://doi.org/10.1016/j.geodrs.2023.e00702>

91. Dafflon, B., Leger, E., Falco, N., Wainwright, H.M., Peterson, J., Chen, J., Williams, K.H., Hubbard, S.S. Advanced monitoring of soil-vegetation co-dynamics reveals the successive controls of snowmelt on soil moisture and on plant seasonal dynamics in a mountainous watershed. *Frontiers in Earth Science*, 2023, Vol. 11. P. 1–17. <https://doi.org/10.3389/feart.2023.976227>

92. Guan, S., Fukami, K., Matsunaka, H., Okami, M., Tanaka, R., Nakano, H., Sakai, T., Nakano, K., Ohdan, H., Takahashi, K. Assessing correlation of high-resolution NDVI with fertilizer application level and yield of rice and wheat crops using small UAVs. *Remote Sensing*, 2019, Vol. 11 (2). P. 1–19. <https://doi.org/10.3390/rs11020112>

93. D'Oleire-Oltmanns, S., Marzloff, I., Peter, K.D., Ries, J.B. Unmanned Aerial Vehicle (UAV) for Monitoring Soil Erosion in Morocco. *Remote Sensing*, 2012, Vol. 4 (11). P. 3390–3416. <https://doi.org/10.3390/rs4113390>

94. Themistocleous, K. The use of UAVs for monitoring land degradation. In: *Proc. SPIE 10428, Earth Resources and Environmental Remote Sensing / GIS Applications VIII*, 2017. P. 2–11. <https://doi.org/10.1117/12.2279512>

95. Kim, J., Kim, I., Ha, E., Choi, B. UAV Photogrammetry for Soil Surface Deformation Detection in a Timber Harvesting Area, South Korea. *Forests*, 2023, Vol. 14 (5):980. P. 1–16. <https://doi.org/10.3390/f14050980>

96. Basurto-Lozada, D., Hillier, A., Medina, D., Pulido, D., Karaman, S., Salas, J. Dynamics of soil surface temperature with unmanned aerial systems. *Pattern Rec. Letters*, 2020, Vol. 138. P. 68–74. <https://doi.org/10.1016/j.patrec.2020.07.003>
97. Wu, Y., Yang, Z., Liu, Y. Internet-of-Things-Based Multiple-Sensor Monitoring System for Soil Information Diagnosis Using a Smartphone. *Micromachines*, 2023, Vol. 14 (7):1395. P. 1–20. <https://doi.org/10.3390/mi14071395>
98. Bayih, A.Z., De By, R.A., Assabie, Y., Guarin, J.V. Internet-of-Things and Wireless Sensor Networks as Enablers for Soil Observation in Smallholder Farms. In: 2023 International Conference on Earth Observation and Geo-Spatial Information (ICEOGI), 2023. P. 1–6. <https://doi.org/10.1109/ICEOGI57454.2023.10292956>
99. Na, A., Isaac, W., Varshney, S., Khan, E. An IoT based system for remote monitoring of soil characteristics. In: 2016 International Conference on Information Technology (InCITe) – The Next Generation IT Summit – IoT: Connect your Worlds, 2016. P. 316–320. <https://doi.org/10.1109/INCITE.2016.7857638>
100. Navulur, S., Sastry, A.S.C.S., Giri Prasad, M.N. Agricultural Management through Wireless Sensors and Internet of Things. *International Journal of Electrical and Computer Engineering*, 2017, Vol. 7 (6). P. 3492–3499. <https://doi.org/10.11591/ijece.v7i6.pp3492-3499>
101. Wu, B., Gommès, R., Zhang, M., Zeng, H., Yan, N., Zou, W., Zheng, Y., Zhang, N., Chang, S., Xing, Q., Van Heijden, A. Global Crop Monitoring: A Satellite-Based Hierarchical Approach. *Remote Sensing*, 2015, Vol. 7 (4). P. 3907–3933. <https://doi.org/10.3390/rs70403907>
102. Lungu, O.N., Chabala, L.M., Shepande, C. Satellite-Based Crop Monitoring and Yield Estimation – A Review. *Journal of Agricultural Science*, 2021, Vol. 13 (1). P. 180–194. <https://doi.org/10.5539/jas.v13n1p180>
103. San Bautista, A., Fita, D., Franch, B., Castineira-Ibanez, S., Arizo, P., Sanchez-Torres, M.J., Becker-Reshef, I., Uris, A., Rubio, C. Crop Monitoring Strategy Based on Remote Sensing Data (Sentinel-2 and Planet), Study Case in a Rice Field after Applying Glycinebetaine. *Agronomy*, 2022, Vol. 12 (3):708. P. 1–23.

<https://doi.org/10.3390/agronomy12030708>

104. Rahman, H. Satellite Based Crop Monitoring and Estimation System for Food Security Application in Bangladesh. In: Expert Meeting on Crop Monitoring for Improved Food Security, 2014. P. 133–148. URL: <https://www.fao.org/3/i4273e/i4273e.pdf>

105. Maimaitijiang, M., Sagan, V., Sidike, P., Daloye, A.M., Erkbol, H., Fritschi, F.B. Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. *Remote Sensing*, 2020, Vol. 12 (9):1357. P. 1–23. <https://doi.org/10.3390/rs12091357>

106. Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., Bareth, G. Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing*, 2014, Vol. 6 (11). P. 10395–10412. <https://doi.org/10.3390/rs61110395>

107. Zhang, L., Zhang, H., Niu, Y., Han, W. Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sensing*, 2019, Vol. 11 (6):605. P. 1–24. <https://doi.org/10.3390/rs11060605>

108. Gokool, S., Mahomed, M., Kunz, R., Clulow, A., Sibanda, M., Naiken, V., Chetty, K., Mabhaudhi, T. Crop Monitoring in Smallholder Farms Using Unmanned Aerial Vehicles to Facilitate Precision Agriculture Practices: A Scoping Review and Bibliometric Analysis. *Sustainability*, 2023, Vol. 15 (4):3557. P. 1–18. <https://doi.org/10.3390/su15043557>

109. D'Urso, M. G., Rotondi, A., Gagliardini, M. UAV Low-Cost System for Evaluating and Monitoring the Growth Parameters of Crops. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, Vol. IV-5. P. 405–413. <https://doi.org/10.5194/isprs-annals-IV-5-405-2018>

110. Jabbari, A., Humayed, A., Reegu, F.A., Uddin, M., Gulzar, Y., Majid, M. Smart Farming Revolution: Farmer's Perception and Adoption of Smart IoT Technologies for Crop Health Monitoring and Yield Prediction in Jizan, Saudi Arabia. *Sustainability*, 2023, Vol. 15 (19):14541. P. 1–19. <https://doi.org/10.3390/su151914541>

111. Gonzalez Preto, F.A., Avendano Fernandez, E., Salcedo Parra, O.J. Intelligent Mobil App Design of IoT System Based on Wireless Sensor Networks for monitoring and improvement of production in fruit crops. *Revista EIA*, 2024, Vol. 21 (41):4114. P. 1–29. <https://doi.org/10.24050/reia.v21i41.1674>

112. Bhavani, P., Roy, P.S., Chakravarthi, V., Kanawade, V.P. Satellite Remote Sensing for Monitoring Agriculture Growth and Agricultural Drought Vulnerability Using Long-Term (1982–2015) Climate Variability and Socio-economic Data set. In: *Proceedings of the National Academy of Sciences, India Section A: Phys. Sc.*, 2017. P. 733–750. <https://doi.org/10.1007/s40010-017-0445-7>

113. Brown, M.E. Satellite Remote Sensing in Agriculture and Food Security Assessment. *Procedia Environmental Sciences*, 2015, Vol. 29. P. 307. <https://doi.org/10.1016/j.proenv.2015.07.278>

114. Tarariko, O., Iliencko, T., Kuchma, T., Velychko, V. Long-term prediction of climate change impact on the productivity of grain crops in Ukraine using satellite data. *Agricultural Science and Practice*, 2017, Vol. 4 (2). P. 3–13. <https://doi.org/10.15407/agrisp4.02.003>

115. Shahzaman, M., Zhu, W., Bilal, M., Habtemicheal, B.A., Mustafa, F., Arshad, M., Ullah, I., Ishfaq, S., Iqbal, R. Remote Sensing Indices for Spatial Monitoring of Agricultural Drought in South Asian Countries. *Remote Sensing*, 2021, Vol. 13 (11):2059. P. 1–25. <https://doi.org/10.3390/rs13112059>

116. Wang, X. Remote Sensing Applications to Climate Change. *Remote Sensing*, 2023, Vol. 15 (3):747. P. 1–4. <https://doi.org/10.3390/rs15030747>

117. Di Gennaro, S.F., Matese, A., Gioli, B., Toscano, P., Zaldei, A., Palliotti, A., Genesio, L. Multisensor approach to assess vineyard thermal dynamics combining high-resolution unmanned aerial vehicle (UAV) remote sensing and wireless sensor network (WSN) proximal sensing. *Scientia Horticulturae*, 2017, Vol. 221. P. 83–87. <https://doi.org/10.1016/j.scienta.2017.04.024>

118. Furlan, L.M., Moreira, C.A., Alencar, P.G.d., Rosolen, V. Environmental monitoring and hydrological simulations of a natural wetland based on high-resolution unmanned aerial vehicle data (Paulista Peripheral Depression, Brazil).

Environmental Challenges, 2021, Vol. 4. P. 1–8.  
<https://doi.org/10.1016/j.envc.2021.100146>

119. Popescu, D., Stoican, F., Stamatescu, G., Ichim, L., Dragana, C. Advanced UAV–WSN System for Intelligent Monitoring in Precision Agriculture. *Sensors*, 2020, Vol. 20 (3):817. P. 1–25. <https://doi.org/10.3390/s20030817>

120. Marques, G., Pitarma, R. Agricultural environment monitoring system using wireless sensor networks and IoT. In: 2018 13th Iberian Conference on Information Systems and Technologies (CISTI), 2018. P. 1–6. <https://doi.org/10.23919/CISTI.2018.8399320>

121. Kiani, F., Seyyedabbasi, A. Wireless Sensor Network and Internet of Things in Precision Agriculture. *International Journal of Advanced Computer Science and Applications*, 2018, Vol. 9 (6). P. 99–103. <http://dx.doi.org/10.14569/IJACSA.2018.090614>

122. Suman, K.G., Kumar, D. Role of IoT in Smart Precision Agriculture. In: Aswal, D.K., Yadav, S., Takatsuji, T., Rachakonda, P., Kumar, H. (eds) *Handbook of Metrology and Applications*: Singapore, Springer, 2023. P. 1217–1238. [https://doi.org/10.1007/978-981-99-2074-7\\_66](https://doi.org/10.1007/978-981-99-2074-7_66)

123. Karim, F., Karim, Fat., Ali frihida. Monitoring system using web of things in precision agriculture. *Procedia Computer Science*, 2017, Vol. 110. P. 402–409. <https://doi.org/10.1016/j.procs.2017.06.083>

124. Laktionov, I., Diachenko, G., Koval, V., Yevstratiev, M. Computer-Oriented Model for Network Aggregation of Measurement Data in IoT Monitoring of Soil and Climatic Parameters of Agricultural Crop Production Enterprises. *Baltic Journal of Modern Computing*, 2023, Vol. 11 (3). P. 500–522. <https://doi.org/10.22364/bjmc.2023.11.3.09>

125. Laktionov, I.S., Vovna, O.V., Kabanets, M.M., Sheina, H.O., Getman, I.A. Information model of the computer-integrated technology for wireless monitoring of the state of microclimate of industrial agricultural greenhouses. *Instrumentation Measure Metrologie*, 2021, Vol. 20 (6). P. 289–300. <https://doi.org/10.18280/i2m.200601>

126. Laktionov, I.S., Vovna, O.V., Bashkov, Y.O., Zori, A.A., Lebediev, V.A. Improved Computer-Oriented Method for Processing of Measurement Information on Greenhouse Microclimate. *International Journal Bioautomation*, 2019, Vol. 23 (1). P. 71–86. <https://doi.org/10.7546/ijba.2019.23.1.71-86>

127. Zhu, Q., Luo, Y., Xu, Y.-P., Tian, Y., Yang, T. Satellite Soil Moisture for Agricultural Drought Monitoring: Assessment of SMAP-Derived Soil Water Deficit Index in Xiang River Basin, China. *Remote Sensing*, 2019, Vol. 11 (3):362. P. 1–22. <https://doi.org/10.3390/rs11030362>

128. Ihuoma, S.O., Madramootoo, C.A., Kalacska, M. Integration of satellite imagery and in situ soil moisture data for estimating irrigation water requirements. *International Journal of Applied Earth Observation and Geoinformation*, 2021, Vol. 102. P. 1–11. <https://doi.org/10.1016/j.jag.2021.102396>

129. Araujo, D.C.d.S., Montenegro, S.M.G.L., Neto, A.R., Silva, S.M.d. Evaluation of satellite-based soil moisture for agricultural drought monitoring in the Brazilian semiarid region. *Remote Sensing Applications: Society and Environment*, 2024, Vol. 33. P. 1–15. <https://doi.org/10.1016/j.rsase.2023.101111>

130. Peng, J., Albergel, C., Balenzano, A., Brocca, L., Cartus, O., Cosh, M.H., Crow, W.T., Dabrowska-Zielinska, K., Dadson, S., Davidson, M.W.J., de Rosnay, P., Dorigo, W., Gruber, A., Hagemann, S., Hirschi, M., Kerr, Y.H., Lovergine, F., Mahecha, M.D., Marzahn, P., Mattia, F., Musial, J.P., Preuschmann, S., Reichle, R.H., Satalino, G., Silgram, M., van Bodegom, P.M., Verhoest, N.E.C., Wagner, W., Walker, J.P., Wegmuller, U., Loew, A. A roadmap for high-resolution satellite soil moisture applications – confronting product characteristics with user requirements. *Remote Sensing of Environment*, 2021, Vol. 252. P. 1–15. <https://doi.org/10.1016/j.rse.2020.112162>

131. Hegazi, E.H., Samak, A.A., Yang, L., Huang, R., Huang, J. Prediction of Soil Moisture Content from Sentinel-2 Images Using Convolutional Neural Network (CNN). *Agronomy*, 2023, Vol. 13 (3):656. P. 1–18. <https://doi.org/10.3390/agronomy13030656>

132. Sang, Y., Yu, S., Lu, F., Sun, Y., Wang, S., Ade, L., Hou, F. UAV

Monitoring Topsoil Moisture in an Alpine Meadow on the Qinghai–Tibet Plateau. *Agronomy*, 2023, Vol. 13 (9):2193. P. 1–23. <https://doi.org/10.3390/agronomy13092193>

133. Ge, X., Ding, J., Jin, X., Wang, J., Chen, X., Li, X., Liu, J., Xie, B. Estimating Agricultural Soil Moisture Content through UAV-Based Hyperspectral Images in the Arid Region. *Remote Sensing*, 2021, Vol. 13 (8):1562. P. 1–25. <https://doi.org/10.3390/rs13081562>

134. Zhang, Y., Han, W., Zhang, H., Niu, X., Shao, G. Evaluating soil moisture content under maize coverage using UAV multimodal data by machine learning algorithms. *Journal of Hydrology*, 2023, Vol. 617 (C). P. 1–12. <https://doi.org/10.1016/j.jhydrol.2023.129086>

135. Bertalan, L., Holb, I., Pataki, A., Negyesi, G., Szabo, G., Kupasne Szaloki, A., Szabo, S. UAV-based multispectral and thermal cameras to predict soil water content – A machine learning approach. *Computers and Electronics in Agriculture*, 2022, Vol. 200. P. 1–11. <https://doi.org/10.1016/j.compag.2022.107262>

136. Lloret, J., Sendra, S., Garcia, L., Jimenez, J.M. A Wireless Sensor Network Deployment for Soil Moisture Monitoring in Precision Agriculture. *Sensors*, 2021, Vol. 21 (21):7243. P. 1–24. <https://doi.org/10.3390/s21217243>

137. Zhang, X., Zhang, J., Li, L., Zhang, Y., Yang, G. Monitoring Citrus Soil Moisture and Nutrients Using an IoT Based System. *Sensors*, 2017, Vol. 17 (3):447. P. 1–10. <https://doi.org/10.3390/s17030447>

138. Vandome, P., Leauthaud, C., Moinard, S., Sainlez, O., Mekki, I., Zairi, A., Belaud, G. Making technological innovations accessible to agricultural water management: Design of a low-cost wireless sensor network for drip irrigation monitoring in Tunisia. *Smart Agricultural Technology*, 2023, Vol. 4. P. 1–11. <https://doi.org/10.1016/j.atech.2023.100227>

139. Bogen, H.R., Weuthen, A., Huisman, J.A. Recent Developments in Wireless Soil Moisture Sensing to Support Scientific Research and Agricultural Management. *Sensors*, 2022, Vol. 22 (24):9792. P. 1–19. <https://doi.org/10.3390/s22249792>

140. Shanmugam, L., Adline, A.L.A., Aishwarya, N., Krithika, G. Disease detection in crops using remote sensing images. In: 2017 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR), 2017. P. 112–115. <https://doi.org/10.1109/TIAR.2017.8273696>
141. Zhang, J., Huang, Y., Yuan, L., Yang, G., Chen, L., Zhao, C. Using satellite multispectral imagery for damage mapping of armyworm (*Spodoptera frugiperda*) in maize at a regional scale. *Pest Management Science*, 2016, Vol. 74. P. 335–348. <https://doi.org/10.1002/ps.4003>
142. Sabtu, N.M., Idris, N.H., Ishak, M.H.I. The role of geospatial in plant pests and diseases: an overview. *IOP Conf. Ser.: Earth Environ. Sci.*, 2018, Vol. 169. P. 1–11. <https://doi.org/10.1088/1755-1315/169/1/012013>
143. Shahi, T.B., Xu, C.-Y., Neupane, A., Guo, W. Recent Advances in Crop Disease Detection Using UAV and Deep Learning Techniques. *Remote Sensing*, 2023, Vol. 15 (9):2450. P. 1–29. <https://doi.org/10.3390/rs15092450>
144. Lopez-Granados, F., Torres-Sanchez, J., Serrano-Perez, A., de Castro, A.I., Mesas-Carrascosa, F.-J., Pena, J.-M. Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds. *Precision Agriculture*, 2016, Vol. 17. P. 183–199. <https://doi.org/10.1007/s11119-015-9415-8>
145. Gasparovic, M., Zrinjski, M., Barkovic, D., Radocaj, D. An automatic method for weed mapping in oat fields based on UAV imagery. *Computers and Electronics in Agriculture*, 2020, Vol. 173. P. 1–12. <https://doi.org/10.1016/j.compag.2020.105385>
146. Su, J., Liu, C., Coombes, M., Hu, X., Wang, C., Xu, X., Li, Q., Guo, L., Chen, W.-H. Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery. *Computers and Electronics in Agriculture*, 2018, Vol. 155. P. 157–166. <https://doi.org/10.1016/j.compag.2018.10.017>
147. Bah, M.D., Hafiane, A., Canals, R. Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images. *Remote Sensing*, 2018, Vol. 10 (11):1690. P. 1–22. <https://doi.org/10.3390/rs10111690>

148. Zhang, X., Han, L., Dong, Y., Shi, Y., Huang, W., Han, L., Gonzalez-Moreno, P., Ma, H., Ye, H., Sobeih, T. A Deep Learning-Based Approach for Automated Yellow Rust Disease Detection from High-Resolution Hyperspectral UAV Images. *Remote Sensing*, 2019, Vol. 11 (13):1554. P. 1–16. <https://doi.org/10.3390/rs11131554>

149. Zhao, G., Zhang, Y., Lan, Y., Deng, J., Zhang, Q., Zhang, Z., Li, Z., Liu, L., Huang, X., Ma, J. Application Progress of UAV-LARS in Identification of Crop Diseases and Pests. *Agronomy*, 2023, Vol. 13 (9):2232. P. 1–23. <https://doi.org/10.3390/agronomy13092232>

150. Zhang, R., Hewitt, A., Li, L., Yuan, H., Ferguson, J.C., Chen, L. Editorial: Advanced technologies of UAV application in crop pest, disease and weed control. *Frontiers in Plant Science*, 2023, Vol. 14:1253841. P. 1–3. <https://doi.org/10.3389/fpls.2023.1253841>

151. Singh, K.U., Kumar, A., Raja, L., Kumar, V., Singh kushwaha, A.K., Vashney, N., Chhetri, M. An Artificial Neural Network-Based Pest Identification and Control in Smart Agriculture Using Wireless Sensor Networks. *Journal of Food Quality*, 2022, Vol. 2022. P. 1–12. <https://doi.org/10.1155/2022/5801206>

152. Khattab, A., Habib, S.E.D., Ismail, H., Zayan, S., Fahmy, Y., Khairy, M.M. An IoT-based cognitive monitoring system for early plant disease forecast. *Computers and Electronics in Agriculture*, 2019, Vol. 166. P. 1–13. <https://doi.org/10.1016/j.compag.2019.105028>

153. Wang, S., Qi, P., Zhang, W., He, X. Development and Application of an Intelligent Plant Protection Monitoring System. *Agronomy*, 2022, Vol. 12 (5):1046. P. 1–15. <https://doi.org/10.3390/agronomy12051046>

154. Laktionov, I., Diachenko, G., Rutkowska, D., Kisiel-Dorohinicki, M. An Explainable AI Approach to Agrotechnical Monitoring and Crop Diseases Prediction in Dnipro Region of Ukraine. *Journal of Artificial Intelligence and Soft Computing Research*, 2023, Vol. 13 (4). P. 247–272. <https://doi.org/10.2478/jaiscr-2023-0018>

155. Ouhami, M., Hafiane, A., Es-Saady, Y., El Hajji, M., Canals, R. Computer Vision, IoT and Data Fusion for Crop Disease Detection Using Machine

Learning: A Survey and Ongoing Research. *Remote Sensing*, 2021, Vol. 13 (13):2486. P. 1–24. <https://doi.org/10.3390/rs13132486>

156. Gao, D., Sun, Q., Hu, B., Zhang, S. A Framework for Agricultural Pest and Disease Monitoring Based on Internet-of-Things and Unmanned Aerial Vehicles. *Sensors*, 2020, Vol. 20 (5):1487. P. 1–18. <https://doi.org/10.3390/s20051487>

157. Sagan, V., Maimaitijiang, M., Sidike, P., Maimaitiyiming, M., Erkbol, H., Hartling, S., Peterson, K.T., Peterson, J., Burken, J., Fritschi, F. UAV/Satellite Multiscale Data Fusion for Crop Monitoring and Early Stress Detection, *Int. Arch. Photogramm. Remote Sensing and Spatial Information Sciences*, 2019, Vol. XLII-2/W13. P. 715–722. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-715-2019>

158. Li, M., Shamschiri, R.R., Weltzien, C., Schirrmann, M. Crop Monitoring Using Sentinel-2 and UAV Multispectral Imagery: A Comparison Case Study in Northeastern Germany. *Remote Sensing*, 2022, Vol. 14 (17):4426. P. 1–21. <https://doi.org/10.3390/rs14174426>

159. Sita Kumari, K., Abdul Haleem, S.L., Shivaprakash, G., Saravanan, M., Arunsundar, B., Pandraju, T.K.S. Agriculture monitoring system based on internet of things by deep learning feature fusion with classification. *Computers and Electrical Engineering*, 2022, Vol. 102. P. 1–14. <https://doi.org/10.1016/j.compeleceng.2022.108197>

160. Gagliardi, G., Lupia, M., Cario, G., Cicchello Gaccio, F., D'Angelo, V., Cosma, A.I.M., Casavola, A. An Internet of Things Solution for Smart Agriculture. *Agronomy*, 2021, Vol. 11 (11):2140. P. 1–18. <https://doi.org/10.3390/agronomy11112140>

161. Triantafyllou, A., Sarigiannidis, P., Bibi, S. Precision Agriculture: A Remote Sensing Monitoring System Architecture. *Information*, 2019, Vol. 10 (11):348. P. 1–25. <https://doi.org/10.3390/info10110348>

162. Ndunagu, J.N., Ukhurebor, K.E., Akaaza, M., Onyanha, R.B. Development of a Wireless Sensor Network and IoT-based Smart Irrigation System. *Applied and Environmental Soil Science*, 2022, Vol. 2022. P. 1–13.

<https://doi.org/10.1155/2022/7678570>

163. Madeira, R.N., Santos, P.A., Java, O., Priebe, T., Graca, E., Sarkozi, E., Asprión, B., Gomez, R.P.-B. Towards Digital Twins for Multi-Sensor Land and Plant Monitoring. *Procedia Computer Science*, 2022, Vol. 210. P. 45–52. <https://doi.org/10.1016/j.procs.2022.10.118>

164. Vijayalakshmi, K., Al-Otaibi, S., Arya, L., Almaiah, M.A., Anithaashri, T.P., Karthik, S.S., Shishakly, R. Smart Agricultural–Industrial Crop-Monitoring System Using Unmanned Aerial Vehicle–Internet of Things Classification Techniques. *Sustainability*, 2023, Vol. 15 (14):11242. P. 1–20. <https://doi.org/10.3390/su151411242>

165. Li, W., Dong, W., Zhang, X., Zhang, J. A New Remote Sensing Service Mode for Agricultural Production and Management Based on Satellite–Air–Ground Spatiotemporal Monitoring. *Agriculture*, 2023, Vol. 13 (11):2063. P. 1–21. <https://doi.org/10.3390/agriculture13112063>

166. Indira, P., Arafat, I.S., Karthikeyan, R., Selvarajan, S., Balachandran, P.K. Fabrication and investigation of agricultural monitoring system with IoT & AI. *SN Applied Sciences*, 2023, Vol. 5. P. 1–13. <https://doi.org/10.1007/s42452-023-05526-1>

167. Gu, Z., Zeng, M. The Use of Artificial Intelligence and Satellite Remote Sensing in Land Cover Change Detection: Review and Perspectives. *Sustainability*, 2024, Vol. 16 (1):274. P. 1–22. <https://doi.org/10.3390/su16010274>

168. Liu, J., Shu, L., Lu, X., Liu, Y. Survey of Intelligent Agricultural IoT Based on 5G. *Electronics*, 2023, Vol. 12 (10):2336. P. 1–46. <https://doi.org/10.3390/electronics12102336>

169. Mazzia, V., Comba, L., Khaliq, A., Chiaberge, M., Gay, P., 2020. UAV and Machine Learning Based Refinement of a Satellite-Driven Vegetation Index for Precision Agriculture. *Sensors*, 2020, Vol. 20 (9):2530. P. 1–16. <https://doi.org/10.3390/s20092530>

170. Okafor, N.U., Alghorani, Y., Delaney, D.T. Improving Data Quality of Low-cost IoT Sensors in Environmental Monitoring Networks Using Data Fusion and Machine Learning Approach. *ICT Express*, 2020, Vol. 6 (3). P. 220–228.

<https://doi.org/10.1016/j.icte.2020.06.004>

171. Lai, X., Yang, T., Wang, Z., Chen, P. IoT Implementation of Kalman Filter to Improve Accuracy of Air Quality Monitoring and Prediction. *Applied Sciences*, 2019, Vol. 9 (9):1831. P. 1–23. <https://doi.org/10.3390/app9091831>

172. Chi, T.-K., Chen, H.-C., Chen, S.-L., Abu, P.A.R. A High-Accuracy and Power-Efficient Self-Optimizing Wireless Water Level Monitoring IoT Device for Smart City. *Sensors*, 2021, Vol. 21 (6):1936. P. 1–16. <https://doi.org/10.3390/s21061936>

173. Raviprasad, B., Mohan, C.R., Naga Rama Devi, G., Pugalenth, R., Manikandan, L.C., Ponnusamy, S. Accuracy determination using deep learning technique in cloud-based IoT sensor environment. *Measurement: Sensors*, 2022, Vol. 24. P. 1–8. <https://doi.org/10.1016/j.measen.2022.100459>

174. Davanam, G., Kallam, S., Singh, N., Gunjan, V.K., Roy, S., Rahebi, J., Farzamia, A., Saad, I. Multi-Controller Model for Improving the Performance of IoT Networks. *Energies*, 2022, Vol. 15 (22):8738. P. 1–15. <https://doi.org/10.3390/en15228738>

175. Nhamo, L., Van Dijk, R., Magidi, J., Wiberg, D., Tshikolomo, K. Improving the Accuracy of Remotely Sensed Irrigated Areas Using Post-Classification Enhancement Through UAV Capability. *Remote Sensing*, 2018, Vol. 10 (5):712. P. 1–12. <https://doi.org/10.3390/rs10050712>

176. Jin, Z., Azzari, G., Lobell, D.B. Improving the accuracy of satellite-based high-resolution yield estimation: A test of multiple scalable approaches. *Agricultural and Forest Meteorology*, 2017, Vol. 247. P. 207–220. <https://doi.org/10.1016/j.agrformet.2017.08.001>

177. Coman, C.M., D'amico, G., Coman, A.V., Florescu, A. Techniques to Improve Reliability in an IoT Architecture Framework for Intelligent Products. *IEEE Access*, 2021, Vol. 9. P. 56940–56954. <https://doi.org/10.1109/ACCESS.2021.3072168>

178. O'Neill, V., Soh, B. Improving Fault Tolerance and Reliability of Heterogeneous Multi-Agent IoT Systems Using Intelligence Transfer. *Electronics*,

2022, Vol. 11 (17):2724. P. 1–38. <https://doi.org/10.3390/electronics11172724>

179. Imran, Zuhairi, M.F.A., Ali, S.M., Shahid, Z., Alam, M.M., Su'ud, M.M. Improving Reliability for Detecting Anomalies in the MQTT Network by Applying Correlation Analysis for Feature Selection Using Machine Learning Techniques. *Applied Sciences*, 2023, Vol. 13 (11):6753. P. 1–26. <https://doi.org/10.3390/app13116753>

180. Chilipirea, C., Ursache, A., Popa, D.O., Pop, F. Energy efficiency and robustness for IoT: Building a smart home security system. In: 2016 IEEE 12th International Conference on Intelligent Computer Communication and Processing (ICCP), 2016. P. 43–48, <https://doi.org/10.1109/ICCP.2016.7737120>

181. Alghofaili, Y., Rassam, M.A. A Trust Management Model for IoT Devices and Services Based on the Multi-Criteria Decision-Making Approach and Deep Long Short-Term Memory Technique. *Sensors*, 2022, Vol. 22 (2):634. P. 1–27. <https://doi.org/10.3390/s22020634>

182. Bampatsikos, M., Politis, I., Bolgouras, V., Xenakis, C. Multi-Attribute Decision Making-based Trust Score Calculation in Trust Management in IoT. In: Proceedings of the 18th International Conference on Availability, Reliability and Security (ARES '23), 2023. P. 1–8. <https://doi.org/10.1145/3600160.3605074>

183. Al-Hamadi, H., Chen, I.R. Trust-Based Decision Making for Health IoT Systems. *IEEE Internet of Things Journal*, 2017, Vol. 4 (5). P. 1408–1419. <https://doi.org/10.1109/JIOT.2017.2736446>

184. Guo, Y., Wang, N., Xu, Z.-Y., Wu, K. The Internet of things-based decision support system for information processing in intelligent manufacturing using data mining technology. *Mechanical Systems and Signal Processing*, 2020, Vol. 142. P. 1–11. <https://doi.org/10.1016/j.ymssp.2020.106630>

185. Noh, K.M., Park, J.H., Park, J.S. Data Transmission Direction Based Routing Algorithm for Improving Network Performance of IoT Systems. *Applied Sciences*, 2020, Vol. 10 (11):3784. P. 1–19. <https://doi.org/10.3390/app10113784>

186. Ahmed, Z.E., Saeed, R.A., Mukherjee, A., Ghorpade, S.N. 10-Energy optimization in low-power wide area networks by using heuristic techniques. In:

LPWAN Technologies for IoT and M2M Applications, 2020. P. 199–223.  
<https://doi.org/10.1016/B978-0-12-818880-4.00011-9>

187. Anjum, S.S., Noor, R.M., Ahmedy, I., Anisi, M.H. Energy optimization of sustainable Internet of Things (IoT) systems using an energy harvesting medium access protocol. IOP Conference Series: Earth and Environmental Science, 2019, Vol. 268. P. 1–7. <https://doi.org/10.1088/1755-1315/268/1/012094>

188. Reyana, A., Kautish, S., Alnowibet, K.A., Zawbaa, H.M., Wagdy Mohamed, A. Opportunities of IoT in Fog Computing for High Fault Tolerance and Sustainable Energy Optimization. Sustainability, 2023, Vol. 15 (11):8702. P. 1–14. <https://doi.org/10.3390/su15118702>

189. Park, J., Park, K. A Lightweight Blockchain Scheme for a Secure Smart Dust IoT Environment. Applied Sciences, 2020, Vol. 10 (24):8925. P. 1–18. <https://doi.org/10.3390/app10248925>

190. Shin, S., Kwon, T. A Privacy-Preserving Authentication, Authorization, and Key Agreement Scheme for Wireless Sensor Networks in 5G-Integrated Internet of Things. IEEE Access, 2020, Vol. 8. P. 67555–67571. <https://doi.org/10.1109/ACCESS.2020.2985719>

191. Wazid, M., Das, A.K., Odelu, V., Kumar, N., Conti, M., Jo, M. Design of Secure User Authenticated Key Management Protocol for Generic IoT Networks. IEEE Internet of Things Journal, 2018, Vol. 5 (1). P. 269–282. <https://doi.org/10.1109/JIOT.2017.2780232>

192. Santhanakrishnan Chinnaswamy, Annapurani, K. Trust aggregation authentication protocol using machine learning for IoT wireless sensor networks. Computers & Electrical Engineering, 2021, Vol. 91. P. 1–13. <https://doi.org/10.1016/j.compeleceng.2021.107130>

193. Yang, X., Shu, L., Chen, J., Ferrag, M.A., Wu, J., Nurellari, E., Huang, K. A Survey on Smart Agriculture: Development Modes, Technologies, and Security and Privacy Challenges. IEEE/CAA Journal of Automatica Sinica, 2021, Vol. 8 (2). P. 273–302. <https://doi.org/10.1109/JAS.2020>

194. Mowla, M.N., Mowla, N., Shah, A.F.M.S., Rabie, K.M., Shongwe, T.

Internet of Things and Wireless Sensor Networks for Smart Agriculture Applications: A Survey. *IEEE Access*, 2023, Vol. 11. P. 145813–145852. <https://doi.org/10.1109/ACCESS.2023.3346299>

195. Srivastava, A., Das, D.K. A Comprehensive Review on the Application of Internet of Thing (IoT) in Smart Agriculture. *Wireless Personal Communications*, 2022, Vol. 122. P. 1807–1837. <https://doi.org/10.1007/s11277-021-08970-7>

196. Omia, E., Bae, H., Park, E., Kim, M.S., Baek, I., Kabenge, I., Cho, B.-K. Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. *Remote Sensing*, 2023, Vol. 15 (2):354. P. 1–46. <https://doi.org/10.3390/rs15020354>

197. Karmakar, P., Teng, S.W., Murshed, M., Pang, S., Li, Y., Lin, H. Crop monitoring by multimodal remote sensing: A review. *Remote Sensing Applications: Society and Environment*, 2024, Vol. 33. P. 1–15. <https://doi.org/10.1016/j.rsase.2023.101093>

198. Sharma, A., Jain, A., Gupta, P., Chowdary, V. Machine Learning Applications for Precision Agriculture: A Comprehensive Review. *IEEE Access*, 2021, Vol. 9. 4843–4873. <https://doi.org/10.1109/ACCESS.2020.3048415>

199. Kim, J., Kim, S., Ju, C., Son, H.I. Unmanned Aerial Vehicles in Agriculture: A Review of Perspective of Platform, Control, and Applications. *IEEE Access*, 2019, Vol. 7. P. 105100–105115. <https://doi.org/10.1109/ACCESS.2019.2932119>

200. Venua, V., Sreenath, B, Ramdas, E.R. Various Mathematical Models in Agricultural Engineering. *Current Journal of Applied Science and Technology*, 2023, Vol. 42 (41). P. 13–20. <https://doi.org/10.9734/CJAST/2023/v42i414263>

201. Mosur, I., Polyvoda, O., Rudakova, H., Polyvoda, V. Modeling Methods of Technical Equipment Location Subsystem of Data Collection for Remote Monitoring of Agriculture Based on IoT. *Applied Questions of Mathematical Modelling*, 2021, Vol. 4 (2.1). P. 170–178. <https://doi.org/10.32782/KNTU2618-0340/2021.4.2.1.18>

202. Lopez-Jimenez, J., Vande Wouwer, A., Quijano, N. Dynamic Modeling of

Crop–Soil Systems to Design Monitoring and Automatic Irrigation Processes: A Review with Worked Examples. *Water*, 2022, Vol. 14 (6):889. P. 1–37. <https://doi.org/10.3390/w14060889>

203. Tryhuba, A., Padyuka, R., Tymochko, V., Lub, P. Mathematical model for forecasting product losses in crop production projects. In: 1st Workshop of the 10th International scientific and practical conference Information technologies in energy and agroindustrial complex, 2021. P. 25–31. URL: <https://ceur-ws.org/Vol-3109/paper4.pdf>

204. Sadenova, M.A., Beisekenov, N.A., Rakhymberdina, M., Varbanov, P.S., Klemes, J.J. Mathematical Modelling in Crop Production to Predict Crop Yields. *Chemical Engineering Transactions*, 2021, Vol. 88. P. 1225–1230. <https://doi.org/10.3303/CET2188204>

205. Rossel, D., Ortiz-Laurel, H., Kanswohl, N., Schlegel, M. Mathematical modelling for precisely improving inputs supply for crop production. *Agronomy Research*, 2008, Vol. 6 (Special issue). P. 307–314. URL: <https://agronomy.emu.ee/vol06Spec/p6S16.pdf>

206. Anwar, N., Ahmad, I., Kiani, A.K., Shoaib, M., Raja, M.A.Z. Numerical treatment for mathematical model of farming awareness in crop pest management. *Frontiers in Applied Mathematics and Statistics*, 2023, Vol. 9:1208774. P. 1–18. <https://doi.org/10.3389/fams.2023.1208774>

207. Zerihun, B.M., Olwal, T.O., Hassen, M.R. Design and Analysis of IoT-Based Modern Agriculture Monitoring System for Real-Time Data Collection. In: Uddin, M.S., Bansal, J.C. (eds) *Computer Vision and Machine Learning in Agriculture*, 2022, Vol. 2. Algorithms for Intelligent Systems. P. 73–82. [https://doi.org/10.1007/978-981-16-9991-7\\_5](https://doi.org/10.1007/978-981-16-9991-7_5)

208. Liu, S., Guo, L., Webb, H., Ya, X., Chang, X. Internet of Things Monitoring System of Modern Eco-Agriculture Based on Cloud Computing. *IEEE Access*, 2019, Vol. 7. P. 37050–37058. <https://doi.org/10.1109/ACCESS.2019.2903720>

209. Siddiquee, K.N.-e-A., Islam, Md.S., Singh, N., Gunjan, V.K.,

Yong, W.H., Huda, M.N., Naik, D.S.B. Development of Algorithms for an IoT-Based Smart Agriculture Monitoring System. *Wireless Communications and Mobile Computing*, 2022, Vol. 2022. P. 1–16. <https://doi.org/10.1155/2022/7372053>

210. Laktionov, I.S., Vovna, O.V., Zori, A.A., Lebediev, V.A. Results of simulation and physical modeling of the computerized monitoring and control system for greenhouse microclimate parameters. *Int. J. on Smart Sensing and Intelligent Systems*, 2018, Vol. 11 (1). P. 1–15. <https://doi.org/10.21307/ijssis-2018-017>

211. Crop Monitoring as an E-agriculture tool in developing countries: Project Final Report. Retrieved from: <https://cordis.europa.eu/docs/projects/cnect/1/270351/080/deliverables/001-FinalReportEAGRI2014V10.pdf> (accessed March 18, 2024).

212. Atalla, S., Tarapiah, S., Gawanmeh, A., Daradkeh, M., Mukhtar, H., Himeur, Y., Mansoor, W., Hashim, K.F.B., Daadoo, M. IoT-Enabled Precision Agriculture: Developing an Ecosystem for Optimized Crop Management. *Information*, 2023, Vol. 14 (4):205. P. 1–23. <https://doi.org/10.3390/info14040205>

213. Song, Y., Bi, J., Wang, X. Design and implementation of intelligent monitoring system for agricultural environment in IoT. *Internet of Things*, 2024, Vol. 25. P. 1–14. <https://doi.org/10.1016/j.iot.2023.101029>

214. Saqib, M., Almohamad, T.A., Mehmood, R.M. A Low-Cost Information Monitoring System for Smart Farming Applications. *Sensors*, 2020, Vol. 20 (8):2367. P. 1–18. <https://doi.org/10.3390/s20082367>

215. Rahman, M.B., Chakma, J.D., Momin, A., Islam, S., Uddin, M.A., Islam, M.A., Aryal, S. Smart Crop Cultivation System Using Automated Agriculture Monitoring Environment in the Context of Bangladesh Agriculture. *Sensors*, 2023, Vol. 23 (20):8472. P. 1–23. <https://doi.org/10.3390/s23208472>

216. Lebediev, V.A., Laktionov, I.S., Vovna, O.V., Kabanets, M.M., Sahaida, P.I., Dobrovolska, L.O. Methods of improving technical and functional characteristics of serial budget microprocessor platforms. *Journal Eur. des Systemes Automatises*, 2022, Vol. 55 (1). P. 81–88. <https://doi.org/10.18280/jesa.550108>

**РОЗДІЛ 2**

**СТРУКТУРНО-АЛГОРИТМІЧНА ОРГАНІЗАЦІЯ ТА**  
**АПАРАТНО-ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНИХ**  
**ТЕХНОЛОГІЙ АГРОТЕХНІЧНОГО ОНЛАЙН-МОНІТОРИНГУ**  
**ҐРУНТОКЛІМАТИЧНИХ ПАРАМЕТРІВ**  
**СІЛЬСЬКОГОСПОДАРСЬКИХ ВИРОБНИЦТВ**

**2.1 Комп'ютерно-орієнтована модель мережевої агрегації та периферійної обробки результатів моніторингу ґрунтокліматичних параметрів**

Одним із сучасних і ефективних підходів до планування агротехнічних заходів під час посівів і вирощування с/г культур є автоматичне генерування рекомендацій щодо агротехнічних процедур на підставі глибинної обробки вимірювальних даних щодо динаміки ґрунтокліматичних параметрів (вологість і температура повітря та ґрунту, кількість опадів, час зволоження листя, ефективна енергетична освітленість, швидкість і напрямок вітру та інше) з урахуванням типів і періодів вегетації вирощуваних культур [1]–[4].

Варто зазначити, що на сьогоднішній день відома значна кількість якісних результатів науково-прикладних досліджень із розробки IoT мереж моніторингу розподілених фізико-хімічних параметрів, у тому числі агротехнічного призначення, як це показано в таблиці 2.1.

