

Міністерство освіти і науки України

Луцький національний технічний університет

(повне найменування закладу вищої освіти)

Факультет комп'ютерних та інформаційних технологій

(повне найменування факультету)

Кафедра комп'ютерної інженерії та безпеки

(повне найменування кафедри)

КВАЛІФІКАЦІЙНА РОБОТА  
ЗА СТУПЕНЕМ ВИЩОЇ ОСВІТИ «МАГІСТР»

ОЦІНКА ПРИДАТНОСТІ ЗЕМЛІ В РОЗУМНИХ ФЕРМАХ НА  
ОСНОВІ ІОТ ТА ШІ

IOT AND AI BASED LAND SUITABILITY ASSESSMENT IN  
SMART FARMS

спеціальність 123 Комп'ютерна інженерія  
(шифр і назва спеціальності)

освітня програма Комп'ютерна інженерія  
(назва освітньої програми)

Виконав: здобувач вищої освіти  
групи КІм-21  
Стахурський Андрій Миколайович

(підпис)

Керівник:  
к.т.н., доцент  
Поліщук Микола Миколайович

(підпис)

Кваліфікаційну роботу  
допущено до захисту  
«\_\_\_» грудня 2025 р.

Гарант освітньої програми:  
к.т.н., доцент  
Гринюк Сергій Васильович

(підпис)

Луцьк – 2025 року

ЛУЦЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ

Факультет комп'ютерних та інформаційних технологій

Кафедра комп'ютерної інженерії та безпеки

Ступінь вищої освіти: магістр

Галузь знань: 12 Інформаційні технології

Спеціальність: 123 Комп'ютерна інженерія

Освітня програма: «Комп'ютерна інженерія»

ЗАТВЕРДЖУЮ

Завідувач кафедри

доц. Т. Терлецький

« \_\_\_\_\_ » \_\_\_\_\_ 2025 р.

ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ ЗДОБУВАЧУ ВИЩОЇ ОСВІТИ

Стахурському Андрію Миколайовичу

(прізвище, ім'я, по батькові)

1. Тема кваліфікаційної роботи Оцінка придатності землі в розумних фермах на основі IoT та III

Керівник роботи к.т.н., доцент Поліщук Микола Миколайович

затверджені наказом закладу вищої освіти від «17» червня 2025 року №0 290/01-02

2. Строк подання здобувачем вищої освіти кваліфікаційної роботи 09.12.2025р.

3. Вихідні дані до роботи Джерелом розробки є науково-технічна література та публікації в періодичних виданнях з даного питання, опубліковані зарубіжні та вітчизняні роботи в даній області, різні інтернет-ресурси технічного спрямування

4. Зміст пояснювальної записки (перелік питань, які потрібно розробити):

Вступ

Теоретичні основи оцінки придатності земель та технологій розумного землеробства

Аналіз систем і методів оцінки придатності земель

Експериментальне дослідження та оцінка ефективності системи

Висновки

5. Перелік графічного (ілюстративного) матеріалу:

## 6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис	
		завдання видав	завдання прийняв
<i>Теоретичні основи оцінки придатності земель та технологій розумного землеробства</i>	<i>Поліщук М.М., доцент</i>		
<i>Аналіз систем і методів оцінки придатності земель</i>	<i>Поліщук М.М., доцент</i>		
<i>Експериментальне дослідження та оцінка ефективності системи</i>	<i>Поліщук М.М., доцент</i>		
<i>Нормоконтроль</i>	<i>Багнюк Н.В., доцент</i>		
<i>Гарант ОП</i>	<i>Гринюк С.В., доцент</i>		
<i>Показник запозичень тексту</i>	_____ %		
<i>Академічна доброчесність</i>	<i>Міскевич О.І., ст. викладач</i>		

7. Дата видачі завдання 18.06.2025 р.

## КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1.	<i>Огляд літератури із досліджуваної проблеми, аналіз предметної області та наявних рішень</i>	до 26.08.2025 р.	
2	<i>Теоретичні основи оцінки придатності земель та технологій розумного землеробства</i>	до 04.09.2025 р	
3.	<i>Аналіз систем і методів оцінки придатності земель</i>	до 24.09.2025 р.	
4.	<i>Експериментальне дослідження та оцінка ефективності системи</i>	до 12.10.2025 р.	
5.	<i>Висновки та пропозиції</i>	До 25.10.2025 р	
6.	<i>Формування переліку використаних джерел</i>	До 27.10.2025 р.	
7.	<i>Формування додатків</i>	До 30.10.2025 р.	
8.	<i>Оформлення ілюстративного матеріалу</i>	До 05.11.2025 р.	
9..	<i>Представлення остаточного варіанту кваліфікаційної роботи керівникові</i>	До 11.11.2025 р.	
10.	<i>Нормоконтроль</i>	До 29.11.2025 р.	
11.	<i>Інструментальна перевірка на академічний плагіат</i>	До 02.12.2025 р.	
12.	<i>Здача кваліфікаційної роботи та всіх супровідних документів на кафедру</i>	До 09.12.2025 р.	

Здобувач вищої освіти

\_\_\_\_\_ (підпис)

Стахурський А.М.

\_\_\_\_\_ (прізвище, ініціали)

Керівник кваліфікаційної роботи

\_\_\_\_\_ (підпис)

Поліщук М.М.

\_\_\_\_\_ (прізвище, ініціали)

## АНОТАЦІЯ

Стахурський А. М. Оцінка придатності землі в розумних фермах на основі IoT та ШІ. Рукопис.