На підставі систематизації результатів проведеного аналізу апріорної інформації (табл. 2.1) встановлено:

- під час побудови фізичного рівня IoT систем використовується архітектура на основі бездротових сенсорних мереж;
- під час мережевого обміну даними використовуються технології LoRa, ZigBee, 4G LTE та BLE;
- задля вирішення задач трансформації та аналітики вимірювальних даних використовується технологія хмарних обчислень;

– синтез структурно-алгоритмічної організації бездротових сенсорних мереж агротехнічного призначення в більшості випадків виконується на підставі однофакторного підходу за критеріями енергоефективності або зони покриття мережі.

Таблиця 2.1 – Результати змістовного аналізу і логічного узагальнення науково-прикладних результатів щодо побудови IoT систем розподіленого онлайн-моніторингу

<b>Предмет дослідження</b>	<b>Використані технології</b>	<b>Посилання</b>
Система вимірювального контролю та діагностики електротехнічних об'єктів	WSN, DPM	[5]
Ймовірнісна модель бездротової мережі сенсорів із обліком критеріїв якості мережевого зв'язку та зони покриття	WSN	[6]
Модель побудови бездротової сенсорної мережі з обліком оптимізації критеріїв ефективності та безпеки маршрутизації інформаційних повідомлень	WSN	[7]
Розробка узагальненої функціональної схеми бездротової мережі сенсорів для IoT системи аграрного моніторингу	WSN	[8]
Геометричні моделі побудови мережі бездротових сенсорів для цілей аграрного моніторингу на підставі багатопараметричної оптимізації	WSN, GA	[9]
Апаратно-програмне рішення інтелектуальної IoT системи збору, мережевого обміну та хмарної обробки вимірювальних даних агротехнічного моніторингу	WSN, PLC, LoRa	[10]
Аналіз мережевих сценаріїв обміну вимірювальними даними під час агротехнічного IoT моніторингу	WSN, LoRa	[11]
Структурно-алгоритмічна організація бездротової системи моніторингу параметрів мікроклімату теплиць	WSN, ZigBee	[12]
Аналіз сучасних тенденцій побудови IoT систем із використання бездротових мереж давачів	WSN, ZigBee	[13]

IoT система детектування лісових пожеж із оптимізованими показниками споживання електроенергії	WSN, Bluetooth, LoRa, 4G LTE	[14]
Концепція побудови мережевих моделей на основі даних із відкритих джерел	WSN, WANET, MANET	[15]
Аналіз архітектурних рішень побудови IoT систем із вбудованими алгоритмами AI для розумних міст	ICT, AI	[16]
Методи оцінки якості сигналів бездротових сенсорних мереж на основі ML-алгоритмів для тепличних умов моніторингу	WSN, ML, ZigBee	[17]
Методи та інтерфейси оптимізації споживаної потужності в бездротових сенсорних мережах	WSN, LPWAN	[18]
Розробка архітектури та програмно-апаратного рішення агротехнічного моніторингу на основі бездротової мережі сенсорів та мережевого протоколу MQTT	WSN, MQTT	[19]

В основу розроблюваного програмно-апаратного рішення онлайн IoT моніторингу ґрунтокліматичних параметрів сільськогосподарських підприємств рослинництва покладено технологію WSN за схемою зірка зірок (рис. 2.1).

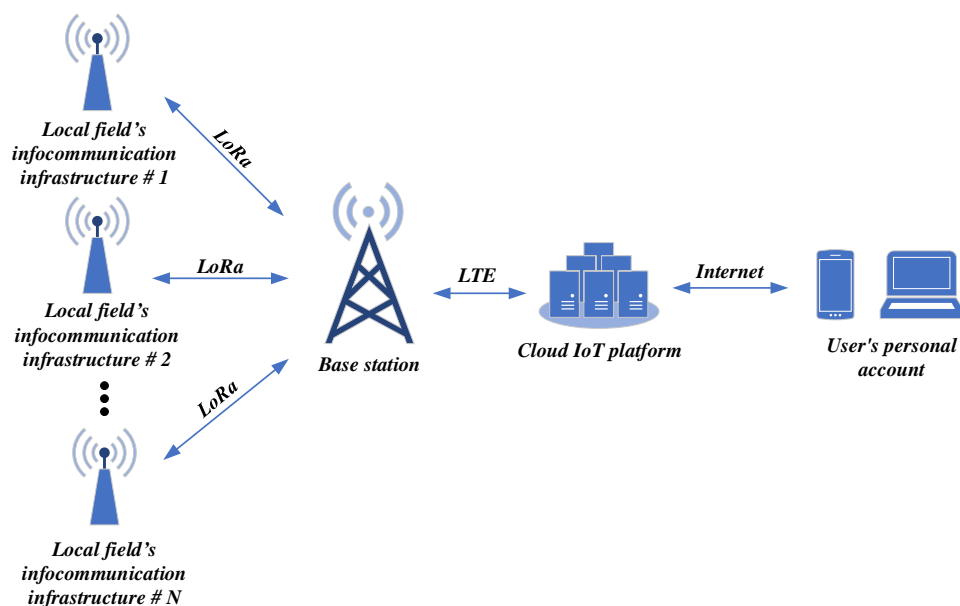


Рисунок 2.1 – Узагальнена архітектура інфокомунікаційної інфраструктури IoT мережі агротехнічного моніторингу

У такій архітектурі кожен функціональний блок «Local field's infocommunication infrastructure» являє собою локацію (окремий фрагмент, як показано на рисунку 2.2), що агрегує дані з кінцевих вузлів (сукупність інтелектуальних давачів ґрунтокліматичних параметрів) за бездротовою технологією ZigBee (Type A).




Рисунок 2.2 – Деталізована структурно-функціональна організація інфокомунікаційної інфраструктури IoT мережі агротехнічного моніторингу

Після цього агреговані дані від мережевих вузлів Type A, що пройшли процедури попереднього статистичного аналізу у відповідних мережевих вузлах Type B (усереднення в часі й просторі) передаються за допомогою технології LoRa до базової станції (Type C) мережевої інфраструктури поля.

Основними функціями базової станції (мережевий вузол Type C) є: формування локальної бази даних результатів вимірювальних спостережень; інтелектуальний аналіз даних із можливістю прогнозування впливу ґрунтокліматичних параметрів на показники якості вирощування сільськогосподарських культур; узгодження мережевих протоколів; відправлення інформаційних повідомлень (оброблених даних) до хмарного сервера за допомогою технології LTE.

Хмарний сервер у такій архітектурі (рис. 2.1) виконує роль IoT платформи, що надає доступ до вимірювальної інформації на віддалених пристроях користувачів. Зазначені вище технології бездротового зв'язку обрано на підставі типових показників радіусу дії, енергоспоживання та алгоритмів шифрування даних.

Таким чином, функціональний ланцюг ретрансляції інформаційних повідомлень із використанням запропонованої архітектури (рис. 2.1) та структурно-алгоритмічної організації (рис. 2.2) IoT мережі агротехнічного моніторингу наведено на рисунку 2.3.

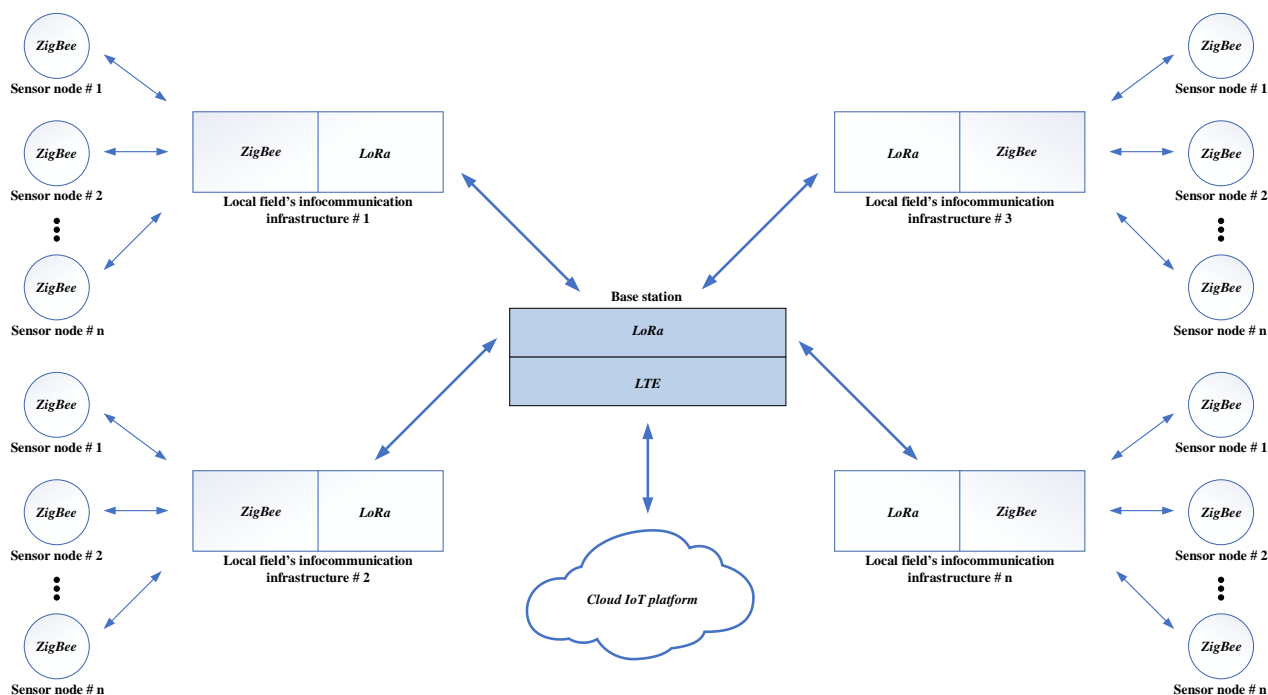


Рисунок 2.3 – Функціональний ланцюг використання мережевих технологій обміну вимірювальними даними агромоніторингу

Варто зазначити, що можливі варіанти геометричних моделей розміщення сенсорних вузлів (рис. 2.2) були встановлені шляхом аналізу результатів досліджень, які висвітлено в науковій статті [9]. Отже, наведена на рисунку 2.2 структурно-функціональна організація інфокомунікаційної інфраструктури IoT мережі агротехнічного моніторингу потребує проведення додаткових досліджень із обґрунтування оптимальної геометричної моделі їх розміщення за критеріями надійності та зони покриття.

В основу алгоритму оцінки ефективності геометричних моделей бездротової мережі сенсорів досліджуваної IoT технології агротехнічного моніторингу (рис. 2.2) покладено задачу максимізації двопараметричної цільової функції:

$$F = optimum(S_{cover\ norm}, P_{uptime}) \rightarrow \max, \quad (2.1)$$

де  $F$  – цільова функція двопараметричної оптимізації;  $S_{cover\ norm}$  – приведені значення загальної площі покриття;  $P_{uptime}$  – вірогідність безвідмовної роботи.

З метою більш змістовного аналізу ефективності побудови WSN за певною геометричною моделлю під час оцінки ефективності (2.1) в якості першого критерію запропоновано використовувати приведені значення площі зони покриття до кількості задіяних бездротових модулів:

$$S_{cover\ norm} = \frac{S_{cover}}{n}, \quad (2.2)$$

де  $S_{cover\ norm}$  – приведені значення загальної площі покриття;  $S_{cover}$  – загальна площа покриття;  $n$  – кількість бездротових модулів, що організують відповідну геометричну модель мережі.

Загальна зона покриття геометричної моделі WSN може бути однозначно обчислена через радіус дії бездротового модуля за формулами [9]:

$$S_{cover} = \begin{cases} \left(\frac{7\pi}{3} + 2\sqrt{3} + 4\right) \cdot r^2 // \text{квадрат} \\ \left(\frac{11\pi}{3} + 8\sqrt{3}\right) \cdot r^2 // \text{ромб} \\ \left(\frac{9\pi}{4} + 6.13\right) \cdot r^2 // \text{п'ятикутник} \end{cases}, \quad (2.3)$$

де  $r$  – радіус дії модуля бездротового зв'язку.

В якості другого критерію двопараметричної оптимізації ефективності (2.1) запропоновано використовувати ймовірність безвідмовної роботи WSN за певною геометричною моделлю (квадрат, ромб або п'ятикутник). Цей критерій може бути обчислений за алгоритмом, який описано нижче.

Кожна локальна геометрична модель польового рівня агрегування даних із точки зору мережевої організації являє собою певну сукупність передавачів (рис. 2.2 – Type A) та одного приймача (рис. 2.2 – Type B). Імовірність відмови (виникнення непрацездатного стану) хоча б одного із вузлів передавачів інформаційних повідомлень у мережевій структурі може бути знайдена як диз'юнкція ймовірностей відмови окремо взятих передавачів. Кінцевий вигляд виразу (2.4) знайдено шляхом перетворень диз'юнктивної форми до кон'юнктивної за правилом де Моргана:

$$Q_{transmitter} = q_1 \text{ or } q_2 \text{ or } \dots \text{ or } q_m = \overline{\overline{q_1} \text{ and } \overline{q_2} \text{ and } \dots \text{ and } \overline{q_m}}, \quad (2.4)$$

де  $q_i = 1 - p_i$

де  $Q_{transmitter}$  – імовірність відмови передавачів;  $q_i$  – імовірність відмови  $i$ -го передавача;  $p_i$  – імовірність безвідмовної роботи  $i$ -го передавача;  $i$  – порядковий номер передавача;  $m$  – кількість передавачів (пристроїв Type A) у відповідній геометричній моделі.

Наступним кроком є перетворення логічних операцій виразу (2.4) до алгебраїчних, а саме: операція *and* замінюється алгебраїчним добутком,

операція інверсії – операцією  $(1-q_i)$ . Також під час отримання виразу (2.5) було враховано факт того, що передавачі побудовано на ідентичних пристроях, які введено в експлуатацію одночасно, отже виконується умова:  $q=q_i$ . Таким чином, отримуємо:

$$Q_{transmitter} = 1 - (1 - q)^m. \quad (2.5)$$

Під повним непрацездатним станом мережевої організації розуміється одночасна відмова приймача інформаційних повідомлень (Type A) та хоча б одного з передавачів (Type B). Таке припущення є справедливим для мереж, які побудовано на основі технології ZigBee, що самоорганізуються.

Імовірність виникнення непрацездатного стану мережі сенсорів за відповідною топологією може бути розрахована за булевим виразом:

$$Q_{total} = Q_{receiver} \text{ and } Q_{transmitter}, \quad (2.6)$$

де  $Q_{total}$  – імовірність появи непрацездатного стану мережі;  $Q_{receiver}$  – імовірність відмови приймача (B);  $Q_{transmitter}$  – імовірність відмови передавачів (A).

Після еквівалентних перетворень логічних операцій до алгебраїчних, а також із урахуванням того, що приймач має ідентичну схемотехнічну реалізацію до передавачів (різниця обумовлена лише вбудованим програмним кодом), то виконується умова:  $Q_{receiver}=q$ .

Отже, ймовірність виникнення непрацездатного стану мережевої організації може бути обчислена за формулою:

$$Q_{total} = q \cdot (1 - (1 - q)^m). \quad (2.7)$$

На підставі виразу (2.7) може бути обчислена ймовірність безвідмовної роботи певної геометричної моделі бездротової мережі сенсорів за формулою:

$$P_{uptime} = 1 - Q_{total} = 1 - q \cdot (1 - (1 - q)^m). \quad (2.8)$$

Таким чином, на підставі аналізу формули (2.8) встановлено, що критерій ефективності безвідмовної роботи IoT системи моніторингу ґрунтокліматичних параметрів є нелінійною функцією, що залежить від кількості кінцевих функціональних елементів бездротової мережі сенсорів (Sensor node).

Під час оцінки критерію ефективності синтезованої IoT мережі агротехнічного моніторингу прийнято наступні припущення: граничне значення радіусу дії типових ZigBee модулів для польових умов дорівнює 100 м [20]; граничне значення радіусу дії типових LoRa модулів для польових умов дорівнює 15 км [21]; модулі ZigBee розглядаються як інтегральні мікропроцесорні пристрої, що побудовані на напівпровідниковій компонентній базі; динамічний діапазон зміни ймовірність відмови ZigBee модулів прийнятий на підставі експериментальних досліджень авторів статті [22] від 0,01 відн. од. до 0,1 відн. од., що відповідає періоду напрацювання 5 років у відповідності до нормального закону розподілу. Результати оцінки площі зони покриття та її приведенного значення залежно від геометричної моделі побудови WSN, що обчислені за формулами (2.2) і (2.3), наведено на рисунку 2.4.




Рисунок 2.4 – Залежність площі покриття моделей мереж бездротових сенсорів

Графічні результати оцінки показників надійності досліджуваних геометричних моделей організації сенсорних мереж польового рівня IoT системи агротехнічного моніторингу, що обчислені за формулами (2.7) і (2.8), наведено на рисунку 2.5.

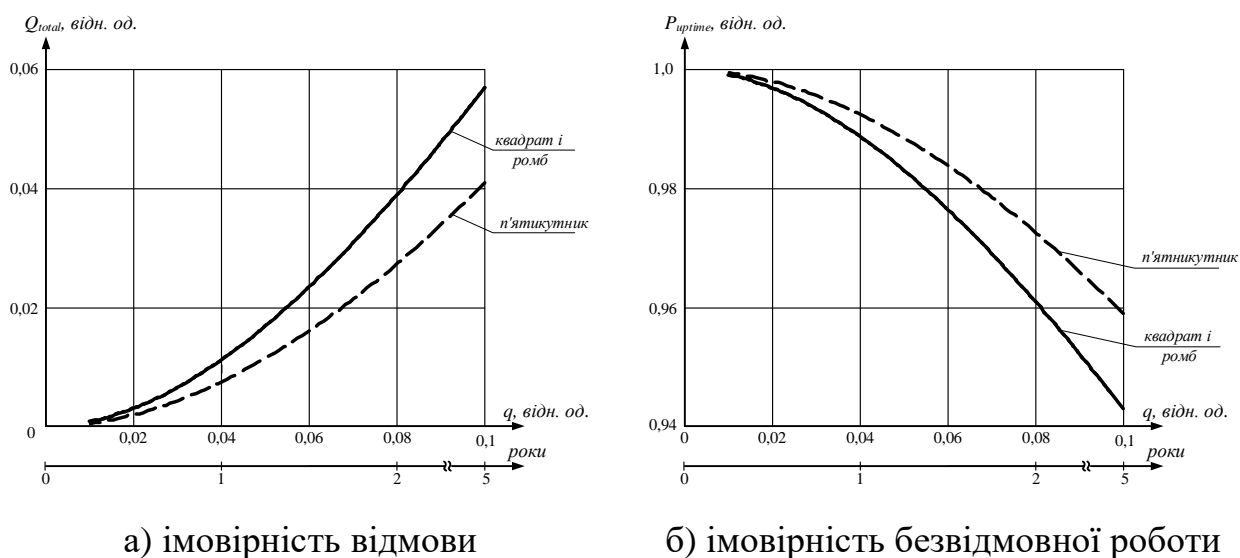


Рисунок 2.5 – Динаміка показників надійності моделей бездротових сенсорних мереж

У таблиці 2.2 наведено узагальнені результати аналізу оцінки критеріїв ефективності досліджуваної мережевої організації бездротових сенсорів IoT технології.

Таблиця 2.2 – Кількісні оцінки ефективності IoT системи агротехнічного моніторингу

Параметр	Приведене значення зони покриття ( $S_{cover\ norm}$ )		Вірогідність безвідмовної роботи ( $P_{uptime}$ )	
	Граничне значення, $m^2$ /кількість	Відносне відхилення від максимуму, %	Граничне значення, відн. од.	Відносне відхилення від максимуму, %
квадрат	$1,64 \cdot 10^4$	-41,8	0,943	-1,67
ромб	$2,82 \cdot 10^4$	0	0,943	-1,67
п'ятикутник	$2,20 \cdot 10^4$	-22,0	0,959	0

Результати аналізу даних, які наведено в таблиці 2.2, на основі цільової функції двопараметричної оптимізації структурно-алгоритмічної організації IoT системи моніторингу ґрунтокліматичних параметрів сільськогосподарських підприємств рослинництва (2.1) дозволили встановити такі положення. За умови рівності вагових показників критеріїв приведеної зони покриття та вірогідності безвідмовної роботи найбільш ефективною є геометрична модель у вигляді ромба під час побудови WSN. Отже, функціональні вузли Sensor node (Type A) мають розташовуватись у вигляді ромба у межах одного функціонального фрагмента поля (Local field's infocommunication infrastructure) із подальшим агрегуванням даних у вузлі (Base station), як це показано на рисунку 2.2. Кількість таких локацій (Local field's infocommunication infrastructure) може бути визначена на підставі площі сільськогосподарського об'єкта рослинництва, що підлягає моніторингу, як відношення загальної площі поля до площі, що перекривається однією локацією (граничне значення становить  $2,54 \cdot 10^5 \text{ м}^2$ ).

Задля валідації отриманих результатів із критеріального синтезу структурно-алгоритмічної організації досліджуваної IoT системи моніторингу ґрунтокліматичних параметрів було розроблено комп'ютерну модель програмно-апаратного рішення цієї IoT системи (рис. 2.6). Під час розробки та тестування відповідної моделі було обрано кількість функціональних блоків «Local field's infocommunication infrastructure» рівною 4, що покриває площу поля, яка приблизно дорівнює 100 га.

У наведеній моделі: вузол SINK\_70 (в центрі моделі) відіграє роль базової станції (рис. 2.2, Type C); вузли S\_28, S\_36, S\_49 та S\_61 (центри ромбів) відіграють роль пристроїв локальної агрегації та попередньої статистичної обробки даних (рис. 2.2, Type B); всі інші вузли є моделями інтелектуальних давачів фізико-хімічних параметрів (рис. 2.2, Type A).

Окрім цього, як зазначалось вище, кожен із таких функціональних вузлів являє собою апаратно-програмне рішення, що функціонує на певній мережевій технології (рис. 2.3). У середовищі CupCarbon налаштування цих

функціональних блоків було виконано програмними засобами у вигляді SenScript блоків.

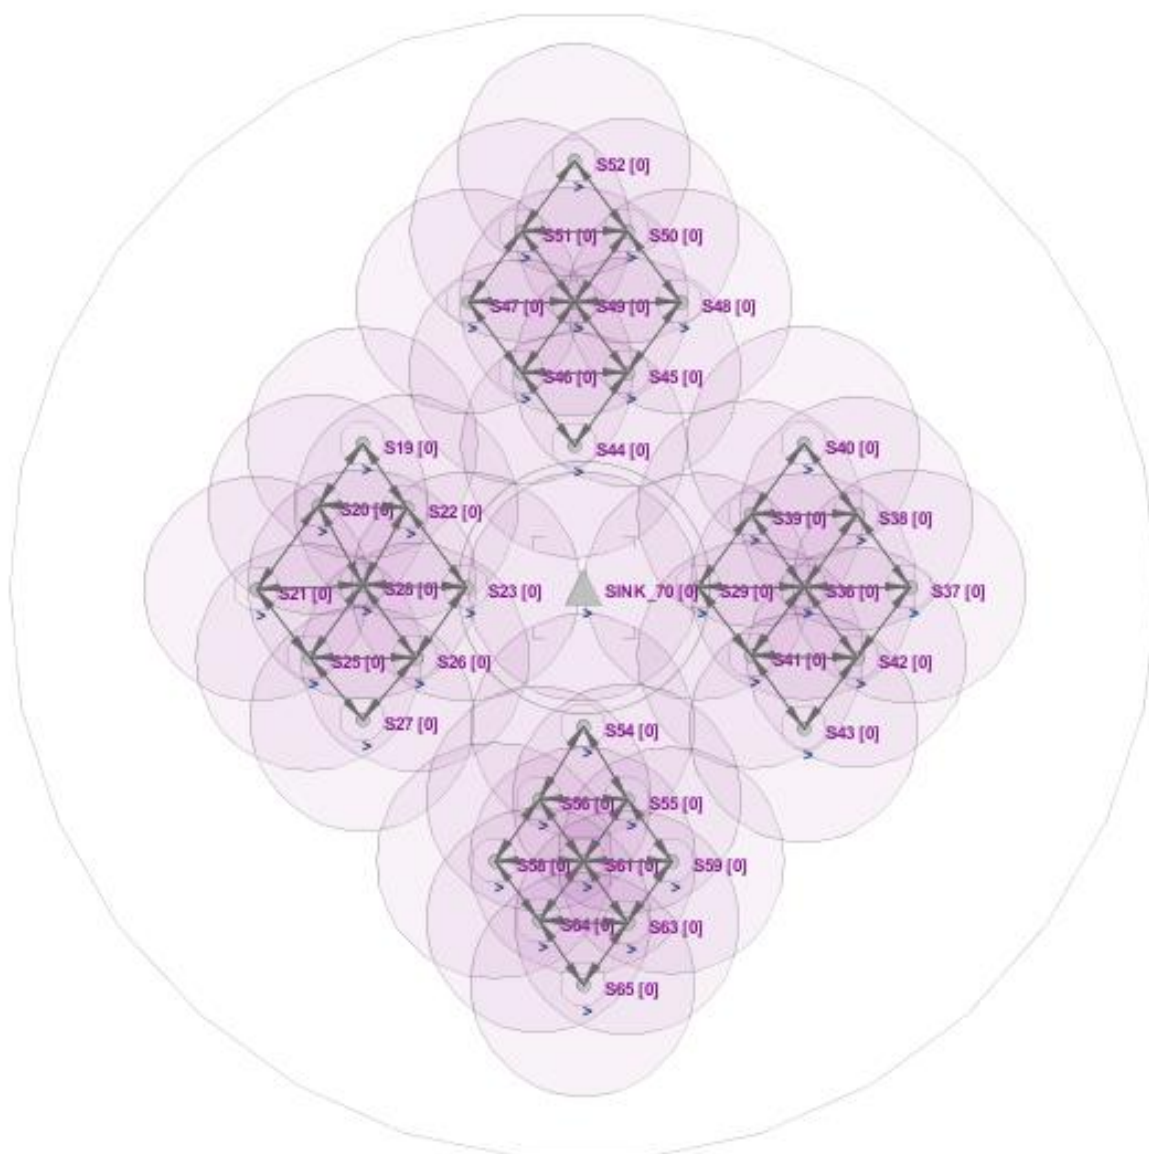


Рисунок 2.6 – Імітаційна комп’ютерна модель WSN IoT системи агротехнічного моніторингу ґрунтокліматичних параметрів в середовищі CupCarbon

Розроблена комп’ютерна модель програмно-апаратного забезпечення IoT системи моніторингу ґрунтокліматичних параметрів сільськогосподарських підприємств була протестована в програмі CupCarbon, як це показано у вигляді графічних результатів на рисунках 2.7–2.9.




Рисунок 2.7 – Графічна інтерпретація процесу передачі інформаційних повідомлень із функціональних вузлів Type A до вузлів Type B




Рисунок 2.8 – Графічна інтерпретація процесу передачі інформаційних повідомлень із функціональних вузлів Type B до Base station (Type C)




Рисунок 2.9 – Графічна інтерпретація процесу передачі інформаційних повідомлень із функціонального вузла Type C до віддаленого хмарного сервера

У результаті валідації комп'ютерної моделі (рис. 2.7–2.9) було доведено працездатність та ефективність синтезованої структурно-алгоритмічної організації IoT системи. Цей факт було встановлено шляхом детектування інформаційних повідомлень на відповідних функціональних вузлах моделі, що відпрацьовують алгоритми бездротового мережевого обміну вимірювальними даними щодо ґрунтокліматичних параметрів сільськогосподарських об'єктів рослинництва.

Як зазначалось вище, під час розробки комп'ютерно-орієнтованої моделі IoT мережі детектування вірогідності виникнення хвороб сільськогосподарських культур із підтримкою прийняття рішень покладено технологію WSN за топологією зірка зірок (рис. 2.1). У такій архітектурі кожен функціональний блок «Local field's network infocommunication infrastructure» являє собою локацію (окремий фрагмент «Type B» на рис. 2.10), що агрегує дані з кінцевих вузлів (сукупність інтелектуальних давачів ґрунтокліматичних

параметрів) за допомогою NRF24 на робочій частоті ISM 2.5 GHz (Type A на рис. 2.10). Після цього агреговані дані від мережевих вузлів Type A, що пройшли процедури попереднього статистичного аналізу у відповідних мережевих вузлах Type B (усереднення в часі й просторі) передаються за допомогою технології LoRa до базової станції (Type C) мережевої інфраструктури поля. Основними функціями базової станції (мережевий вузол Type C) є: формування локальної бази даних результатів вимірювальних спостережень; інтелектуальний аналіз даних із можливістю прогнозування впливу ґрунтокліматичних параметрів на показники якості вирощування сільськогосподарських культур; узгодження мережевих протоколів; відправлення інформаційних повідомлень (оброблених даних) до хмарного сервера за допомогою технології LTE. Хмарний сервер у такій архітектурі (рис. 2.1) виконує роль IoT платформи, що надає доступ до візуалізації вимірювальної інформації на віддалених пристроях користувачів.

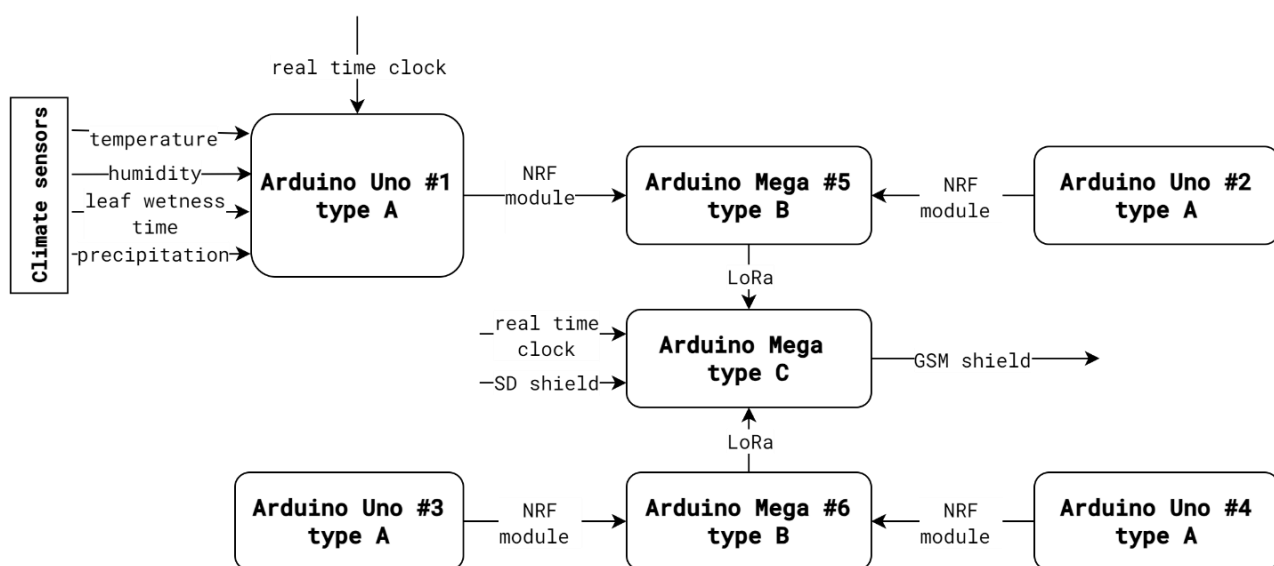


Рисунок 2.10 – Деталізована структурно-функціональна організація інфокомунікаційної інфраструктури мережевого агротехнічного моніторингу

Зазначені вище технології бездротового зв'язку та наведена на рисунку 2.10 структурно-функціональна організація інфокомунікаційної інфраструктури IoT мережі обґрунтовані на підставі проведених досліджень у

науковій роботі [23] із визначенням оптимальної геометричної моделі розміщення сенсорних вузлів за критеріями надійності та зони покриття типових з урахуванням показників радіусу дії, енергоспоживання та алгоритмів шифрування даних.

Задля проведення досліджень із розробки та валідації програмно-апаратного забезпечення комп'ютерно-орієнтованої моделі IoT мережі детектування вірогідності виникнення хвороб сільськогосподарських культур обґрунтовано структурно-алгоритмічну організацію нейро-нечіткої моделі обробки даних (рис. 2.11) і UML-діаграму взаємодії компонент цієї IoT мережі (рис. 2.12).

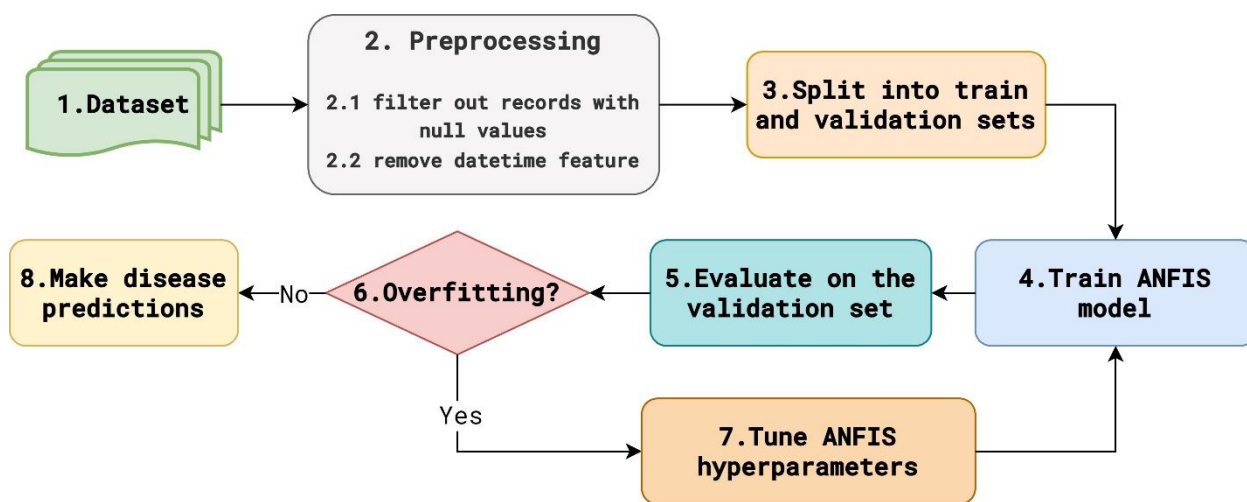


Рисунок 2.11 – Структурно-алгоритмічна організація нейро-нечіткої моделі обробки даних

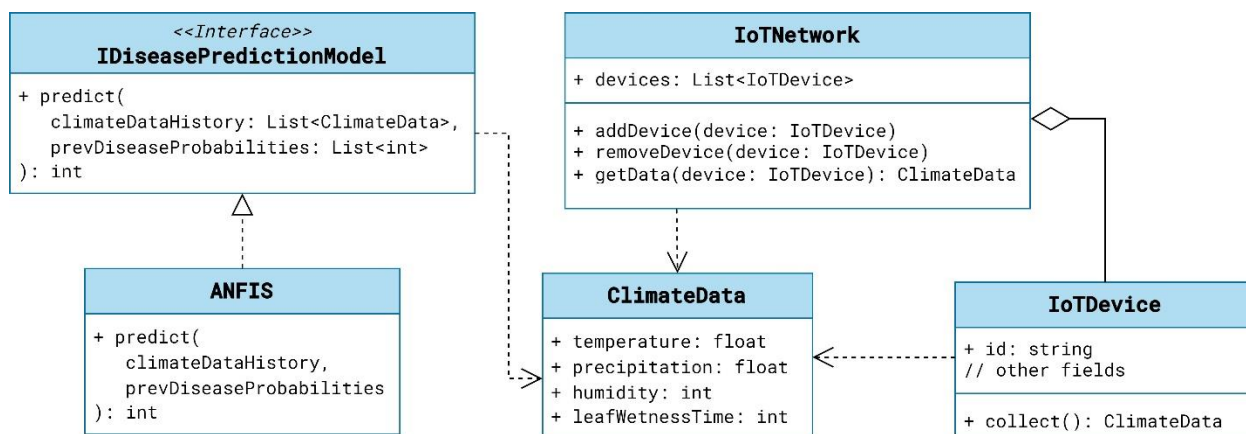


Рисунок 2.12 – UML діаграма запропонованої моделі

Набір даних є основою для навчання моделі ANFIS [24]. Він містить історичні дані такі як, дата та час вимірювання, температура повітря, відносна вологість повітря, кількість опадів та час зволоження листя. Кожен запис у наборі даних являє собою конкретне спостереження в контексті сільського господарства, а цільовою змінною, є вірогідність появи хвороб сільськогосподарських культур у динамічному діапазоні від 0 % до 100 %.

Важливо забезпечити якість даних шляхом належної обробки пропущених значень. На цьому кроці відфільтровуються записи, що містять нульові значення. Відсутні дані можуть негативно вплинути на процес навчання та точність моделі, тому дуже важливо або імплікувати, або видалити такі записи. Ознака часу даних може не мати прямого відношення до прогнозування захворювань та її збереження в наборі даних може призвести до того, що спостерігається зайва складність моделі, отже цей параметр вилучається.

Поділ масиву даних на навчальний та перевірочний набори є стандартною практикою в машинному навчанні. Навчальний набір використовується для навчання моделі ANFIS закономірностям у даних, тоді як валідаційний набір допомагає оцінити ефективність узагальнення моделі на даних, що не входять до навчальної вибірки. Цей крок має вирішальне значення для запобігання перенавчання.

Навчання моделі ANFIS передбачає оптимізацію її параметрів відповідно до закономірностей у навчальних даних. Модель вивчає взаємозв'язки між вхідними ознаками та цільовою змінною (вірогідністю появи хвороби с/г культури) під час цієї фази. Процес навчання спрямований на мінімізацію похибки між прогнозованими та фактичними результатами.

Після того, як модель ANFIS навчена, оцінюється її ефективність на валідаційній вибірці. Цей крок дає уявлення про те, наскільки добре модель узагальнює нові дані, відповідно до стандартних метрик як MAE, RMSE та  $R^2$ .

Якщо модель демонструє ознаки перенавчання (добре працює на навчальній вибірці, але погано на валідаційній), необхідно внести корективи,

щоб запобігти цьому. Перенавчання відбувається, коли модель вивчає шум у навчальних даних замість основних закономірностей. Цей крок передбачає налаштування гіперпараметрів.

Якщо модель ANFIS не демонструє перенавчання і добре працює на валідаційному наборі, її можна використовувати для прогнозування вірогідності появи хвороб.

Дослідження проводилося за таких умов та обмежень:

- масив даних (за період з вересня 2022 по вересень 2023) з кліматичними параметрами було зібрано з метеостанції Metos by Pessl Instruments за допомогою IoT-платформи FieldClimate, доступ до якої надано компанією Metos Ukraine LLC;

- агрокліматична зона отримання експериментальних даних: Північний Степ України (посушлива і тепла зона; гідротермічний коефіцієнт становить від 0,7 до 1,0; типова річна сума температур від знаходиться в діапазоні від 2900 °C до 3300 °C);

- тип сільськогосподарських культур: кукурудза;

- діагностована хвороба: Fusarium Head Blight (FHB);

- інформативні ґрунтокліматичні параметри: температура повітря (°C), відносна вологість повітря (%), кількість опадів (мм) та тривалість зволоження листя (хв).

Ланку польового рівня збору вимірювальних даних у досліджуваній моделі було реалізовано за допомогою стандартних компонент середовища моделювання Proteus. У якості мікроконтролерної ланки використано Arduino Uno та Arduino Mega 2560. Компоненти, які були використані під час побудови моделі, наведено в таблиці 2.3. Мережевий зв'язок забезпечено за допомогою: HC-05 на основі Serial Interface, Modulo RF library та Sim900D. Пристрої візуалізації: Virtual terminal.

Деталізацію типів і зв'язків компонент, на яких побудовано комп'ютерно-орієнтовану модель IoT системи мережевого агромоніторингу, наведено в таблиці 2.3.

Таблиця 2.3 – Компоненти досліджуваної системи агромоніторингу

Компоненти	Мережевий модуль	Моделльний аналог
Temperature sensor	Type A, Type B, Type C	DHT22
Relative humidity sensor	Type A, Type B, Type C	DHT22
Precipitation sensor	Type A, Type B, Type C	POT-HG 10 k $\Omega$ , POWER, GROUND
Leaf wetness sensor	Type A, Type B, Type C	WATER SENSOR (Designed by www.TheEngineeringProjects.com), CAP 300 uF, INDUCTOR 27 uH, POT_HG 1 k $\Omega$ , GROUND, POWER
Real-time clock	Type A, Type B, Type C	DS1307 (Designed by www.TheEngineeringProjects.com), DC Generator 5 V, GROUND
NRF module	Type A, Type B	MODULO RX (modulo rf library), MODULO TX (modulo rf library), GROUND, POWER,
LoRa module	Type B, Type C	HC-05 на основі Serial Interface (Designed by www.TheEngineeringProjects.com)
GSM shield	Type C	SIM900D-GREEN
Arduino Uno Rev3	Type A	ARDUINO UNO R3
Arduino Mega 2560 Rev3	Type B, Type C	ARDUINO MEGA 2560, GROUND, POWER

На основі деталізованої структурно-алгоритмічної організації інфокомунікаційної інфраструктури мережевого агротехнічного моніторингу (рис. 2.10), з урахуванням принципу декомпозиції дослідного завдання розробки та тестування комп'ютерних моделей функціональних складових інформаційної технології, в програмному середовищі Proteus була реалізована імітаційна комп'ютерна модель для тестування мережевої взаємодії різних протоколів на різних архітектурних рівнях IoT системи. Також для тестування інтегрованого інтелектуального алгоритму прогнозування вірогідності появи хвороб с/г культур у Matlab & Simulink Fuzzy Logic Toolbox було реалізовано відповідну модель ANFIS для обробки даних (see Fig. 5) [24]. Алгоритм створення та тестування комп'ютерної моделі полягає в наступному:

1. Перетворення ANFIS-моделі отриманої в [24] у програмний код для мікроконтролерної платформи Arduino Mega за допомогою спеціалізованого онлайн-ресурсу з відкритим вихідним кодом [25]. Наступним кроком було редагування аргументів функцій програмних компонентів для забезпечення їх відповідності номерам задіяних виводів мікроконтролера та діапазоном зміни фізико-хімічних ґрунтокліматичних параметрів.

2. Розробка імітаційної моделі мережевого вузлу Type A на базі Arduino Uno Rev3 в середовищі Proteus (рис. 2.13). До цієї імітаційної моделі інтегровано програмне забезпечення, що розроблене в середовищі Arduino IDE, яке реалізує опитування давачів ґрунтокліматичних параметрів, попередній статистичний аналіз (усереднення в часі й просторі) та передачу даних вимірювань до мережевого вузлу Type B за допомогою модуля NRF.

3. Розробка імітаційної моделі мережевого вузла Type B на базі Arduino Mega 2560 в середовищі Proteus (рис. 2.14). До цієї імітаційної моделі інтегровано програмне забезпечення, що розроблене в середовищі Arduino IDE, яке агрегує дані вимірювань від мережевих вузлів Type A, опитує власні давачі ґрунтокліматичних параметрів, виконує попередній статистичний аналіз (усереднення в часі й просторі) та передає результат до базової станції Type C за допомогою технології LoRa.

4. Розробка імітаційної моделі базової станції Type C на базі Arduino Mega 2560 в середовищі Proteus (рис. 2.15). До цієї імітаційної моделі інтегровано програмний код, який агрегує дані вимірювань від мережевих вузлів Type B, опитує власні давачі ґрунтокліматичних параметрів, виконує попередній статистичний аналіз (усереднення в часі й просторі), за допомогою ANFIS виконує прогнозування вірогідності появи хвороби с/г культури та відправляє SMS з отриманим результатом інтелектуального аналізу на вказаний номер.

5. Тестування режимів функціонування розробленої комп'ютерної моделі шляхом детектування даних, що передаються в результаті мережевої взаємодії різних протоколів на різних архітектурних рівнях IoT системи, виконано за

допомогою віртуального терміналу. Це дозволило оцінити валідність та робастність запропонованого програмно-апаратного рішення.

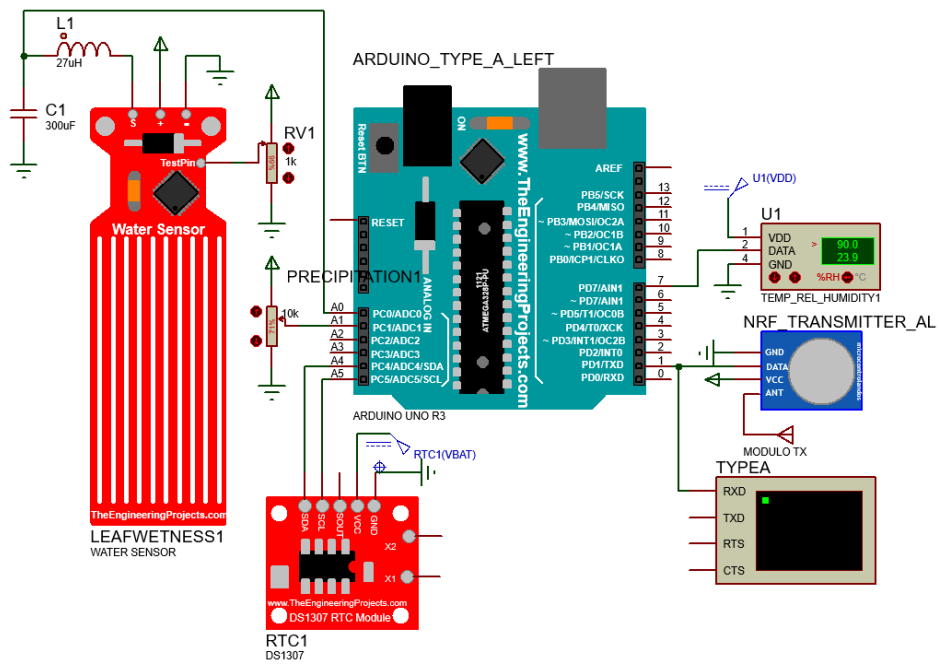


Рисунок 2.13 – Зовнішній вигляд моделі вузла Type A

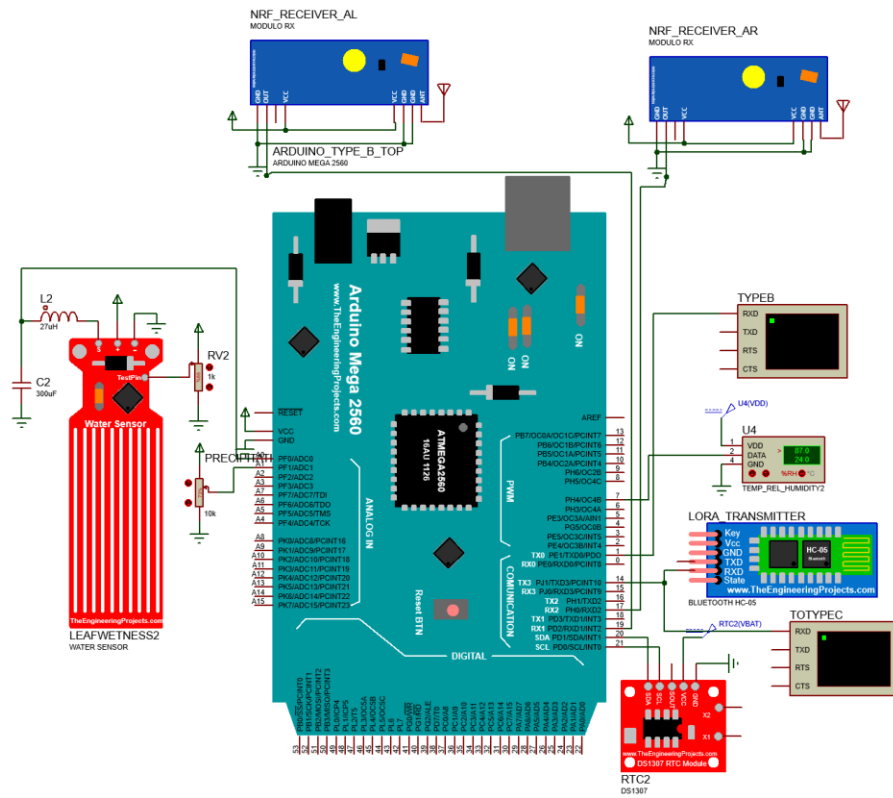


Рисунок 2.14 – Зовнішній вигляд моделі вузла Type B




Рисунок 2.15 – Зовнішній вигляд моделі вузла Type C

На основі викладених вище положень щодо розробки комп'ютерної моделі IoT мережі детектування вірогідності виникнення хвороб сільськогосподарських культур із підтримкою прийняття рішень проведено її дослідження методами комп'ютерного моделювання з відповідним аналізом отриманих результатів на якісному та кількісному рівнях.

Зовнішній вигляд всієї моделі наведено на рисунку 2.16. Ця комп'ютерна модель побудована у відповідності до структурно-функціональної організації системи, яку наведено на рисунку 2.10. У зв'язку з обчислювальними обмеженнями середовища Proteus, реалізовано спрощену версію схеми структурно-функціональної організація інформаційно-комунікаційної інфраструктури мережі агротехнічного моніторингу, а саме: два вузли Type A, один вузол Type B та один вузол Type C.

Відповідні результати валідації мережевої взаємодії різних протоколів на різних архітектурних рівнях IoT системи наведено у вигляді скріншотів

віртуальних терміналів середовища Proteus (рис. 2.17–2.21). Відповідні результати тестування інтегрованої інтелектуальної складової детектування вірогідності виникнення хвороб сільськогосподарських культур наведено у вигляді графіків залежності ґрунтокліматичних параметрів зони вирощування від часу та вірогідності виникнення хвороби при різних комбінаціях цих факторів (рис. 2.22). На рисунку 2.22 наведено часовий проміжок з 2023-08-10 19:00 по 2023-08-11 11:00, де перші 7 точок з інтервалом в одну годину – це передісторія, а з 2023-08-11 02:00 – етап прогнозування.




Рисунок 2.16 – Зовнішній вигляд повної моделі системи агромоніторингу

```

Virtual Terminal - TYPEA
TYPE A NODE TEST PROGRAM
DS1307 configured
Running...
Sending data to Type B...
&;NODE_TOP_A;23.9;90;2.8;60;2023-08-11;11:00:00;&
    
```

Рисунок 2.17 – Результати валідації мережевої взаємодії Type A # 1

Virtual Terminal - TYPEAR

```
TYPE A NODE (R) TEST PROGRAM
DS1307 configured
Running...
Sending data to Type B...
&;NODE_TOP_AR;24.1;79;2.5;60;2023-08-11;11:00:00;&
```

Рисунок 2.18 – Результати валідації мережевої взаємодії Type A # 2

Virtual Terminal - TYPEB

```
TYPE B NODE TEST PROGRAM
DS1307 configured
Running...
Parsing...
from TypeA
&;NODE_TOP_A;23.9;90;2.8;60;2023-08-11;11:00:00;&
Mode ID: NODE_TOP_A
Temperature: 23.9
Relative Humidity: 90
Precipitation: 2.8
Leaf Wetness: 60
Date: 2023-08-11
Time: 11:00:00
Parsing...
from TypeAR
&;NODE_TOP_AR;24.1;79;2.5;60;2023-08-11;11:00:00;&
Mode ID: NODE_TOP_AR
Temperature: 24.1
Relative Humidity: 79
Precipitation: 2.5
Leaf Wetness: 60
Date: 2023-08-11
Time: 11:00:00
Ok, Time = 11:00:05, Date (D/M/Y) = 11/8/2023
Temperature (C): 24.0
Relative Humidity (%): 87
Precipitation (mm): 2.9
Leaf Wetness (min): 60
Sending data to Type C...
&;NODE_TOP_B;24.0;85;2.7;60;2023-08-11;11:00:05;&
```

Рисунок 2.19 – Результати валідації мережевої взаємодії Type B

Virtual Terminal - FROMSIM900

```
AT
OK
AT+CMGF=1
AT+CMGS="+38(0XX)XXX-XX-XX"
ANFIS out: 83.08
```

Рисунок 2.20 – Результати валідації мережевої взаємодії модуля SIM900D

```
Virtual Terminal - TYPEC
TYPE C NODE TEST PROGRAM
Initializing SIM9000...
DS1307 configured
Running...
Parsing...
from TypeBTOP
&;NODE_TOP_B;24.0;85;2.7;60;2023-08-11;11:00:05;&
Node ID: NODE_TOP_B
Temperature: 24.0
Relative Humidity: 85
Precipitation: 2.7
Leaf Wetness: 60
Date: 2023-08-11
Time: 11:00:05
Ok, Time = 11:00:09, Date (D/M/Y) = 11/8/2023
Temperature (C): 24.0
Relative Humidity (%): 84
Precipitation (mm): 2.6
Leaf Wetness (min): 60
Sending data via GSM...
```

Рисунок 2.21 – Результати валідації мережевої взаємодії Type C

Основною метою цього експерименту було: протестувати передачу даних в рамках мережевої взаємодії різних протоколів на різних архітектурних рівнях IoT системи; протестувати можливість задіяння технології граничних обчислень під час інтеграції розробленої ANFIS моделі до мікроконтролерної ланки задля прогнозування вірогідності виникнення хвороб сільськогосподарських культур під час комплексного впливу інформативних факторів.

Результати комп'ютерного експерименту в середовищі Proteus продемонстрували достовірність та надійність розробленої комп'ютерно-орієнтованої моделі. Емуляція мережевих вузлів, базової станції та протоколів зв'язку точно відображала реальний сценарій, надаючи поточну інформацію про поведінку системи. Крім того, успішна передача даних між модулями підтвердила ефективність впроваджених механізмів зв'язку, таких як технології NRF і LoRa. Інтеграція ANFIS для прогнозування ймовірності захворювань у поєднанні з SMS-повідомленнями через LTE продемонструвала здатність

системи виконувати розширену аналітику та надавати кінцевим користувачам інформацію щодо детектованої вірогідності виникнення конкретної хвороби для конкретного типу с/г культури.

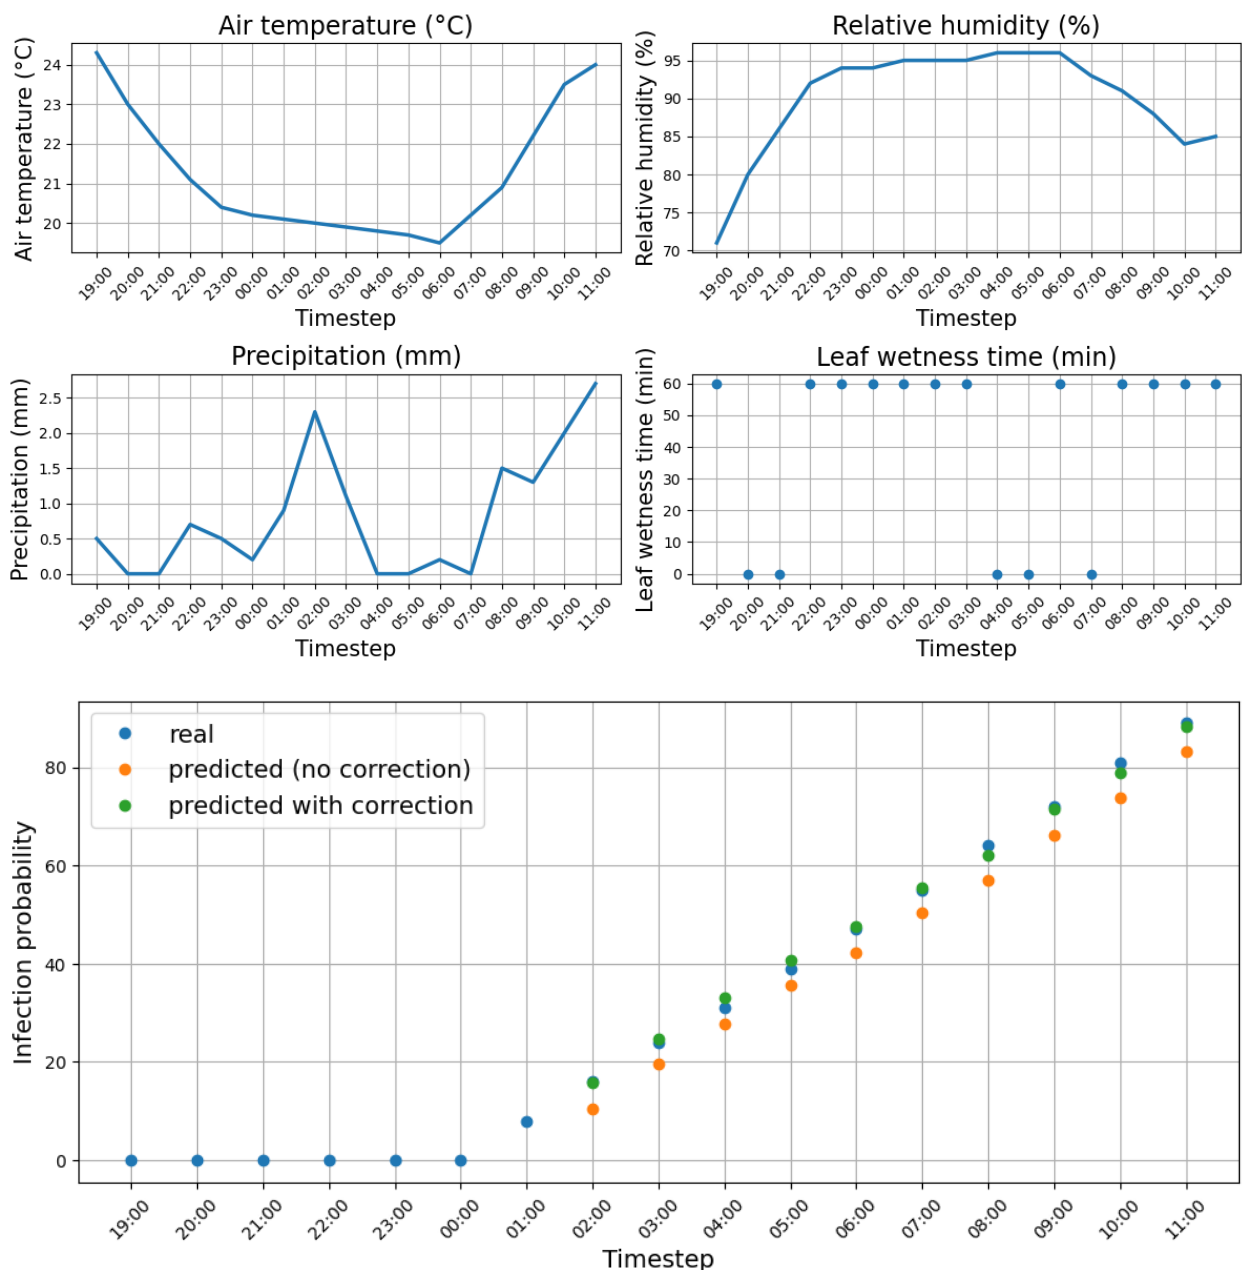


Рисунок 2.22 – Графіки залежності ґрунтокліматичних параметрів аграрних об’єктів і вірогідності появи хвороби сільськогосподарських культур від часу

На основі результатів тестування (рис. 2.22) за допомогою формул розрахунку математичного очікування ( $\Delta Probability_{mean}$ ) та

середньоквадратичного відхилення ( $\sigma_{\Delta\text{Probability}}$ ) оцінено вірогіднісні характеристики похибки апроксимації експериментальних даних ґрунтокліматичного моніторингу з використанням запропонованої моделі:

$$\Delta\text{Probability}_{mean} = \frac{1}{n} \sum_{i=1}^n \left| \text{Probability}_{Dataset_i} - \text{Probability}_{Model_i} \right|, \quad (2.9)$$

$$\sigma_{\Delta\text{Probability}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\Delta\text{Probability}_i - \Delta\text{Probability}_{mean})^2}, \quad (2.10)$$

де  $\text{Probability}_{Dataset_i}$  – вірогідність появи хвороби з набору даних IoT-платформи FieldClimate,  $\text{Probability}_{Model_i}$  – прогнозована вірогідність появи хвороби (вихідне значення моделі на основі ANFIS).

На підставі проведених обчислень встановлено, що математичне очікування похибки апроксимації даних дорівнює 5,2 % з середньоквадратичним відхиленням похибки  $\pm 1,4\%$ . Також було встановлено, що ця похибка носить адитивний характер і може бути зменшена шляхом введення поправки до результатів апроксимації. Чисельно ця поправка дорівнює математичному очікуванню похибки зі зворотним знаком (рис. 2.22). Після введення поправки значення похибки не перевищує  $1,1 \pm 0,7\%$ .

Результати комп'ютерного експерименту, які наведено на рисунках 2.17–2.22, довели придатність розробки для використання під час реалізації апаратно-програмних засобів інтелектуального моніторингу ґрунтокліматичних параметрів та детектування вірогідності виникнення хвороб сільськогосподарських культур. Це, у свою чергу, дає можливість реалізувати технологію інтелектуальних граничних обчислень на основі бюджетних вбудованих мікропроцесорних і сенсорних технологій в умовах агротехнічних виробництв рослинництва відкритих ґрунтів. Також запропоновані програмно-апаратні рішення для розробки відповідної інформаційної технології можуть бути адаптовані до більш широкого спектру вирощуваних культур і

масштабовані з урахуванням більшої кількості факторів впливу та фізико-хімічних параметрів без принципової зміни архітектури заявленої технології. Проведені дослідження доводять позитивний ефект щодо покращення техніко-функціональних характеристик застосовуваних на сьогодні агротехнічних інформаційних технологій моніторингу та контролю.

## **2.2 Метод і комп'ютерні моделі обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування та прогнозування хвороб сільськогосподарських культур на основі алгоритмів машинного навчання**

Під час досліджень цього підрозділу використано набір даних з професійних метеостанцій Metos by Pessl Instruments із використанням IoT платформи FieldClimate, доступ до якої був наданий компанією Metos Ukraine LLC. Дані було зібрано за період з вересня 2022 року по вересень 2023 року з інтервалом дискретизації 1 година для двох агрокліматичних зон: Північний Степ (Дніпропетровська область) та Лісостеп (Черкаська область) України. Тип сільськогосподарської культури – кукурудза. Діагностована хвороба – Fusarium Head Blight (ФНВ). Набір даних містив 17345 спостережень і 6 змінних. Змінні включали в себе дату та час опитування давачів (параметр `datetime`), інформативні ґрунтокліматичні параметри (температура повітря, відносна вологість повітря, кількість опадів та час зволоження листя агрокультур) та цільову змінну для цього набору даних (функція `disease probability`). Таким чином, набір даних із метеостанцій Metos by Pessl Instruments – це набір точок даних, що залежать від часу. Це означає, що кожній точці даних присвоєна певна часова мітка. У таблиці 2.4 наведено попередньо оброблені та узагальнені статистичні показники щодо ґрунтокліматичних параметрів у аналізованих агрокліматичних зонах, такі як: кількість спостережень для кожної зони, середнє значення, стандартне відхилення, медіана, мінімальне значення та

максимальне значення для зібраних кліматичних параметрів та ймовірності виникнення хвороби.

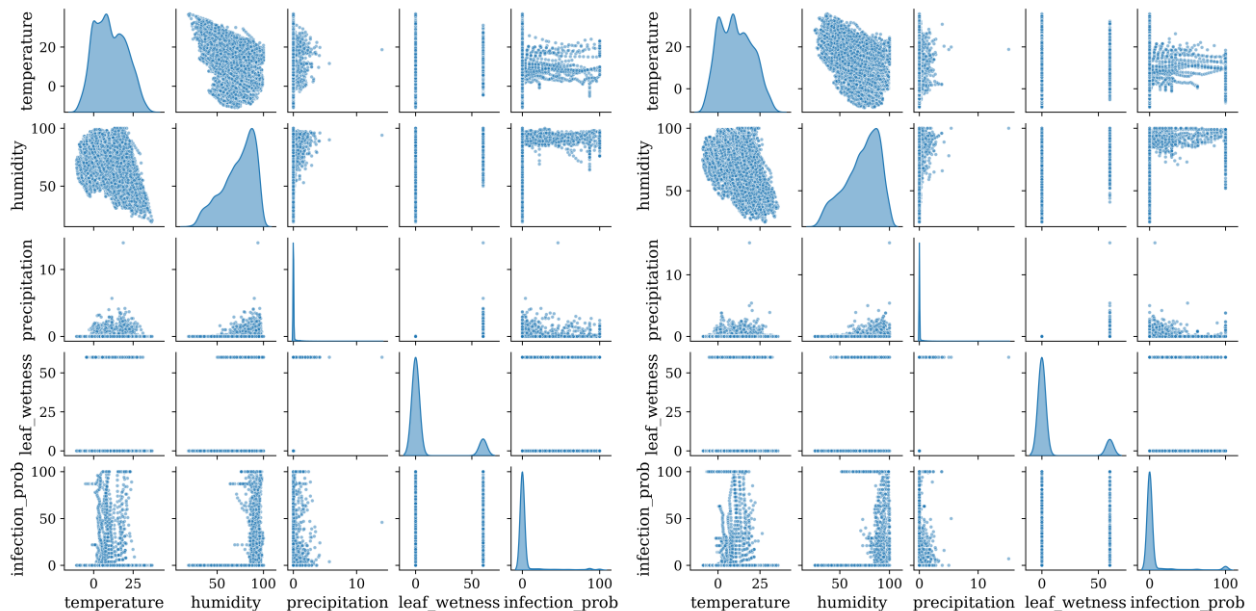
Таблиця 2.4 – Набір даних описової статистики ґрунтокліматичного агромоніторингу

Статистичні показники	Температура повітря, °С	Відносна вологість повітря, %	Кількість опадів, мм	Час зволоження с/г культур, хв	Вігорідність появи хвороби, %
<b>Північний Степ України</b>					
кількість			8658		
середнє значення	10,62	72,8	0,07	8,7	4,84
с.к.в.	9,74	17,32	0,34	21,13	17,61
медіана	9,65	76	0	0	0
мінімальне значення	-10,9	19	0	0	0
максимальне значення	37	100	14	60	100
<b>Лісостеп України</b>					
кількість			8687		
середнє значення	10,64	72,4	0,06	8,5	5,7
с.к.в.	9,58	17,07	0,32	20,93	20,43
медіана	9,90	76	0	0	0
мінімальне значення	-9,00	25	0	0	0
максимальне значення	36	100	15.2	60	100

Матриці розсіювання з гістограмами розподілу ґрунтокліматичних показників та ймовірностей захворювання, а також точкових графіків, що показують взаємні залежності змін вхідних (ґрунтокліматичні параметри) та вихідного (вірогідність появи хвороби кукурудзи) параметрів, наведено на рисунку 2.23.

Із наведених матриць розсіювання (рис. 2.23) для двох агрокліматичних зон видно, що більшість ненульових значень вірогідності появи захворювання спостерігались у температурному діапазоні від 0 °С до 20 °С. Також майже всі значення додатних імовірностей захворювання відповідали значенням відносної вологості повітря більше від 85 %. Із точкового графіка для часу

зволоження листя видно, що для даного кліматичного показника в наведених даних були присутні лише два можливих значення – 0 хв або 60 хв. Це інтерпретується як наступна логічна умова: чи було листя вологе або ні за останню годину.



а) Північний Степ

б) Лісостеп

Рисунок 2.23 – Графічна інтерпретація взаємозалежностей ґрунтокліматичних параметрів і вірогідності появи хвороби (*Fusarium Head Blight*)

Оскільки параметр `datetime` не містить корисної інформації для прогнозування ймовірності захворювання кукурудзи, то його не було враховано в якості вхідного значення у досліджуваних моделях ML та AI. Однак, `datetime` використовується для розташування даних у хронологічному порядку, а часові мітки мають бути рівновіддаленими в часових рядах. Хронологічний порядок досягається шляхом сортування наборів даних за часовими мітками. У досліджуваному наборі даних немає пропущених значень, що позбавляє від необхідності в будь-якій явній обробці пропущених даних. Це гарантує, що весь набір даних є повним і готовим для подальшої попередньої обробки та аналізу без необхідності застосування методів обробки або видалення неповних спостережень. Вибірку з 500 рядками з даних Північного Степу наведено на

рисунку 2.24, що демонструє типову локальну ділянку набору даних із аномаліями. В ній ймовірність виникнення захворювання на деяких проміжках поступово зростає, а потім різко спадає в 0, що може негативно вплинути на прогностні якості моделі, а отже, є предметом досліджень шляхом додаткової обробки.




Рисунок 2.24 – Приклад аномальних зон зміни ймовірності захворювання для вибірки даних із Дніпровського регіону

Для вирішення зазначеної задачі введено припущення, що застосування експоненціальної функції спадання для згладжування цих аномальних інтервалів може підвищити точність прогнозування моделей. Впроваджуючи цей підхід, очікуваним є ефект пом'якшення різких переходів у ймовірності виникнення захворювання, тим самим сприяючи більш безперервному й послідовному представленню основних моделей даних. Ця гіпотеза припускає, що експоненціальне згладжування покращує прогностні якості моделі завдяки ефективному відображенню поступових змін ймовірності виникнення захворювання та мінімізації дестабілізуючого впливу різких спадань до нуля,

що корелює з реальними фізичними процесами зволоження та висихання листяного покриву с/г культур.

Для згладжування проміжків, де ймовірність різко спадає до нуля, використано функцію експоненційного спадання (exponential decay) (2.11):

$$f(t) = Ae^{-kt}, \quad (2.11)$$

де  $A$  – значення ймовірності захворювання перед спадом до нульового значення;  $t$  – час (аргумент функції спадання): при  $t=0$ ,  $f(0)=A$ ;  $k$  – константа експоненційного затухання (більшим значенням відповідає більш швидке спадання функції, меншим – більш «гладке» спадання).

Таким чином, на основі гіпотези щодо використання експоненціальної функції спадання для згладжування інтервалів різкого спадання до нуля ймовірності виникнення захворювання постає дослідницька задача визначення оптимального коефіцієнта експоненціального спадання (2.11). Вибір відповідного коефіцієнта спадання передбачає пошук балансу між збереженням значних варіацій у наборі даних та зменшенням дестабілізуючого впливу таких аномальних ділянок у навчальних наборах даних залежно від типу ML та AI алгоритму. Ця задача передбачає проведення обчислювальних експериментів із подальшим аналізом для з'ясування впливу різних коефіцієнтів спадання функції на вихідну точність прогнозування з використанням запропонованого алгоритму.

Деякі моделі машинного навчання, такі як нейронні мережі, навчаються за допомогою чисельного методу оптимізації градієнтного спуску, який досягає більш швидкої збіжності на однаково масштабованих даних. Вхідні дані були масштабовані з використанням нормалізації та стандартизації. Враховуючи розподіл значень часу вологості листя (leaf wetness duration) та ймовірності виникнення захворювання (disease probability) (рис. 2.23), дані показники були нормалізовані за співвідношенням [26]:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}, \quad (2.12)$$

де  $x'$  – нормалізоване значення числової характеристики  $x$ ;  $\max(x)$  та  $\min(x)$  – максимальне та мінімальне значення  $x$ , відповідно.

Кількість опадів (precipitation), температура повітря (air temperature) та відносна вологість (relative humidity) були стандартизовані із використанням наступної формули [27]:

$$x' = \frac{x - \bar{x}}{\sigma}, \quad (2.13)$$

де  $x'$  – стандартизоване значення числової характеристики  $x$ ;  $\bar{x}$  – середнє значення  $x$  на навчальній вибірці;  $\sigma$  – с.к.в.  $x$  на навчальній вибірці.

Процес машинного навчання охоплює кілька важливих етапів, включаючи агрегацію та попередню обробку даних, вибір моделі, навчання обраної моделі на наборі даних, оцінку її ефективності та, зрештою, розгортання моделі.

Ефективне налаштування гіперпараметрів є передумовою у виборі оптимальної моделі. Суть налаштування гіперпараметрів полягає у використанні знань, отриманих під час попередніх ітерацій навчання, для покращення роботи моделі. Тонке налаштування параметрів алгоритму сприяє поступовому підвищенню ефективності моделі. В цьому дослідженні пошук оптимальних конфігурацій параметрів виконано методами ітераційного комп'ютерного експерименту.

Для врахування історії змін кліматичних параметрів та ймовірностей захворювання введено додатковий гіперпараметр (*timesteps*), що визначає кількість попередніх часових міток кліматичних параметрів та ймовірностей захворювання, які необхідно додатково використати в якості вхідних значень у моделі машинного навчання. Наприклад, для значення *timesteps*=1, поточні

кліматичні параметри разом із кліматичними параметрами та ймовірністю захворювання годину тому використовуються в якості вхідних значень. Для значення  $timesteps=2$ , поточні кліматичні параметри разом із кліматичними параметрами та ймовірностями захворювання за останні 2 години використовуються в якості вхідних значень.

Враховуючи введення гіперпараметра ( $timesteps$ ), який регулює глибину включення історичних даних про кліматичні параметри та ймовірність захворювання в досліджуваних моделях ML та AI, дослідницька задача полягає у виборі оптимального значення цього параметра. Гіперпараметр ( $timesteps$ ) безпосередньо визначає кількість історичних даних, що подаються на вхід моделі та, як наслідок, впливають на її складність. Задача цього дослідження враховує два аспекти: по-перше, емпірично дослідити вплив різних значень  $timesteps$  на продуктивність і складність моделі, а по-друге, визначити оптимальне значення, яке максимізує точність прогнозування при мінімізації складності моделі. Таким чином, графічну інтерпретацію запропонованого алгоритму машинного навчання наведено на рисунку 2.25.

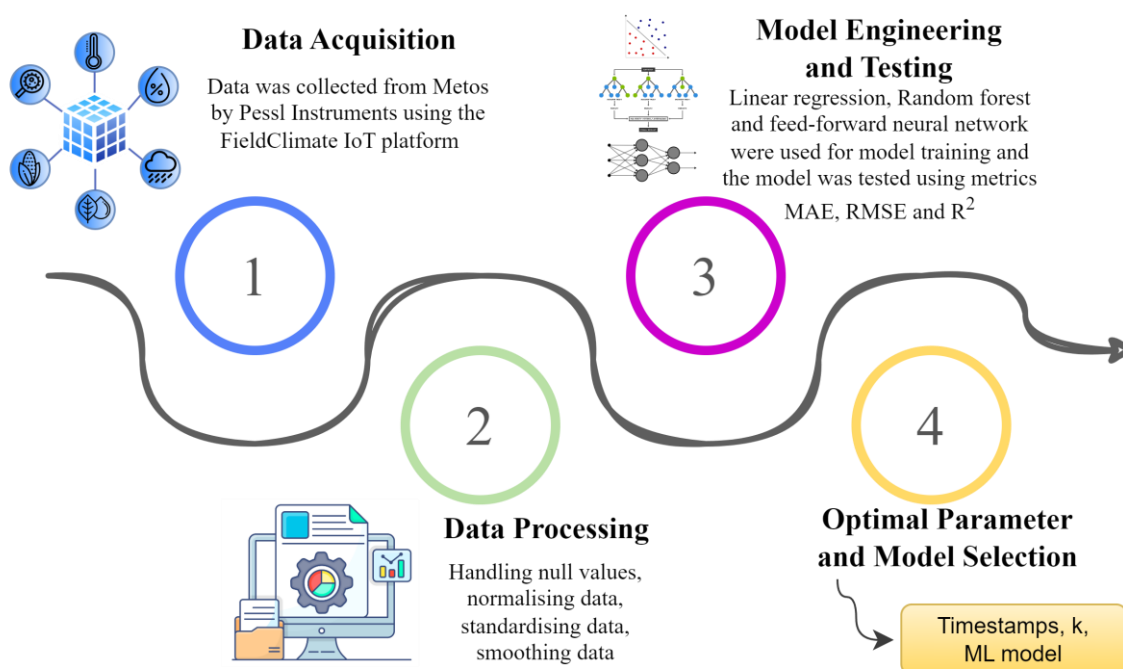


Рисунок 2.25 – Запропонована модель машинного навчання щодо детектування й прогнозування вірогідності появи Fusarium Head Blight кукурудзи

Після попередньої обробки даних виконано навчання таких моделей ML, як: лінійна регресія (linear regression), випадковий ліс (random forest) та нейронна мережа прямого поширення (FNN).

У цьому дослідженні використовується метод прогнозування з відкритим циклом, який передбачає прогнозування наступного кроку в послідовності, використовуючи лише вхідні дані. Цей метод ґрунтується на зборі достовірних значень із джерела даних і використанні їх як вхідних даних під час прогнозування значень на наступних часових кроках. Наприклад, для прогнозування значення на часовому кроці  $t+1$  використовуються дані, зібрані на часових кроках від  $t-timesteps$  до  $t$ . Згодом для прогнозування значення на часовому кроці  $t+2$  записується значення на часовому кроці  $t+1$ , а потім дані з  $(t+1)-timesteps$  до  $t+1$  часового кроку використовуються як вхідні дані для наступного прогнозу.

Навчання моделей ML здійснюється з використанням двох різних підходів: перший – використання моделей машинного навчання, що базуються виключно на кліматичних даних та їх історичних значеннях; другий – включення моделей машинного навчання, що базуються як на кліматичних даних, так і на ймовірності виникнення хвороби, разом з відповідними історичними значеннями.

Алгоритм навчання та вибору найбільш задовільної моделі для прогнозування ймовірності виникнення FHV кукурудзи є наступним:

1. Збір даних: збираються кліматичні дані, включаючи ймовірність виникнення хвороб с/г культур.

2. Вибір інформативних ознак: враховуються попередні значення кліматичних параметрів та ймовірності захворювань за останні  $k$  годин, де  $k$  – визначається значенням гіперпараметра «*timesteps*».

3. Розбиття даних: набір даних для Північного Степу (Дніпропетровська область) розділено на навчальний, валідаційний та тестовий набори у співвідношенні 70:15:15 відповідно. Набір даних для Лісостепу (Черкаська область) використовується лише під час тестування.

4. Масштабування даних: навчальний набір масштабується для забезпечення однорідності значень ознак.

5. Узгодженість масштабування: валідаційний та тестовий набори масштабуються з використанням статистичних параметрів, отриманих з навчального набору, таких як середнє значення та с.к.в. кліматичних параметрів.

6. Навчання моделі: коефіцієнти моделі коригуються з використанням навчальної вибірки. Метрики регресії обчислюються на навчальній вибірці.

7. Валідація: регресійні метрики обчислюються на валідаційному наборі для оцінки продуктивності моделі.

8. Оцінка перенавчання: ефективність моделі на валідаційній вибірці порівнюється з її ефективністю на навчальній вибірці, щоб визначити, чи відбулося перенавчання. Якщо перенавчання виявлено, процес переходить до налаштування гіперпараметрів (крок 8.1), інакше – до кроку 9.

8.1. Налаштування гіперпараметрів: гіперпараметри моделі налаштовуються для оптимізації продуктивності.

8.2. Донавчання моделі: скоригована модель повторно навчається на навчальній вибірці.

9. Тестування: продуктивність розглянутих моделей оцінюється на незалежному тестовому наборі.

10. Вибір моделі: найбільш придатна до використання модель обирається на основі попередньо визначених регресійних метрик, таких як середня абсолютна похибка (MAE), середньоквадратична похибка (RMSE) та коефіцієнт детермінації ( $R^2$ ), обраних для найкращого представлення точності прогнозування.

Після навчання моделей було проведено їх оцінку за різними показниками ефективності. Це кількісні показники, що дають змогу оцінити здатність застосованих моделей ML та AI до прогнозування. В таблиці 2.5 наведено використані регресійні метрики та формули для їх розрахунку.

Таблиця 2.5 – Використані регресійні метрики

№	Метрика	Формула
1	Середня абсолютна похибка (MAE)	$MAE = \frac{1}{m} \sum_{i=1}^m  y_i - y_{\hat{at}_i} $
2	Середньоквадратична похибка (RMSE)	$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y_{\hat{at}_i})^2}$
3	Коефіцієнт детермінації ( $R^2$ )	$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - y_{\hat{at}_i})^2}{\sum_{i=1}^m (y_i - \bar{y}_i)^2}$

де  $m$  – кількість результатів спостережень,  $y_i$  – експериментальне значення вірогідності появи хвороби,  $y_{\hat{at}_i}$  – прогнозоване значення вірогідності появи хвороби,  $\bar{y}_i$  – середнє значення вірогідності появи хвороби

На основі запропонованого алгоритму проведено дослідження роботи розглянутих моделей ML для різних значень гіперпараметра  $timesteps=(3, 5, 7, 9)$  у двох режимах: на першому етапі – без обліку значень ймовірностей захворювання (табл. 2.6), на другому – з обліком значень ймовірностей захворювання за останні  $timesteps$  годин (табл. 2.7).

Таблиця 2.6 – Результати випробувань моделей ML на тестових даних Дніпровської вибірки при різних значеннях гіперпараметра  $timesteps$  із урахуванням лише кліматичних параметрів у якості вхідних даних

Timesteps	Linear Regression	Random Forest	FNN
3	$R^2=0,138$ , MAE=8,12 RMSE=17,13	$R^2=0,389$ , MAE=5,463 RMSE=14,42	$R^2=0,246$ , MAE=6,51 RMSE=16,019
5	$R^2=0,113$ , MAE=6,92 RMSE=14,47	$R^2=0,333$ , MAE=4,56 RMSE=12,55	$R^2=0,233$ , MAE=5,17 RMSE=13,457
7	$R^2=0,139$ , MAE=7,53 RMSE=15,48	$R^2=0,422$ , MAE=4,495 RMSE=12,69	$R^2=0,306$ , MAE=5,205 RMSE=13,908
9	$R^2=0,138$ , MAE=7,902 RMSE=16,307	$R^2=0,457$ , MAE=4,56 RMSE=12,93	$R^2=0,233$ , MAE=5,434 RMSE=15,379

Таблиця 2.7 – Результати випробувань моделей ML на тестових даних Дніпровської вибірки при різних значеннях гіперпараметра *timesteps* з урахуванням попередніх імовірностей захворювання в якості додаткових входів

<b>Timesteps</b>	<b>Linear Regression</b>		<b>Random Forest</b>		<b>FNN</b>	
3	R <sup>2</sup> =0,961, MAE=0,85	RMSE=3,61,	R <sup>2</sup> =0,964, MAE=0,379	RMSE=3,46,	R <sup>2</sup> =0,961, MAE=0,75	RMSE=3,609,
5	R <sup>2</sup> =0,901, MAE=0,79	RMSE=4,83,	R <sup>2</sup> =0,958, MAE=0,357	RMSE=3,11,	R <sup>2</sup> =0,922, MAE=0,68	RMSE=4,266,
7	R <sup>2</sup> =0,901, MAE=0,93	RMSE=5,01,	R <sup>2</sup> =0,972, MAE=0,30	RMSE=2,77,	R <sup>2</sup> =0,92, MAE=0,85	RMSE=4,71,
9	R <sup>2</sup> =0,973, MAE=0,95	RMSE=2,85,	R <sup>2</sup> =0,987, MAE=0,27	RMSE=1,96,	R <sup>2</sup> =0,965, MAE=0,919	RMSE=3,26,

Як можна побачити з результатів, наведених у таблицях 2.6 і 2.7, найбільш придатним для прогнозування у відповідних агрокліматичних умовах є значення гіперпараметра *timesteps*, що дорівнює 9.

Використання додатково попередніх імовірностей захворювання в якості входних значень дало значне покращення регресійних метрик (табл. 2.7) у порівнянні з моделями, що приймали на вхід лише кліматичні показники за минулі проміжки часу (табл. 2.6).

Серед моделей, що приймали ймовірності захворювання в якості входних значень, модель random forest показала найбільшу точність на тестових даних: R<sup>2</sup>=0,987, MAE=0,27, RMSE=1,96.

Оцінені на підставі комп'ютерного експерименту значення гіперпараметрів моделей random forest та FNN є такими:

1. Random forest: max\_depth=5 (максимальна глибина дерева), n\_estimators=10 (кількість дерев).

2. FNN: 12, 6, 4, 4 та 1 нейрон у внутрішньому шарі, оптимізатор=AdamW (weight\_decay=0.25), активаційні функції – ReLU для внутрішніх шарів та лінійна на виході, batch\_size=256, epochs=500.

На рисунку 2.26 показано графік експериментальних та прогнозованих із використанням моделі random forest значення ймовірності захворювання за умови *timesteps*=9 з урахуванням попередніх імовірностей захворювання.




Рисунок 2.26 – Графічна інтерпретація результату порівняння експериментальних та прогнозованих моделлю random forest імовірностей появи Fusarium Head Blight кукурудзи

З метою покращення отриманих із урахуванням гіперпараметра  $timesteps=9$  результатів проведено дослідження зі застосуванням експоненційного затухання для значень параметра затухання  $k=(0,25; 0,5; 0,75)$ . Результати порівняльного комп'ютерного експерименту наведено в таблицях 2.8 і 2.9 для моделей, що використовують лише кліматичні параметри, та моделей, які додатково використовують попередні ймовірності захворювання, відповідно.