Кваліфікаційна робота магістра ОП «Комп'ютерна інженерія» спеціальності 123 Комп'ютерна інженерія. Луцький національний технічний університет. Луцьк, 2025.

Кваліфікаційна робота складається з вступу, трьох розділів, висновків, переліку використаних джерел, додатку.

У першому розділі розглянуто концепцію «розумного землеробства» (Smart Farming) як базову парадигму цифрової трансформації агровиробництва та проаналізовано ключові складові його інфраструктури. Проаналізовано підходи до оцінювання придатності земель у межах систем Smart Farming із використанням сучасних алгоритмів глибинного навчання, зокрема рекурентних нейронних мереж типу LSTM.

У другому розділі виконано аналіз існуючих систем і методів оцінювання придатності земель із позицій застосування технологій Інтернету речей та штучного інтелекту. Охарактеризовано склад і структуру експериментальних наборів даних, що використовуються для навчання моделей прогнозування, та обґрунтовано онтологічний підхід до інтеграції гетерогенних інформаційних ресурсів агромоніторингу.

У третьому розділі здійснено експериментальні дослідження розробленої інтелектуальної системи оцінки придатності земель на основі технологій IoT та штучного інтелекту.

Ключові слова: Smart Farming, Інтернет речей, IoT, оцінка придатності земель, штучний інтелект, LSTM, нейронні мережі, агромоніторинг, прогнозування родючості ґрунтів, онтологічні моделі

## ANNOTATION

Stahurskyi A. Land Suitability Assessment in Smart Farms Based on IoT and AI. Manuscript.

Qualification work of the master of the specialty «Computer Engineering» specialty 123 Computer Engineering. Lutsk National Technical University. Lutsk, 2025.

Qualification work consists of an introduction, three chapters, conclusions, a list of references, and an appendix.

The first chapter examines the concept of 'Smart Farming' as the basic paradigm of digital transformation in agricultural production and analyzes the key components of its infrastructure. Approaches to land suitability assessment within Smart Farming systems using modern deep learning algorithms, in particular LSTM-type recurrent neural networks, are analyzed.

The second chapter analyzes existing systems and methods for land suitability assessment from the perspective of applying Internet of Things and artificial intelligence technologies. The composition and structure of experimental datasets used for training predictive models are described, and an ontological approach to integrating heterogeneous agromonitoring information resources is justified.

In the third chapter, experimental studies of the developed intelligent land suitability assessment system based on IoT and artificial intelligence technologies were carried out.

Keywords: Smart Farming, Internet of Things, IoT, land suitability assessment, artificial intelligence, LSTM, neural networks, agromonitoring, soil fertility forecasting, ontological models

## ЗМІСТ

ВСТУП .....	8
РОЗДІЛ 1 ТЕОРЕТИЧНІ ОСНОВИ ОЦІНКИ ПРИДАТНОСТІ ЗЕМЕЛЬ ТА ТЕХНОЛОГІЙ РОЗУМНОГО ЗЕМЛЕРОБСТВА .....	10
1.1 Сутність і завдання оцінки придатності земель у сучасному агромоніторингу .....	10
1.2 Концепція «розумного землеробства» (Smart Farming) та її складові .....	17
1.2.1 Інфраструктура датчиків та Інтернет речей (IoT) .....	19
1.2.2 Кіберфізичні системи та польова автоматизація .....	19
1.2.3 Платформи обробки даних, Big Data та хмарні сервіси .....	20
1.2.4 Аналітика, штучний інтелект та системи підтримки рішень .....	20
1.2.5 Людино-машинні інтерфейси та цифрові сервіси .....	21
1.2.6 Стандарти, інтероперабельність та кібербезпека .....	22
1.2.7 Взаємозв'язок Smart Farming та оцінки придатності земель .....	22
1.3 Використання технологій штучного інтелекту (ШІ) у задачах класифікації та прогнозування родючості ґрунтів .....	23
1.3.1 Класифікація родючості ґрунтів за допомогою алгоритмів машинного навчання .....	23
1.3.2 Прогнозування родючості ґрунтів і параметрів агросистем .....	24
1.3.3 Використання супутникових та IoT-даних для оцінки родючості .....	25
1.3.4 Інтерпретація моделей ШІ та формування рекомендацій .....	26
1.4 Розумне сільське господарство з використанням технології Інтернету речей .....	27
РОЗДІЛ 2 АНАЛІЗ СИСТЕМ І МЕТОДІВ ОЦІНКИ ПРИДАТНОСТІ ЗЕМЕЛЬ.....	30
2.1 Архітектура розумних ферм на основі IoT та ШІ.....	30
2.2 Характеристика набору даних для оцінки придатності земель .....	32
2.3 Онтологічний підхід до інтеграції гетерогенних даних в системах оцінки придатності земель.....	39

2.4 Візуалізація даних і формування рекомендацій для фермерів.....	41
2.4.1 Принципи візуалізації результатів оцінки придатності земель .....	41
2.4.2 Інтерактивні панелі моніторингу (dashboards) для розумної ферми.....	42
2.4.3 Інтерпретація результатів моделей ШІ та пояснюваність рекомендацій .....	44
2.4.4 Формування персоналізованих рекомендацій для фермерів .....	44
РОЗДІЛ 3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ .....	46
3.1 Вихідні дані та умови експерименту .....	46
3.2 Тестування системи в умовах розумної ферми.....	47
3.3 Аналіз точності та продуктивності алгоритмів ШІ.....	50
3.4 Порівняння результатів із традиційними методами оцінки родючості .....	56
ВИСНОВКИ.....	60
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	62
ДОДАТКИ.....	66