Таблиця 2.8 – Результати роботи моделей ML на тестових даних Дніпровської вибірки з кліматичними параметрами в якості входів за умови використанні експоненційного затухання

Значення $k$	Результати тестування моделей ML		
	Linear regression	Random forest	FNN
0,25	$R^2=0,15$ , RMSE=16,19, MAE=7,91	$R^2=0,498$ , RMSE=12,447, MAE=4,47	$R^2=0,33$ , RMSE=14,37, MAE=5,083
0,5	$R^2=0,15$ , RMSE=16,19, MAE=7,91	$R^2=0,498$ , RMSE=12,447, MAE=4,47	$R^2=0,31$ , RMSE=14,58, MAE=5,29
0,75	$R^2=0,15$ , RMSE=16,19, MAE=7,91	$R^2=0,498$ , RMSE=12,447, MAE=4,47	$R^2=0,318$ , RMSE=14,05, MAE=5,181

Таблиця 2.9 – Результати роботи алгоритмів ML на тестових даних зі задіянням попередніх імовірностей захворювання і експоненційного згасання

Значення $k$	Результати тестування моделей ML		
	Linear regression	Random forest	FNN
0,25	$R^2=0,996$ , RMSE=1,006, MAE=0,331	$R^2=0,997$ , RMSE=0,87, MAE=0,212	$R^2=0,989$ , RMSE=1,83, MAE=0,639
0,5	$R^2=0,996$ , RMSE=1,006, MAE=0,331	$R^2=0,997$ , RMSE=0,88, MAE=0,212	$R^2=0,986$ , RMSE=2,09, MAE=0,83
0,75	$R^2=0,996$ , RMSE=1,006, MAE=0,331	$R^2=0,997$ , RMSE=0,88, MAE=0,212	$R^2=0,987$ , RMSE=2,03, MAE=0,703

Як можна побачити зі значень регресійних метрик, наведених у таблицях 2.8 і 2.9, результати для всіх моделей ML покращились під час використання експоненційного згасання для апроксимації проміжків, де ймовірність захворювання різко спадала до нуля. Зміна параметра експоненційного згасання ( $k$ ) майже не вплинула на результати, тому для подальших досліджень обрано значення  $k=0,75$ , оскільки при цьому значенні ймовірність захворювання найшвидше спадає та апроксимовані значення максимально наближені до початкових. На рисунку 2.27 показано порівняння експериментальних і прогнозованих імовірностей захворювання під час застосування експоненційного згасання.




Рисунок 2.27 – Графічна інтерпретація результату порівняння експериментальних і прогнозованих моделлю random forest імовірностей появи Fusarium Head Blight під час використання експоненційного згасання

З урахуванням визначених значень гіперпараметрів препроцесінгу ґрунтокліматичних даних ( $timesteps=9$  та  $k=0,75$ ) проведено серію порівняльних комп'ютерних експериментів щодо роботи моделей ML лише з кліматичними параметрами в якості входів та моделей ML з імовірностями захворювання в якості додаткових входів. Кількісні результати зазначених комп'ютерних експериментів наведено в таблицях 2.10 і 2.11, відповідно.


Таблиця 2.10 – Результати порівняння роботи моделей ML лише з кліматичними параметрами в якості входів

ML модель	Північний Степ (Дніпропетровська область)	Лісостеп (Черкаська область)
Linear Regression	$R^2=0,15$ , RMSE=16,19, MAE=7,91	$R^2=0,134$ , RMSE=18,88, MAE=8,61
Random Forest	$R^2=0,498$ , RMSE=12,447, MAE=4,47	$R^2=0,362$ , RMSE=16,20, MAE=6,45
FNN	$R^2=0,31$ , RMSE=14,58, MAE=5,29	$R^2=0,260$ , RMSE=17,46, MAE=6,98


Таблиця 2.11 – Результати порівняння роботи моделей ML із імовірностями захворювання в якості додаткових входів

ML модель	Північний Степ (Дніпропетровська область)	Лісостеп (Черкаська область)
Linear Regression	$R^2=0,996$ , RMSE=1,006, MAE=0,331	$R^2=0,986$ , RMSE=2,33, MAE=0,553
Random Forest	$R^2=0,997$ , RMSE=0,88, MAE=0,212	$R^2=0,995$ , RMSE=1,374, MAE=0,206
FNN	$R^2=0,986$ , RMSE=2,09, MAE=0,83	$R^2=0,976$ , RMSE=3,09, MAE=0,74

Додатково на рисунках 2.28–2.30 наведено графічну інтерпретацію результатів комп'ютерних експериментів щодо порівняння експериментальних і прогнозованих значень із використанням моделей лінійної регресії (linear regression), випадкового лісу (random forest) та нейронної мережі з прямим поширенням (FNN) на основі даних, які наведено в таблиці 2.11, щодо ймовірностей захворювання кукурудзи для вибірок даних в агрокліматичних умовах Північного Степу та Лісостепу України.




а) Північний Степ




б) Лісостеп

Рисунок 2.28 – Результати тестування зі застосуванням лінійної регресії




а) Північний Степ




б) Лісостеп

Рисунок 2.29 – Результати тестування зі застосуванням FNN



а) Північний Степ



б) Лісостеп

Рисунок 2.30 – Результати тестування зі застосуванням випадкового лісу

У результаті порівняння ефективності різних типів ML моделей під час побудови програмно-апаратних рішень прогнозування вірогідності появи хвороб с/г культур на основі моніторингу ґрунтокліматичних параметрів із обліком вірогідності появи хвороби в попередні моменти часу за умови прийнятого значення гіперпараметра  $timestep=9$  і препроцесінгу вхідних наборів даних було встановлено, що для агрокліматичних умов Північного Степу (Дніпропетровська обл.) та Лісостепу (Черкаська обл.) України алгоритм випадкового лісу (random forest) має найкращі предикативні характеристики за метриками MAE, RMSE і  $R^2$ .

Таким чином, на підставі проведених досліджень із обґрунтування методу, комп'ютерних моделей і програмних засобів інтелектуальної обробки ґрунтокліматичних кліматичних параметрів із застосуванням алгоритмів машинного навчання з метою детектування прогнозованих значень вірогідності появи Fusarium Head Blight кукурудзи для агрокліматичних умов Лісостепу і Північного Степу України було обґрунтовано структурно-алгоритмічну організацію відповідного програмно-апаратного забезпечення, як показано на рисунку 2.31.

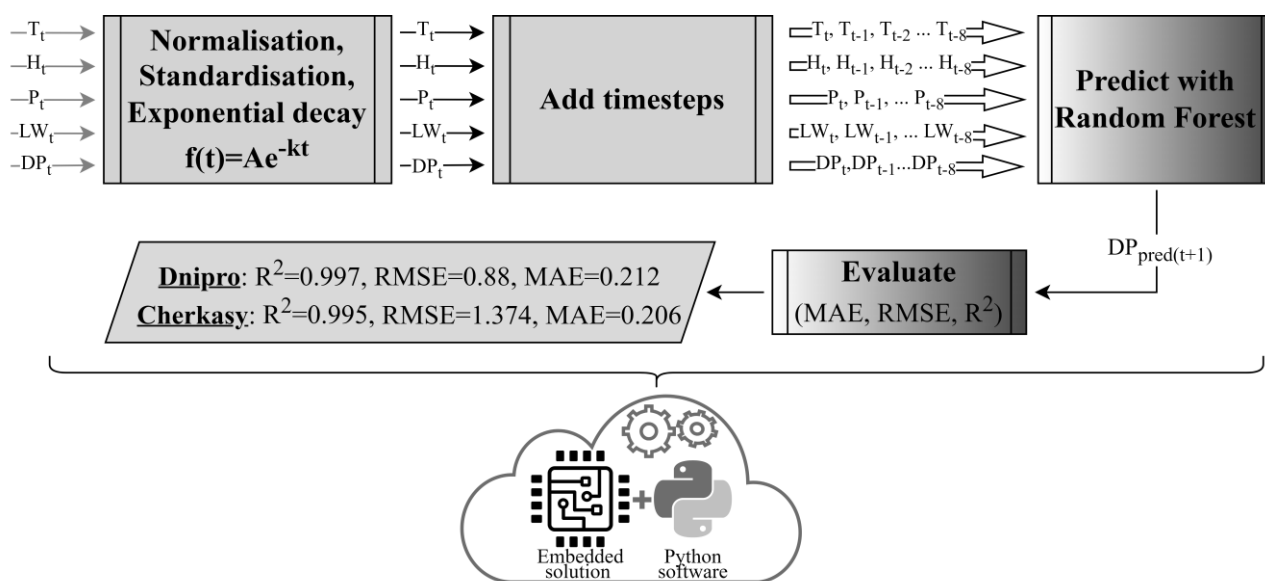


Рисунок 2.31 – Структурно-алгоритмічна організація розробленого програмно-апаратного забезпечення прогнозування вірогідності появи хвороб сільськогосподарських культур на прикладі Fusarium Head Blight кукурудзи

Умовні позначення, які наведено на рисунку 2.31, є такими:  $T$  – температура повітря, °C;  $H$  – відносна вологість повітря, %;  $P$  – кількість опадів, мм;  $LW$  – час зволоження листя, хв;  $DP$  – вірогідність появи хвороби, %;  $t$  – аналізований період часу.

Таким чином, структурно-алгоритмічна організація розробленого програмно-апаратного забезпечення (рис. 2.31) може бути використана в якості базової під час прогнозування вірогідності хвороб кукурудзи на основі технології граничних обчислень за результатами комп'ютеризованого онлайн моніторингу та автоматичної інтелектуальної обробки впливних ґрунтокліматичних параметрів.

### **2.3 Метод і комп'ютерні моделі обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування та прогнозування хвороб сільськогосподарських культур на основі адаптивних нейро-нечітких мереж**

Теоретико-прикладну основу досліджень цього підрозділу, який спрямовано на розробку методів і комп'ютерних моделей обробки результатів моніторингу ґрунтокліматичних параметрів під час детектування та прогнозування хвороб с/г культур, становлять алгоритми адаптивних нейро-нечітких мереж (ANFIS). Цей вибір обумовлено специфікою досліджуваної задачі, а саме: наявна значна кількість вхідних параметрів (температура повітря, вологість повітря, кількість атмосферних опадів та час зволоження листяного покриву), закономірність впливу яких на вихідну функцію (ймовірність виникнення хвороби) носить емпіричний характер, що встановлена на основі багаторічного експертного досвіду в галузі вирощування зернових агрокультур. Додатково на вибір ANFIS технології впливає специфіка дослідної задачі з точки зору математичного обґрунтування: багатопараметричний динамічний нелінійний регресійний аналіз із екстраполяцією даних.

На першому етапі досліджень цього підрозділу було обґрунтовано структурну схему комп'ютерно-орієнтованої моделі (рис. 2.32), яку використано під час розробки методів і моделей прогнозного аналізу ймовірності виникнення хвороб кукурудзи.

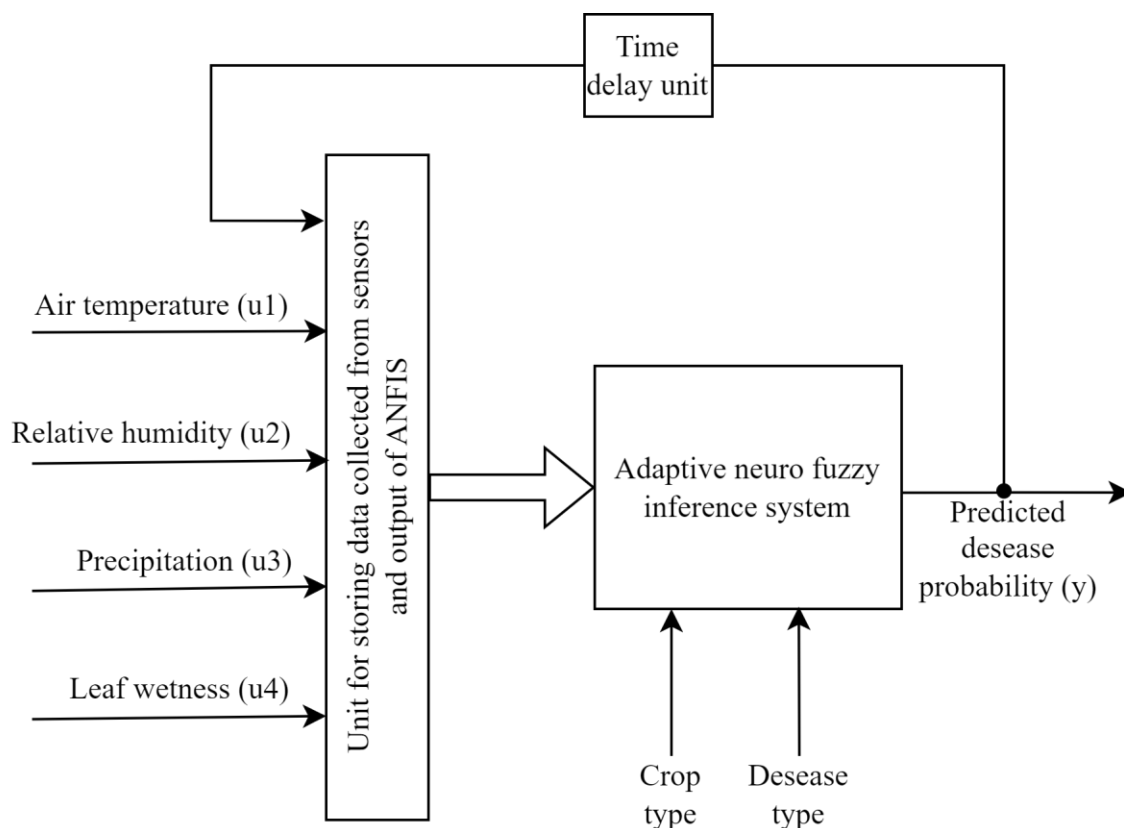


Рисунок 2.32 – Структурна схема комп'ютерно-орієнтованої моделі предикативного аналізу на основі ANFIS

На рисунку 2.32 введено такі умовні позначення:  $u_1$  – температура повітря, °C;  $u_2$  – відносна вологість повітря, %;  $u_3$  – кількість опадів, мм;  $u_4$  – час зволоження листяного покриву с/г культур, хв. Крім того, модель містить у собі механізм зворотного зв'язку через вихідний сигнал блока ANFIS ( $y$ ), який означає ймовірність виникнення хвороби у відсотках. Цей механізм включено до складу моделі на підставі того, що ймовірність виникнення хвороб у агрокультур є величиною, що залежить не тільки від поточних значень вхідних фізико-хімічних параметрів, а й від попередніх значень вхідних і вихідного модельних параметрів у певному часовому діапазоні. Наявність зворотного

зв'язку дозволяє моделі адаптуватися й уточнювати свої прогнози на основі попередніх предикативних даних, підвищуючи загальні прогностичні можливості моделі.

Розроблювана модель (рис. 2.32) враховує фактори та обмеження:

– тип сільськогосподарських культур: кукурудза;

– діагностовані хвороби: *Fusarium Head Blight*, *Leaf Blight*, *Helminthosporium turcicum* (*Southern Corn Leaf Blight*, *Northern Corn Leaf Blight*);

– агрокліматична зона отримання експериментальних даних: Північний Степ України (посушлива і тепла зона; гідротермічний коефіцієнт становить від 0,7 до 1,0; типова річна сума температур від знаходиться в діапазоні від 2900 °C до 3300 °C);

– інформативні ґрунтокліматичні параметри: температура повітря, відносна вологість повітря, кількість опадів та час зволоження листя агрокультур.

Завдяки врахуванню основних агрокліматичних параметрів навколишнього середовища (температури та відносна вологість повітря, кількість опадів і час зволоження листя), а також використанню адаптивних і предикативних можливостей технології ANFIS, ця модель є потенційно придатною під час обліку складного взаємозв'язку між цими змінними та ймовірністю виникнення конкретних видів хвороб у конкретних типів с/г культур. Таким чином, це дає можливість розробки та дослідження апаратно-програмних рішень детектування та прогнозування ймовірності виникнення хвороб із обліком різноманітності вирощуваних с/г культур, їх вегетаційних періодів та складності взаємозв'язків ґрунтокліматичних параметрів, що характеризують мінливі умови вирощування.

Реалізація досліджуваної ANFIS технології дозволяє підвищити ефективність оперативного прийняття рішень практикуючими фахівцями в галузі рослинництва відкритого ґрунту завдяки використанню програмно-

апаратних засобів автоматизованої підтримки прийняття рішень щодо планування агротехнічних заходів із вирощування с/г культур.

Враховуючи теоретико-прикладні особливості задачі дослідження та попередній досвід розробки прикладних інформаційних систем на основі нечіткої логіки [3], [4], [28], в якості базового алгоритму було обрано алгоритм Такагі-Сугено (тип 1). Структурно-алгоритмічний базис ANFIS задовольняє умовам дослідної задачі прогнозування ймовірності виникнення хвороб агрокультур завдяки своїй гібридній природі, поєднуючи сильні сторони нечіткої логіки та нейронних мереж. Таке поєднання дозволяє моделі врахувати складність взаємозв'язків між факторами навколишнього середовища та ймовірністю виникнення хвороби, що лежать в основі моделі. Архітектура оптимізує свої параметри за допомогою ітеративного навчання, гарантуючи, що вихідні дані системи збігаються з точними оцінками ймовірності виникнення хвороби.

В якості вхідних змінних та цільової функції обрано такі фізичні величини у відповідних діапазонах: температура повітря ( $u_1$ : від  $-10,9$  °C до  $35,6$  °C), відносна вологість повітря ( $u_2$ : від 27 % до 99 %), кількість опадів ( $u_3$ : від 0 мм до 5,7 мм), час зволоження листя ( $u_4$ : від 0 хв до 60 хв), ймовірність виникнення хвороб ( $y$ : від 0 % до 100 %).

Наступним кроком є процес фазицікації, процес перетворення чітких (числових) вхідних значень у нечіткі множини. Кожна вхідна характеристика  $X_i$  асоціюється з набором функцій належності ( $MFs$ ), які визначають ступінь належності вхідних даних до кожної нечіткої множини. У такому випадку застосовуються гаусові функції належності, що відповідає нормальному закону розподілу результатів агрокліматичного вимірювального моніторингу.

База нечітких правил визначає функціональні зв'язки між нечіткими вхідними множинами та вихідними. Кожне нечітке правило відповідає комбінації нечітких наборів вхідних ознак. Для ANFIS типу Сугено правило має вигляд: IF  $x_1$  is  $A_1$  AND  $x_2$  is  $A_2$  AND ... AND  $x_n$  is  $A_n$  THEN  $y=f(x_1, x_2, \dots, x_n)$ ,

де  $A_1, A_2, \dots, A_n$  – обрані функції належності для кожної вхідної ознаки  $y=f(x_1, x_2, \dots, x_n)$  – лінійна функція від вхідних даних.

Для кожної вхідної комбінації на основі нечітких вхідних даних визначаються значення належності нечітких множин у антецедентній (*IF*) частині правил. Це показує, наскільки кожне правило «активується» вхідними даними.

Активовані правила впливають на кінцевий результат через середньозважене значення. Ваги розраховуються на основі сили активації правила та лінійної функції, визначеної в наступній (*THEN*) частині правила.

Зважені значення, отримані на попередньому кроці, потім нормалізуються, щоб підсумкове значення ваг дорівнювало 1. Цей крок гарантує, що вихідні дані системи залишаються інтерпретованими та послідовними. Після цього нормалізовані зважені результати всіх правил підсумовуються для отримання кінцевого результату на виході підсистеми ANFIS. Нечіткий результат перетворюється назад у чітке значення для полегшення інтерпретації. В цьому дослідженні під час дефазифікації було застосовано функціонал типу «*wtaver*» (середньозважене значення всіх виходів правил).

Процес навчання моделі передбачає використання попередніх даних щодо ймовірності виникнення хвороби та відповідних умов навколишнього середовища. Завдяки глибинному навчанню підсистема ANFIS коригує свої функції належності та правила, щоб відобразити складні взаємодії між вхідними даними та ймовірністю виникнення хвороби на виході. Під час досліджень використано такі налаштування: алгоритм навчання – hybrid, метод кластеризації – Subtractive Clustering.

Експериментальні дані, що використано під час розробки ANFIS-моделей прогнозування ймовірностей виникнення хвороб с/г культур, охоплюють період з 12 вересня 2022 року по 31 липня 2023 року. Час дискретизації даних становить 60 хвилин. Крім того, були проаналізовані емпіричні значення ймовірності ураження основними типами хвороб кукурудзи – Fusarium Head

Blight (FHB), Leaf Blight *Helminthosporium turcicum* (Southern Corn Leaf Blight (SCLB), Northern Corn Leaf Blight (NCLB)). Ці ймовірності були визначені практикуючими фахівцями-експертами в галузі агрокультури відкритого ґрунту шляхом поєднання польових спостережень та лабораторних аналізів, що дозволило створити широкий набір даних для перевірки моделі.

Експериментальні дані щодо динаміки ґрунтокліматичних параметрів с/г підприємств рослинництва відкритого ґрунту (рис. 2.33) охоплюють зміну сезонів і динаміку навколишнього середовища, які відіграють ключову роль у формуванні ймовірності виникнення хвороби. Обрані часові рамки дають ґрунтовне уявлення про взаємодію кліматичних факторів та їхній зв'язок із виникненням хвороб на різних етапах росту кукурудзи.

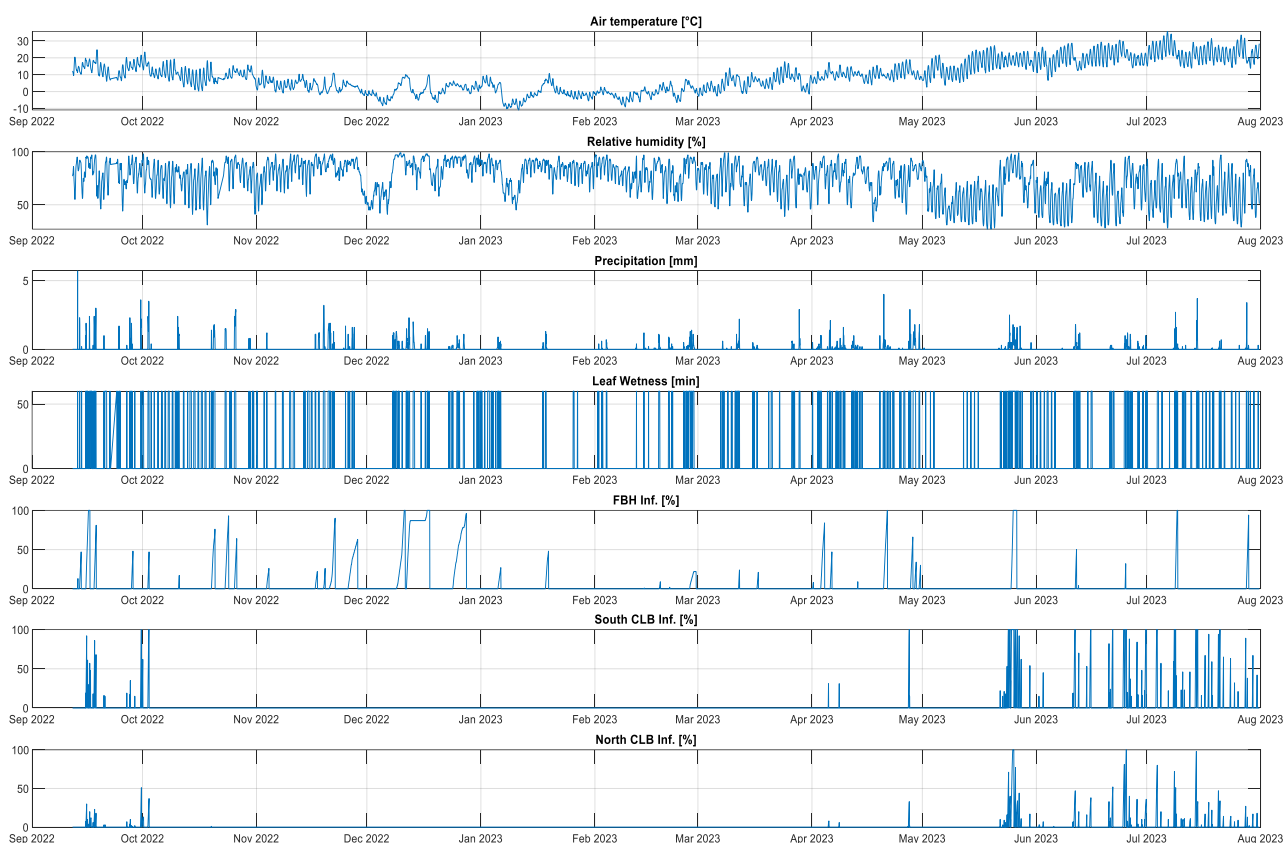


Рисунок 2.33 – Динаміка ґрунтокліматичних параметрів та ймовірностей появи аналізованих хвороб сільськогосподарських культур

Для виявлення складних взаємозв'язків між вхідними параметрами та ймовірностями виникнення хвороб були побудовані кореляційні матриці

(рис. 2.34) та відповідні діаграми розміювання (рис. 2.35). Ці графічні інтерпретації використано в якості засобів виявлення потенційних кореляцій і тенденцій у даних.

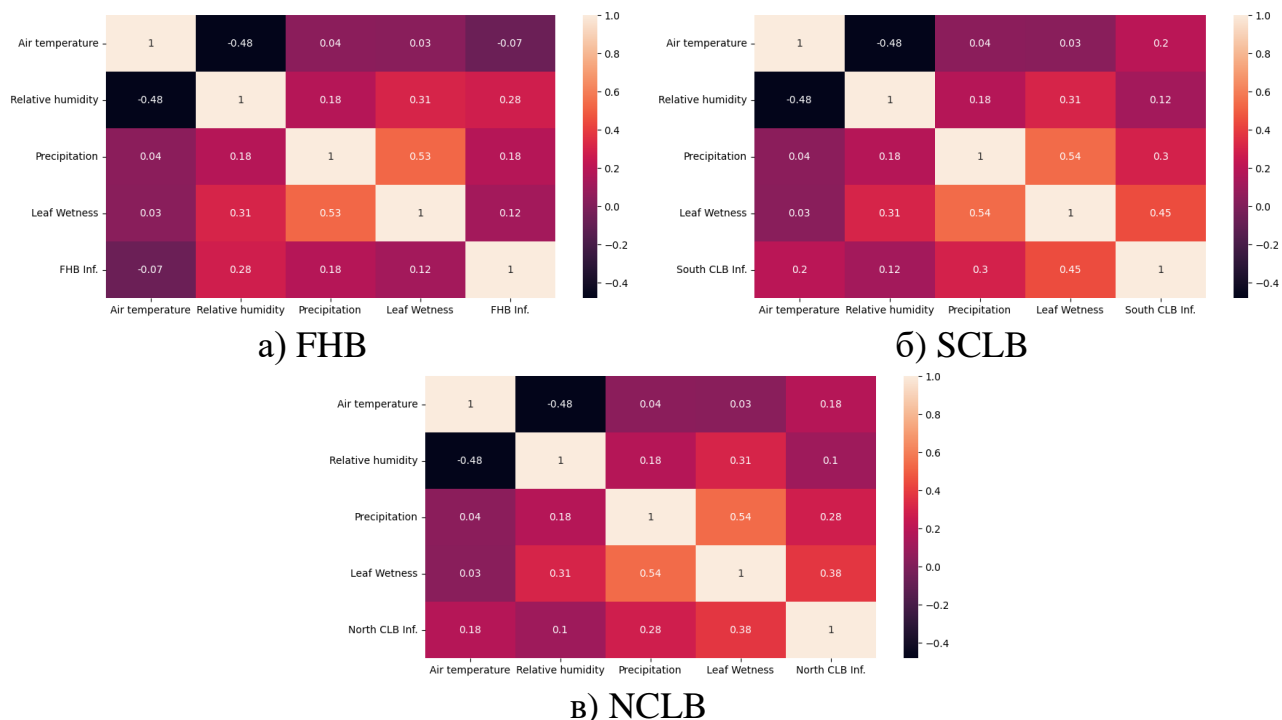


Рисунок 2.34 – Матриці кореляцій ґрунтокліматичних параметрів та ймовірностей появи для аналізованих хвороб с/г культур

Аналізуючи кореляційні матриці для *Fusarium Head Blight* та *Leaf Blight Helminthosporium turcicum*, було визначено ті фактори навколишнього середовища, які переважно сприяють виникненню хвороб. На підставі аналізу графічних залежностей, які наведено на рисунку 2.34,а, можна помітити, що коефіцієнт кореляції між температурою повітря та ймовірністю виникнення хвороби є від’ємним. В той час, як для інших параметрів коефіцієнти є позитивними. Це свідчить про те, що під час збільшення температури ймовірність виникнення хвороби зменшується. На підставі аналізу графічних залежностей, які наведено на рисунках 2.34,б та 2.34,в, встановлено, що всі зазначені вище ґрунтокліматичні параметри мають позитивний коефіцієнт кореляції з *Southern Corn Leaf Blight* та *Northern Corn Leaf Blight*. Ці результати

кореляційного аналізу (рис. 2.34 і 2.35) було використано під час вирішення задачі ідентифікації досліджуваних комп'ютерно-орієнтованих моделей.

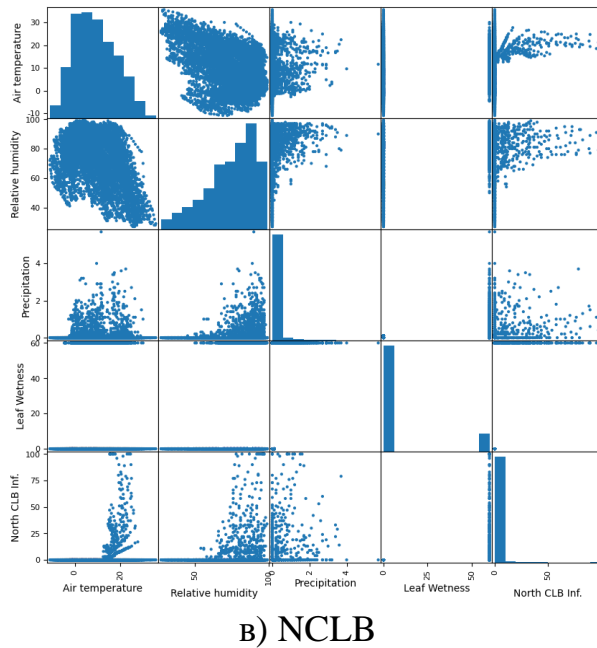
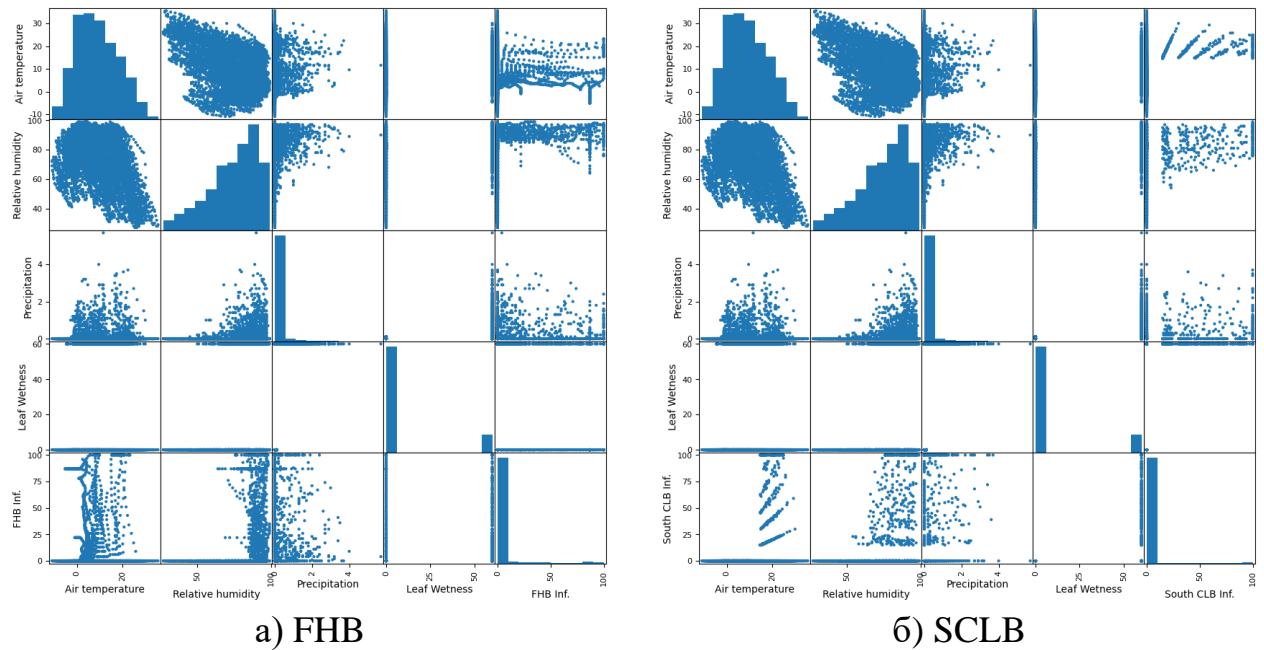


Рисунок 2.35 – Діаграми розсіювання ґрунтокліматичних параметрів та ймовірностей появи для аналізованих хвороб сільськогосподарських культур

Експериментальні дані становлять основу для формування навчальної та валідаційної вибірок під час навчання та перевірки прогностичних можливостей запропонованої й розробленої комп'ютерно-орієнтованої моделі

на основі ANFIS. Для хвороби FHB навчальна вибірка обрана у період з 12 вересня 2022 по 31 травня 2023 року. Валідаційні дані – з 01 червня 2023 по 31 липня 2023 року. Для хвороб SCLB та NCLB навчальна вибірка обрана у період з 12 вересня 2022 по 30 червня 2023 року, а валідаційні дані – з 01 липня 2023 по 31 липня 2023 року. Ці групи даних були обрані на підставі попереднього статичного аналізу на предмет максимального обліку фактора сезонності під час розробки відповідних комп'ютерних моделей для прогнозування появи цих хвороб (FHB, SCLB та NCLB).

Співвідносячи вхідні параметри з імовірністю виникнення відповідних хвороб та аналізуючи пов'язані з ними тенденції, можна оцінити адаптивність і точність моделей. Така валідація на основі даних забезпечує релевантність моделі та її застосовність у реальних сценаріях, підвищуючи її надійність як інструменту прогнозування ймовірності виникнення хвороб під час вирощування кукурудзи на передсимптомній стадії.

Таким чином, подальші дослідження щодо розробки та валідації зазначеної підсистеми ANFIS виконано на основі принципу декомпозиції дослідної задачі, а саме: ідентифікація інформативних параметрів та відповідної регресійної моделі, розробка імітаційної моделі в середовищі комп'ютерного моделювання, навчання ідентифікованої моделі, валідація отриманих результатів комп'ютерного експерименту із подальшим якісним і кількісним аналізом отриманих результатів та формування перспективних напрямів подальших досліджень.

Під час вирішення завдання ідентифікації ANFIS-моделей прогнозування хвороб с/г культур спочатку було визначено, які змінні мають бути використані як вхідні аргументи для кожного типу хвороби окремо. Це завдання зводиться до моделювання «чорної скриньки»: випадок, коли неможливо отримати точне математичне представлення системи з фізичних міркувань, а отже форма моделі та її чисельні характеристики ґрунтуються на експериментальних даних. У такому випадку математичну основу розроблюваної моделі ідентифікації становить підхід до ідентифікації нелінійних систем [29] із урахуванням

результатів апріорного кореляційного аналізу даних, які наведено вище на рисунках 2.34 і 2.35.

Для хвороби типу ГНВ на основі попереднього аналізу було використано 23 вхідні фактори:  $y(k-1)$ ,  $y(k-2)$ ,  $y(k-3)$ ,  $y(k-6)$ ,  $y(k-7)$ ,  $y(k-8)$ ,  $y(k-9)$ ,  $u_1(k-1)$ ,  $u_1(k-2)$ ,  $u_1(k-3)$ ,  $u_1(k-4)$ ,  $u_2(k-1)$ ,  $u_2(k-2)$ ,  $u_2(k-3)$ ,  $u_3(k-1)$ ,  $u_3(k-2)$ ,  $u_3(k-3)$ ,  $u_4(k-1)$ ,  $u_4(k-2)$ ,  $u_4(k-3)$ ,  $u_4(k-7)$ ,  $u_4(k-8)$ ,  $u_4(k-9)$ . Параметр  $y(k)$  використано в якості цільової функції (виходу системи). До зазначених параметрів відносяться: вихідна функція ( $y$ ) з показником передісторії в діапазоні від 1 год до 9 год; температура повітря ( $u_1$ ) з показником передісторії в діапазоні від 1 год до 4 год; вологість повітря ( $u_2$ ) з показником передісторії в діапазоні від 1 год до 3 год; кількість опадів ( $u_3$ ) з показником передісторії в діапазоні від 1 год до 3 год; час зволоження листя ( $u_4$ ) з показником передісторії в діапазоні від 1 год до 9 год. Такі атрибути моделі ідентифікації встановлено шляхом апріорного якісного аналізу експериментальних даних (рис. 2.33) та тестових комп'ютерних експериментів моделі ідентифікації системи.

На основі комп'ютерного ідентифікаційного експерименту відносно ГНВ кількість входів моделі була обрана рівною 7 (два входи для  $y$ , два входи для  $u_4$ , та по одному – для  $u_1$ ,  $u_2$  і  $u_3$ ). Після цього було виконано послідовний прямий пошук за входами: під час ітераційного процесу послідовно вибираються комбінації вхідних змінних для мінімізації середньоквадратичного відхилення (RMSE). На рисунку 2.36 наведено графік для всіх протестованих комбінацій входів для навчальної та валідаційної вибірок відсортованих за зменшенням показника RMSE.

За результатами пошуку було обрано комбінацію  $y(k-1)$ ,  $y(k-6)$ ,  $u_1(k-4)$ ,  $u_2(k-1)$ ,  $u_3(k-3)$ ,  $u_4(k-1)$  та  $u_4(k-7)$  як вхідні дані, оскільки модель із цими вхідними даними характеризується мінімальними значеннями  $RMSE \pm 4,33\%$  і  $\pm 5,32\%$  для навчальної та валідаційної вибірок даних, відповідно.

Наступним кроком ідентифікації моделі було визначення параметрів навчання. В якості методу кластеризації обрано – Subtractive clustering (швидкий однопрохідний алгоритм для оцінки кількості кластерів та центрів

кластерів у наборі даних) із діапазоном впливу кластера 0,5. Важливою перевагою використання такого методу кластеризації для пошуку правил є те, що отримані правила краще відповідають вхідним даним, ніж правила, згенеровані без кластеризації. Таке підлаштування зменшує загальну кількість правил, коли вхідні дані мають велику розмірність. Такий підхід використано з урахуванням того, що реалізована модель в подальшому має бути інтегрована до бюджетних мікроконтролерних пристроїв у вигляді вбудованого програмного забезпечення, що відповідає прикладним засадам граничних і туманних обчислень.






Рисунок 2.36 – Графік динаміки RMSE для тестованих комбінацій вхідних параметрів для FNB

З метою покращення роботи досліджуваної моделі було здійснено її оптимізацію. Під час цього було використано період тренування, який дорівнює 100 епох (рис. 2.37,*a*). Також під час цього дослідження було одразу встановлено тренування з використанням валідаційної вибірки для можливості виявити

перенавчання, коли помилка валідації починає зростати, тоді як помилка навчання продовжує зменшуватися (рис. 2.37,б).



а) навчальна вибірка



б) валідаційна вибірка

Рисунок 2.37 – Графік динаміки похибок моделювання для FNB

На підставі аналізу графічної залежності, яку наведено на рисунку 2.37,а , встановлено, що похибка навчання продовжує зменшуватись навіть на 100-й епосі. Проте ця динаміка починаючи з 90-ї епохи є незначною.

На підставі аналізу графічної залежності, яку наведено на рисунку 2.37,б , встановлено, що найменше значення похибки для валідаційної вибірки даних має місце на 36-й епосі. Після цієї точки вона дещо зростає, навіть якщо ANFIS продовжує мінімізувати похибку порівняно з навчальними даними. Ця закономірність є ознакою перенавчання. Залежно від заданої точності до похибки, графік валідаційних похибок може також вказувати на здатність моделі узагальнювати тестові дані. За результатами навчання обрано модель, налаштування якої відповідають 36-й епосі навчання, для якої параметр RMSE дорівнює  $\pm 4,06\%$  і  $\pm 4,50\%$  для навчальної та валідаційної вибірок даних, відповідно.

Для хвороби типу SCLB на основі попереднього кореляційного аналізу було встановлено обмеження у вигляді 21 вхідного фактора, а саме:  $y(k-1)$ ,  $y(k-2)$ ,  $y(k-3)$ ,  $y(k-6)$ ,  $y(k-7)$ ,  $y(k-9)$ ,  $u_1(k-1)$ ,  $u_1(k-3)$ ,  $u_1(k-4)$ ,  $u_2(k-1)$ ,  $u_2(k-2)$ ,

$u_2(k-3), u_3(k-1), u_3(k-2), u_3(k-3), u_4(k-1), u_4(k-2), u_4(k-3), u_4(k-7), u_4(k-8), u_4(k-9)$ . Параметр  $y(k)$  використано в якості цільової функції (виходу системи). Комбінація входів обирається за процедурою аналогічною до алгоритму, який описано вище для хвороби FHB.

На рисунку 2.38 наведено графічні залежності динаміки похибки для всіх комбінацій входів для навчальної та валідаційної вибірок відсортованих за зменшенням показника RMSE для навчальної вибірки даних SCLB. За результатами пошуку обрано параметри  $y(k-1), y(k-9), u_1(k-4), u_2(k-3), u_3(k-1), u_4(k-1)$  та  $u_4(k-9)$  як вхідні дані, оскільки модель із цими вхідними даними характеризується найменшими значеннями RMSE  $\pm 6,02\%$  і  $\pm 13,07\%$  для навчальної та валідаційної вибірок, відповідно.





Рисунок 2.38 – Графік динаміки RMSE для тестованих комбінацій вхідних параметрів для SCLB

Оптимізацію ANFIS моделі для SCLB виконано за алгоритмом, який є аналогічним до FHB. Відповідні результати оптимізації за період тренування, що

дорівнює 100 епох, наведено на рисунку 2.39.



а) навчальна вибірка

б) валідаційна вибірка

Рисунок 2.39 – Графік динаміки похибок моделювання для SCLB

За результатами навчання моделі для SCLB обрано налаштування моделі, які відповідають 97-й епосі навчання, для якої показник RMSE дорівнює  $\pm 5,92\%$  і  $\pm 13,61\%$  для навчальної та валідаційної вибірок даних, відповідно.

Для NCLB вхідні параметри для навчання ідентичні кейсу FHB, а саме:  $y(k-1)$ ,  $y(k-2)$ ,  $y(k-3)$ ,  $y(k-6)$ ,  $y(k-7)$ ,  $y(k-8)$ ,  $y(k-9)$ ,  $u_1(k-1)$ ,  $u_1(k-2)$ ,  $u_1(k-3)$ ,  $u_1(k-4)$ ,  $u_2(k-1)$ ,  $u_2(k-2)$ ,  $u_2(k-3)$ ,  $u_3(k-1)$ ,  $u_3(k-2)$ ,  $u_3(k-3)$ ,  $u_4(k-1)$ ,  $u_4(k-2)$ ,  $u_4(k-3)$ ,  $u_4(k-7)$ ,  $u_4(k-8)$ ,  $u_4(k-9)$ . Параметр  $y(k)$  використано в якості цільової функції (виходу системи).