## ВСТУП

Інтеграція технологій Інтернету речей (IoT) із методами штучного інтелекту та глибокого машинного навчання відкриває нові можливості для побудови систем прогнозування придатності земель на основі реальних потоків сенсорних даних, супутникових спостережень та історичних агроекологічних записів. Застосування нейромережевих моделей, зокрема рекурентних мереж типу LSTM, дозволяє враховувати складні нелінійні взаємозв'язки між кліматичними, ґрунтовими та агротехнічними параметрами, підвищуючи точність просторового зонування територій та формування персоналізованих рекомендацій для аграрного виробника. Саме тому дослідження ефективності оцінки придатності земель у розумних фермах на основі IoT та штучного інтелекту є науково обґрунтованим, практично значущим та актуальним напрямом розвитку сучасних систем цифрового землеробства.

Метою кваліфікаційної роботи є розробка та експериментальна оцінка інтелектуальної системи оцінки придатності земель у середовищі розумних ферм на основі технологій Інтернету речей і методів штучного інтелекту.

Для досягнення поставленої мети в роботі передбачено вирішення таких завдань:

- визначити ключові тенденції розвитку технологій «розумного землеробства»;
- дослідити інфраструктуру розумних аграрних систем на базі технологій Інтернету речей (IoT);
- сформувати комплексну архітектуру інтелектуальної системи оцінювання на основі IoT та ШІ;
- обґрунтувати вибір і структуру наборів експериментальних даних, необхідних для тестування та валідації моделей прогнозування;
- провести експериментальне тестування системи в умовах розумної ферми;

– порівняти результати роботи розробленої системи з традиційними методами оцінки родючості ґрунтів.

Об'єктом дослідження є моніторинг агроекологічного стану земельних ресурсів у системах розумного землеробства з використанням цифрових технологій збору та обробки даних.

Предметом дослідження є методи та інформаційно-програмні засоби оцінки придатності земельних ділянок на основі інтеграції технологій Інтернету речей (IoT), онтологічної уніфікації даних і алгоритмів штучного інтелекту, зокрема нейромережових моделей типу LSTM.

Наукова новизна роботи полягає у розробці комплексного підходу до інтелектуальної оцінки придатності земель, який поєднує багатоканальний збір гетерогенних IoT-даних, онтологічну модель їхньої семантичної уніфікації та глибинні рекурентні нейронні мережі для просторово-часового прогнозування родючості ґрунтів. Запропоновано для задач аграрного моніторингу інтегровану архітектуру безперервної обробки потоків телеметрії з автоматичним відновленням втрачених показників і сценарною візуалізацією результатів оцінки зон придатності земель у середовищі Smart Farming.

Практичне значення роботи полягає у можливості безпосереднього використання розробленої інтелектуальної системи в господарствах точного землеробства для оперативного моніторингу агроекологічних показників, автоматизованої класифікації земель за рівнем придатності та формування рекомендацій щодо оптимізації землекористування. Результати дослідження можуть бути застосовані для підвищення ефективності агровиробництва, зменшення витрат на агрохімічні дослідження, мінімізації ризиків деградації ґрунтів та підтримки прийняття управлінських рішень щодо вибору агротехнологічних стратегій.

Основні положення кваліфікаційної роботи апробовано на Міжнародній науково-практичній конференції молодих вчених та студентів (6 травня 2025 р.) [1].

## РОЗДІЛ 1

### ТЕОРЕТИЧНІ ОСНОВИ ОЦІНКИ ПРИДАТНОСТІ ЗЕМЕЛЬ ТА ТЕХНОЛОГІЙ РОЗУМНОГО ЗЕМЛЕРОБСТВА

#### 1.1 Сутність і завдання оцінки придатності земель у сучасному агромоніторингу

У сучасних умовах інтенсивного використання земельних ресурсів, кліматичних змін та зростання вимог до продовольчої безпеки оцінка придатності земель посідає центральне місце в системі агромоніторингу та прийнятті управлінських рішень у сільському господарстві. Під оцінкою придатності земель, як правило, розуміють систематичний процес визначення того, наскільки конкретна земельна ділянка відповідає вимогам певного виду сільськогосподарського використання (культури, технології, системи землеробства) з урахуванням її природних, агрохімічних, кліматичних, екологічних та соціально-економічних характеристик. Класичні підходи, започатковані у «Framework for Land Evaluation» ФАО, пропонують ранжувати землі за класами придатності (S1 – високопридатні, S2 – помірно придатні, S3 – маргінально придатні, N – непридатні) для конкретного виду використання [2].

На відміну від традиційних ґрунтово-агрономічних обстежень, що базувалися переважно на разових польових зйомках і експертних оцінках, сучасний агромоніторинг ґрунтується на інтеграції мультиджерельних потоків даних: супутникових та безпілотних знімків, наземних сенсорних мереж (у тому числі IoT-датчиків вологості, температури та поживних речовин), метеорологічних спостережень, геоінформаційних систем (ГІС), методів дистанційного зондування Землі, а також аналітичних моделей – від класичних АНР та інших MCDM-процедур до сучасних алгоритмів машинного навчання та глибокого навчання [3].

У такому середовищі оцінка придатності земель виконує функцію «аналітичного ядра», яке перетворює розрізнені потоки просторово

розподілених даних на узгоджені управлінські продукти – карти класів придатності, зони ризику, рекомендації щодо структури посівних площ та технологій обробітку, що можуть безпосередньо використовуватися в системах підтримки прийняття рішень, платформних рішеннях «розумної ферми» та сервісах точного землеробства [4].

З теоретичної точки зору, оцінка придатності земель базується на концепції узгодження (matching) між вимогами певного виду землекористування (наприклад, вирощування пшениці озимої, кукурудзи на зерно, овочевих культур чи органічного садівництва) та наявними властивостями земельної ділянки. У методології ФАО це узгодження описується через перехід від вимог культури до якостей землі (land qualities) й конкретних характеристик землі (land characteristics), що вимірюються або обчислюються. До основних груп таких характеристик належать:

- ґрунтові властивості (гранулометричний склад, вміст гумусу, рН, забезпеченість NPK, кам'янистість, глибина ґрунтового профілю);
- рельєф (крутість схилу, експозиція, мікрорельєф);
- гідрологічні параметри (глибина залягання ґрунтових вод, дренажність, ризик підтоплення);
- кліматичні умови (сума активних температур, кількість опадів, тривалість безморозного періоду, частота посух);
- екологічні обмеження (засолення, кислотність, забруднення важкими металами чи пестицидами, ерозійна небезпека) [5].

Розвиток концепції FESLM (Framework for Evaluating Sustainable Land Management) розширив класичне поняття придатності земель, запропоноване у Framework for Land Evaluation, у бік оцінки сталості землекористування, де придатність розглядається не лише як відповідність земель поточним вимогам культури, а й як здатність системи землекористування залишатися продуктивною та екологічно збалансованою в часі [6]. Саме перехід від вузько продуктивістського підходу (максимізація врожайності за будь-яку ціну) до концепції сталого землекористування з урахуванням екологічних, соціальних та

економічних критеріїв визначає сучасне розуміння оцінки придатності земель у агромоніторингу.

Концептуальну сутність оцінки придатності земель у системі агромоніторингу подано у вигляді узагальненої схеми, що відображає взаємодію ключових факторів та моделей аналізу (рис. 1.1).

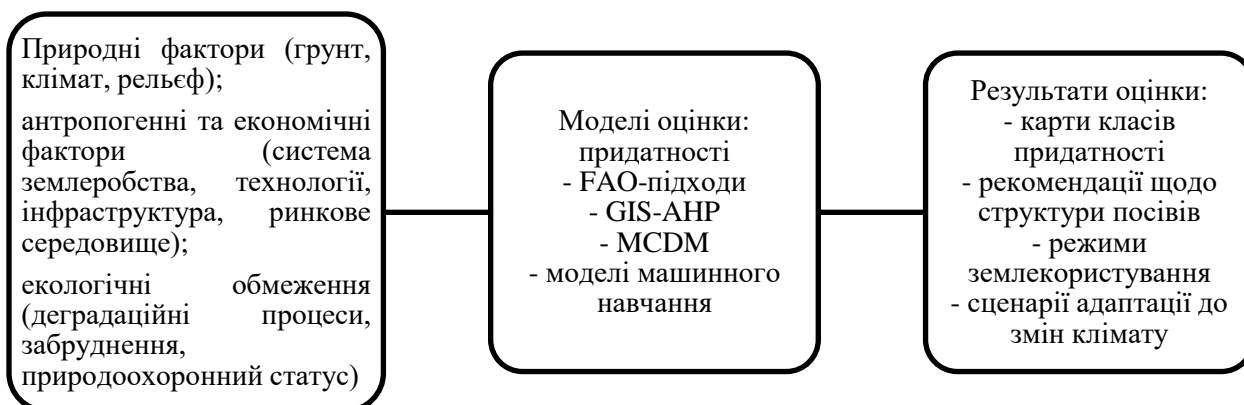


Рисунок 1.1 – Концептуальна схема сутності оцінки придатності земель у системі агромоніторингу [6]

У структурі сучасних систем агромоніторингу оцінка придатності земель виконує переважно стратегічну функцію. Якщо оперативний моніторинг зосереджений на поточному стані посівів (індекси рослинності NDVI, EVI, індикатори листової поверхні LAI, вологість ґрунту, стан рослинності за супутниковими та дронними даними), то оцінка придатності відповідає за середньо- та довгострокові рішення:

- де доцільно розміщувати певні культури;
- які технології обробітку й зрошення застосовувати;
- які ділянки потребують меліорації, зміни культури або консервації;
- які сценарії землекористування є сталими в умовах змін клімату [7].

Сучасні дослідження демонструють, що інтеграція дистанційного зондування, ГІС та методів багатокритеріального аналізу (АНР, МСЕ/MCDM, fuzzy-логіка) дає змогу будувати високоточні карти придатності для окремих культур або систем землеробства, причому з урахуванням як біофізичних

факторів (клімат, ґрунт, рельєф), так і соціально-економічних (доступність водних ресурсів, транспортна інфраструктура, наближеність до ринків збуту) [3].

Для України особливо актуальною є агроекологічна оцінка придатності земель з урахуванням деградаційних процесів, зміни клімату та переходу до органічного виробництва. Дослідження степової зони та Лісостепу України демонструють значну частку земель із обмеженою придатністю або непридатних для екологічного землеробства, що вимагає просторово обґрунтованого планування, зонування та введення природоохоронних обмежень [8]. У поєднанні з просторовими моделями впливу кліматичних змін це дає змогу формувати сценарії перебудови структури посівів, зони ризику для певних культур та пріоритетні зони для розвитку органічного садівництва чи зрошуваного землеробства.