На рисунку 2.40 наведено графічні залежності динаміки похибки для всіх комбінацій входів для навчальної та валідаційної вибірок, відсортованих за зменшенням показника RMSE для навчальної вибірки даних NCLB.

За результатами пошуку обрано  $y(k-1)$ ,  $y(k-9)$ ,  $u_1(k-2)$ ,  $u_2(k-3)$ ,  $u_3(k-3)$ ,  $u_4(k-3)$  та  $u_4(k-8)$  як вхідні дані, оскільки модель з цими вхідними даними характеризується мінімальними значеннями RMSE  $\pm 3,06\%$  і  $\pm 6,92\%$  для навчальної та валідаційної вибірок експериментальних агрокліматичних даних, відповідно.






Рисунок 2.40 – Графік динаміки RMSE для тестованих комбінацій вхідних параметрів для NCLB

Оптимізацію ANFIS-моделі для NCLB виконано за алгоритмом, який є аналогічним до FNB і SCLB. Відповідні результати оптимізації за період тренування, що дорівнює 100 епох, наведено на рисунку 2.41.



а) навчальна вибірка



б) валідаційна вибірка

Рисунок 2.41 – Графік динаміки похибок моделювання для NCLB

За результатами навчання моделі для NCLB обрано налаштування моделі, які відповідають 51-й епосі навчання, для якої показник RMSE дорівнює  $\pm 2,9\%$  і  $\pm 6,3\%$  для навчальної та валідаційної вибірок даних, відповідно.

Таким чином, результати ідентифікації досліджуваних ANFIS-моделей для FHB, SCLB і NCLB дозволили встановити і оптимізувати перелік вхідних параметрів задля підвищення точності прогнозу аналітики ймовірності виникнення розповсюджених хвороб кукурудзи. В ідентифікованих моделях окрім первинних ґрунтокліматичних параметрів (температура й відносна вологість повітря, кількість опадів та час зволоження листа) в якості вхідних величин використовуються значення вихідної функції (ймовірність виникнення хвороби) та вхідних ґрунтокліматичних параметрів у попередні моменти часу, а саме:

- для FHB: температура із затримкою 4 год, вологість повітря із затримкою 1 год, кількість опадів із затримкою 3 год, час зволоження листа із затримкою 1 год і 7 год, а також вихідна функція (вірогідність появи хвороби FHB) із затримкою 1 год і 6 год;

- для SCLB: температура із затримкою 4 год, вологість повітря із затримкою 3 год, кількість опадів із затримкою 1 год, час зволоження листа із затримкою 1 год і 9 год, а також вихідна функція (вірогідність появи хвороби SCLB) із затримкою 1 год і 9 год;

- для NCLB: температура із затримкою 2 год, вологість повітря із затримкою 3 год, кількість опадів із затримкою 3 год, час зволоження листа із затримкою 3 год і 8 год, а також вихідна функція (вірогідність появи хвороби North CLB) із затримкою 1 год і 9 год.

Отже, конкретний перелік інформативних атрибутів предикативної моделі визначається типом діагностованої хвороби. Цей підхід було реалізовано у вигляді комп'ютерних моделей у середовищі моделювання Matlab & Simulink.

За результатами ідентифікації інформативних параметрів, які наведено вище, в середовищі Fuzzy Logic Designer app для кожного виду хвороб створено

відповідні комп'ютерні моделі на основі підходу Type-1 Sugeno, як показано на рисунку 2.42.

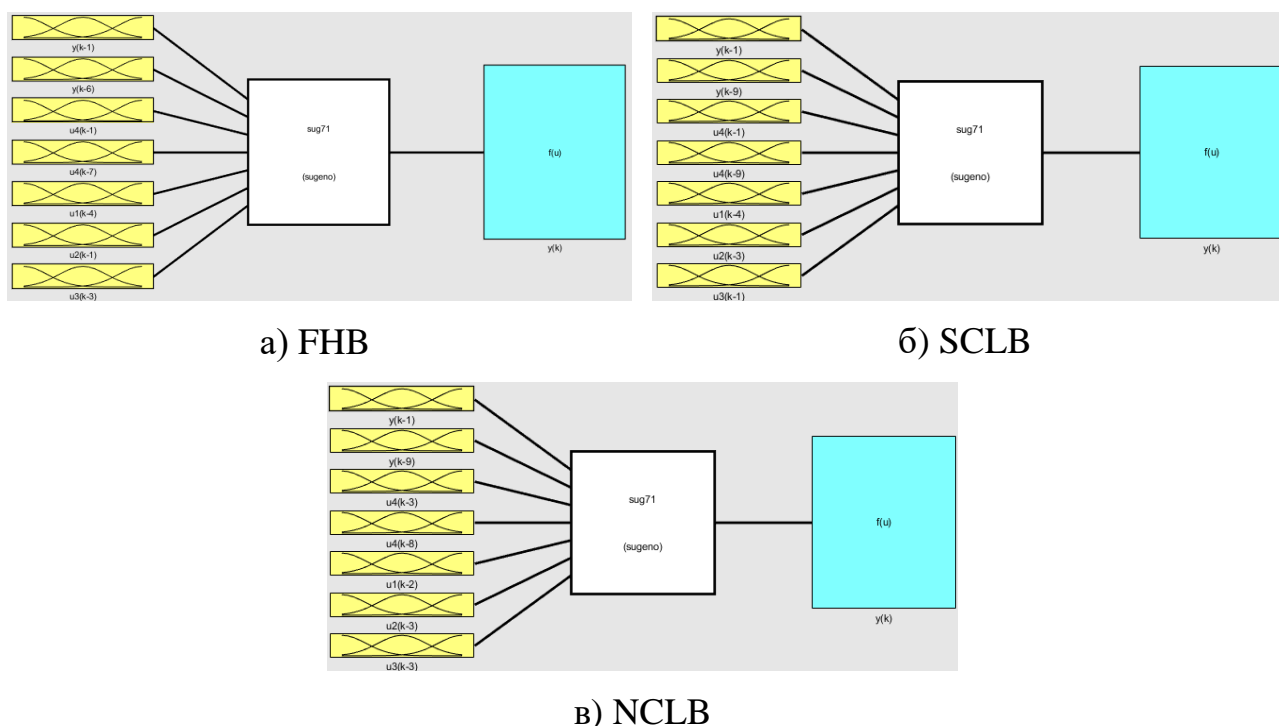


Рисунок 2.42 – Комп'ютерні нейро-нечіткі моделі для прогнозування ймовірності виникнення хвороб кукурудзи

Створені моделі ANFIS (рис. 2.42) асимілюють чотири ключові вхідні параметри, а саме: температура повітря ( $u_1$ ), відносна вологість повітря ( $u_2$ ), кількість опадів ( $u_3$ ) і час зволоження листя ( $u_4$ ), а також значення ідентифікованих ґрунтокліматичних параметрів та вихідної функції ( $y$ ) у попередні моменти часу. Комбінація зазначених вхідних даних із затримкою на фіксовану кількість періодів дискретизації (крок дискретизації дорівнює 60 хв) з урахуванням попередніх даних щодо ймовірності виникнення певної хвороби слугують інформаційною основою під час функціонування розробленої моделі щодо детектування ймовірності виникнення певного виду (FHB, SCLB і NCLB) хвороб кукурудзи.

Результатом роботи моделей є кількісне значення ймовірності виникнення хвороби ( $y$ ) в діапазоні від 0 % до 100 %. Цей результат інкапсулює

сукупний вплив вхідних параметрів на ймовірність виникнення відповідної хвороби в посівах кукурудзи під час повного циклу вирощування. Таким чином, розроблені моделі ANFIS встановлюють взаємозв'язок між вхідними параметрами та ймовірністю виникнення хвороб, надаючи практичну інформацію для прийняття управлінських рішень у сільському господарстві щодо появи хвороб с/г культур на передсимптомній стадії. Крім того, завдяки ітеративному процесу навчання модель ANFIS оптимізує свої функції належності та правила, що дозволяє їй достатньо прецизійно відображати складні взаємозв'язки між входами та виходами. Цей механізм навчання, під впливом експериментальних даних та ідентифікації системи, дозволяє моделі уточнювати свої прогнози з часом, забезпечуючи її адаптивність до динамічних умов навколишнього середовища.

Отже, наведені на рисунку 2.42, імітаційні моделі слугують функціональною основою під час проведення серії комп'ютерних експериментів з валідації розробленої ANFIS моделі детектування ймовірності виникнення конкретних типів хвороб кукурудзи.

Процедура фазифікації вхідних та вихідних змінних реалізована в середовищі Fuzzy Logic Designer пакета прикладних програм Matlab & Simulink за наступною процедурою.

Нечітка система Sugeno, створена з використанням функцій належності, отриманих безпосередньо з кластерів даних, знайдених за допомогою Subtractive clustering вхідних і вихідних даних. Кожна вхідна і вихідна змінна містить одну функцію належності для кожного кластера. Вхідні змінні використовують гаусові функції належності. Кількість термів фазифікації вхідних змінних: для кожного параметра моделі FHB дорівнює 3, для кожного параметра моделі SCLB – 4, для кожного параметра моделі NCLB – 4. Вихідні змінні використовують лінійні функції належності. Коефіцієнти для вихідної лінійної функції наведено в таблицях 2.12–2.14, відповідно для FHB, SCLB і NCLB.

Таблиця 2.12 – Коефіцієнти вихідної функції ANFIS моделі для FHB

Вхід	Cluster1	Cluster2	Cluster3
extra coefficient	1,047	0,3066	1,03
$y(k-1)$	-0,01584	0,04864	-0,05155
$y(k-6)$	1627	3298	-1,5
$u_4(k-1)$	-0,00605	0,005124	-0,01502
$u_4(k-7)$	0,01749	0,008965	0,0956
$u_1(k-4)$	0,005681	-0,0016	0,135
$u_2(k-1)$	1,379	-4,52	0,04577
$u_3(k-3)$	-0,4342	-0,05988	78,27

Таблиця 2.13 – Коефіцієнти вихідної функції ANFIS моделі для SCLB

Вхід	Cluster1	Cluster2	Cluster3	Cluster4
extra coefficient	-1728	-9175	-0,5165	0,812
$y(k-1)$	-510,2	-227,7	0,01905	0,1412
$y(k-9)$	-1114	2172	-0,6571	-0,1249
$u_4(k-1)$	42,47	-42,56	-0,06345	0,09056
$u_4(k-9)$	0,009674	0,05373	0,1225	0,2887
$u_1(k-4)$	-0,0008521	0,03742	0,02445	-0,007766
$u_2(k-3)$	-2,149	55,35	-19,39	0,4443
$u_3(k-1)$	0,06405	-2,612	1,212	6,292

Таблиця 2.14 – Коефіцієнти вихідної функції ANFIS моделі для NCLB

Вхід	Cluster1	Cluster2	Cluster3	Cluster4
extra coefficient	1,253	1,408	0,2345	0,8651
$y(k-1)$	0,02065	0,02942	0,0503	0,1478
$y(k-9)$	-2,406	93,65	-0,05027	-0,04665
$u_4(k-3)$	-553,7	-14,47	-0,02527	0,008054
$u_4(k-8)$	0,001263	0,02038	0,07957	0,06213
$u_1(k-2)$	0,0001716	0,01448	0,006851	0,01
$u_2(k-3)$	0,3012	4,254	10,77	-0,5421
$u_3(k-3)$	-0,01968	-1,009	0,4468	1,799

Коефіцієнти, які наведено в таблицях 2.12–2.14, пов'язані з кожним кластером і відповідають за перетворення нечітких вхідних даних на чіткі вихідні. Фізичним змістом цих коефіцієнтів є частинні коефіцієнти чутливості вихідної функції до вхідних параметрів. У поєднанні з гаусівською формою термів фазифікації вони дозволяють робити прецизійні прогнози, які налаштовані на специфічні характеристики зв'язку між входами та виходами кожного кластера. Включення цих коефіцієнтів підвищує точність прогнозування та покращує здатність моделі враховувати складні взаємозв'язки

між вхідними параметрами та ймовірністю виникнення конкретних видів хвороб с/г культур.

У результаті систематизації результатів із ідентифікації параметрів та створення комп'ютерних моделей ANFIS, було проведено серію комп'ютерних імітаційних тестів в середовищі Fuzzy Logic Designer пакета прикладних програм Matlab & Simulink, в яких прогнознi значення ймовірності виникнення хвороб кукурудзи порівнювались із фактичними даними. Результатами цих тестів стали: графіки часових рядів, як показано на рисунках 2.43, 2.44, 2.46, 2.47, 2.49, 2.50, а також графіки порівняння фактичних і прогнозованих даних, як показано на рисунках 2.45, 2.48, 2.51. У таблиці 2.15 наведено результати комплексного порівняння показників ефективності прогнозування ймовірності виникнення хвороб кукурудзи на передсимптомній стадії за такими оцінками статистичного розподілу: середня абсолютна похибка (MAE), середньоквадратичне відхилення (RMSE) і коефіцієнт детермінації ( $R^2$ ).




Рисунок 2.43 – Графічні залежності прогнозування ймовірності виникнення ГНВ кукурудзи на навчальній вибірці даних






Рисунок 2.44 – Графічні залежності прогнозування ймовірності виникнення ГНВ кукурудзи на валідаційній вибірці даних



а) навчальна вибірка



б) валідаційна вибірка

Рисунок 2.45 – Порівняльні графічні залежності прогнозування ймовірності виникнення FHB кукурудзи




Рисунок 2.46 – Графічні залежності прогнозування ймовірності виникнення SCLB кукурудзи на навчальній вибірці даних






Рисунок 2.47 – Графічні залежності прогнозування ймовірності виникнення SCLB кукурудзи на валідаційній вибірці даних



а) навчальна вибірка



б) валідаційна вибірка

Рисунок 2.48 – Порівняльні графічні залежності прогнозування ймовірності виникнення SCLB кукурудзи




Рисунок 2.49 – Графічні залежності прогнозування ймовірності виникнення NCLB кукурудзи на навчальній вибірці даних






Рисунок 2.50 – Графічні залежності прогнозування ймовірності виникнення NCLB кукурудзи на валідаційній вибірці даних



а) навчальна вибірка



б) валідаційна вибірка

Рисунок 2.51 – Порівняльні графічні залежності прогнозування ймовірності виникнення NCLB кукурудзи

Для обчислення кількісних оцінок точності прогнозування з використанням запропонованих ANFIS-моделей (табл. 2.15) використано метрики, які обчислюються за формулами (2.14)–(2.16):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|; \quad (2.14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (2.15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (2.16)$$

де  $y_i$  – експериментальні значення ймовірності виникнення відповідних хвороб кукурудзи;  $\hat{y}_i$  – модельні значення ймовірності виникнення відповідних хвороб кукурудзи;  $\bar{y}$  – середнє арифметичне значення експериментальних даних ймовірності виникнення відповідних хвороб кукурудзи.

Таблиця 2.15 – Результати комплексного порівняння показників ефективності прогнозування ймовірності виникнення хвороб кукурудзи

<b>Метрика</b>	<b>Тип набору даних</b>	<b>FNB</b>	<b>SCLB</b>	<b>NCLB</b>
MAE, %	навчальний	0,76	1,36	0,56
	валідаційний	0,72	5,57	2,3
RMSE, %	навчальний	±4,06	±5,92	±2,94
	валідаційний	±4,5	±13,62	±6,28
R <sup>2</sup>	навчальний	0,96	0,75	0,8
	валідаційний	0,8	0,61	0,7

Отже, на підставі аналізу результатів серії комп'ютерних експериментів встановлено і доведено ефективність запропонованих ANFIS-моделей для прогнозування ймовірності виникнення хвороб на передсимптомній стадії під час вирощування кукурудзи. Завдяки зіставленню прогнозованих і фактичних даних, аналізу показників ефективності та з'ясуванню часової динаміки доведено здатність моделей на основі нейро-нечітких технологій до прогнозування ймовірності виникнення хвороб. Такий підхід дозволяє реалізувати програмно-апаратні компоненти інформаційних технологій прецизійного аналізу вимірювальних даних із підтримкою прийняття рішень у режимі реального часу з урахуванням значної кількості функціональних взаємозв'язків ґрунтокліматичних факторів широкого спектру вирощуваних сільськогосподарських культур в різні періоди їх вегетації, що, в свою чергу, забезпечує можливість адаптувати запропоновані комп'ютерні моделі до використання у вигляді апаратно-програмного забезпечення бюджетних мікроконтролерних пристроїв, що відповідає сьогоденним прикладним засадам реалізації концептуальних положень граничних і туманних обчислень.

Таким чином, можна зазначити, що основний науково-практичний ефект результатів дослідження цього підрозділу полягає в розвитку програмно-апаратного забезпечення інформаційних технологій агротехнічного моніторингу для сталого вирощування сільськогосподарських культур у воєнний та повоєнний час завдяки розробці комп'ютерно-орієнтованої моделі на базі ANFIS та синтезі структурно-алгоритмічного забезпечення щодо

ідентифікації та прогнозування ймовірності виникнення хвороб кукурудзи (FHB, SCLB і NCLB) під час повного циклу її вирощування. Запропоноване комп'ютерно-орієнтоване забезпечення може бути використане у вигляді інтегрованого програмного забезпечення під час створення інформаційних технологій моніторингу агротехнічного призначення, що дозволяє в режимі реального часу реалізовувати підтримку прийняття рішень практикуючими фахівцями в галузі рослинництва відкритого ґрунту. Фізичний принцип дії розробленої моделі базується на онлайн-детектуванні та інтелектуалізованому аналізі ґрунтокліматичних даних (температура повітря із урахуванням попередніх часових відліків із затримкою від 1 год до 4 год, вологість повітря та кількість опадів із урахуванням попередніх часових відліків із затримкою від 1 год до 3 год, час зволоження листя із урахуванням попередніх часових відліків із затримкою 1 год до 9 год залежно від типу діагностованої хвороби), що надходять від відповідних розподілених сенсорів фізико-хімічних величин. Також варто акцентувати увагу на тому, що розроблені ANFIS-моделі передбачають використання вихідної функції (вірогідність виникнення конкретного виду хвороби) в попередні відліки часу із затримкою від 1 год до 9 год, у відповідності до типу діагностованої хвороби, в якості вхідного аргументу. Такий підхід, на відміну від відомих, що базуються на принципі розпізнавання зображень, придатний під час вирішення задачі прогнозування ймовірності виникнення хвороби на передсимптомній стадії, тобто попередження її виникнення, що є неможливим для методів, які базуються на розпізнаванні зображень, адже вони придатні для діагностування та класифікації типів хвороб, які вже виникли в агрокультурі. Отже, інтеграція розроблених моделей у вигляді вбудованого програмного забезпечення до використовуваних на сьогоднішній день комп'ютеризованих агрокліматичних метеостанцій дозволяє значно розширити їх функціональні можливості завдяки реалізації підтримки прийняття рішень щодо планування і реалізації агротехнічних процедур під час повного циклу вирощування різних типів с/г культур. Типовими агротехнічними процедурами, що можуть бути заплановані

та реалізовані на підставі розробленої моделі є оптимальне планування часу посівів, вибір оптимальних типів і часу внесення добрив, зрошення ґрунту та ін.

Перспективними пріоритетними напрямками подальших досліджень у відповідності до отриманих результатів цього підрозділу є проведення додаткових досліджень із метою розширення набору даних і включення ширшого спектру агрокультур та типів діагностованих хвороб; врахування практики внесення добрив, стратегії зрошення та інших заходів для отримання цілісного уявлення про динаміку ймовірності виникнення хвороб; тривалі експериментальні випробування в реальних умовах експлуатації в різних кліматичних зонах; комплексна техніко-економічна оцінка інвестиційної привабливості щодо впровадження отриманих рішень.

Проведення досліджень за зазначеними вище напрямками дозволить підвищити показники адекватності, адаптивності та масштабності детектування та прогнозування ймовірності виникнення хвороб с/г культур на передсимптомній стадії, що позитивно вплине на інвестиційну привабливість та довгострокову стійкість національної с/г галузі завдяки підвищенню інноваційної складової аграрного сектору.

## **2.4 Висновки до другого розділу**

У цьому розділі отримано результати досліджень, які присвячено вирішенню науково-прикладної задачі обґрунтування структурно-алгоритмічної організації та розробці апаратно-програмного забезпечення інтелектуальних технологій агротехнічного онлайн-моніторингу ґрунтокліматичних параметрів с/г виробництв. Основні якісні та кількісні результати досліджень і розробок цього розділу є такими:

1. Обґрунтовано структурно-алгоритмічну організацію інформаційної технології мережевої агрегації та периферійної обробки результатів моніторингу ґрунтокліматичних факторів, що, на відміну від раніше відомих, синтезована з урахуванням інтегрального впливу критеріїв приведеної до

кількості бездротових мережевих модулів зони покриття та надійності обміну вимірювальними даними. Розроблена й протестована комп'ютерно-орієнтована модель інформаційної технології базується на алгоритмах багаторівневого мережевого обміну вимірювальними даними на основі технологій ZigBee та LoRa із передачею статистично оброблених даних до віддаленого хмарного сервера через мережу Інтернет. Проведено дослідження щодо вибору оптимальної геометричної моделі бездротової мережі польового рівня збору вимірювальних даних. За інтегральним критерієм максимуму приведеної зони покриття та вірогідності безвідмовної роботи оптимальною виявилась ромбоподібна топологія: приведена зона покриття –  $2,82 \cdot 10^4 \text{ м}^2/\text{од.}$ , вірогідність безвідмовної роботи за період експлуатації п'ять років – 0,959.

2. Розроблено та валідовано комп'ютерну модель інфокомунікаційної інфраструктури мережі агротехнічного моніторингу, що реалізує засади граничних обчислень. Створена комп'ютерна модель дозволила протестувати та валідувати мережеву взаємодію різних протоколів на різних архітектурних рівнях інформаційної технології агротехнічного моніторингу за критерієм об'єктивного відпрацювання алгоритмів багаторівневої агрегації, обробки та передачі даних. Апаратну частину інформаційної технології розроблено на основі серійних і бюджетних сенсорних, мікроконтролерних і мережевих компонент, а програмна компонента комп'ютерної моделі являє собою вбудоване до мікроконтролерного блока програмне забезпечення на основі ANFIS алгоритмів прогнозування ймовірності появи хвороб с/г культур.

3. Розроблено комп'ютеризовану методику досліджень програмних засобів обробки кліматичних параметрів з метою підвищення ефективності прогнозування хвороби FHB кукурудзи, що дозволило методами комп'ютерного експерименту оцінити доцільність застосування ML та AI під час предикативної аналітики сукупного впливу температури повітря, відносної вологості повітря, кількості опадів та часу зволоження листя агрокультур на вірогідність появи зазначеної вище хвороби кукурудзи. Ідентифіковано та програмно реалізовано модель обліку кліматичних параметрів та вірогідності

появи хвороби FHB в попередні моменти часу на прогнозоване значення вірогідності появи цієї хвороби: оптимальне значення параметра timestep (відповідає за кількість годин передісторії даних) дорівнює 9 год для агрокліматичних умов Лісостепу і Північного Степу України. Розроблено та програмно реалізовано мовою програмування Python алгоритм попередньої обробки локальних патернів вхідних наборів даних із різким спаданням вірогідності появи хвороб експоненційними залежностями. Це дозволило підвищити якість обробки даних за рахунок зменшення негативного впливу таких аномальних ділянок у навчальних наборах даних: коефіцієнт детермінації для системи без попередньої експоненційної апроксимації даних змінюється в діапазоні від 0,901 до 0,987, а для системи з попередньою експоненційною апроксимацією даних – від 0,986 до 0,997 залежно від використовуваного типу ML та AI алгоритму. Визначено, що оптимальним для агрокліматичних умов Лісостепу і Північного Степу України, є використання алгоритму випадкового лісу під час побудови програмно-апаратних рішень детектування вірогідності появи хвороби FHB кукурудзи: для Дніпропетровської області (Північний Степ) –  $R^2=0,997$ ,  $RMSE=\pm 0,88$ ,  $MAE=0,212$  та для Черкаської області (Лісостеп) –  $R^2=0,995$ ,  $RMSE=\pm 1,374$ ,  $MAE=0,206$ .

4. Створено та валідовано комп'ютерно-орієнтовану модель обробки даних на основі ANFIS алгоритмів, яка, на відміну від відомих, враховує одночасний вплив сукупності ґрунтокліматичних параметрів с/г підприємств рослинництва відкритого ґрунту, їх попередню динаміку, а також передісторію вихідного параметра (ймовірність виникнення специфічних хвороб), що дозволило детектувати ймовірність виникнення хвороб у кукурудзи зі значенням коефіцієнта детермінації на валідаційних даних: FHB – 0,8, SCLB – 0,61 та NCLB – 0,7. Під час досліджень розроблено та протестовано модель ідентифікації параметрів комп'ютерної моделі, яка враховує можливі комбінації вхідних та вихідних даних із затримкою на фіксовану кількість періодів дискретизації, що дозволило встановити сукупність найбільш інформативних параметрів із найменшими значеннями похибки 4,33 % на

тренувальній вибірці для FNB, 6,02 % для SCLB та 5,92 % для NCLB. Також реалізовано моделі в середовищі Matlab & Simulink, що дозволило виконати серію комп'ютерних експериментів, де прогнознi значення ймовірності виникнення хвороб порівнювались із фактичними даними, ці моделі є адаптивними до динамічних умов навколишнього середовища й масштабованими до набору вхідних даних.

5. Обґрунтовано перспективні пріоритетні напрямки подальших досліджень щодо оптимізації структурно-алгоритмічної організації та вдосконалення апаратно-програмного забезпечення інтелектуальних технологій агротехнічного онлайн-моніторингу ґрунтокліматичних параметрів с/г виробництв рослинництва відкритого ґрунту. Проведення досліджень за встановленими перспективними напрямами дозволить підвищити показники адекватності й масштабності детектування та прогнозування ймовірності виникнення хвороб с/г культур на передсимптомній стадії, що позитивно вплине на інвестиційну привабливість та довгострокову стійкість національної с/г галузі завдяки підвищенню інноваційної складової аграрного сектору.

### **Список використаних джерел до другого розділу**

1. Slater, L.J., Huntingford, C., Pywell, R.F., Redhead, J.W., Kendon, E.J. Resilience of UK crop yields to compound climate change. *Earth System Dynamics*, 2022, Vol. 13 (3). P. 1377–1396. <https://doi.org/10.5194/esd-13-1377-2022>

2. Chia, S.Y., Lim, M.W. A critical review on the influence of humidity for plant growth forecasting. *IOP Conf. Series: Materials Science and Engineering*, 2022, Vol. 1257. P. 1–6. <https://doi.org/10.1088/1757-899X/1257/1/012001>

3. Laktionov, I., Vovna, O., Kabanets, M. Computer-Oriented Method of Adaptive Monitoring and Control of Temperature and Humidity Mode of Greenhouse Production. *Baltic Journal of Modern Computing*, 2023, Vol. 11 (1). P. 202–225. <https://doi.org/10.22364/bjmc.2023.11.1.12>

4. Laktionov, I., Vovna, O., Kabanets, M. Information Technology for

Comprehensive Monitoring and Control of the Microclimate in Industrial Greenhouses Based on Fuzzy Logic. JAISCR, 2023, Vol. 13 (1). P. 19–35. <https://doi.org/10.2478/jaiscr-2023-0002>

5. Damodaram, D., Rakesh Kumar Godi, Rajkumar, Divakara Rao, D.V., Glory, K.B., Somu, K. Power control management system model using wireless sensor network. Measurement: Sensors, 2023, Vol. 25. P. 1–5. <https://doi.org/10.1016/j.measen.2022.100639>

6. Hossain, A., Mishra, R. Sensing and Link Model for Wireless Sensor Network: Coverage and Connectivity Analysis. In: 2nd National Conference EAPE, 2014. P.1–5. <https://doi.org/10.48550/arXiv.1406.1275>

7. Ganesh, S., Amutha, R. Efficient and Secure Routing Protocol for Wireless Sensor Networks through Optimal Power Control and Optimal Handoff-Based Recovery Mechanism. Journal of Computer Networks and Communications, 2012, Vol. 2012. P. 1–8. <https://doi.org/10.1155/2012/971685>

8. Cao, W., Xu, J., Shan, J., Sun, R. Research and Application of Wireless Sensor Networks in Agriculture. In: 2017 International Conference on Electronic Industry and Automation, 2017. P. 151–154. <https://doi.org/10.2991/eia-17.2017.32>

9. Kaiwartya, O., Abdullah, A.H., Cao, Y., Raw, R.S., Kumar, S., Lobiyal, D.K., Isnin, I.F., Liu, X., Shah, R.R. T-MQM: Testbed-Based Multi-Metric Quality Measurement of Sensor Deployment for Precision Agriculture – A Case Study. IEEE Sensors Journal, 2016, Vol. 16 (23). P. 8649–8664. <https://doi.org/10.1109/JSEN.2016.2614748>

10. Saban, M., Bekkour, M., Amdaouch, I., El Gueri, J., Ait Ahmed, B., Chaari, M.Z., Ruiz-Alzola, J., Rosado-Munoz, A., Aghzout, O. A Smart Agricultural System Based on PLC and a Cloud Computing Web Application Using LoRa and LoRaWan. Sensors, 2023, Vol. 23 (2725). P. 1–16. <https://doi.org/10.3390/s23052725>

11. Pagano, A., Croce, D., Tinnirello, I., Vitale, G. A Survey on LoRa for Smart Agriculture: Current Trends and Future Perspectives. IEEE Internet of Things Journal, 2023, Vol. 10 (4). P. 3664–3679. <https://doi.org/10.1109/JIOT.2022.3230505>



21. Electronics Lab.: Introduction to LoRa – send data between two Arduino using LoRa. Retrieved from: <https://www.electronics-lab.com/project/introduction-lora-send-data-two-arduino-using-lora/> (accessed September 28, 2024).
22. Conti, M., Orcioni, S. Modeling of Failure Probability for Reliability and Component Reuse of Electric and Electronic Equipment. *Energies*, 2020, Vol. 13 (11). P. 1–18. <https://doi.org/10.3390/en13112843>
23. Laktionov, I., Diachenko, G., Koval, V., Yevstratiev, M. Computer-Oriented Model for Network Aggregation of Measurement Data in IoT Monitoring of Soil and Climatic Parameters of Agricultural Crop Production Enterprises. *BJMC*, 2023, Vol. 11(3). P. 500–522. <https://doi.org/10.22364/bjmc.2023.11.3.09>
24. Laktionov, I., Diachenko, G., Rutkowska, D. and Kisiel-Dorohinicki, M. An explainable ai approach to agrotechnical monitoring and crop diseases prediction in Dnipro region of Ukraine. *JAISSCR*, 2023, Vol. 13 (4). P. 247–272. <https://doi.org/10.2478/jaiscr-2023-0018>
25. MakeProto. Retrieved from: [http://www.makeproto.com/projects/fuzzy/matlab\\_arduino\\_FIST/index.php](http://www.makeproto.com/projects/fuzzy/matlab_arduino_FIST/index.php) (accessed September 30, 2024).
26. Cao, X.H., Stojkovic, I., Obradovic, Z. A robust data scaling algorithm to improve classification accuracies in biomedical data. *BMC Bioinformatics*, 2016, Vol. 17 (359). P. 1–10. <https://doi.org/10.1186/s12859-016-1236-x>
27. Wan, X. 2019. Influence of feature scaling on convergence of gradient iterative algorithm. *Journal of Physics: Conference Series*, 2019. P. 1–6. <https://doi.org/10.1088/1742-6596/1213/3/032021>
28. Laktionov, I., Rutkowski, L., Vovna, O., Byrski, A., Kabanets, M. A Novel Approach to Intelligent Monitoring of Gas Composition and Light Mode of Greenhouse Crop Growing Zone on the Basis of Fuzzy Modelling and Human-in-the-Loop Techniques. *Engineering Applications of Artificial Intelligence*, 2023, Vol. 126 (B). P. 1–21. <https://doi.org/10.1016/j.engappai.2023.106938>
29. MathWorks: Nonlinear System Identification. Retrieved from: <https://www.mathworks.com/help/fuzzy/nonlinear-system-identification.html> (accessed October 03, 2024).

## РОЗДІЛ 3

# ІНТЕЛЕКТУАЛЬНА ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ОБРОБКИ ТА АНАЛІЗУ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ДЛЯ КАРТОГРАФУВАННЯ ЗЕМНОЇ ПОВЕРХНІ

### 3.1 Метод попередньої обробки супутникових зображень із використанням згорткової нейронної мережі

З урбанізацією та зростанням зацікавленості до геоінформаційних систем, точних картографічних досліджень та екологічного моніторингу виникає необхідність у вдосконаленні методів злиття цифрових супутникових зображень високої роздільної здатності для отримання більш деталізованих та інформативних зображень [1]. Супутникові зображення високого просторового розрізнення мають великий потенціал щодо вирішення різноманітних завдань, у тому числі й агротехнічного призначення, але їхнє використання в більшості випадків обмежується низькою динамікою контрасту та обмеженою спектральною інформацією. Одним із ключових етапів попередньої обробки супутникових зображень є їхнє злиття, або паншарпенінг, що містить у собі поєднання панхроматичних (ПЗ) та багатоканальних зображень (БЗ), які хоч і мають нижче просторове розрізнення, ніж панхроматичні, проте містять спектральну інформацію, що є невід’ємною частиною аналізу земної поверхні [2], [3]. Методи паншарпенінгу не лише підвищують просторову роздільну здатність отриманих зображень, але й зберігають спектральну інформацію. Такий підхід дозволяє отримати більш повні та інформативні дані для їх подальшого тематичного аналізу (виявлення, розпізнавання об’єктів, класифікація земного покриття тощо).

На теперішній час відома значна кількість наукових досліджень, присвячених вирішенню проблеми злиття супутникових зображень. Ці дослідження можна розділити на дві групи: традиційні методи оптимізації та методи, що базуються на глибокому навчанні. Метод тон–насиченість–

значення (HSV) [4], [5], аналіз головних компонент (PCA) [6] та перетворення Грама-Шмідта (Gram–Schmidt) [7], метод Бровей (Brovey) тощо є традиційними методами. Ці методи дозволяють досягти високої просторової роздільної здатності, але призводять до значних спектральних спотворень. З іншого боку, методи, що базуються на аналізі множинної роздільної здатності, такі як вейвлет-перетворення [5], фільтри високих частот та узагальнена піраміда Лапласа [8], можуть зберігати спектральну інформацію, але призводять до просторових спотворень. Поширеним є метод паншарпенінгу на основі стискання (CS) [9]. Його недоліком є те, що він потребує великої кількості навчальних зображень із високою роздільною здатністю, які можуть бути недоступними. Для вирішення цієї проблеми запропоновано використання комбінованих методів, таких як Revisited AWLP, керованого фільтра тощо. Ці методи призначені для збільшення просторової здатності зображень при збереженні спектральної інформації. Проте експериментально доведено, що ці методи все одно призводять до певних спектральних і просторових спотворень.

Останнім часом велика увага приділяється методам паншарпенінгу на основі глибокого навчання. Авторами [10] запропоновано методіку самокодування з низьким рівнем шуму для отримання співвідношення між зображеннями з високою та низькою роздільною здатністю за допомогою глибоких нейронних мереж. У роботі [11] застосовано згорткові нейронні мережі (CNNs), що значно покращило продуктивність алгоритму порівняно з традиційними методами. Автори [12] вирішили проблему втрати інформації під час вилучення ознак на основі нейронних мереж. У роботі [13] запропоновано модель PanNet для спектрального збереження та просторового покращення первинних даних.

Незважаючи на значні досягнення вирішення задач попередньої обробки супутникових зображень, існуючі методи паншарпенінгу все ще мають свої обмеження та недоліки. Недостатня точність, артефакти та втрата деталей можуть виникати через неповне врахування взаємодії спектральних та просторових характеристик зображень конкретних аерокосмічних носіїв.

Методи на основі глибокого навчання покращують якість злитих зображень краще, ніж традиційні методи, але мають високу складність обчислень на зображеннях високої роздільної здатності та не враховують адаптацію розмірності каналу.

Однією з основних задач дослідження є розробка методу попередньої обробки цифрових супутникових зображень із використанням згорткової нейронної мережі, яка здатна ефективно вилучати деталі текстури та просторові залежності, а також локальну та нелокальну інформацію, що дозволить покращити точність та деталізацію отриманих зображень.

Структурно-функціональною основою запропонованого методу є інформаційна технологія, яку наведено на рисунку 3.1. Алгоритм її функціонування містить у собі такі етапи: завантаження первинних цифрових супутникових зображень; застосування геометричної, радіометричної та атмосферної корекцій; використання нейронної мережі, яка складається з вивчення глобальної інформації про текстуру та отримання просторової інформації з кожної смуги зображення за відповідними каналами.

На першому етапі виконується завантаження багатоканального в композиції RGB (наприклад, канали 5-3-2 космічного апарата WorldView-2) та панхроматичного зображень. Далі виконується низка корекцій, спрямованих на усунення різноманітних спотворень, що можуть виникати під час зйомки та передачі зображень із космосу. Геометрична корекція цифрових супутникових зображень є важливим етапом попередньої обробки для усунення спотворень, що виникають у зображеннях через геометричні особливості процесу зйомки. Математично перерахунок значень пікселів можна виразити за допомогою формул [14], [15]:

$$\begin{aligned} X_{corr} &= X_{inp} \times \frac{S_x}{S_y} + \Delta x \\ Y_{corr} &= Y_{inp} \times \frac{S_x}{S_y} + \Delta y \end{aligned}, \quad (3.1)$$

де  $X_{inp}, Y_{inp}$  – координати пікселя первинного супутникового зображення;  $X_{corr}, Y_{corr}$  – координати пікселя після геометричної корекції;  $S_x, S_y$  – коефіцієнти за осями  $X$  та  $Y$ ;  $\Delta x, \Delta y$  – зсуви за відповідними осями.

Наступний етап містить у собі процес передискретизації, який полягає в масштабуванні БЗ до розмірів ПЗ зі застосуванням формули [5]:

$$P'(x', y') = a \cdot P(x, y) + b \cdot P(x + 1, y) + c \cdot P(x, y + 1) + d \cdot P(x + 1, y + 1). \quad (3.2)$$

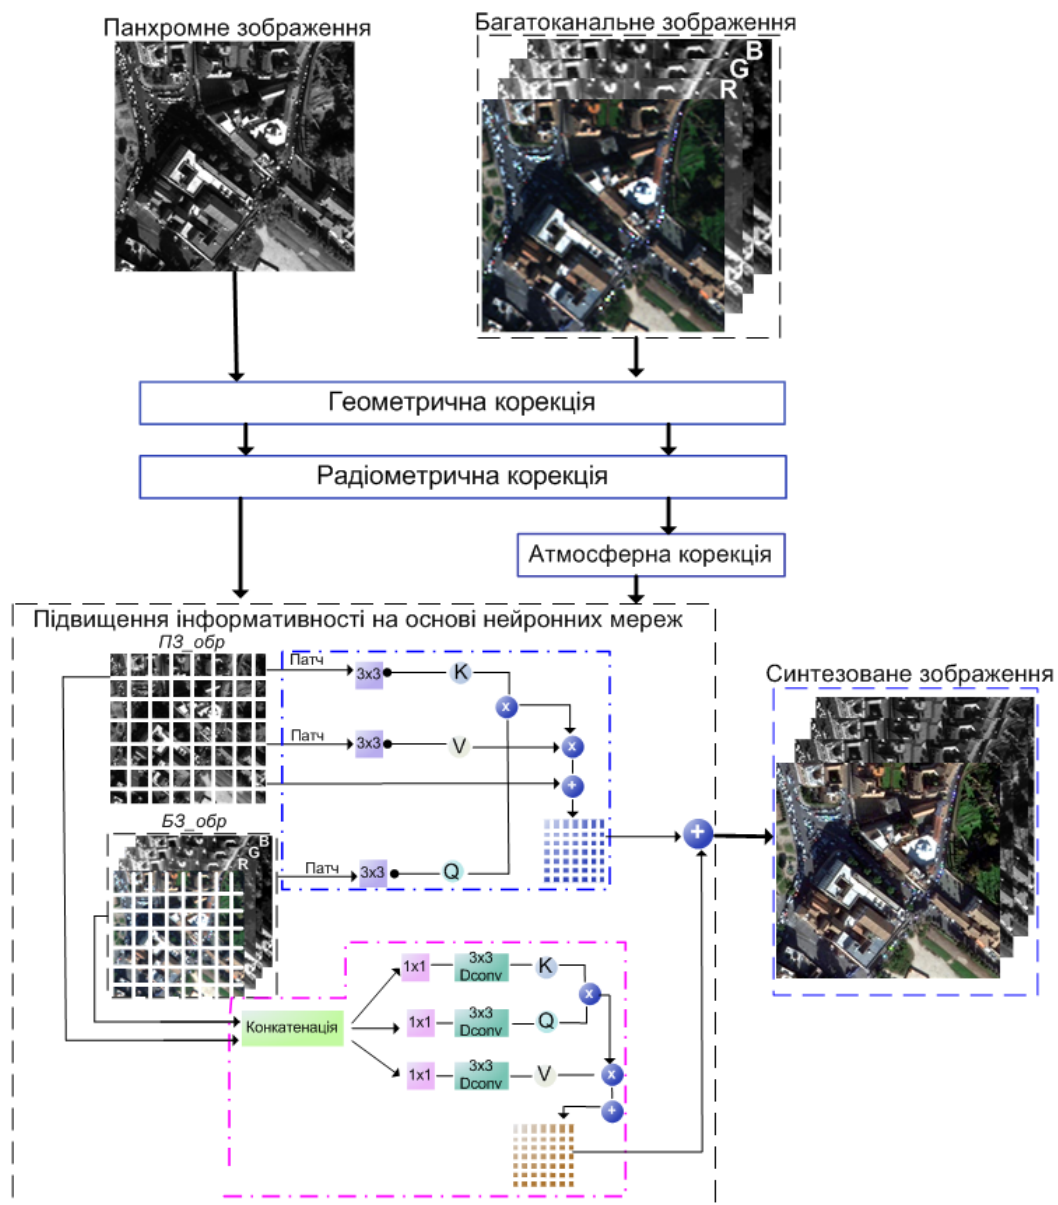


Рисунок 3.1 – Схема методу попередньої обробки супутникових зображень із використанням згорткової нейронної мережі

Радіометрична корекція, спрямована на виправлення впливу атмосферних умов на оптичних зображеннях. Однією з найбільш поширених проблем у оптичному дистанційному зондуванні є хмарний покрив, який може заважати спостереженню земної поверхні. Таким чином, важливо виконати відносне радіометричне калібрування для мінімізації впливу цих артефактів [14]:

$$q = \frac{p - A}{B}, \quad (3.3)$$

де  $q$  – радіометрично виправлені дані сенсора;  $p$  – необроблені дані сенсора;  $A$  – зсув «темряви» для конкретного супутникового зображення;  $B$  – відносний коефіцієнт підсилення сенсора.