Разом з тим швидкий розвиток розумних ферм, заснованих на технологіях Інтернету речей та штучного інтелекту (AIoT), зміщує акценти від разових кадастрових оцінок до динамічних, даними-керованих оцінок придатності. У таких системах дані з IoT-сенсорів (вологості ґрунту, температури, електропровідності, рівня ґрунтових вод) та мікроклімату безперервно надходять до аналітичних модулів, де за допомогою алгоритмів машинного навчання уточнюються карти придатності та зони ризику на основі фактичної реакції культур на умови середовища.

Структурну роль оцінки придатності земель у контурі сучасної системи агромоніторингу доцільно продемонструвати як послідовність етапів трансформації даних – від їхнього первинного надходження до прийняття управлінських рішень. Такий підхід дозволяє чітко показати, як різномірні джерела інформації інтегруються у геоінформаційну базу, перетворюються на систему екологічних та агрономічних індикаторів, обробляються спеціалізованими моделями оцінки придатності та, зрештою, формують карти придатності й рекомендації для менеджменту агроландшафтів. Узагальнене подання цієї логіки у вигляді блок-схеми наведено на рисунку 1.2.

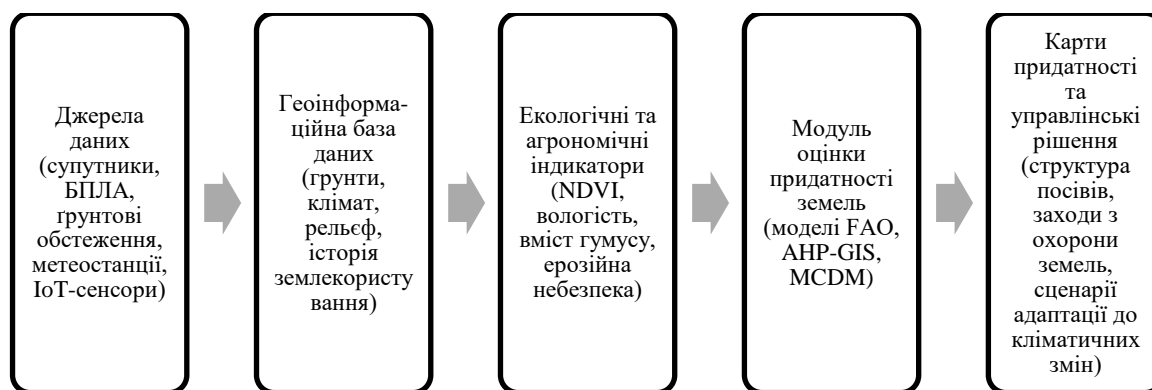


Рисунок 1.2 – Місце оцінки придатності земель у загальній структурі системи агромоніторингу

У контексті цифровізації агросектору, розвитку точного землеробства та розумних ферм до основних завдань оцінки придатності земель у системі агромоніторингу належать:

- класифікація земель за придатністю для конкретних видів використання. Це включає побудову карт класів придатності для ключових культур (пшениця, кукурудза, соняшник, ріпак, овочеві та садові культури) з урахуванням ґрунтових, кліматичних, гідрологічних і соціальних факторів. На практиці широко застосовуються підходи GIS-AHP, fuzzy-логіка, багатокритеріальний аналіз (MCDM), а також моделі машинного навчання, що дозволяють підвищити точність класифікації порівняно з традиційними методами [3];

- виявлення обмежень та зон ризику – оцінка придатності дає змогу ідентифікувати ділянки з критичними обмеженнями: високою ерозійною небезпекою, дефіцитом вологи, засоленням, забрудненням, надмірною розораністю, ризиком підтоплень. У системах агромоніторингу ці просторові дані поєднуються з постійним контролем інтенсивності землекористування, динаміки рослинного покриву та реакції культур на стреси, що особливо важливо для планування меліоративних заходів і протиерозійного захисту [8];

- підтримка просторово обґрунтованого планування землекористування. На основі результатів оцінки придатності формуються рекомендації щодо розміщення культур, зонування територій під інтенсивне, екстенсивне, органічне та природоохоронне використання (екологічні коридори, консервація

деградованих земель, захисні лісосмуги). Це особливо важливо для регіонів із високим антропогенним навантаженням та кліматичними ризиками, де неправильний вибір землекористування може призвести до незворотної деградації ґрунтів [7];

– забезпечення продовольчої безпеки та сталого розвитку. На рівні державної аграрної політики оцінка придатності земель використовується для аналізу потенціалу виробництва продовольства, моделювання сценаріїв зміни структури посівів, оцінки впливу кліматичних змін на продуктивність агроландшафтів і визначення пріоритетних зон для інвестицій. Це створює інформаційну основу для реалізації цілей сталого розвитку ООН, пов'язаних із подоланням голоду, збереженням земельних ресурсів та адаптацією до змін клімату [5];

– інтеграція з технологіями точного землеробства та розумних ферм – карти придатності доповнюють карти врожайності, електропровідності ґрунту, мікрорельєфу та слугують базою для диференційованого внесення добрив, насіння та засобів захисту, оптимізації зрошення, управління рухом техніки. В умовах розумної ферми вони можуть використовуватися як шар «повільно змінної» інформації, на який накладаються оперативні дані IoT-сенсорів і супутникового моніторингу, формуючи комплексні AIoT-рішення для автоматизованого управління агротехнологіями [9];

– оцінка сталості та екологічної ефективності використання земель. У поєднанні з підходами FESLM оцінка придатності дозволяє не лише визначити потенціал землі для певного виду використання, а й оцінити, чи буде таке використання екологічно й соціально виправданим у довгостроковій перспективі. Йдеться про аналіз ерозійних процесів, запасів органічної речовини в ґрунті, викидів парникових газів, впливу на біорізноманіття та водні ресурси. Ці аспекти набувають особливого значення в умовах реалізації кліматичних стратегій та переходу до вуглецево-нейтрального агросектору [6].

Узагальнену систему цілей і функцій, які реалізує оцінка придатності земель у сучасному агромоніторингу, доцільно розглядати не ізольовано, а в

тісному зв'язку з основними напрямками управління агроландшафтами. Вона одночасно забезпечує інформаційну підтримку планування землекористування, розвитку точного землеробства та розумних ферм, управління ризиками деградації, формування аграрної політики й систем екологічного моніторингу. Таку інтегровану роль оцінки придатності земель зручно відобразити у вигляді схемної моделі взаємозв'язків із ключовими підсистемами управління агросферою (рис. 1.3).



Рисунок 1.3 – Узагальнена структура завдань оцінки придатності земель у системі агромоніторингу

Отже, у сучасному агромоніторингу оцінка придатності земель розглядається не як разова кадастрова процедура, а як безперервний, даними-керований процес, інтегрований у цифрові платформи управління агроландшафтами й розумними фермами. Її сутність полягає у зіставленні вимог конкретних видів землекористування з властивостями земельних ресурсів у просторі й часі, а ключові завдання охоплюють класифікацію земель за придатністю, виявлення обмежень і зон ризику, підтримку просторового планування, забезпечення продовольчої безпеки та оцінку сталості агросистем.

В умовах інтенсивного впровадження IoT-технологій і методів штучного інтелекту оцінка придатності земель еволюціонує від статичної картографічної процедури до динамічного інтелектуального модуля, що в режимі, наближеному до реального часу, підживлюється даними сенсорних мереж і моделей машинного навчання та стає невід'ємною складовою розумних ферм нового покоління.

## **1.2 Концепція «розумного землеробства» (Smart Farming) та її складові**

Поняття «розумного землеробства» (Smart Farming, Agriculture 4.0) охоплює комплекс цифрових технологій, спрямованих на підвищення ефективності, стійкості та керованості агровиробництва за рахунок масового застосування датчиків, Інтернету речей (IoT), кіберфізичних систем (CPS), хмарних та периферійних обчислень, аналітики великих даних і штучного інтелекту (ШІ). У такій парадигмі сільськогосподарське підприємство або «розумна ферма» розглядається як розподілена кіберфізична система, в якій фізичні процеси вирощування культур, роботи техніки та стан агроландшафтів безперервно відображаються в цифровому середовищі, а управлінські рішення формуються на основі даних у реальному або наближеному до реального часі [10].

Сучасні огляди відзначають, що ядром Smart Farming є саме даноцентричний підхід: агросистема генерує різноманітні потоки даних (сенсори ґрунту та мікроклімату, знімки БПЛА, супутникові продукти, телеметрія техніки, фермерські журнали), які збираються у хмарно-периферійну інфраструктуру, де виконуються фільтрація, злиття, статистичний та інтелектуальний аналіз, моделювання і візуалізація. На основі цих даних реалізуються сервіси підтримки рішень щодо вибору культур, режимів поливу, живлення, захисту рослин, завантаження техніки, а також оцінки ризиків і стійкості агросистем [11].

У структурному плані розумне землеробство зазвичай подають як багаторівневу архітектуру: рівень пристроїв і датчиків (IoT), рівень кіберфізичних систем та автоматизації в полі, рівень платформ обробки даних (Big Data, хмара, edge/fog), рівень аналітики та ШІ, а також рівень людино-машинної взаємодії (НМІ) та цифрових сервісів для користувачів – фермерів, агрономів, менеджерів. Над усією цією інфраструктурою «накладаються» вимоги до стандартизації, інтероперабельності, кібербезпеки й захисту даних, які визначають можливість масштабування та інтеграції окремих рішень [12]. На рисунку 1.4 подано узагальнену структурну схему застосування технологій Інтернету речей у сфері розумного сільського господарства, яка ілюструє взаємодію ключових компонентів агромоніторингу, точного землеробства, логістики, аналітики та автоматизованих виробничих систем.