Атмосферна корекція БЗ полягає в перетворенні радіометрично скоригованих пікселів зображення на спектральну яскравість верхнього шару атмосфери з мінімальним значенням. Для цього використовується загальне рівняння, яке враховує параметри сенсора на висоті 770 км супутника WorldView-2 [14]:

$$B(\lambda) = \frac{L(\lambda)}{\tau(\lambda)} + L_{atm}(\lambda) \left(1 - \frac{1}{\tau(\lambda)}\right) + L_p(\lambda), \quad (3.4)$$

де  $B(\lambda)$  – спектральна яскравість верхнього шару атмосфери;  $L(\lambda)$  – виміряне спектральне випромінювання на поверхні Землі;  $\tau(\lambda)$  – коефіцієнт пропускання атмосфери;  $L_{atm}(\lambda)$  – спектральна яскравість атмосфери;  $L_p(\lambda)$  – підсвічування.

Після геометричної, радіометричної та атмосферної корекцій первинних зображень використовується нейронна мережа. Спочатку оновлені зображення сегментуються на ділянки однакового розміру, що не перетинаються. Потім кодується їхнє положення для створення послідовності ділянок. Ці патчи зображень використовуються як вхідні ознаки текстури. Далі, ознаки

виділяються за допомогою згортки  $3 \times 3$  і проєктуються на компоненти, що необхідні для відповідного трансформатора:  $Q$  (запит),  $K$  (ключ) і  $V$  (значення) [16]:

$$Q = X \cdot W_q, \quad (3.5)$$

$$K = X \cdot W_k, \quad (3.6)$$

$$V = X \cdot W_v, \quad (3.7)$$

де  $X$  – вектор властивостей патча;  $W_q$ ,  $W_v$  – матриця ваг області ПЗ;  $W_k$  – матриця ваг області БЗ.

Використовуючи ознаки  $Q$  та  $K$  для оцінки схожості, формується матриця асоціацій. Потім виконується множення цієї матриці асоціацій на матрицю асоціацій PAN-зображення (ознака  $V$ ). Це дозволяє отримати остаточну зважену карту ознак. Додатково вводиться перехідний зв'язок, щоб уникнути втрати інформації. Нарешті, всі згенеровані карти особливостей патчів знову зшиваються разом за допомогою кодування позиції, щоб отримати остаточну карту особливостей текстури.


Наступна гілка мережі дозволяє отримати відповідну просторову інформацію кожного каналу зображення. Спочатку застосовується точкова згортка  $1 \times 1$  для отримання контекстної інформації між різними каналами на рівні пікселів, а потім використовується глибинна згортка  $3 \times 3$  для отримання просторового контексту вздовж каналу. Після цього отримана інформація згортки розділяється для подальшого використання у векторах  $Q$ ,  $K$  і  $V$ :

$$X = \text{Concat}(\text{ПЗ\_нов}, \text{БЗ\_нов}), \quad (3.8)$$

де  $X$  – результуюче зображення після злиття ПЗ та БЗ;  $\text{ПЗ\_нов}$ ,  $\text{БЗ\_нов}$  – оновлені зображення.

Отримані зважені карти ознак кожного фрагмента інтегруються разом для створення нового синтезованого зображення. Це зображення являє собою комбінацію інформації про текстуру та просторову здатність панхроматичного та багатоканального зображень. Це дозволяє отримати більш інформативне зображення, порівняно з первинними даними.

У цьому дослідженні для конкретності використано 16-розрядні стандартні мультипослідовності рівня 2 зі супутника WorldView-2. Ці дані містять односмугові панхроматичні та 8-смугові багатоканальні зображення. Розмір кожного зображення складає 599 на 576 пікселів. На рисунку 3.2 наведено первинні та оброблені на основі запропонованого методу супутникові зображення. Синтезовані зображення характеризуються збільшеною роздільною здатністю, при цьому локальні збільшені частини не демонструють явного розмиття контурів, що свідчить про високу якість паншарпенінгу.



а) панхроматичне

б) багатоканальне  
(канали 5-3-2)

в) після обробки з  
використанням

запропонованої технології

Рисунок 3.2 – Супутникові зображення космічного апарата WorldView-2:

Для оцінки ефективності запропонованого методу із використанням згорткової нейронної мережі обрано сім методів порівняння: HSV (Hue, Saturation, Value), Adaptive Tonal Weighting Transformation (ATWT), Adaptive

Weighted Linear Prediction (AWLP), Brightness-Difference-Based Saturation-Difference (BDSD), Brovey Transform, High Pass Filtering (HPF) та комбінацію вейвлет із методом HSV (Wavelet + HSV). Використано критерій максимальної інформативності для оцінки якості зображень на основі ймовірності виникнення різних значень пікселів у зображенні [2], [15]. На рисунку 3.3 наведено значення ентропії для традиційних методів обробки зображень та запропонованої технології.




Рисунок 3.3 – Графічне представлення значень ентропії

За результатами аналізу отриманих результатів, які наведено на рисунку 3.3, можна зробити висновок, що запропонований метод має найвище значення ентропії, що свідчить про більшу різноманітність та складність інформації в отриманому зображенні порівняно з іншими методами обробки.

Коефіцієнт кореляції (*corr*) є важливим інструментом для кількісної оцінки ступеня відповідності між двома наборами даних, у нашому випадку – між синтезованим та оригінальними зображеннями. Цей показник дозволяє визначити, наскільки злиге зображення відтворює оригінальні дані. Високий

коефіцієнт кореляції свідчить про те, що синтезоване зображення добре відтворює оригінальні дані, тобто воно має високу схожість з оригіналом [4], [5]. У таблиці 3.1 наведено оцінені значення коефіцієнта кореляції для різних методів.

Аналізуючи дані з таблиці 3.1, встановлено, що метод HSV демонструє високий рівень кореляції для всіх трьох каналів (R, G, B), що свідчить про добре збережену спектральну інформацію після злиття зображень. Методи ATWT, AWLP, BDSD, Brovey та HPF мають нижчі значення кореляції порівняно з методом HSV. Це вказує на меншу ефективність цих методів у збереженні спектральної інформації під час злиття зображень. Метод Wavelet+HSV також має високий рівень кореляції, що свідчить про добре збереження спектральної інформації. Запропонований метод демонструє найвищий рівень кореляції для всіх трьох каналів, що свідчить про його високу ефективність під час збереження спектральної інформації та збереження деталізації зображення.

Таблиця 3.1 – Значення коефіцієнта кореляції (*corr*)

Методи	Канали		
	R	G	B
HSV	0,87	0,84	0,85
ATWT	0,59	0,61	0,63
AWLP	0,64	0,65	0,66
BDSD	0,60	0,61	0,64
Brovey	0,53	0,50	0,54
HPF	0,55	0,56	0,58
Wavelet+ HSV	0,90	0,86	0,86
<b>Запропонований метод</b>	<b>0,97</b>	<b>0,96</b>	<b>0,96</b>

Важливими метриками для оцінки якості зображень є також коефіцієнти структурної схожості зображень (SSIM) та PSNR (Peak Signal-to-Noise Ratio). SSIM аналізує структурну подібність між оригінальним та обробленим зображеннями, визначаючи ефективність методів обробки, тоді як PSNR

вимірює якість відтворення зображення після компресії або обробки. Значення цих метрик наведено в таблиці 3.2.

Коефіцієнт SSIM має кращі показники для запропонованого методу, що свідчить про високий рівень структурної подібності між синтезованим та оригінальним зображеннями. Значення коефіцієнту PSNR для запропонованого методу вказує на високу якість відтворення оброблених зображень порівняно з оригінальними. А для методів AWLP і Brovey, демонструють значно менші значення PSNR, що вказує на більш великі втрати якості відтворення.

Таблиця 3.2 – Значення коефіцієнтів SSIM та PSNR

Методи	SSIM			PSNR		
	Канали			Канали	Канали	Канали
	R	G	B	R	G	B
HSV	0,49	0,46	0,45	17,85	16,75	17,35
ATWT	0,48	0,50	0,51	13,92	14,45	14,93
AWLP	14,32	14,77	15,22	0,46	0,48	0,48
BDSB	0,50	0,51	0,51	13,85	14,38	14,88
Brovey	0,40	0,40	0,41	13,14	13,16	14,07
HPF	0,44	0,46	0,47	13,30	13,82	14,29
Wavelet+ HSV	0,56	0,54	0,52	23,12	22,96	22,95
<b>Запропонований метод</b>	<b>0,71</b>	<b>0,65</b>	<b>0,67</b>	<b>37,60</b>	<b>38,38</b>	<b>38,93</b>

Метрики ERGAS (Relative Dimensionless Global Error in Synthesis) і RMSE (Root Mean Square Error) використовуються для оцінки точності обробки та відтворення зображень. На рисунку 3.4 наведено кількісні результати оцінки метрик ERGAS та RMSE.

Аналізуючи отримані результати (рис. 3.4) встановлено, що значення ERGAS та RMSE для запропонованого методу та методу Wav+HSV є найменшими порівняно з іншими методами. Це свідчить про високу точність синтезу та відтворення зображень за допомогою цих методів. З іншого боку, значення ERGAS та RMSE для методів HSV, ATWT, AWLP, BDSB, Brovey і HPF свідчать про меншу точність злиття зображень.




Рисунок 3.4 – Графічне представлення метрик ERGAS та RMSE

Під час порівняльного аналізу різних методів злиття WorldView-2 зображень (рис. 3.5) можна помітити відмінності у якості синтезованих зображень. Методи ATWT, AWLP, BSDS та HPF демонструють значні просторові спотворення, отже загальне зображення виглядає розмитим.

Підходи Brovey і HSV призводять до розмиття кольорів, а спотворення первинних кольорів трави на зображеннях стають очевидними. Ці артефакти знижують інформативність зображення та роблять його менш придатним для подальшого використання в додатках, де важлива точність кольору та деталізація. Gram-Shmidt та Wav+HSV, хоча ближчі за просторовою структурою та спектральним збереженням, але все ще демонструють просторове розмиття.

Синтезоване зображення на основі запропонованого методу із використанням згорткової нейронної мережі демонструє високу інформативність, чіткість та деталізацію без помітного розмиття або просторових спотворень.



Рисунок 3.5 – Порівняння різних методів злиття

### 3.2 Неймережева сегментація для картографування земного покриву

Точне та своєчасне володіння інформацією про сільськогосподарські землі, зокрема за допомогою створення карт земного покриву, є надзвичайно важливим для розвитку точного землеробства та сільського господарства. Визначення площі та територіальне розміщення посівів є важливим для отримання необхідної аграрної інформації [17]. Традиційні методи сегментації земного покриву за допомогою польових вимірювань, досліджень та статистичних аналізів потребують значних людських та фінансових

ресурсів [18]. Завдяки стрімкому розвитку технологій ДЗЗ, зокрема підвищенню просторової та часової роздільної здатності зображень, багатоспектральні дані дистанційного зондування стали широко застосовуватися в аграрних дослідженнях [19]. Багатоспектральні дані відіграють важливу роль під час моніторингу стану посівів, оцінці врожайності сільськогосподарських культур та моніторингу шкідників [20], [21]. Однак, незважаючи на значний прогрес у космічних технологіях та збільшенні кількості сенсорів супутників спостереження Землі, створення детальних карт ґрунтового покриву залишається складним, трудомістким та тривалим процесом [22]. Карти земного покриву зазвичай мають обмежену часову роздільну здатність, що ускладнює постійний моніторинг змін. Наприклад, продукти наземного покриву EU Corine [23] доступні лише для певних років, а останні продукти Європейського космічного агентства (ESA) WorldCover [24] охоплюють лише 2020 та 2021 роки. Отже, існує необхідність у створенні машинних моделей, які можуть точно створювати карти земного покриву на основі супутникових даних, що дозволить покращити моніторинг змін та управління сільськогосподарськими ресурсами.

Традиційні методи сегментації поділяються на два основні типи: некерована та керована класифікація [25]. Прикладом некерованої класифікації є методи, такі як К-середнє (K-means) та максимізація очікуваного значення (Expectation Maximization), які дозволяють створювати категорії для обробки даних, однак атрибути результатів класифікації залишаються невизначеними. Алгоритм IsoData, який є вдосконаленою версією K-means, дозволяє адаптивно змінювати кількість кластерів під час ітераційного процесу класифікації.

До методів керованої класифікації відносяться метод опорних векторів (SVM), дерева рішень, класифікація за максимальною правдоподібністю (Maximum Likelihood), метод мінімальної відстані (Minimum Distance) і паралелепіпедний метод (Parallelepiped). У цих методах параметри дискримінантної функції визначаються на основі відомих даних щодо елементів зображення. Після цього дискримінантна функція застосовується для

класифікації невідомих елементів зображення, що забезпечує точність класифікації на основі навчальних даних.

Традиційні методи сегментації відзначаються високою повторюваністю та оперативністю порівняно з візуальною інтерпретацією даних. Але їх точність значно знижується під час зміни даних або області дослідження [26].

На відміну від класичних алгоритмів машинного навчання, глибинне навчання (ГН) демонструє унікальні переваги в класифікації зображень. Тоді як традиційні алгоритми машинного навчання вимагають ручної розробки ознак для завдань класифікації, глибинне навчання усуває необхідність у цьому. Алгоритми на основі ГН автоматично навчаються і вилучають ознаки, що мають відношення до цільового завдання. Ця властивість автоматичного вилучення ознак забезпечує високу надійність моделей глибинного навчання та спрощує їх адаптацію до різних наборів даних [27]. Крім того, алгоритми глибинного навчання можуть обробляти великі масиви даних, виявляючи потенційні шаблони та закономірності, що сприяє підвищенню точності та ефективності класифікації земного покриття. Але незважаючи на переваги, які надає глибинне навчання, класифікація зображень у галузі дистанційного зондування сільськогосподарських територій часто обмежується через відсутність надійно маркованих наборів даних.

Один із найбільш досліджених і широко використовуваних наборів даних для класифікації зображень дистанційного зондування – це набір землекористування UC Merced (UCM), наведений у роботі [28]. Набір даних містить 21 клас землекористування та земного покриття зі 100 зображеннями для кожного класу розміром 256x256 пікселів із просторовою роздільною здатністю близько 30 см на піксель. Всі зображення мають колірний простір RGB і були отримані з колекції знімків міських територій Національної карти США, отриманих із літальних апаратів. Проте невелика кількість зображень на клас є значним обмеженням під час використання цього набору даних у задачах класифікації.

Для покращення ситуації з набором даних різні дослідження використовували комерційні зображення Google Earth для створення нових наборів даних [29]. Наприклад, набори даних PatternNet [30] і NWPU-RESISC45 [31] базуються на зображеннях із високою роздільною здатністю до 30 см на піксель. Однак, через складність і трудомісткість процесу створення маркованих наборів даних, ці набори даних також мають обмежену кількість зображень на клас, що варіюється від кількох сотень до кількох тисяч.

Одним із найбільших доступних наборів даних є набір аерофотознімків (Aerial Image Dataset, AID), який включає 30 класів, кожен із яких містить від 200 до 400 зображень розміром 600x600 пікселів, отриманих з Google Earth. Незважаючи на розширене покриття класів, використання комерційних і попередньо оброблених зображень обмежує їхню придатність для реальних програм спостереження Землі, таких як Sentinel-2.

Також набір даних SAT-6, наведений у джерелі [32], базується на аерофотознімках із просторовою роздільною здатністю 1 метр на піксель. Набір даних SAT-6 отримано зі зображень Національної програми сільськогосподарських знімків (NAIP) і містить у собі 6 класів: неродючі землі, дерева, луки, дороги, будівлі та водні об'єкти. Патчі зображень мають розмір 28x28 пікселів і представлені в червоному, зеленому, синьому та ближньому інфрачервоному діапазонах.

Порівняно з наборами даних, згаданими вище, розроблено новий набір даних, який використовує супутникові зображення з роздільною здатністю 10 метрів на піксель, що робить його більш відповідним для реальних програм спостереження Землі. Застосований у цьому дослідженні набір даних базується на знімках супутника Sentinel-2, що дозволяє включати значно більшу площу покриття. Тому запропоновано розробити геоінформаційний метод виділення множинних ознак із супутникових знімків Sentinel-2 та їх використання для сегментації земного покриття за допомогою нейронної мережі ResNet. Це дозволить підвищити точність та деталізацію класифікації різних типів земного покриття, таких як сільськогосподарські культури, дерева, об'єкти забудови та

дороги, що, в свою чергу, сприяє поліпшенню моніторингу та управління земельними ресурсами.

У рамках дослідження виконано такі етапи: попередня обробка даних, вилучення спектральних, морфологічних і текстурних ознак зі супутникових знімків, навчання глибокої нейронної мережі ResNet і сегментація зображень земного покриву. Алгоритм, що ілюструє роботу запропонованої геоінформаційної технології, яка реалізує розроблений метод, наведено на рисунку 3.6.

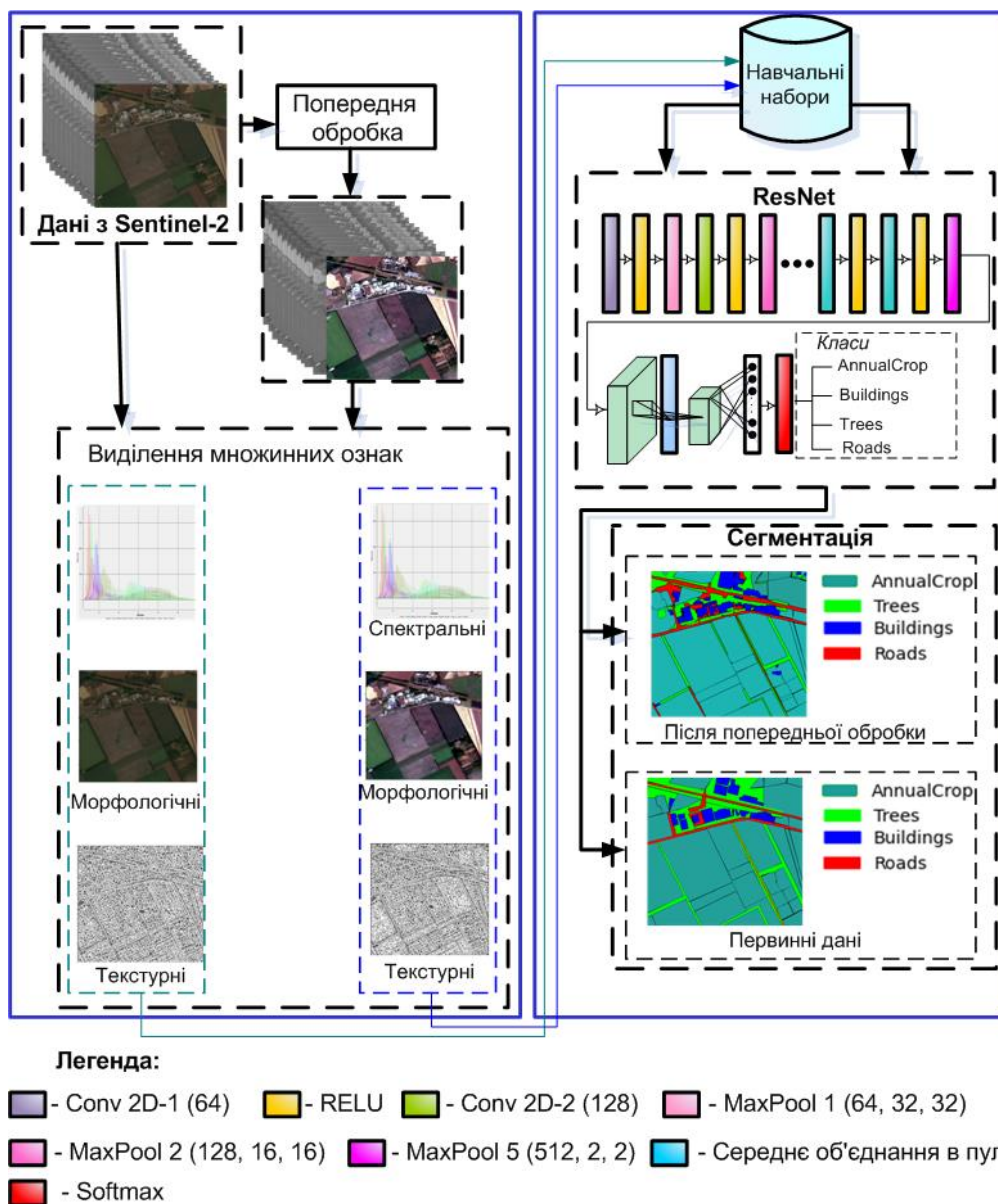


Рисунок 3.6 – Схема нейромережевої сегментації для картографування земного покриву

Знімки Sentinel-2 з 12 каналами після завантаження проходять етап попередньої обробки, який містить у собі атмосферну корекцію, геометричне та радіометричне калібрування [33]. Після цього дані приводяться до однакового масштабу для підвищення стабільності навчання нейронної мережі.

Наступним етапом є виділення множинних ознак: спектральних (містять інформацію про різні типи земного покриття), морфологічних (дозволяють виділяти структури та форми об'єктів на зображенні) та текстурних (дозволяють визначати характеристики поверхні земного покриття), які слугують вхідними даними для подальшої обробки за допомогою нейронної мережі. Це дозволяє моделі навчатися різноманітним зразкам, характерним для різних типів земного покриття. Ці етапи обробки виконуються як для попередньо оброблених, так і для первинних даних Sentinel-2.

Для навчання моделі підготовлено навчальні вибірки первинних даних супутника Sentinel-2 Дніпропетровщини до та після попередньої обробки. Вибірка містила класи: AnnualCrop (сільськогосподарські угіддя), Trees (дерева), Buildings (об'єкти забудови) та Roads (дороги). Кожне зображення мало розмір 64x64 пікселів, що дозволило забезпечити високу деталізацію та точність моделі.

Під час навчання виділено спектральні, морфологічні та текстурні ознаки, які подаються на вхід ResNet. Ця глибока нейронна мережа використовує послідовність конволюційних шарів для автоматичного виділення високорівневих ознак із вхідних зображень [34]:

$$Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1,j+n-1} \cdot k_{m,n}, \quad (3.9)$$

де  $x$  – вхідне зображення,  $k$  – ядро конволюції,  $y$  – вихідне зображення.

Функція активації ReLU:

$$f(x) = \max(0, x). \quad (3.10)$$

На етапі класифікації виділені ознаки подаються на вхід повнозв'язного шару нейронної мережі. Повнозв'язний шар (fully connected layer) здійснює кінцеву класифікацію на основі отриманих ознак, що дозволяє визначити належність кожного пікселя до одного з чотирьох класів: сільськогосподарські угіддя (AnnualCrop), будівлі (Buildings), дерева (Trees) та дороги (Roads). Функція втрат для класифікації (Softmax та Cross-Entropy) є такою [34]:

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}, \quad (3.11)$$

$$\text{Cross-EntropyLoss} = -\sum_{i \in C} y_i \log(\hat{y}_i), \quad (3.12)$$

де  $y_i$  – істинна ймовірність класу,  $\hat{y}_i$  – передбачена ймовірність класу;  $C$  – множина всіх класів.

Адаптивне середнє об'єднання реалізується за формулою [34]:

$$y_{i,j} = \frac{1}{|R|} \sum_{(m,n) \in R} x_{m,n}, \quad (3.13)$$

де  $y_{i,j}$  – значення пікселя у вихідному зображенні після об'єднання,  $R$  – область усереднення, тобто область вхідного зображення, значення пікселів якої усереднюються;  $|R|$  – кількість елементів (пікселів) в області  $R$ ;  $x_{m,n}$  – значення пікселя у вхідному зображенні.

Модель навчається на підготовлених вибірках, оптимізуючи параметри за допомогою зворотного поширення помилки. Це дозволяє моделі адаптуватися до різноманітних варіацій у даних та забезпечувати точну класифікацію типів земного покриття.

На основі результатів класифікації створюється сегментоване зображення, де кожному пікселю присвоюється клас. Це дозволяє візуально

відобразити результати аналізу супутникових даних та забезпечити точну сегментацію земного покриття.

У цьому дослідженні використано супутникові знімки Sentinel-2 Дніпропетровщини (рис. 3.7).



а) первинний

б) після попередньої обробки

Рисунок 3.7 – Супутникові знімки космічного апарату Sentinel-2 синтезовані у RGB канали

На рисунку 3.8 наведено результати сегментації земного покриття, отримані за допомогою розробленого методу. За результатами візуального аналізу можна зробити висновок, що класифікація земного покриття після попередньої обробки знімка та застосування нейронної мережі ResNet є значно чіткішою та точнішою в порівнянні з класифікацією на первинних даних супутникових знімків Sentinel-2.

У цьому дослідженні проведено порівняння різних методів сегментації, включаючи IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood, Parallelepiped і запропонований метод на основі нейронної мережі. На рисунку 3.9 наведено результат сегментації класичними методами (IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood, Parallelepiped) та запропонованим методом на основі нейронної мережі ResNet.

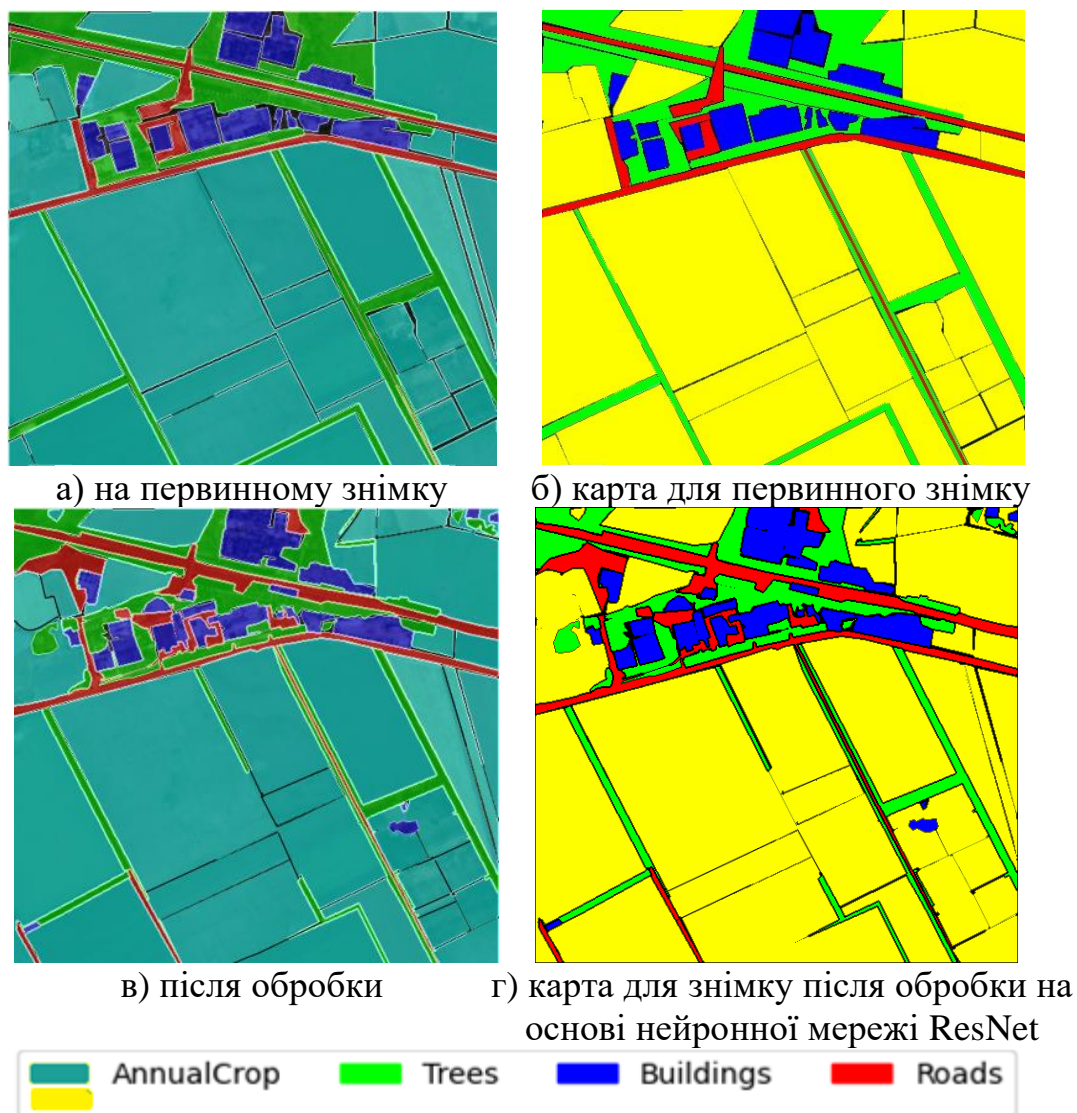


Рисунок 3.8 – Сегментація земного покриву для Sentinel-2

За результатами візуального аналізу метод IsoData (рис. 3.9,а) показує здатність розпізнавати основні ділянки з культурами та деревами. Але значні труднощі виникають під час сегментації будівель та доріг, що призводить до змішування класів та знижує загальну точність методу. Метод K-means (рис. 3.9,б) демонструє дещо вищу точність порівняно з IsoData. Культури та дерева класифікуються успішніше, але проблеми з розрізненням будівель та доріг все ще залишаються. Деякі області будівель і доріг змішані з іншими класами, що впливає на точність сегментації. Метод SVM (рис. 3.9,в) демонструє вищу точність сегментації культур та дерев в порівнянні з IsoData та K-means. Метод Minimum-Distance (рис. 3.9,г) демонструє нижчу точність

порівняно з методами IsoData, K-means та SVM. Великі області пікселів були помилково класифіковані, особливо у класі доріг, що робить цей метод менш ефективним для задач сегментації. Метод Maximum Likelihood (рис. 3.9,г) показує кращі результати, ніж Minimum Distance, але все ще виникають значні проблеми з сегментацією доріг. Культури та дерева класифікуються успішно, а будівлі – з певними труднощами. Метод Parallelepiped (рис. 3.9,д) стикається зі значними труднощами під час класифікації всіх класів. Велика частина пікселів була помилково класифікована, що знижує загальну ефективність методу. Запропонований метод на основі нейронної мережі ResNet (рис. 3.8,з) демонструє кращі результати порівняно з класичними підходами. Такі класи, як дерева, дороги, будівлі та культури, були чітко ідентифіковані, що свідчить про ефективність методів сегментації для супутникових знімків Sentinel-2.

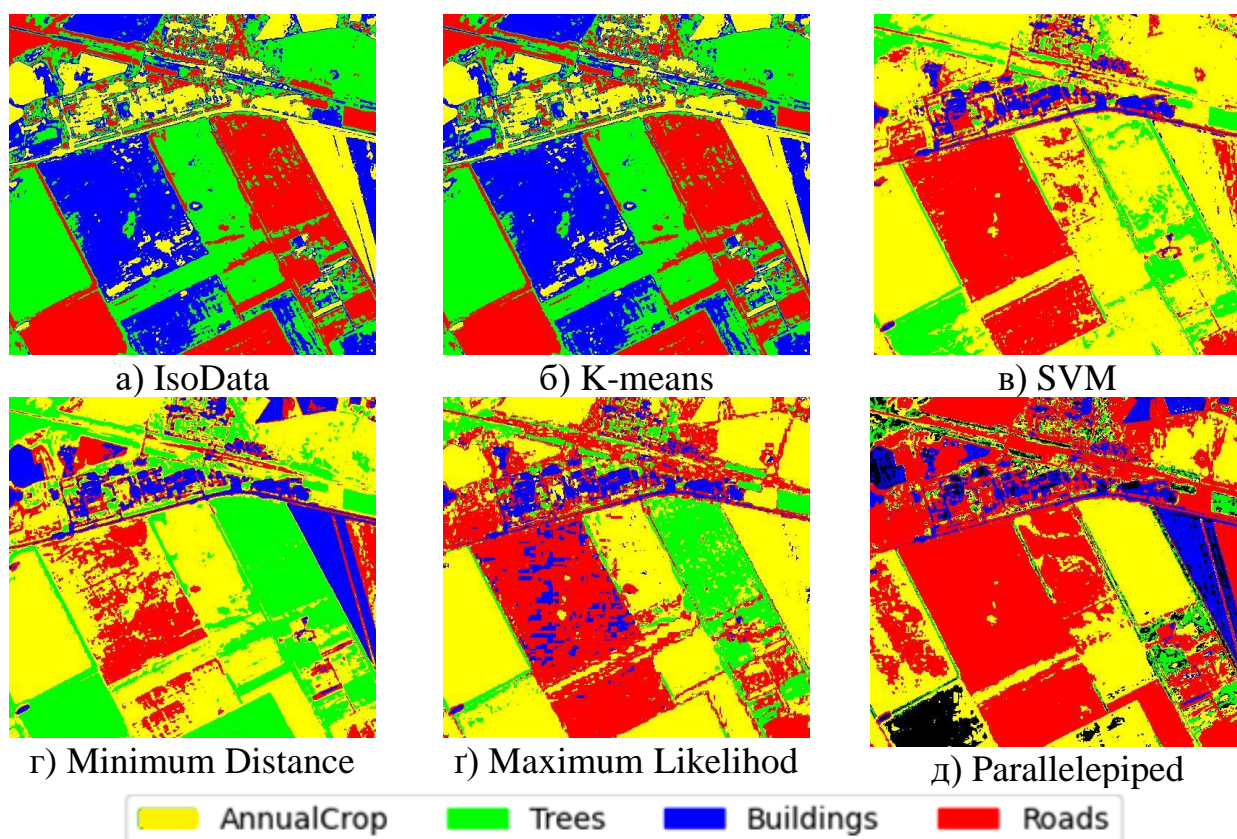



Рисунок 3.9 – Сегментація земного покриття для Sentinel-2

На рисунку 3.10 наведено графіки динаміки зміни втрат (Loss) та точності (Accuracy) для тренувального і тестового наборів даних протягом 30 епох

навчання нейронної мережі. Значне зниження втрат під час навчання (рис. 3.10,*а*) спостерігається вже на перших епохах. Починаючи з показника 0,5 на початку, втрати швидко зменшуються до приблизно 0,15 вже на п'ятій епосі. Потім зниження продовжується повільнішими темпами, досягаючи 0,008 до кінця тридцятій епохи. Це свідчить про те, що модель добре навчається на навчальних даних. Точність під час навчання (рис. 3.10,*б*) значно збільшується з 88 % до приблизно 94 % вже на перших епохах. Потім зростання продовжується більш поступово, досягаючи близько 99,9% до кінця тридцятій епохи. Це демонструє, що модель успішно навчається на навчальних даних і здатна досягти високої точності.



а) втрати (loss)

б) точність (accuracy)

Рисунок 3.10 – Графік динаміки зміни втрат та точності

Для кількісного аналізу побудовано матрицю невідповідностей (confusion matrix), яка дозволила оцінити точність класифікації пікселів за чотирма класами: AnnualCrop, Trees, Buildings, і Roads (рис. 3.11). Матриця невідповідностей дозволяє детально оцінити точність сегментації різними методами. Для методу IsoData (рис. 3.11,*а*) спостерігаються значні помилки під час класифікації доріг (Roads), де більшість пікселів були неправильно класифіковані як AnnualCrop. Це свідчить про низьку точність для класу доріг (Roads). Метод K-means (рис. 3.11,*б*) також показав помилки під час

класифікації доріг, але краща точність у порівнянні з методом IsoData. Метод SVM (рис. 11,в) має найбільше помилок під час класифікації доріг, але суттєво менше помилок для інших класів в порівнянні з методами K-means та IsoData. Метод Minimum Distance (рис. 3.11,г) показав вищу точність під час класифікації будівель (Buildings) і дерев (Trees), але все ще мав значні помилки під час класифікації доріг.

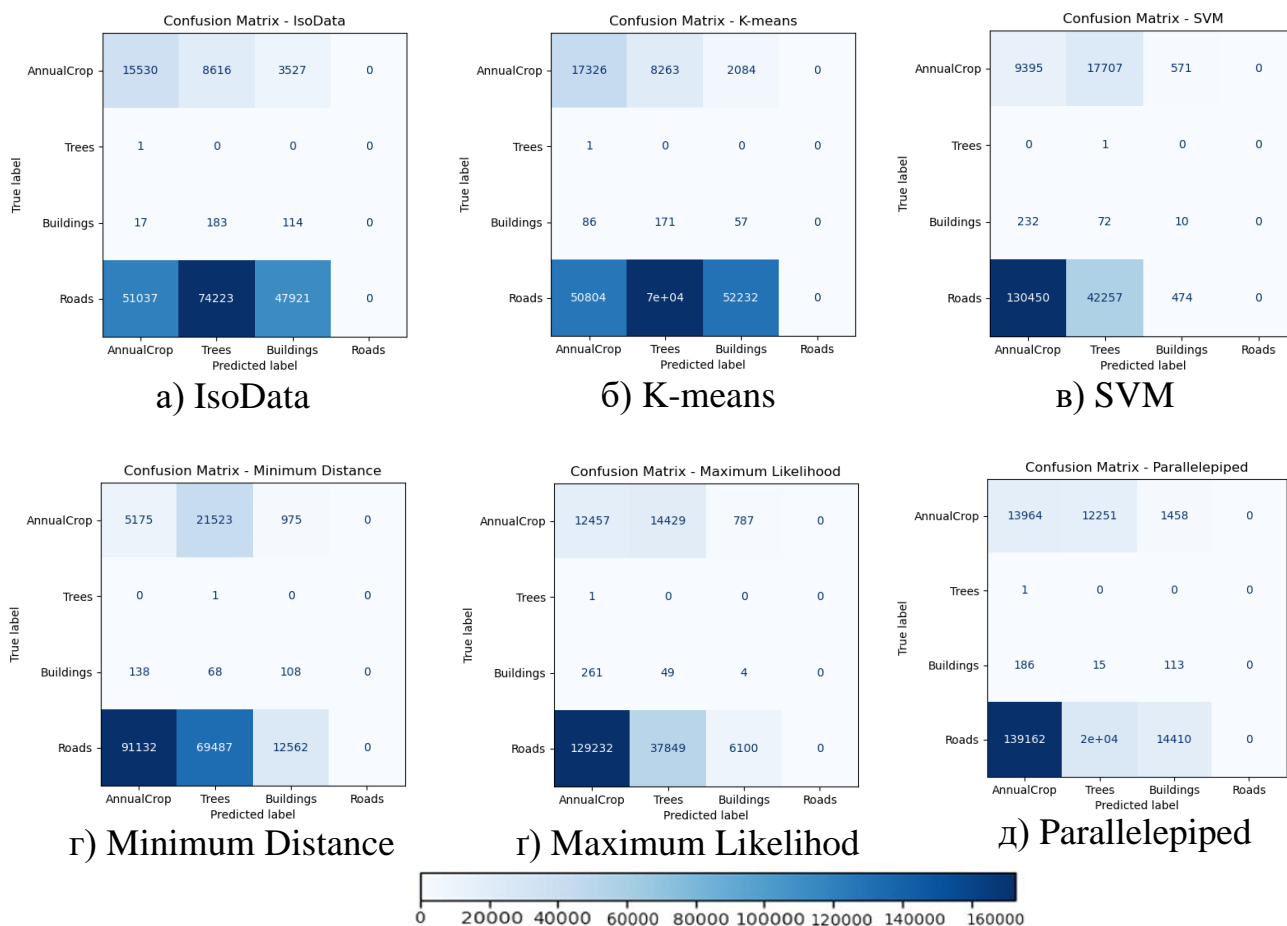



Рисунок 3.11 – Матриця невідповідностей

Для методу Maximum Likelihood (рис. 3.11, г) спостерігається вища точність під час класифікації доріг у порівнянні з методами IsoData, K-means, SVM та Minimum Distance, але все ще залишається значна кількість помилок під час класифікації інших класів. Метод Parallelepiped (рис. 3.11,д) показує найгірші результати серед класичних методів, з найбільшими помилками для всіх класів, зокрема для доріг. Запропонована технологія на основі нейронної

мережі (рис. 3.12,*a*) продемонструвала найкращі результати з мінімальними помилками для всіх класів. Всі пікселі були правильно класифіковані, що вказує на високу точність технології.



а) матриця невідповідностей

б) матриця помилок

Рисунок 3.12 – Кількісні показники запропонованої технології

Аналіз матриць помилок дозволяє виявити, які класи були неправильно класифіковані (рис. 3.13). Метод IsoData (рис. 3.13,*a*) показав значні помилки, зокрема для класу доріг, які були неправильно класифіковані як AnnualCrop. Метод K-means (рис. 3.13,*б*) демонструє помилки, схожі на ті, що спостерігаються у методі IsoData, але з дещо покращеною точністю: кількість помилок для класифікації доріг. Метод SVM (рис. 3.13,*в*) характеризується найбільшою кількістю помилок для класу доріг, але значно покращив точність для інших класів. Метод Minimum Distance (рис. 3.13,*г*) демонструє кращі результати під час класифікації будівель і дерев, але зберігаються значні помилки для класу доріг. Метод Maximum Likelihood (рис. 3.13,*д*) має кращі результати під час класифікації доріг порівняно з іншими методами, але все ще спостерігається значна кількість помилок, зокрема для класу дерев (Trees). Метод Parallelepiped (рис. 3.13,*е*) відзначився найбільшими помилками серед усіх методів, зокрема при класифікації доріг.