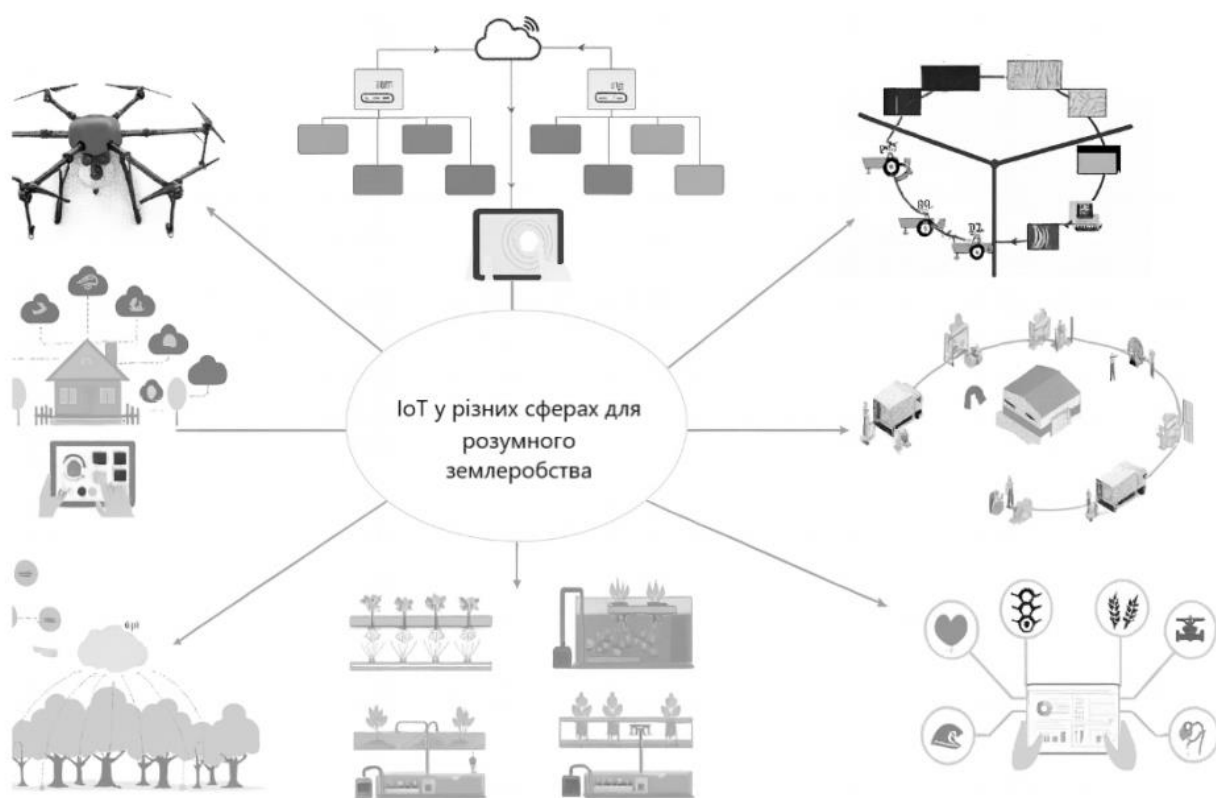


Рисунок 1.4 – Схематична діаграма, що ілюструє застосування Інтернету речей у різних сферах для розумного землеробства [12]

Важливим також є те, що оцінка придатності земель у розумному землеробстві перестає бути лише аналітичною процедурою на основі карт ґрунтів: вона інтегрується в потоки IoT-даних, моделі машинного навчання та системи підтримки рішень, які в режимі «онлайн/near real-time» пропонують оптимальні варіанти використання кожної ділянки поля, конфігурації сівозміни та налаштувань технологій (полив, удобрення, навантаження техніки).

### 1.2.1 Інфраструктура датчиків та Інтернет речей (IoT)

Базовою складовою Smart Farming є інфраструктура датчиків та IoT-пристроїв, яка забезпечує безперервний збір даних про стан ґрунту, рослин, мікроклімату, техніки та довкілля. До типових елементів належать сенсори вологості та температури ґрунту, електропровідності, вмісту азоту, рН, датчики атмосферних параметрів, рівня води, стану зрошувальної мережі, а також бортові датчики на сільськогосподарській техніці (GPS/ГЛОНАСС, вимірювачі витрат пального, датчики навантаження) і камери видимого та багатоспектрального діапазонів [13].

Комунікаційна частина цієї інфраструктури базується на низці бездротових технологій (LoRaWAN, NB-IoT, ZigBee, Wi-Fi, мобільний зв'язок 4G/5G), які забезпечують передавання даних від польових вузлів до шлюзів і далі – у хмарні чи периферійні обчислювальні ресурси. Правильно спроектована IoT-інфраструктура дозволяє суттєво підвищити просторово-часову роздільну здатність агромоніторингу та забезпечити ті самі дані, які надалі будуть використані для оцінки придатності земель, прогнозування врожайності та прийняття оперативних рішень.

### 1.2.2 Кіберфізичні системи та польова автоматизація

Кіберфізичні системи (CPS) у розумному землеробстві – це інтегровані комплекси, в яких фізичні процеси в полі (рух машин, полив, внесення добрив, обробка посівів) тісно пов'язані з цифровими моделями, алгоритмами керування та мережевою інфраструктурою. До цієї категорії належать автоматизовані поливні системи, роботизовані трактори й обприскувачі, автономні платформи

для механізованих операцій, мобільні роботи-скаути, які виконують обстеження і локальні втручання (наприклад, точкове внесення ЗЗР чи добрив) [10].

Систематичні огляди вказують, що CPS у сільському господарстві розглядаються як ключова технологія досягнення високоточного землеробства: завдяки замкненим контурам «сенсори – аналіз – приводи» вони дозволяють реалізувати адаптивні режими обробки поля, враховуючи просторову неоднорідність ґрунтів, рельєфу та стану рослин. У контексті оцінки придатності земель CPS важливі тим, що забезпечують зв'язок між картами придатності та реальними діями техніки – наприклад, зміною глибини обробітку, норм висіву чи швидкості руху агрегату на різних ділянках поля.

### 1.2.3 Платформи обробки даних, Big Data та хмарні сервіси

Другим критично важливим шаром Smart Farming є платформи обробки даних, які реалізують збирання, зберігання, попередню обробку та аналіз великих масивів агроданих (Big Data). В сучасних архітектурах застосовується модель спільної роботи хмара – периферія – пристрої, де периферійні вузли (edge/fog) виконують фільтрацію, агрегацію і базову аналітику в полі, а хмарні сервіси – складне моделювання, тренування моделей машинного навчання й зберігання історичних даних [14].