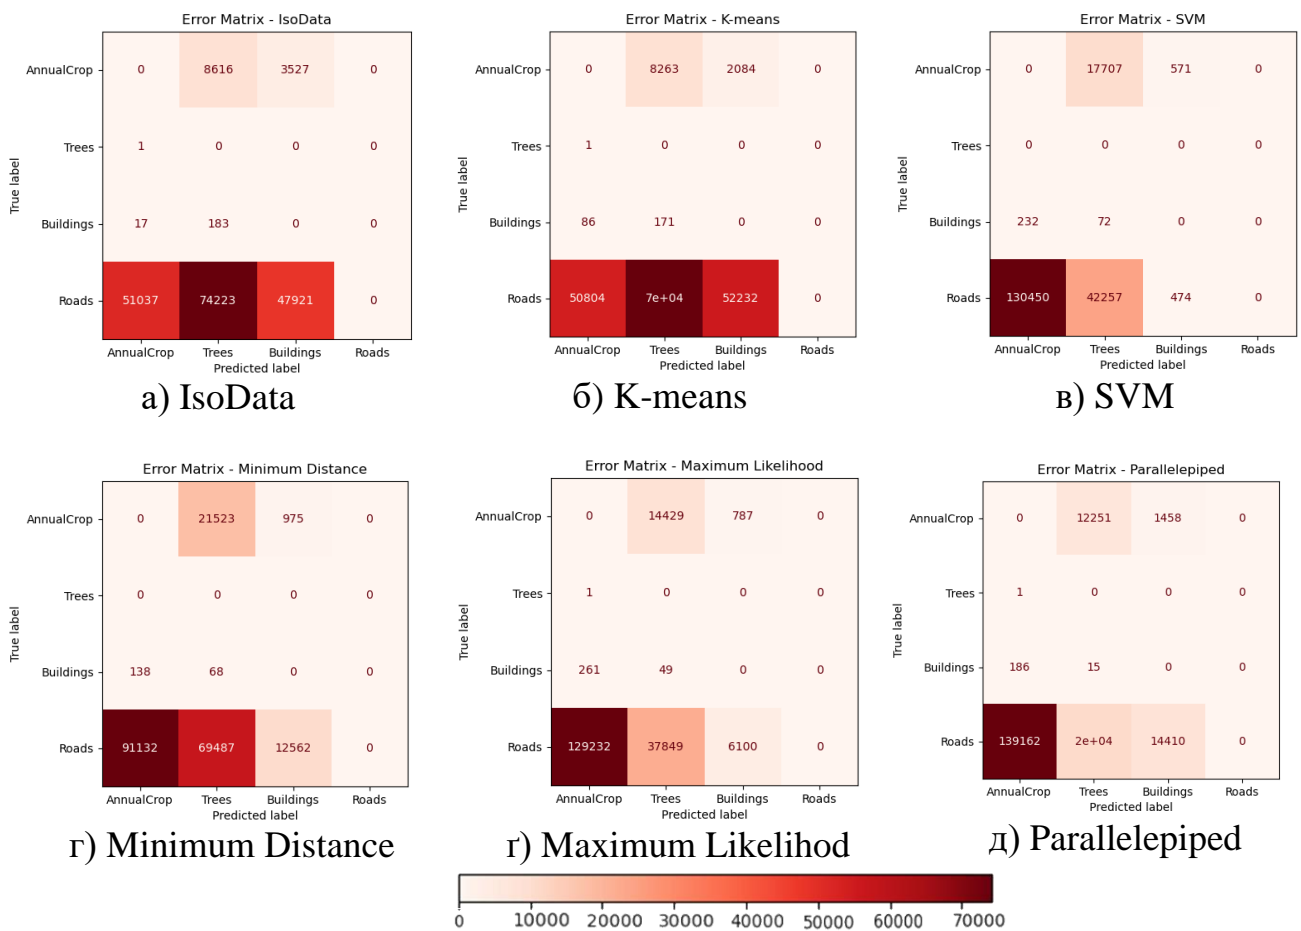


Рисунок 3.13 – Матриця помилок

Запропонована нейромережева сегментація для картографування земного покриву (рис. 3.12,б) продемонструвала найкращі результати з мінімальними помилками для всіх класів. Це вказує на високу точність і ефективність у порівнянні з класичними методами.

### 3.3 Синергетична обробка багатоспектральних Sentinel-зображень із використанням згорткових нейронних мереж для підвищення точності виділення меж сільськогосподарських полів

Сьогодні значна кількість актуальних світових проблем прямо чи опосередковано пов'язана з сільськогосподарським виробництвом [35] та малим фермерством. Аграрний сектор України є джерелом експорту до країн Америки, Європейського Союзу та Азії. Інтенсивний розвиток цього сектору

сприяє економічному зростанню та зміцненню міжнародних економічних відносин. Дослідження показують, що Україна значно випереджає країни зі схожими кліматичними умовами щодо експорту та прибутковості. Наприклад, у 2023 році Україна експортувала 16,1 млн тонн пшениці до 65 країн, 26,2 млн тонн кукурудзи до 80 країн та 5,7 млн тонн соняшникової олії до 130 країн. Оскільки населення зростає та раціон харчування змінюється, нарощування сільськогосподарського виробництва має вирішальне значення для забезпечення глобальної продовольчої безпеки [36], [37]. Дестабілізуючі фактори різної природи впливають на стабільність сільськогосподарського сектору, ставлячи під сумнів традиційні методи моніторингу через високі фінансові витрати та ризики для працівників. Отже, необхідно проводити надійний і точний сільськогосподарський моніторинг для підтримки балансу всіх послуг, що надаються цією екосистемою [38], [39].

Завдяки сучасним технологіям, таким як супутникове спостереження Землі та технології хмарних обчислень, відкриваються нові можливості під час сільськогосподарського моніторингу. Ці інструменти дають змогу надавати детальну інформацію щодо посівів на національному рівні в системах землеробства. Наприклад, Європейське космічне агентство (ESA) в рамках програми Copernicus надає безкоштовні та відкриті дані зі супутників Sentinel-1 і Sentinel-2, що дозволяє отримати детальну інформацію про стан сільськогосподарських угідь. Радіометрична роздільна здатність цих супутників дозволяє розпізнавати різні типи сільськогосподарських культур шляхом вимірювання відбивної здатності на різних довжинах хвиль, включаючи видимий, ближній та середній інфрачервоний діапазони. Часова роздільна здатність необхідна для моніторингу динамічних процесів, таких як зміна вегетаційного періоду сільськогосподарських культур, що дозволяє оцінювати фази росту і розвитку рослин.

Оптичні зображення Sentinel-2 складаються з 13 спектральних каналів у видимому, ближньому інфрачервоному (NIR) та короткохвильовому інфрачервоному (SWIR) діапазонах. Просторова роздільна здатність цих

зображень включає смуги 10 м, 20 м і 60 м. Смуги роздільної здатності 10 м (Band 2, Band 3, Band 4 і Band 8) є оптимальними для детального аналізу та картографування. Для порівняння, 20-метрові (Band 5, Band 6, Band 7, Band 8a, Band 11 і Band 12) і 60-метрові (Band 1, Band 9 і Band 10) містять важливу спектральну інформацію, необхідну для оцінки стану рослинності сільськогосподарських угідь, визначення вмісту хлорофілу, водного стресу та атмосферної корекції.

Сільське господарство потребує точних просторових даних для ефективного управління. Супутникові знімки з космічного апарату Sentinel-2 зазвичай не відповідають цим вимогам через низьку роздільну здатність пікселів. Діапазони 20 м і 60 м не забезпечують достатньої деталізації для ідентифікації полів, меж посівів та інших сільськогосподарських об'єктів. Це створює труднощі під час картографування, моніторингу та управління сільськогосподарськими землями.

Значна частина даних дистанційного зондування знаходиться в цифровому вигляді. Це піднімає питання вибору оптимальних методів та алгоритмів комп'ютерної обробки супутникових даних. Значні труднощі можуть виникнути на етапі попередньої обробки, оскільки часто не існує універсальних підходів до покращення первинного зображення. Крім того, одна і та ж ділянка землі може бути отримана з космосу в різні періоди з використанням різних сенсорів, спектральних діапазонів і роздільної здатності. Для успішного аналізу даних необхідно їх об'єднати та обробити, що вимагає точного координатного вирівнювання знімків на субпіксельному рівні. Більшість традиційних алгоритмів попередньої та тематичної обробки супутникових знімків, таких як ітераційні методи реєстрової корекції або складні алгоритми фільтрації, передбачають численні математичні операції, в тому числі багатоетапні перетворення та трансформації. Ці алгоритми є ресурсоємними під час швидкої обробки великих обсягів даних, а також не завжди забезпечують необхідну точність через помилки, пов'язані з реальними змінними характеристиками знімків, такими як різні умови освітлення або

атмосферні перешкоди.

Одним із широко використовуваних методів попередньої обробки є панорамування. Цей метод поєднує зображення з різною просторовою роздільною здатністю для створення нового зображення з підвищеною деталізацією. Паншарпінг використовує супутникові знімки (наприклад, Worldview і Landsat), які містять панхроматичний канал із високою роздільною здатністю і мультиспектральні канали з нижчою просторовою роздільною здатністю. Однак, у випадку супутників Sentinel-2 відсутність панхроматичного каналу ускладнює безпосереднє застосування традиційних методів паншарпінгу. Отже, для досягнення високої точності виділення та аналізу сільськогосподарських угідь на основі даних Sentinel-2 існує потреба в розробці альтернативних підходів до збільшення просторової роздільної здатності каналів з 20 м та 60 м до 10 м [40].

Методи обробки супутникових знімків поділяються на дві основні категорії: попередня обробка та тематична обробка. Попередня обробка охоплює покращення, корекцію та реставрацію зображень. Тематична обробка зосереджена на вилученні інформації із зображень. Методи попередньої обробки спрямовані на перетворення зображень для полегшення візуального аналізу, підвищення інформативності та точності даних, а також на підготовку зразків для подальшого автоматизованого аналізу та створення карт. Методи тематичної обробки використовують автоматизований аналіз зображень для класифікації об'єктів на знімках, як з апріорною інформацією про характеристики класів, що ідентифікуються, так і без неї.

Підвищення просторової здатності зображення є основним етапом попередньої обробки. Основними підходами до злиття зображень є компонентна заміна (CS), аналіз з множинною роздільною здатністю (MRA) [41] та панорамне наведення різкості. У підході CS вихідне багатоспектральне зображення перетворюється на нову область шляхом заміни одного з компонентів на смугу з тонкою просторовою роздільною здатністю, наприклад, панхроматичну (PAN) смугу. Поширеними прикладами CS є аналіз головних

компонент [42], інтенсивність-відтінок-насиченість (IHS) [43], перетворення Бровея (BT), перетворення Грама-Шмідта (GS) [44], адаптивне GS (GSA) та адаптивна заміна компонент з частковою заміною (PRACS).

Просторова здатність вводиться в підході MRA шляхом багаторазового розкладання тонкої смуги. Він включає фільтрацію високих частот (ФВЧ), згладжуючу фільтрацію на основі модуляції інтенсивності (SFIM), вейвлет-перетворення [45], адитивне вейвлет-перетворення (ATWT) [46], ATWT з використанням моделі 2 (ATWTM2) і моделі 3 (ATWT-M3), а також узагальнену піраміду Лапласа з фільтром, узгодженим з передавальною функцією модуляції (MTF-GLP).

Просторова здатність знімків Sentinel-2 підвищується за рахунок синтезу 10-метрового діапазону як панхроматичного каналу для покращення просторової роздільної здатності 20-метрового діапазону [47]. Отримані результати використовуються для класифікації земного покриву [48]. Однак, враховуючи особливості знімків Sentinel-2, чотири смуги високої роздільної здатності, що використовуються для підвищення роздільної здатності 20-метрового та 60-метрового діапазонів, не містять просторової інформації, яка характерна для панхроматичного каналу. Спектральний діапазон смуг високої роздільної здатності не повинен перекриватися з діапазонами смуг низької роздільної здатності. Саме тому використання методів паншарпінгу обмежується підвищенням інформативності знімків Sentinel-2.

Геостатистичні підходи, такі як кригінг-інтерполяція, підвищують інформативність за рахунок злиття зображень. Наприклад, методи кернелізованого зовнішнього дрейфу (KED), кернелізації з пониженням масштабу (DSCK) та кернелізації регресії за площею (ATPRK) мають значну перевагу в тому, що вони зберігають спектральні властивості спостережуваних необроблених зображень, тобто є когерентними. Разом з тим, ATPRK є обчислювально ефективнішим і зручнішим для користувача, ніж KED і DSCK.

Традиційні методи попередньої та тематичної обробки космічних знімків аналізують просторові, спектральні, текстурні, морфологічні та інші

характеристики. Однак аналітичні підходи поверхневого навчання, які використовують знімки з високою просторовою роздільною здатністю, але низькою спектральною та часовою роздільною здатністю, часто не можуть ефективно розрізняти класи землекористування через схожість спектральних сигнатур. Натомість глибоке навчання, яке є багаторівневим і використовує дані для навчання, працює значно краще, ніж поверхневі методи, і вже доведено, що воно перевершує результати, отримані вручну. У дослідженні [49] автори навчили глибоку залишкову нейронну мережу з високою роздільною здатністю на зображеннях Sentinel-2, використовуючи великий набір навчальних даних. Згорткові нейронні мережі (CNN), як форма глибокого навчання, можуть використовувати контекстну та спектральну інформацію для аналізу зображень [50].

Авторами науково-прикладного дослідження [51] розроблено розширену структуру згорткової нейронної мережі для об'єднання зображень Sentinel-2 і Landsat 8. Хоча методи глибокого навчання ефективно підвищують інформативність супутникових знімків, їх використання має певні обмеження. Наприклад, загальнодоступні супутникові знімки часто мають велику площу покриття та низьку просторову роздільну здатність, що не відповідає вимогам згорткових нейронних мереж.

У статті [52] авторами зазначається, що для покращення картографування рослинного покриву необхідна інтеграція технологій комп'ютерного зору з традиційними методами аналізу космічних знімків. У такому випадку основною дослідною задачею є розробка інтелектуальної технології обробки супутникових знімків Sentinel для картографування сільськогосподарських угідь із використанням згорткових нейронних мереж. Очікується, що такий підхід дозволить підвищити точність та деталізацію отриманих зображень, що має вирішальне значення для успішного використання даних Sentinel під час сільськогосподарського моніторингу.

Авторами запропоновано використовувати паралельну залишкову архітектуру на основі згорткових нейронних мереж для об'єднання та

підвищення інформативності зображень Sentinel-2. На рисунку 3.14 показано схему запропонованого методу.

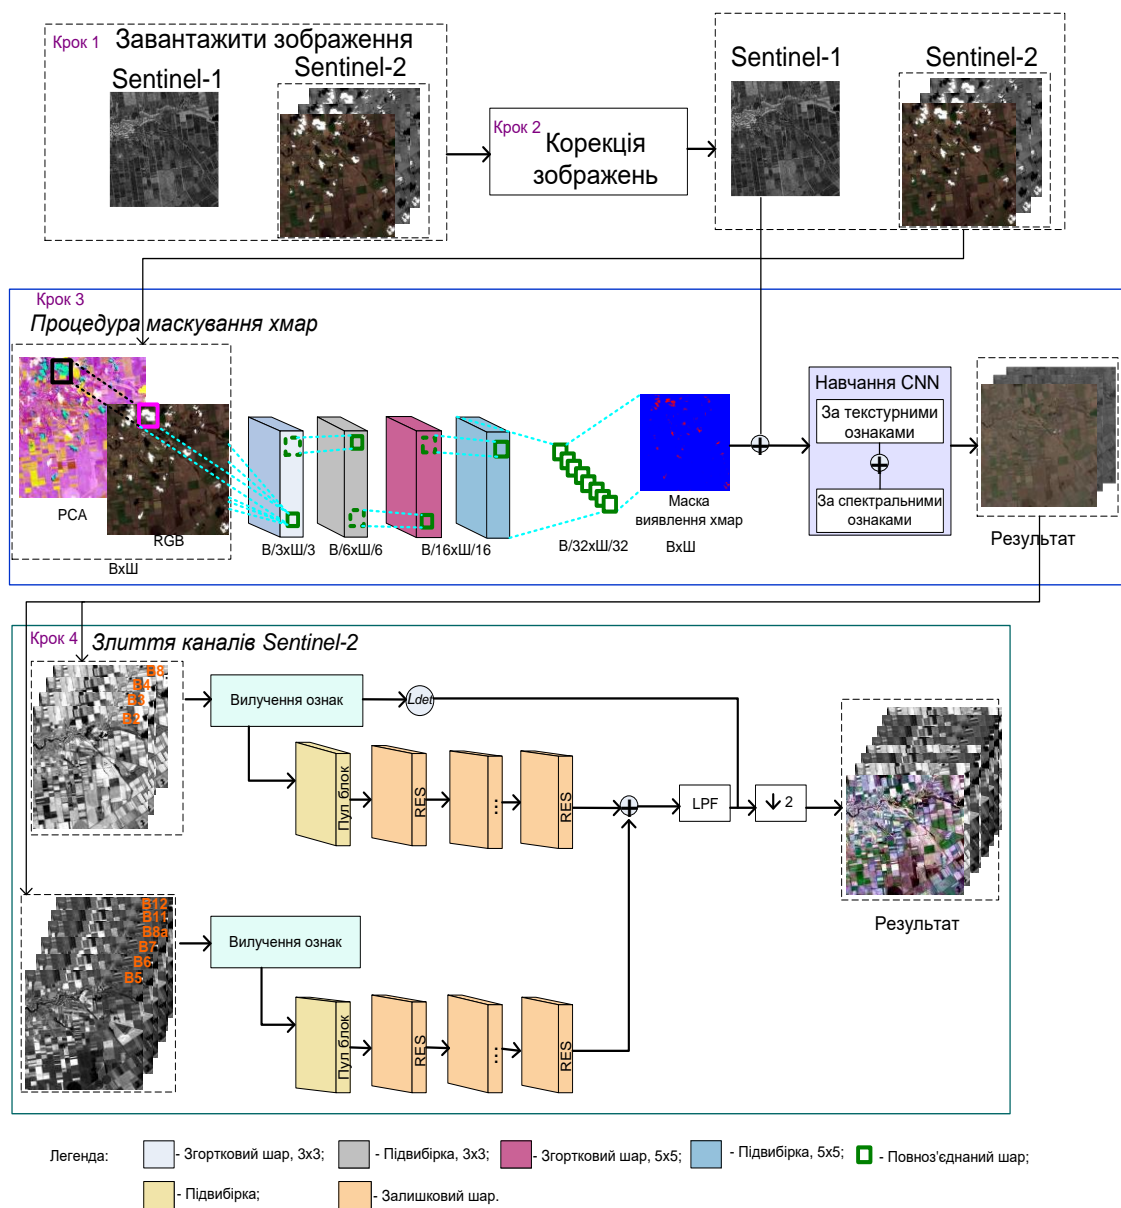


Рисунок 3.14 – Схема запропонованого методу

На першому етапі реалізується завантаження зображень космічних апаратів Sentinel-1 та Sentinel-2 з сайту Європейського космічного агентства [53]. На другому етапі виконується попередня обробка супутникових знімків. Геопросторові дані Sentinel-1 коригуються за алгоритмом, який детально описано в науковому джерелі [54]. Для оптичних знімків зі супутника Sentinel-2 цей етап включає наступні кроки: геометричну корекцію, радіометричне

калібрування та перетворення яскравості. Геометрична корекція покращує якість первинного зображення шляхом усунення різних артефактів, які виникають через кути нахилу камери, позиційні неточності, вплив рельєфу місцевості та атмосферні умови. Запропоновано використовувати метод біквадратичної інтерполяції для геометричної корекції зображення (ресемплінгу). Цей метод враховує кількість пікселів, що входять до оновлених значень, та використовує бібліотеку обробки зображень OpenCV мови програмування Python.

Після обробки зображення методом біквадратичної інтерполяції навколо кожного пікселя обчислюється нове значення на основі значень сусідніх пікселів. Це допомагає виправити геометричні спотворення і перетворити дані в географічні координати.

Радіометричне калібрування являє собою процес мінімізації різниці в значеннях яскравості між зображеннями, яка може виникнути через дефекти сенсора або атмосферний шум. Для радіометричної корекції супутникових знімків використовується метод вирівнювання гістограм за формулою [55]:

$$G(z) = \frac{L-1}{MN} \sum_{j=0}^z n_j, \quad (3.14)$$

де  $G(z)$  – нове значення інтенсивності для пікселів із вихідного зображення;  $z$  – значення інтенсивності пікселів;  $L$  – максимальне значення інтенсивності (зазвичай 256 для 8-бітного зображення);  $M$  та  $N$  – розміри зображення;  $n_j$  – кількість пікселів із вихідного зображення з інтенсивністю  $j$ .

Перетворення яскравості спрямоване на покращення візуального сприйняття первинного зображення (шляхом підвищення яскравості та контрастності). Первинне зображення зазвичай має обмежений діапазон відтінків (8-бітовий або 256-рівневий діапазон), який використовується лише частково, що може призводити до втрати деталей та розривів у відображенні. Гістограмне вирівнювання використовується для покращення контрастності

шляхом розподілу значень яскравості рівномірно по всьому діапазону. Розтягнення гістограми також використовується для збереження деталей та покращення контрастності зображення.

На третьому етапі процедури корекції отримуємо радіометрично і геометрично скориговані супутникові зображення в картографічній системі координат (або проєкції).

Четвертим етапом є виконання процедури маскування та видалення хмар, артефактів, що можуть вплинути на точність аналізу. В процедурі маскування хмар використовується архітектура згорткової нейронної мережі (CNN), яка складається з шарів нейронів, розташованих у тривимірному просторі: ширина, висота та глибина. Це дозволяє забезпечити ефективну обробку багатоканальних даних. Нейрони в шарах з'єднані лише з невеликою областю вхідного зображення перед тим, як вони пройдуть через процес згортки, що дозволяє значно зменшити кількість параметрів і ваг, які потрібно навчити. Одним із відмінних аспектів CNN є їх здатність визначати найбільш відповідні фільтри в процесі навчання. Це дозволяє виділяти ознаки на різних рівнях складності зображень. Кожен шар згортки виокремлює ознаки зростаючої складності, діючи як набір фільтрів для виокремлення хмар та тіней. Операції в CNN архітектурі виконуються як у просторовій, так і у спектральній областях. Згорткові шари зберігають просторовий зв'язок між пікселями, що дозволяє вивчити особливості зображення, тоді як шари об'єднання (субдискретизація) зменшують розмірність кожної карти ознак, при цьому зберігаючи найважливішу інформацію про зображення. Процес згортки математично визначається таким чином [56]:

$$G_i = f(G_{i-1} \otimes W_i + b_i), \quad (3.15)$$

де  $W_i$  – вектор вагових коефіцієнтів  $i$ -го фільтра згортки; символ  $\otimes$  – операція згортки між  $i$ -м шаром зображення та  $i-1$ -м шаром;  $b_i$  – вектор зсуву; карта

ознак  $G_i$   $i$ -го шару отримується за допомогою лінійної активаційної функції  $f(\bullet)$ .

Операції об'єднання застосовують різноманітні методи агрегування даних, такі як максимум, середнє або сума. Кількість різних операцій згортки та об'єднання визначається кількістю фільтрів, які застосовуються в кожному шарі. На цьому етапі використовуються багатоканальні зображення (у форматі RGB) патчів, а також дані після PCA-перетворення з набору даних Sentinel-2. Архітектура має чотири приховані шари (з розмірами ядер 3x3, 3x3, 5x5 та 5x5) та кінцевий шар із двома виходами, які відповідають класам «безхмарний» та «хмарний».

Запропонований алгоритм комплексно використовує інформацію щодо вмісту, текстури та спектральної інформації в кожному вимірі для побудови адаптивної зваженої тензорної регуляризаційної моделі низького рангу для відновлення хмарних ділянок. Ця модель містить у собі мережу відновлення об'єктів, яка відновлює відсутні об'єкти на зображенні, мережу відновлення спектральних характеристик, яка відновлює спектральну інформацію про ці об'єкти, а також мережу відновлення текстур, яка допомагає покращити якість відновлення. Кожен шар згорткової мережі піддається активації за допомогою виправлених лінійних одиниць (ReLU) [57]:

$$ReLU(x) = \max(0, x). \quad (3.16)$$

Для відновлення хмарних ділянок використовується функція втрат, яка базується на порівнянні зображень, що містять хмари (Sentinel-2), з безхмарними зображеннями (Sentinel-1). В якості функції втрат використовується середньоквадратична похибка, яка обчислюється шляхом порівняння вихідних і прогнозованих значень інтенсивності пікселів на зображеннях. Формально, середньоквадратичну похибку визначають як середнє

значення квадратів різниць між інтенсивностями пікселів на відповідних позиціях двох зображень [58]:

$$L(X_1, Y_i) = \frac{1}{2N} \sum_{i=1}^N \|X_1 - Y_i\|_2^2, \quad (3.17)$$

де  $N$  – кількість додаткових даних;  $X_1$  – часовий знімок із областями, покритими хмарою;  $Y_i$  – додаткові дані, такі як спектральні або часові дані.

Для обчислення вихідної карти ознак  $GNN\_output$  з вхідними картами ознак  $G_{CNN\_1}$  і  $G_{CNN\_2}$ , які отримано відповідно від текстурної і спектральної  $CNN$ . Формула використовує функцію  $V$ , яка застосовується до вихідних карт, отриманих попередньою згортковою операцією:

$$GNN\_output = G_{CNN\_1} + V(C((G_{CNN\_1}, G_{CNN\_2}))), \quad (3.18)$$

де  $GNN\_output$  – це результат  $CNN$ , що містить дані про вміст-текстуру-спектральну характеристику;  $G_{CNN\_1}$  – карта ознак, створена за допомогою текстурної  $CNN$ ;  $G_{CNN\_2}$  – карта ознак, створена за допомогою спектральної  $CNN$ ;  $C(G_{CNN\_1}, G_{CNN\_2})$  – всі вхідні карти ознак, отримані шляхом конкатенації  $G_{CNN\_1}$  і  $G_{CNN\_2}$ ;  $V(G_{CNN\_1}, G_{CNN\_2})$  – це карта ознак, отримана за допомогою згорткової операції з ядром, яке використовує  $C(G_{CNN\_1}, G_{CNN\_2})$  як вхідні дані.

На п'ятому етапі запропоновано використовувати паралельну залишкову архітектуру на основі згорткових нейронних мереж для об'єднання та підвищення інформативності зображень Sentinel-2. Дані зображень Sentinel-2 поділено на два набори з роздільною здатністю – 10 метрів та 20 метрів. Кожен набір містить відповідні індекси каналів та спектральні характеристики, які наведено в таблиці 3.3. Канал 10 (Band 10) виключено з просторового підвищення через його низьку радіометричну якість та артефакти поперечної смуги [23]. Враховуючи ці набори, запропоноване підвищення просторової

здатності даних полягає у використанні каналів з роздільною здатністю 10 метрів у діапазонах 20 метрів. Важливо зазначити, що канали B5, B6 та B7 містять важливу інформацію для оцінки вологості ґрунту та прогнозування погодних умов для оптимізації сільськогосподарських процесів. Канал B8а використовується для вимірювання фотосинтетичної активності рослин, що є важливим показником для оцінки здоров'я та росту рослин. Канали B11 та B12 використовуються для вимірювання температурних змін на земельній поверхні, що дозволяє виявляти теплові аномалії та розробляти стратегії управління тепловими ресурсами. Таким чином, інформація, яка міститься у 20 метрових каналах, є важливою для агросектору, оскільки вона дозволяє здійснювати точний моніторинг та оцінку різних аспектів сільськогосподарського виробництва та управління земельними ресурсами.

Наступним етапом є застосування блока вилучення ознак, що має дві гілки: перша гілка містить блоки пулінгу (підвибірка) та залишковий шар (RES), а друга – деталізовані компоненти втрат ( $L_{det}$ ). Паралельно завантажуються додаткові 20-метрові канали зображень Sentinel-2, які також проходять через блок вилучення ознак. Потім дані з обох гілок об'єднуються і результат піддається низькочастотній фільтрації для зменшення шуму та видалення високочастотних компонент. Далі до отриманих даних додаються деталізовані компоненти втрат ( $L_{det}$ ), які були обчислені раніше. Після цього результат дискретизується для отримання остаточного підвищення інформативності зображення. Для об'єднання інформації різних діапазонів роздільної здатності пропонується компонент об'єднання просторових ознак. Після залишкового навчання отримані карти ознак об'єднуються для передачі на наступний рівень. Для повного поєднання інформації використовуються два повністю зв'язаних шари, кожен із яких супроводжується активацією ReLU. Згодом шар згортки використовується для перетворення карт ознак у просторове залишкове зображення з такими ж каналами, як і канали високої здатності [59]:

$$\begin{cases} z_{f1} = \text{ReLU}(w_{f1} \cdot z + b_{f1}) \\ z_{f2} = \text{ReLU}(w_{f2} \cdot z_{f1} + b_{f2}), \\ z_2 = w_{f3} \cdot z_{f2} + b_{f3} \end{cases} \quad (3.19)$$

де  $z$  – вихідні дані, отримані після попередньої операції згортки;  $z_{f1}$  – вихідні дані першого повністю зв’язаного шару (ПЗ);  $z_{f2}$  – вихідні дані другого шару;  $z_2$  – остаточний вихід;  $w_{f1}, w_{f2}, w_{f3}$  – ваги шарів ПЗ;  $b_{f1}, b_{f2}, b_{f3}$  – зсуви шарів ПЗ.

Таким чином, у формулі (3.19) змінна  $z$  позначає вихідні дані після попередньої операції згортки, яка застосовується до вхідного зображення. Після цієї операції отримані картки ознак подаються на перший повністю зв’язаний шар, позначений як  $z_{f1}$ .

Далі, використовуючи ваги  $w_{f1}$  та зсув  $b_{f1}$ , ці дані обробляються шляхом застосування активаційної функції ReLU.

Таблиця 3.3 – Характеристики каналів для наборів даних Sentinel-2

Роздільна здатність	10 м					20 м				
Канали	B2	B3	B4	B8	B5	B6	B7	B8A	B11	B12
Центр Довжина хвилі (нм)	490	560	665	842	705	740	783	865	1610	2190

При проведенні експерименту використано дані космічного апарата Sentinel-2 Level-1C. Навчальні дані охоплюють сцену села Велика Білозерка Запорізької області України (рис. 3.15) у весняний період 2023 року. У цей період фермери готують поля до посівної кампанії.

Дослідження показало, що в період від весни до літа хмарність на території села Велика Білозерка збільшується порівняно з іншими сезонами. Це обумовлено характерними метеорологічними умовами в цей період, такими як інтенсивніше розгортання циклонів та поширення вологості з Атлантичного океану через вплив весняних зрошувань. Така збільшена хмарність може вплинути на ефективність збору даних зі штучних супутників, зокрема знизити

якість зображень та ускладнити процес аналізу земельних даних. На рисунку 3.16 показано 10-метрові, 20-метрові канали даних.



Рисунок 3.15 – Місце розташування досліджуваної території

Для проведення експериментів було налаштовано ключові параметри запропонованої інформаційної технології таким чином: спочатку паралельну залишкову архітектуру згорткових нейронних мереж (ResNet)3x навчено на зменшених у 2 рази патчах розміром 60x60 пікселів даних. Аналогічно, для навчання паралельної залишкової мережі на основі ResNet5x дані зменшувалися в 5 разів і об'єднувались у патчі 20x20 пікселів.

Для кожної мережі використано 3600 пар зразків під час дослідного етапу навчання, при цьому 10 % із них використовуються під час вирішення завдання валідації даних. Кількість ResBlocks M становить 5 у кожній гілці, а для шарів згортки розміром 3x3 використано 128 фільтрів, за винятком останнього згорткового шару. Використані мережі реалізовано за допомогою фреймворку Keras.

На рисунку 3.17 показано як результати експериментальних налаштувань, так і результати, які отримано з використанням класичних методів обробки, що дозволяє порівняти їх вплив на інформативність зображень.






Рисунок 3.16 – Набір даних з Santinel-2, використаний в експериментах


Для порівняння ефективності запропонованого методу з існуючими (ATWT, AWLP, HPF, GS, HCS, LMM, Brovey, IHS, HPFC та LMVM) використано метрики якості, які отримано для кожного методу на основі зображень Santinel-2: RMSE (Root Mean Square Error), CC (Correlation Coefficient), ERGAS (Relative Global Error), SAM (Spectral Angle Mapper), UIQI (Universal Image Quality Index), SRE (Spectral Reconstruction Error), як показано в таблиці 3.4.




а) первинне зображення




б) запропонована технологія




в) ATWT




г) AWLP




г) Brovey




д) GS




е) HCS




е) HPF




ж) HPFC



з) LMM



и) LMVM



і) IHS

Рисунок 3.17 – Результати підвищення інформативності зображень Sentinel-2

Таблиця 3.4 – Кількісні оцінки

Метод	Метрики					
	RMSE	CC	ERGAS	SAM	UIQI	SRE
ATWT	11,29	0,97	16,47	5,27	0,98	0,01
AWLP	10,25	0,97	16,01	4,81	0,98	0,01
HPF	13,94	0,95	19,46	6,48	0,99	0,02
GS	10,92	0,96	63,77	5,18	0,95	0,01
HCS	13,20	0,96	13,24	5,98	0,99	0,02
LMM	8,38	0,97	19,95	3,96	0,98	0,04
Brovey	10,34	0,96	69,33	4,89	0,95	0,01
IHS	12,29	0,95	71,30	5,82	0,99	0,01
HPFC	17,04	0,95	22,27	6,19	0,98	0,01
LMVM	13,59	0,95	20,62	6,37	0,99	0,01
запропонований метод	3,64	0,99	5,91	0,52	1	0

Аналізуючи кількісні оцінки ефективності традиційних методів обробки зображень (табл. 3.4), можна зробити висновок, що запропонований метод демонструє кращі результати. Наприклад, низьке значення ( $RMSE=3,64$ ) свідчить про високу точність відтворення спектральних властивостей, а високий коефіцієнт кореляції ( $CC=0,997$ ) підтверджує дуже сильну лінійну залежність між оцінюваним та спостережуваним зображеннями. Крім того, низьке значення ( $SAM=0,52$ ) та високий показник ( $UIQI=0,999$ ) свідчать про високу якість та структурну подібність між оцінюваним та спостережуваним зображеннями. Ці результати доводять ефективність запропонованого програмно-апаратного забезпечення під час відтворення спектральних властивостей зображень Sentinel-2.

Для перевірки ефективності запропонованого методу на реальних даних Sentinel-2 здійснено безпосереднє завантаження оригінальних наборів даних із

низькою роздільною здатністю та даних із високою роздільною здатністю у навчені мережі. Це означає, що використано набори даних із роздільною здатністю (20 м, 10 м) для отримання зображень високої роздільної здатності 10 м. Так як відсутні наземні дані, то спектральні смуги з вищою роздільною здатністю розглядалися як еталонні дані для оцінки ефективності методу підвищення роздільної здатності. У рамках проведених експериментів чотири спектральні смуги з роздільною здатністю 10 м використовувалися як зразкові дані для візуальної оцінки результатів. Результати використання методів обробки зображень підтверджують, що запропонована технологія значно покращує різкість країв та насиченість деталей наземних об'єктів. Зображення, відтворене за допомогою методу ATWT, демонструє збереженість спектральних та просторових характеристик, проте спостерігаються деякі артефакти у вигляді шуму та розмиття. Результат застосування методу AWLP характеризується високою якістю збереження деталей та кольорів. Зображення має чіткі контури та низький рівень шуму. Зображення, отримане за допомогою методу Brovey, відтворює спектральні характеристики з високою точністю, але спостерігаються артефакти у вигляді розмиття та перенасиченості кольорів. Застосування методу GS призвело до відтворення зображення з деяким рівнем розмиття та втрати деталей, особливо в областях із тонкими контурами. Зображення, отримане методом HCS, відтворює деталі зі зазначеною точністю, проте спостерігаються артефакти у вигляді шуму та низької роздільної здатності. Зображення, створене методом HPF, характеризується високою роздільною здатністю та чіткими деталями, але присутні шуми. Застосування методу HPFC призвело до значної втрати деталей та високого рівня розмиття на зображенні. Зображення, відтворене за допомогою методу IHS, має деякі артефакти у вигляді перенасиченості кольорів та втрати деталей у темних областях. Метод LMM забезпечує високу якість відтворення деталей та кольорів зображення без помітного рівня шуму. Зображення, отримане методом LMVM, має чіткі деталі та кольори без помітного рівня шуму або артефактів. Зображення, отримане за допомогою запропонованого методу, відтворює

спектральні та просторові характеристики з високою точністю та мінімальним рівнем артефактів.

На рисунку 3.18 наведено графік часу виконання методів обробки зображень. Найшвидшим методом є Brovey, що виконується всього за 0,016 с, це обумовлено його простотою обчислювальної процедури. З іншого боку, найповільнішими методами є LMVM та запропонованого методу, що пов'язано з більш складною обчислювальною процедурою та великим обсягом оброблюваних даних.




Рисунок 3.18 – Час відпрацювання методів обробки зображень

### **3.4 Програмна реалізація інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні**

Програмна реалізація інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні виконана на персональному комп'ютері з процесором Intel(R) Core(TM) i5-7400 CPU з тактовою частотою 3.00 GHz, графічним процесором Nvidia GTX 950M та

16 ГБ оперативної пам'яті. Після завершення процесу навчання запропонованої моделі на основі штучного інтелекту здійснено загальне архітектурне проектування розробленого програмного додатку. На рисунку 3.19 наведено діаграму послідовності, яка відображає кроки та послідовність операцій під час застосування розробленої інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні.

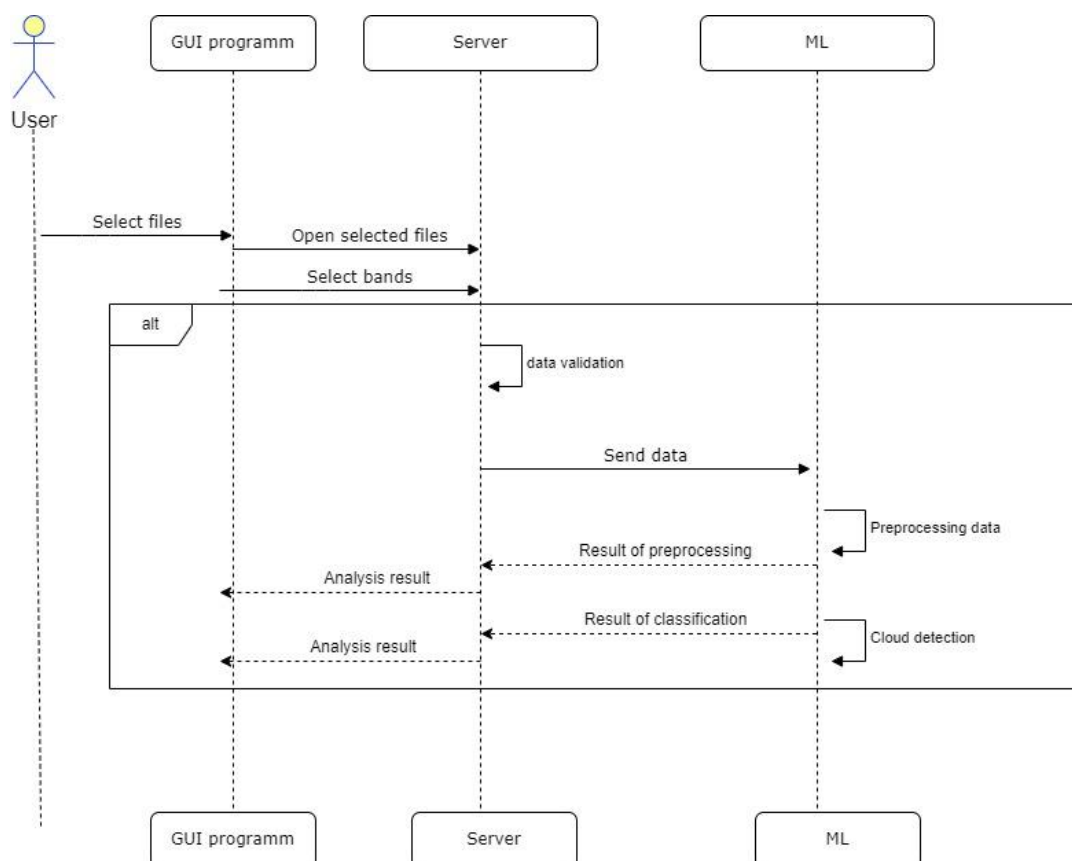


Рисунок 3.19 – Діаграма послідовності обробки зображень зі застосуванням запропонованого програмно-апаратного забезпечення інформаційної технології

Для реалізації технології обрано мову програмування Python разом із графічною бібліотекою Tkinter, яка забезпечила створення інтерактивного інтерфейсу користувача. У процесі розробки програмного забезпечення використовувались такі бібліотеки, як Tensorflow, numpy, matplotlib, rasterio, georandas та earthpy, що дозволило реалізувати повний спектр функціональних

можливостей: роботу з супутниковими даними, їх попередню обробку, візуалізацію результатів і сегментацію земного покриву (рис. 3.20).

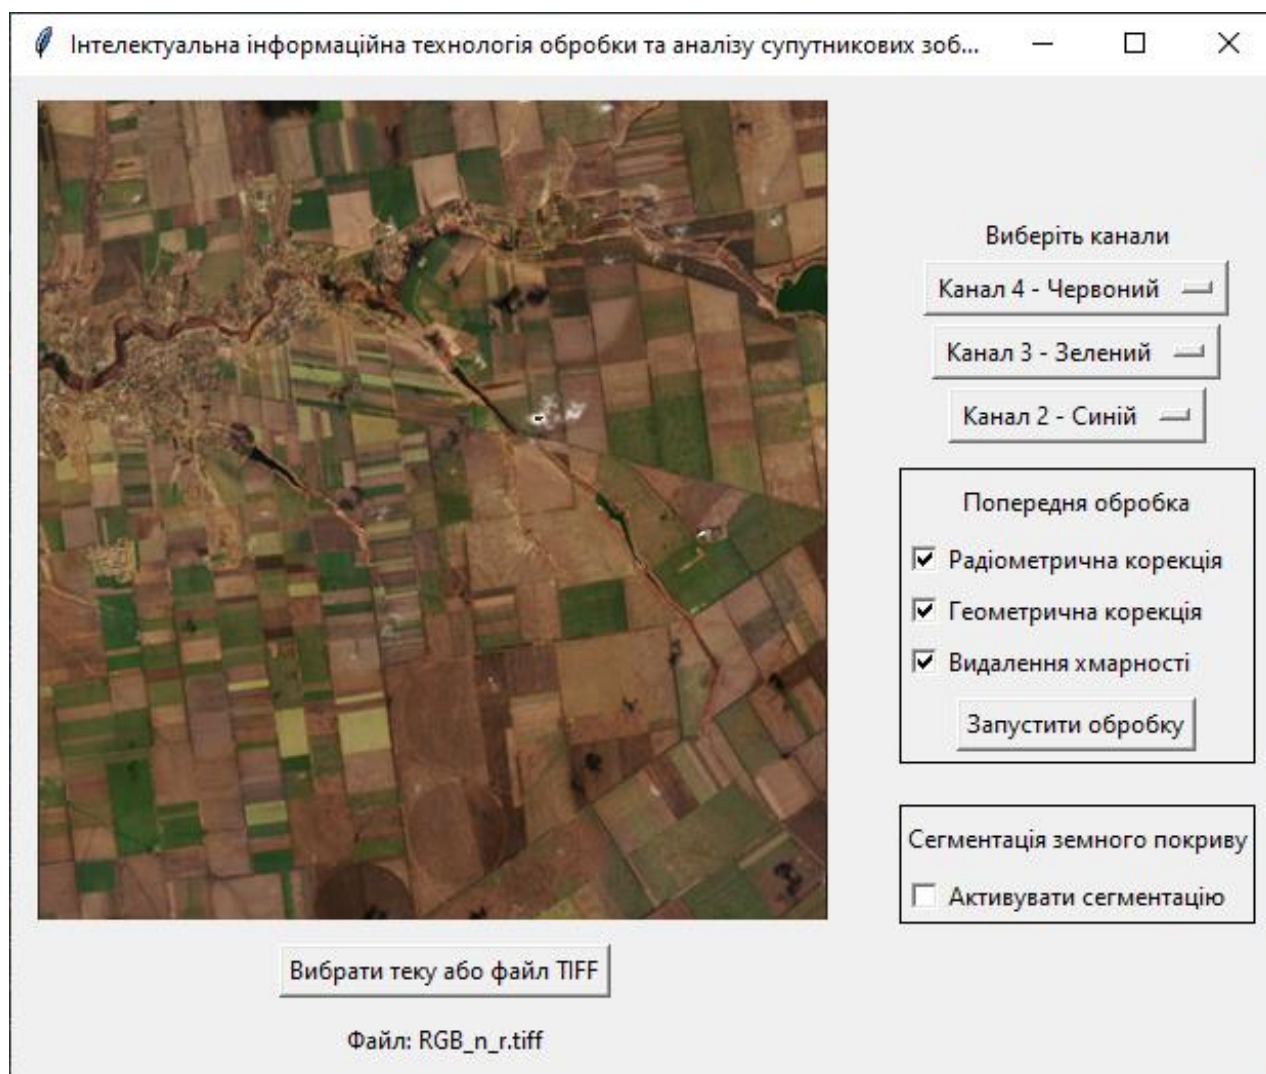


Рисунок 3.20 – Зовнішній вигляд графічного інтерфейсу розробленої технології

У розробленій програмі передбачено можливість завантаження первинних супутникових знімків, виконання попередньої обробки з геометричною та радіометричною корекціями, а також видаленням хмарності. Графічний інтерфейс програми забезпечує зручність використання, зокрема, можливість обирати канали зображення, активувати необхідні корекції та запускати процес сегментації земного покриву. Основою сегментації є запропонована паралельна залишкова архітектура згорткової нейронної мережі (CNN), яка інтегрує дані з різною просторовою роздільною здатністю (10 і 20

метрів). Це рішення дозволяє підвищити інформативність зображень, зменшити кольорові спотворення, покращити деталізацію та забезпечити точну ідентифікацію меж сільськогосподарських полів (рис. 3.21).

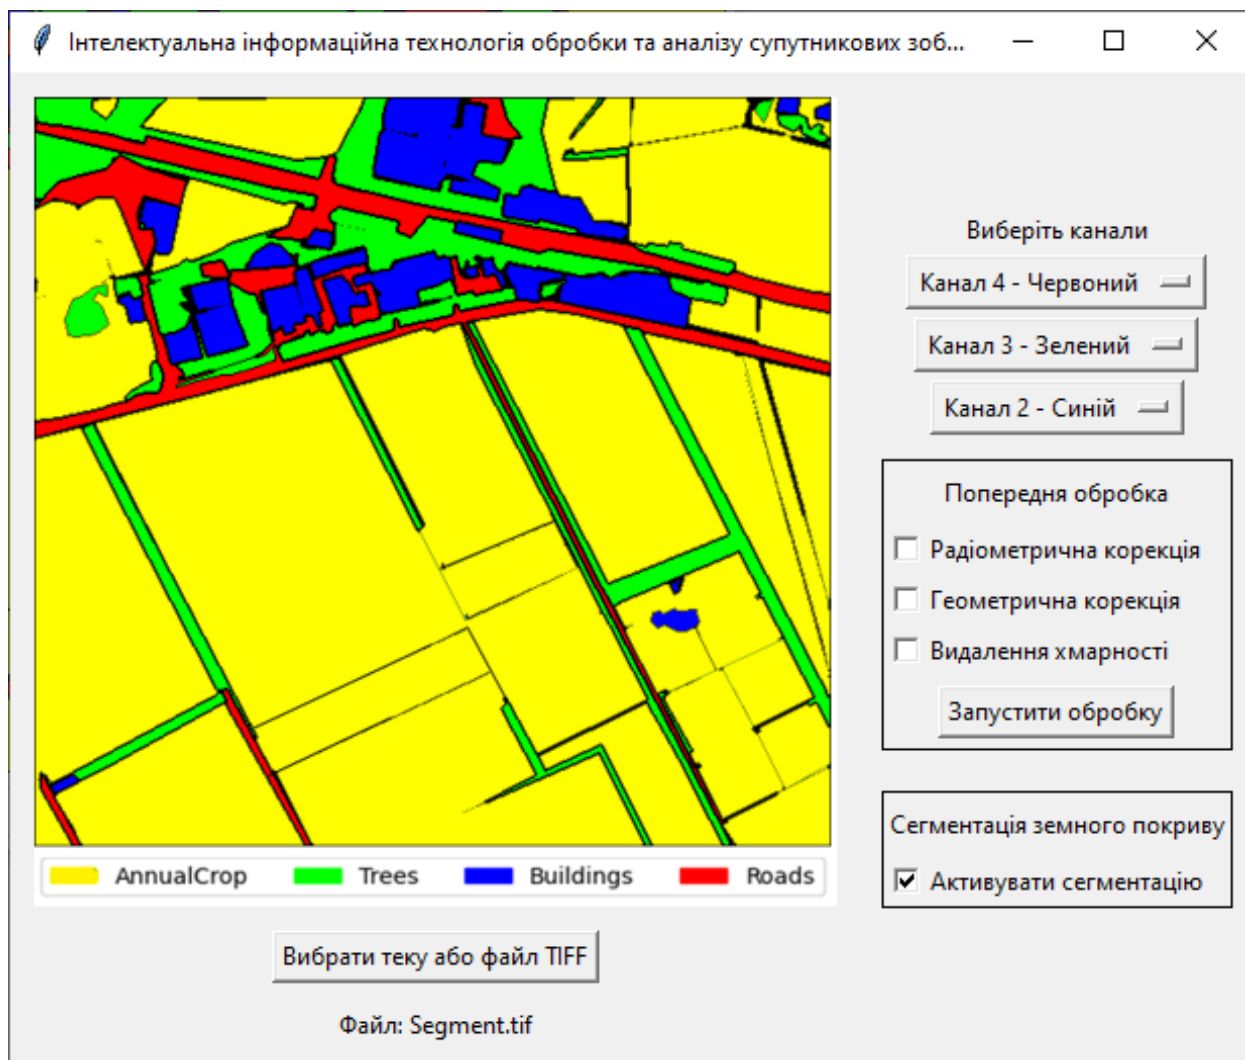


Рисунок 3.21 – Результат розробленої технології для картографування земної поверхні

Розроблена інформаційна технологія спрямована на вирішення практичних завдань у сфері моніторингу сільськогосподарських угідь і планування агротехнічних процесів. Її застосування дозволяє автоматизувати обробку супутникових даних, виконувати сегментацію земного покриття та отримувати високоточні результати, що мають важливе значення для прийняття рішень у сільському господарстві.

### **3.5 Практичне застосування інформаційної технології для картографування зон затоплення земної поверхні**

Затоплення є результатом поєднання метеорологічних і антропогенних факторів. Незважаючи на їх походження, вони мають катастрофічні наслідки, такі як руйнування будівель, інфраструктури та сільськогосподарських угідь [60]. Однією з головних змін у землекористуванні стало зростання урбанізації, що впливає на гідрологічні процеси [61]. Ця тенденція є особливо актуальною в сучасному світі, де мегаполіси та міські агломерації постійно зростають, а земельні ресурси стають обмеженими. Урбанізація призводить до збільшення площі асфальтованих поверхонь, що знижує водопроникність ґрунтів та збільшує ризик затоплення під час сильних дощів або відтавання снігу. Крім того, зміни в природному середовищі, такі як вирубка лісів та руйнування екосистем, також сприяють збільшенню ризику повеней. Зменшення природних бар'єрів, що поглинають воду, призводить до швидшого відведення великих кількостей води, що в результаті може призвести до затоплення низинних районів та міст. Тому важливо звертатись до сучасних методів аналізу зон підтоплення територій. Очевидно, що своєчасне та оперативне виявлення таких зон є важливим завданням для збереження життя людей, рослинного та тваринного світу.

Отримання інформації про елементи та явища, які не можна безпосередньо спостерігати на місці, є важливою складовою для управління ризиками повеней, особливо в умовах військових конфліктів. Виготовлення спеціальних карт зон затоплення з додатковими даними стає необхідним інформаційним ресурсом для ефективного планування та управління в ситуаціях надзвичайних подій. Виявлення цікавих об'єктів і аномалій на супутникових знімках є актуальним завданням уже протягом десятків років, і кількість застосувань, де вона використовується, постійно зростає. Серед них програми, пов'язані з дистанційним зондуванням Землі [62], наземним моніторингом [63], сільським господарством [64], [65] та інше.

Розроблена інформаційна технологія для картографування земної поверхні адаптована для створення карт затоплення. Для визначення зон затоплення внаслідок аварії на гідроелектростанції технологія використовує різночасові супутникові знімки, що дозволяє точно ідентифікувати змінені території, створюючи карти затоплених ділянок. Важливо, що ця технологія також підтримує картографування сільськогосподарських територій, що дає змогу прогнозувати наслідки затоплення для сільськогосподарських культур. Зона затоплення сільськогосподарських територій у випадку руйнування гідроелектростанцій визначається як частина прилеглої до річки (озера, водосховища) території, яка затоплюється водою в результаті цієї події. Вона поділяється на дві основні частини: зону катастрофічного затоплення та зону затоплення. Під час моделювання використовуються дані про топографію місцевості, розміри водосховища, напір води та інші фактори, що впливають на затоплення, як описано вище в цьому підрозділі.

Для подальшого вивчення впливу потенційних наслідків прориву дамби на інфраструктуру, в тому числі на сільське господарство, була побудована карта сільськогосподарських земель Запорізького району. Ця карта є важливим інструментом для прогнозування наслідків прориву дамби та оцінки його впливу на посіви основних сільськогосподарських культур, таких як картопля, кукурудза, пшениця, соняшник та інші (рис. 3.22).

Встановлені гіпотетичні негативні наслідки прориву дамби можуть суттєво позначитися на врожаї сільськогосподарських культур через затоплення та підтоплення полів. Зокрема, вологе середовище, яке виникає внаслідок затоплення, може спричинити руйнування кореневої системи рослин, задушення культур водою, а також розвиток гнилей та інших хвороб, що призводять до втрати врожаю. Поширення забруднених водних потоків з прориву дамби також може призвести до забруднення ґрунтів та водойм, що негативно впливає на екологічну ситуацію в регіоні. Наявність шкідливих речовин у воді може призвести до отруєння рослин та знищення біоти ґрунту, що загрожує довкіллю та різноманіттю екосистеми. Таким чином, прорив

дамби може створити серйозні екологічні загрози для сільськогосподарських угідь та природних екосистем у районі.

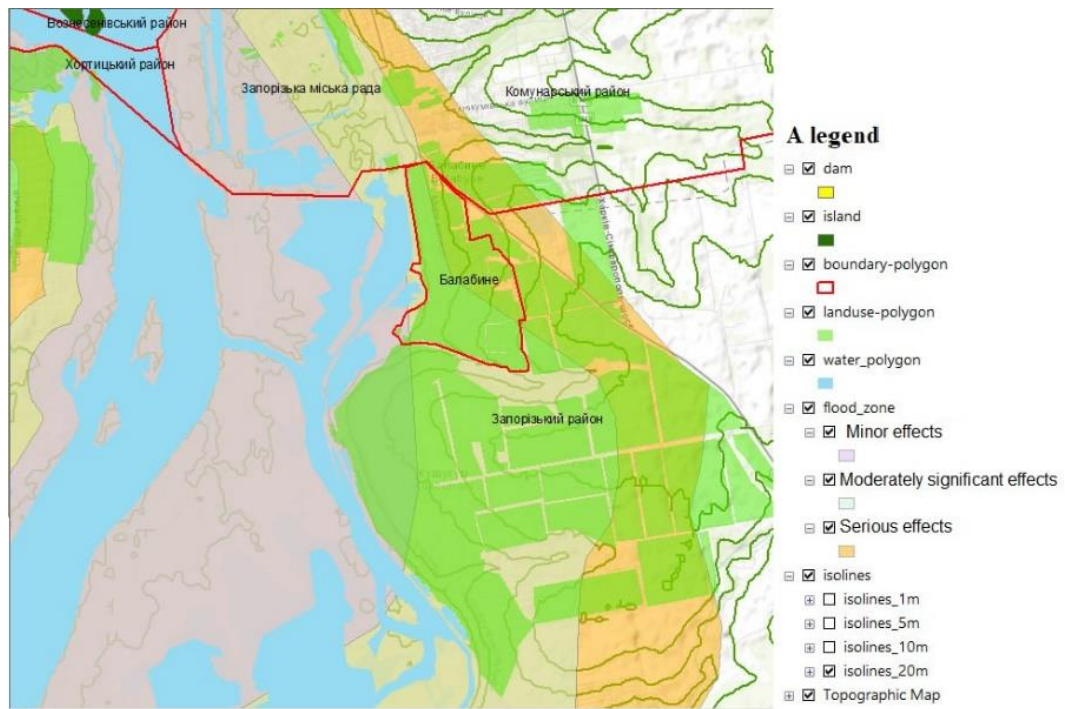


Рисунок 3.22 – Карта затоплення сільськогосподарських угідь

На рисунку 3.23 зображено зміну затоплених площ залежно від часу протягом доби. Дослідження охоплює часові проміжки з 0:00 до 20:00. На початку доби затоплення було відсутнє, однак о 2:00 спостерігається різке збільшення затопленої площі до 150 гектарів. Після цього, о 4:00, площа затоплення зменшилася до 80 гектарів, що вказує на тимчасове покращення ситуації.

Найбільше затоплення спостерігається о 6:00, коли площа досягла 289 гектарів. Це свідчить про пікову інтенсивність процесу затоплення у цей проміжок часу. До 8:00 ситуація частково стабілізувалася, і площа затоплення зменшилася до 250 гектарів. У наступні години, з 10:00 до 12:00, спостерігається подальше зниження затопленої площі до 150 та 99 гектарів відповідно.

Однак, починаючи з 14:00, ситуація знову погіршується, і площа

затоплення збільшується до 273 гектарів. У проміжок між 16:00 та 18:00 відбувається зменшення затопленої площі до 150 та 100 гектарів відповідно, що може бути результатом природного спадання рівня води або вжитих заходів для її усунення. Наприкінці періоду дослідження, о 20:00, площа затоплення становить лише 20 гектарів, що свідчить про суттєве покращення ситуації.

Отримані результати дозволяють визначити часові проміжки найбільшого затоплення, що може бути корисним для планування заходів із запобігання або мінімізації наслідків стихійного лиха. Виявлення піків затоплення о 6:00 та 14:00 особливо важливе для оцінки динаміки подій і прийняття оперативних рішень.



Рисунок 3.23 – Графік динаміки затоплення протягом доби

### 3.6 Висновки до третього розділу

У цьому розділі висвітлено результати досліджень із розробки інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні, а саме:

1. Запропоновано метод попередньої синергетичної обробки супутникових зображень із використанням згорткової нейронної мережі. На відміну від класичних методів злиття зображень, таких як PCA чи Wavelet, розроблений метод дозволяє значно зменшити артефакти злиття різнорідних даних, що виникають під час обробки, та автоматизувати процес аналізу геопросторової інформації, що суттєво підвищує ефективність обробки супутникових знімків.

2. Запропоновано нейромережеву сегментацію для картографування земного покриву (сільськогосподарські культури, дерева, будівлі та дороги). Використання моделі ResNet, яку навчено на даних Sentinel-2 для регіону Дніпропетровщини, дозволило досягти високої точності класифікації зображень. Цей підхід значно покращив точність класифікації порівняно з класичними методами, такими як IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood та Parallelepiped, що демонструють низьку точність, зокрема при сегментації доріг та сільськогосподарських культур.

3. Встановлено, що одним із ключових факторів для досягнення високої якості сегментації, є попередня обробка даних. У процесі дослідження використовувалися методи атмосферної корекції, геометричного та радіометричного калібрування, тощо. Це дозволило значно покращити якість вхідних даних та, відповідно, підвищити точність і стабільність роботи нейромережевих моделей. Запропонована синергетична обробка багатоспектральних Sentinel-зображень з використанням згорткових нейронних мереж показала високі результати під час сегментації всіх класів земного покриву, що свідчить про високу точність і ефективність запропонованої методики, яку забезпечує модель ResNet у поєднанні з попередньою обробкою супутникових даних.

4. Доведено, що особливою перевагою є інтеграція даних із різною роздільною здатністю та використання технологій злиття оптичних і радарних зображень, таких як біквадратична інтерполяція, вирівнювання гістограм і PCA-перетворення. Це дозволило ефективно маскувати хмари на зображеннях і

зберегти високий рівень інформативності даних під час віддаленого моніторингу сільськогосподарських територій. Запропонована синергетична обробка багатоспектральних Sentinel-зображень із використанням згорткових нейронних мереж дає можливість поєднувати дані з роздільною здатністю 10 м та 20 м, що покращує деталізацію та забезпечує збереження спектральних характеристик оптичних зображень Sentinel-2.

5. Розроблено програмні компоненти інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні, що дозволило автоматизувати процес обробки супутникових зображень та адаптувати його до різноманітних задач, зокрема для картографування зон затоплення земної поверхні.

6. Практичне застосування розробленої інформаційної технології обробки та аналізу супутникових зображень для картографування зон затоплення територій у разі аварії на гідроелектростанціях продемонструвало її ефективність для оцінки впливу аварії на сільськогосподарські угіддя. Створення детальних карт зон затоплення дозволяє підготувати плани екстрених заходів та розробити стратегії захисту сільськогосподарських територій у випадку аварійних ситуацій.

### **Список використаних джерел до третього розділу**

1. Luo, X., Tong, X., Hu, Z. Improving Satellite Image Fusion via Generative Adversarial Training. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, Vol. 59 (8). P. 6969–6982. <https://doi.org/10.1109/TGRS.2020.3025821>

2. Kashtan, V.Yu., Hnatushenko, V.V. Automated pansharpening information technology of satellite images. *The scientific journal «Radio Electronics, Computer Science, Control»*, 2021, Vol. 2 (57). 123–133. <https://doi.org/10.15588/1607-3274-2021-2-13>

3. Sanchis, M., Piles, A., Muñoz, M. et al. Synergistic Integration of Optical and Microwave Satellite Data for Crop Yield Estimation. *Remote Sensing of*

Environment, 2019, Vol. 234. P. 1–12. <https://doi.org/10.1016/j.rse.2019.111460>

4. Rahimzadeganasl, A., Alganci, U., Goksel, C. An Approach for the Pan Sharpening of Very High Resolution Satellite Images Using a CIELab Color Based Component Substitution Algorithm. *Applied Sciences*, 2019, Vol. 9 (23):5234. P. 1–30. <https://doi.org/10.3390/app9235234>

5. Kahtan, V.Yu., Hnatushenko, V.V. A Wavelet and HSV Pansharpening Technology of High Resolution Satellite Images. In: *Intelligent Information Technologies & Systems of Information Security IntelITSIS*, 2020. P. 767–766. URL: <https://ceur-ws.org/Vol-2623/paper7.pdf>

6. Duran, J., Buades, A. Restoration of pansharpened images by conditional filtering in the PCA domain. *IEEE Geosci. Remote Sens. Lett.*, 2019, Vol. 16 (3). P. 442–446. <https://doi.org/10.1109/LGRS.2018.2873654>

7. Alcaras, E., Parente, C. The Effectiveness of Pan-Sharpener Algorithms on Different Land Cover Types in GeoEye-1 Satellite Images. *Journal of Imaging*, 2023, Vol. 9 (5):93. P. 1–21. <https://doi.org/10.3390/jimaging9050093>

8. Adesso, P., Restaino, R., Vivone, G. An Improved Version of the Generalized Laplacian Pyramid Algorithm for Pansharpening. *Remote Sensing*, 2021, Vol. 13 (17):3386. P. 1–20. <https://doi.org/10.3390/rs13173386>

9. Ghahremani, M., Ghassemian, H. A Compressed-Sensing-Based Pan-Sharpener Method for Spectral Distortion Reductio. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, Vol. 54. P. 2194–2206. <https://doi.org/10.1109/TGRS.2015.249730>

10. Huang, W., Xiao, L., Liu, H., Wei, Z., Tang, S. A New Pan-Sharpener Method With Deep Neural Networks. *IEEE Geosci. Remote Sens. Lett.*, 2015, Vol. 12. P. 1037–1041. <https://doi.org/10.1109/LGRS.2014.2376034>

11. Imani, M. Texture feed based convolutional neural network for pansharpening. *Neurocomputing*, 2020, Vol. 398. P. 117–130. <https://doi.org/10.1016/j.neucom.2020.02.083>

12. Wei, Y., Yuan, Q., Shen, H., Zhang, L. Boosting the Accuracy of Multispectral Image Pansharpening by Learning a Deep Residual Network. *IEEE*

Geosci. Remote Sens. Lett., 2017, Vol. 14. P. 1795–1799.  
<https://doi.org/10.1109/LGRS.2017.2736020>

13. Yang, J., Fu, X., Hu, Y., Huang, Y., Ding, X., Paisley, J. PanNet: A Deep Network Architecture for Pan-Sharpener. In: Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), 2017. P. 1753–1761.  
<https://doi.org/10.1109/ICCV.2017.193>

14. Li, H., Jing, L., Tang, Y. Assessment of Pansharpening Methods Applied to WorldView-2 Imagery Fusion. Sensors, 2017, Vol. 17 (1):89. P. 1–30.  
<https://doi.org/10.3390/s17010089>

15. Каштан, В.Ю., Гнатушенко, В.В. Дослідження ефективності методів злиття супутникових знімків високого просторового розрізнення. Прикладні питання математичного моделювання, 2020, Т. 3. С. 117–127.  
<https://doi.org/10.32782/KNTU2618-0340/2020.3.2-1.11>

16. Yang, F., Yang, H., Fu, J., Lu, H., Guo, B. Learning texture transformer network for image super-resolution. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020. P. 5790–5799.  
<https://doi.org/10.1109/CVPR42600.2020.00583>

17. Solórzano, J.V., Mas, J.F., Gao, Y., Gallardo-Cruz, J.A. Land Use Land Cover Classification with U-Net: Advantages of Combining Sentinel-1 and Sentinel-2 Imagery. Remote Sens., 2021, Vol. 13 (18). P. 1–23.  
<https://doi.org/10.3390/rs13183600>

18. Zhang, H., Wang, L., Tian, T., Yin, J. A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. Remote Sens., 2021, Vol. 13 (6). P. 1–17.  
<https://doi.org/10.3390/rs13061221>

19. Peng, X., Han, W., Ao, J., Wang, Y. Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield. Remote Sens., 2021, Vol. 13 (6). P. 1–17. <https://doi.org/10.3390/rs13061094>

20. Lianze, T., Yong, L., Hongji, Z., Sijia, L. Summary of UAV Remote Sensing Application Research in Agricultural Monitoring. Sci. Technol. Inf., 2018,

Vol. 16. P. 122–124.

21. Vincent, G., Antin, C., Laurans, M., Heurtebize, J., Durrieu, S., Lavalley, C., Dautat, J. Mapping plant area index of tropical evergreen forest by airborne laser scanning. A cross-validation study using LAI2200 optical sensor. *Remote. Sens. Environ.*, 2017, Vol. 198. P. 254–266. <https://doi.org/10.1016/j.rse.2017.05.034>

22. Rakhlin, A., Davydow, A., Nikolenko, S. Land cover classification from satellite imagery with u-net and lovász-softmax loss. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2018. P. 262–266. URL: [https://openaccess.thecvf.com/content\\_cvpr\\_2018\\_workshops/papers/w4/Rakhlin\\_Land\\_Cover\\_Classification\\_CVPR\\_2018\\_paper.pdf](https://openaccess.thecvf.com/content_cvpr_2018_workshops/papers/w4/Rakhlin_Land_Cover_Classification_CVPR_2018_paper.pdf)

23. Bossard, M., Feranec, J., Otahel, J. *CORINE Land Cover Technical Guide: Addendum*; European Environment Agency: Copenhagen, Denmark, 2000, Vol. 40. 105 p.

24. Zanaga, D., Van De Kerchove, R., De Keersmaecker, W., Souverijns, N., Brockmann, C., Quast, R., Wevers, J., Grosu, A., Paccini, A., Vergnaud, S. et al. *ESA WorldCover 10 m 2020 v100*, 2021. URL: <https://worldcover2020.esa.int/downloader>.

25. Makantasis, K., Karantzalos, K., Doulamis, A., Doulamis, N. Deep supervised learning for hyperspectral data classification through convolutional neural networks. In: *Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015. P. 4959–4962. <https://doi.org/10.1109/IGARSS.2015.7326945>

26. Xie, C., Zhu, H., Fei, Y. Deep coordinate attention network for single image super-resolution. *IET Image Process.*, 2022, Vol. 16. P. 273–284. <https://doi.org/10.1049/ipr2.12364>

27. Kamilaris, A., Prenafeta-Boldú, F.X. Deep learning in agriculture: A survey. *Comput. Electron. Agric.*, 2018, Vol. 147. P. 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>

28. Yang, Y., Newsam, S. Bag-of-visual-words and spatial extensions for land-

use classification. In: Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems, 2010. P. 270–279. URL: [https://faculty.ucmerced.edu/snewsam/papers/Yang\\_ACMGIS10\\_BagOfVisualWords.pdf](https://faculty.ucmerced.edu/snewsam/papers/Yang_ACMGIS10_BagOfVisualWords.pdf)

29. Zhao, L., Tang, P., Huo, L. Feature significance-based multibag-of-visual-words model for remote sensing image scene classification. *Journal of Applied Remote Sensing*, 2016, Vol. 10 (3). P. 1–21. <https://doi.org/10.1117/1.JRS.10.035004>

30. Zhou, W., Newsam, S., Li, C., Shao, Z. Patternnet: a benchmark dataset for performance evaluation of remote sensing image retrieval. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, Vol. 145 (A). P. 1–47. <https://doi.org/10.1016/j.isprsjprs.2018.01.004>

31. Cheng, G., Han, J., Lu X. Remote sensing image scene classification: benchmark and state of the art. *Proceedings of the IEEE*, 2017, Vol. 105 (10). P. 1865–1883. <https://doi.org/10.1109/JPROC.2017.2675998>

32. Basu, S., Ganguly, S., Mukhopadhyay, S., DiBiano, R., Karki, M., Nemani, R. Deepsat: a learning framework for satellite imagery. In: *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2015, Vol. 37. P. 1–22. <https://doi.org/10.48550/arXiv.1509.03602>

33. Каштан, В.Ю., Шевцова, О.С. Інформаційна технологія попередньої обробки супутникових зображень з використанням згорткової нейронної мережі. *Системні технології. Регіональний міжвузівський збірник наукових робіт*, 2024, Вип. 1 (150). С. 36 – 50. <https://doi.org/10.34185/1562-9945-1-150-2024-04>.

34. Selmi, L. Land Use and Land Cover Classification using a ResNet Deep Learning Architecture. In: *Living Planet Symposium*, 2022, P. 1–10. <https://doi.org/10.13140/RG.2.2.12801.53600>.

35. Griffiths, P., Nendel, C., Hostert, P. Intra-annual reflectance composites from Sentinel-2 and Landsat for national-scale crop and land cover mapping. *Remote Sens. Environ*, 2019, Vol. 220. P. 135–151. <https://doi.org/10.1016/j.rse.2018.10.031>.

36. Gerland, P., Hertog, S., Wheldon, M. et al. World Population Prospects 2022: Summary of results: United Nations, 2022. 52 p.

37. Pawlak, K., Kołodziejczak, M. The Role of Agriculture in Ensuring Food Security in Developing Countries: Considerations in the Context of the Problem of Sustainable Food Production. *Sustainability*, 2020, Vol. 12 (13). P. 1–20. <https://doi.org/10.3390/su12135488>.

38. Dudin, V., Polehenka, M., Tkalich, O., Pavlychenko, A., Hapich, H., Roubík, H. Ecological and economic assessment of the effectiveness of implementing bioenergy technologies in the conditions of post-war recovery of Ukraine. *Naukovyi Visnyk Natsionalnoho Hirnychoho Universytetu*, 2024, Vol. 1. P. 203–208. <https://doi.org/10.33271/nvngu/2024-1/203>.

39. Löw, F., Duveiller, G. Defining the spatial resolution requirements for crop identification using optical remote sensing. *Remote Sensing*, 2014, Vol. 6. P. 9034–9063. <https://doi.org/10.3390/rs6099034>.

40. Hnatushenko, V.V., Sierikova, K.Y., Sierikov, I.Y. Development of a Cloud-Based Web Geospatial Information System for Agricultural Monitoring Using Sentinel-2 Data. In: 2018 IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT), 2018. P. 270–273. <https://doi.org/10.1109/STC-CSIT.2018.8526717>

41. Beylkin, G., Monzón, L., Satkauskas, I. On computing distributions of products of random variables via Gaussian multiresolution analysis. *Applied and Computational Harmonic Analysis*, 2019, Vol. 47. P. 306–337. <https://doi.org/10.1016/j.acha.2017.08.008>.

42. Sugumar, R., Suganya, D. A multi-spectral image-based high-level classification based on a modified SVM with enhanced PCA and hybrid metaheuristic algorithm. *Remote Sensing Applications: Society and Environment*, 2023, Vol. 31. P. 1–12. <https://doi.org/10.1016/j.rsase.2023.100984>.

43. Guo, Q., Liu, Z., Liu, S. Color image encryption by using Arnold and discrete fractional random transforms in IHS space. *Optics and Lasers in Engineering*, 2010, Vol. 48. P. 1174–1181.

<https://doi.org/10.1016/j.optlaseng.2010.07.005>

44. Carson, E., Lund, K., Rozložník, M., Thomas, S. Block Gram-Schmidt algorithms and their stability properties. *Linear Algebra and its Applications*, 2022, Vol. 638. P. 150–195. <https://doi.org/10.1016/j.laa.2021.12.017>

45. Li, Y., Liu, Z., Yang, J., Zhang, H. Wavelet Transform Feature Enhancement for Semantic Segmentation of Remote Sensing Images. *Remote Sens.*, 2023, Vol. 15 (24). P. 1–20. <https://doi.org/10.3390/rs15245644>

46. Samia, M., Youcef, S. Panchromatic and multispectral image fusion using the spatial frequency and the a trous wavelet transform. *Journal of Applied Remote Sensing*, 2021, Vol. 15 (3). P. 1–12. <https://doi.org/10.1117/1.JRS.15.036510>.

47. Kaplan, G. Sentinel-2 Pan Sharpening-Comparative Analysis. *MDPI Proc*, 2018, Vol. 2. P. 1–6. <https://doi.org/10.3390/ecrs-2-05158>.

48. Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W., Li, X. Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 2016, Vol. 8 (4). P. 1–19. <https://doi.org/10.3390/rs8040354>

49. Lanaras, C., Bioucas-Dias, J.M., Galliani, S., Baltsavias, E., Schindler, K. Super-Resolution of Sentinel-2 Images: Learning a Globally Applicable Deep Neural Network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, Vol. 146. P. 305–319. <https://doi.org/10.1016/j.isprsjprs.2018.09.018>

50. Yuan, Q., Wei, Y., Meng, X., Shen, H., Zhang, L. A multiscale and multidepth convolutional neural network for remote sensing imagery pan-sharpening. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sensing*, 2018, Vol. 11. P. 978–989. <https://doi.org/10.1109/JSTARS.2018.2794888>.

51. Shao, Z., Cai, J., Fu, P., Hu, L., Lui, T. Deep learning-based fusion of Landsat-8 and Sentinel-2 images for a harmonized surface reflectance product. *Remote Sens. Environ*, 2019, Vol. 235. P. 1–18. <https://doi.org/10.1016/j.rse.2019.111425>

52. Zhang, C., Li, X. Land Use and Land Cover Mapping in the Era of Big Data. *Land*, 2022, Vol. 11. P. 1–22. <https://doi.org/10.3390/land11101692>.

53. ESA website. [Электронный ресурс] – Режим доступа до ресурсу: <https://www.esa.int/>.

54. Hnatushenko, V., Kogut, P., Uvarov, M. Variational approach for rigid co-registration of optical/SAR satellite images in agricultural areas. *Journal of Computational and Applied Mathematics*, 2022, Vol. 400. P. 1–15. <https://doi.org/10.1016/j.cam.2021.113742>

55. Khanna, R., Sa, I., Nieto, J., Siegwart, R. On field radiometric calibration for multispectral cameras. In: 2017 IEEE International Conference on Robotics and Automation (ICRA), 2017. P. 6503–6509. <https://doi.org/10.1109/ICRA.2017.7989768>

56. Hnatushenko, V., Hnatushenko, Vik., Kashtan, V., Reuta, O., Udovyk, I. Voxel Approach to the Shadow Formation Process in Image Analysis. In: 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 2021. P. 33–36. <https://doi.org/10.1109/IDAACS53288.2021.9660909>

57. Lim, B., Son, S., Kim, H., Nah, S., Mu Lee, K. Enhanced deep residual networks for single image super-resolution. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017. P. 136–144. <https://doi.org/10.48550/arXiv.1707.02921>.

58. Segal-Rozenhaimer, M., Li, A., Das, K., Chirayath, V. Cloud detection algorithm for multi-modal satellite imagery using convolutional neural-networks (CNN). *Remote Sensing of Environment*, 2020, Vol. 237. P. 1–17. <https://doi.org/10.1016/j.rse.2019.111446>

59. Loncan, L., De Almeida, L.B., Bioucas-Dias, J.M., Briottet, X., Chanussot, J., Dobigeon, N., Fabre, S., Liao, W., Licciardi, G.A., Simoes, M. et al. Hyperspectral pansharpening: A review. *IEEE Geosci. Remote Sens. Mag.*, 2015, Vol. 3. P. 27–46. <https://doi.org/10.1109/MGRS.2015.2440094>.

60. Laktionov, I., Diachenko, G., Koval, V., Yevstratiev, M. Computer-Oriented Model for Network Aggregation of Measurement Data in IoT Monitoring of Soil and Climatic Parameters of Agricultural Crop Production Enterprises. *Baltic J.*

Modern Computing, 2023, Vol. 11 (3). P. 500–522.  
<https://doi.org/10.22364/bjmc.2023.11.3.09>

61. Le, T.T.H., Nguyen, V.C. Numerical study of partial dam–break flow with arbitrary dam gate location using VOF method. *Appl. Sci.*, 2022, Vol. 12. P. 1–17.  
<https://doi.org/10.3390/app12083884>.

62. Hnatushenko, V.V., Hnatushenko, Vik.V., Mozgovyi, D.K., Vasyliiev, V.V., Kavats, O.O. Satellite Monitoring of Consequences of Illegal Extraction of Amber in Ukraine. *Scientific bulletin of National Mining University. State Higher Educational Institution “National Mining University*, 2017, Vol. 2 (158). P. 99–105. URL: <https://nvngu.in.ua/index.php/en/component/jdownloads/finish/67-02/8619-02-2017-hnatushenko/0>

63. Boussema, S.B.F., Allouche, F.K., Ajmi, R., Chaabane, B., Gad, A. Assessing and monitoring the effects of land cover changes in biodiversity. Case study: Mediterranean coastal region, Sousse, Tunisia. *The Egyptian Journal of Remote Sensing and Space Science*, 2023, Vol. 26. P. 185–196.  
<https://doi.org/10.1016/j.ejrs.2023.01.002>

64. Kashtan, V., Hnatushenko, V., Zhir, S. Information technology analysis of satellite data for land irrigation monitoring: Invited paper. In: *2021 IEEE International Conference on Information and Telecommunication Technologies and Radio Electronics (UkrMiCo)*, 2021. P. 1–4.  
<https://doi.org/10.1109/UkrMiCo52950.2021.9716592>

65. Carlier, J., Doyle, M., Finn, J.A., ÓhUallacháin, D., Ruas, S., Moran, J. The development and potential application of a land use monitoring programme for high nature value farmland and forest quality and quantity in the Republic of Ireland. *Environmental Science & Policy*, 2023, Vol. 146. P. 11–12.  
<https://doi.org/10.1016/j.envsci.2023.03.023>.

## ЗАГАЛЬНІ ВИСНОВКИ

Дослідження цієї монографії присвячено вирішенню актуальної науково-практичної проблеми розробки програмно-апаратного забезпечення та комп'ютерних моделей інтелектуальних інформаційних технологій сільськогосподарського призначення, що в свою чергу сприяє розвитку теорії створення, удосконалення й використання прикладних систем і мереж агротехнічного моніторингу. Основні кількісні та якісні результати досліджень є такими:

1. Результати критичного аналізу та логічного узагальнення глобальних і національних тенденцій сталого розвитку сільськогосподарської галузі рослинництва відкритого ґрунту дозволили виокремити перспективні тренди використання сучасних інфокомунікаційних та комп'ютерних технологій під час модернізації та підвищення інтегральної ефективності виробничих процесів сільськогосподарських підприємств із вирощування зернових культур. На основі аналізу техніко-функціональних характеристик сучасних технологій ґрунтокліматичного моніторингу обґрунтовано базові засади досліджень із побудови структурно-алгоритмічної організації інформаційної технології ґрунтокліматичного моніторингу на базі архітектурної інтеграції програмно-апаратних рішень наземних і супутникових вимірювань зі залученням методів штучного інтелекту та машинного навчання під час агрегування й обробки даних, а також автоматичної підтримки прийняття рішень щодо оптимізації агротехнічних процедур, що дозволить підвищити ефективність технологічних процесів сільськогосподарських виробництв під час повного циклу вирощування польових культур.

2. Запропоновано та доведено ефективність комп'ютерно-орієнтованої моделі інформаційної технології агромоніторингу, що базується на алгоритмах багаторівневого мережевого обміну вимірювальними даними на основі технологій ZigBee та LoRa із передачею статистично оброблених даних до хмарного сервера через мережу Інтернет. Методами обчислювального

експерименту обґрунтовано оптимальну геометричну модель бездротової мережі польового рівня збору даних: за інтегральним критерієм максимуму приведеної зони покриття та вірогідності безвідмовної роботи оптимальною виявилась ромбоподібна топологія (приведена зона покриття –  $2,82 \cdot 10^4$  м<sup>2</sup>/од., вірогідність безвідмовної роботи за період експлуатації п'ять років – 0,959).

3. Проведено дослідження з ідентифікації та програмної реалізації комп'ютерної моделі обліку кліматичних параметрів та вірогідності появи фузаріозу кукурудзи в попередні моменти часу на прогнозоване значення вірогідності появи цієї хвороби: оптимальне значення гіперпараметра, що відповідає за кількість годин передісторії даних, дорівнює 9 год для агрокліматичних умов Лісостепу і Північного Степу України. Розроблено та програмно реалізовано метод підвищення точності обробки даних на основі попереднього експоненційного згладжування аномальних ділянок у навчальних наборах даних. Визначено, що оптимальним для агрокліматичних умов Лісостепу і Північного Степу України, є використання алгоритму випадкового лісу задля побудови програмно-апаратних рішень детектування вірогідності появи фузаріозу кукурудзи: Північний Степ –  $R^2=0,997$ ,  $RMSE=0,88$ ,  $MAE=0,212$  та Лісостеп –  $R^2=0,995$ ,  $RMSE=1,374$ ,  $MAE=0,206$ .

4. Запропоновано та доведено ефективність комп'ютерно-орієнтованої моделі обробки даних агромоніторингу на основі нейро-нечітких алгоритмів, у якій враховано одночасний вплив сукупності ґрунтокліматичних параметрів сільськогосподарських підприємств рослинництва відкритого ґрунту, їх попередню динаміку, а також передісторію вихідного параметра (ймовірність виникнення специфічних хвороб), що дозволило детектувати ймовірність виникнення таких хвороб кукурудзи зі значенням коефіцієнта детермінації на валідаційних даних: FHB – 0,8, SCLB – 0,61 та NCLB – 0,7. Також програмно реалізовано ці моделі в середовищі Matlab & Simulink, що дозволило виконати серію комп'ютерних експериментів, де прогнозні значення ймовірності виникнення хвороб порівнювались із фактичними даними, ці моделі є

адаптивними до динамічних умов навколишнього середовища й масштабованими до набору вхідних даних.

5. Розроблено та доведено ефективність інформаційної технології обробки та аналізу супутникових зображень для картографування земної поверхні. Запропонована синергетична обробка супутникових зображень із використанням згорткової нейронної мережі, на відміну від класичних методів злиття зображень, таких як PCA чи Wavelet, дозволяє значно зменшити артефакти, що виникають під час обробки, а також автоматизувати процес аналізу даних, що суттєво підвищує ефективність обробки супутникових знімків. Доведено, що особливою перевагою є інтеграція даних із різною роздільною здатністю та використання технологій злиття оптичних і радарних зображень, таких як біквадратична інтерполяція, вирівнювання гістограм і PCA-перетворення. Це дозволило ефективно маскувати хмари на зображеннях і зберегти високий рівень інформативності даних під час віддаленого моніторингу сільськогосподарських територій. Практичне застосування розробленої інформаційної технології обробки та аналізу супутникових зображень для картографування зон затоплення територій у разі аварії на гідроелектростанціях продемонструвало її ефективність для оцінки впливу аварії на сільськогосподарські угіддя.

6. Обґрунтовано перспективні пріоритетні напрями подальших досліджень щодо створення та прикладного застосування інтелектуальних інформаційних і комп'ютерних технологій агротехнічного онлайн-моніторингу. Проведення досліджень за визначеними ключовими напрямками дозволить підвищити показники ефективності та оперативності планування й реалізації агротехнічних заходів під час повного циклу вирощування сільськогосподарських культур в умовах відкритого ґрунту. Це в свою чергу позитивно вплине на інвестиційну привабливість та довгострокову стійкість національної сільськогосподарської галузі завдяки підвищенню інноваційної складової аграрного сектору.

Наукове видання

Лактіонов Іван Сергійович  
Гнатушенко Володимир Володимирович  
Каштан Віта Юріївна  
Дяченко Григорій Григорійович

**ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ ТА КОМП'ЮТЕРНІ  
ТЕХНОЛОГІЇ ЗБОРУ ТА АНАЛІЗУ ДАНИХ АГРОМОНІТОРИНГУ**

Монографія

Опубліковано в авторській редакції.  
Електронне видання.  
Підписано до друку 14.02.2025.  
Ум. друк. арк. 13.7.  
Обл.-вид. арк. 17.6.

Підготовлено до друку та видруковано в  
Національному технічному університеті «Дніпровська політехніка»  
Свідоцтво про внесення до Державного реєстру ДК № 1842 від 11.06.2004.  
49005, м. Дніпро, просп. Д. Яворницького, 19