Такі платформи підтримують інтерфейси для підключення IoT-шлюзів, БПЛА, супутникових сервісів, зовнішніх метеорологічних та ринкових даних, а також модулі геоінформаційного аналізу. Вони дозволяють будувати цілісні цифрові двійники полів, ферм і навіть регіонів, у яких може обчислюватися придатність земель, оцінюватися сценарії зміни клімату та структури посівів. Для розумних ферм саме платформи big data стають технологічною основою інтеграції окремих модулів – від оцінки придатності до планування виробництва.

### 1.2.4 Аналітика, штучний інтелект та системи підтримки рішень

На верхніх рівнях архітектури Smart Farming ключову роль відіграють аналітика даних, машинне навчання та системи підтримки прийняття рішень (DSS). Сучасні дослідження демонструють, що алгоритми ML і ШІ застосовуються для прогнозування врожайності, діагностики хвороб, оптимізації

поливу й удобрення, рекомендацій щодо вибору культур, а також для оцінки придатності земель та класифікації їх за класами для конкретних культур чи технологій [11].

Зокрема, у низці робіт запропоновано ML-моделі (Random Forest, Gradient Boosting, нейронні мережі), що на основі ґрунтових, кліматичних, топографічних змінних та супутникових індексів (NDVI тощо) прогнозують придатність територій для певних культур з точністю, яка перевищує традиційні експертні підходи. Це відкриває можливість створення інтелектуальних систем підтримки рішень, у яких карти придатності земель формуються автоматично та інтегруються з іншими шарами просторових даних – наприклад, економічними показниками або ризиками деградації [15].

У поєднанні з IoT-рішеннями та edge-аналітикою такі системи здатні працювати в режимі майже реального часу, надаючи фермеру або агроменеджеру рекомендації безпосередньо у польових умовах – через мобільні додатки, онборд-дисплеї техніки або веб-панелі управління.

#### 1.2.5 Людино-машинні інтерфейси та цифрові сервіси

Людино-машинні інтерфейси (НМІ) та цифрові сервіси формують «фасад» розумного землеробства, забезпечуючи зрозумілу взаємодію користувачів із складними аналітичними системами. До них належать веб-панелі моніторингу, мобільні додатки для агрономів і фермерів, вбудовані інтерфейси на тракторах та обприскувачах, голосові асистенти, AR-/VR-рішення для навчання та планування [13].

Успішні платформи Smart Farming підкреслюють необхідність інтуїтивних візуалізацій (карти, графіки, теплові карти, дашборди), можливість налаштування сценаріїв (наприклад, автоматичного запуску поливу при певних порогах вологості ґрунту), а також інтеграцію з бізнес-процесами ферми (управління запасами, фінансовий облік, планування робіт). Саме через НМІ модуль оцінки придатності земель «перекладається» на мову практичних рекомендацій, наприклад, підказки «цю ділянку доцільно використовувати під

озиму пшеницю з інтенсивною технологією, а сусідню – під багаторічні трави з екологічним режимом».

#### 1.2.6 Стандарти, інтероперабельність та кібербезпека

Масштабування Smart Farming неможливе без стандартизації та інтероперабельності. У сфері машин і знарядь важливу роль відіграє стандарт ISO 11783 (ISOBUS), який визначає єдиний протокол обміну даними між тракторами й причіпними агрегатами різних виробників, дозволяючи реалізувати «plug & play» взаємодію та точне керування агрегатами [16].

Водночас для сенсорних мереж і геопросторових сервісів значення мають стандарти OGC (SensorThings API, WMS/WFS), моделі даних і семантичні профілі, які забезпечують узгоджене описання об'єктів, явищ і вимірювань. Саме інтероперабельність даних дозволяє поєднувати карти ґрунтів, показники сенсорів, супутникові продукти й результати моделей придатності в одній ГІС-платформі [17].

Паралельно зростає актуальність кібербезпеки в розумному землеробстві: дослідження фіксують широкий спектр загроз – від атак на IoT-пристрої й шлюзи до компрометації хмарних платформ і підміни агрономічних рекомендацій. Проблемами є слабка автентифікація, відсутність оновлень, використання небезпечних протоколів, недостатній контроль доступу. У відповідь пропонуються багаторівневі стратегії захисту (шифрування, сегментація мережі, моніторинг аномалій, zero-trust-підходи), які мають враховувати специфіку агросередовища та обмежені ресурси польових пристроїв [18].

#### 1.2.7 Взаємозв'язок Smart Farming та оцінки придатності земель

Узгодження концепції розумного землеробства з оцінкою придатності земель має двосторонній характер. З одного боку, Smart Farming значно розширює дані, моделі та інструменти, доступні для оцінки придатності: потоки сенсорних даних, супутникові спостереження, моделі машинного навчання та цифрові двійники дозволяють переходити від статичних карт до динамічних, сценарно-орієнтованих оцінок, які враховують зміни клімату, деградаційні процеси та технологічні інновації [19].

З іншого боку, результати оцінки придатності земель виступають еталонним шаром для систем Smart Farming, визначаючи обмеження й пріоритети при прийнятті рішень: де доцільно інвестувати в краплинне зрошення, на яких ділянках варто переходити до менш інтенсивних технологій, які поля мають високий потенціал під адаптивні сівозміни тощо. В перспективних розробках пропонується інтегрувати модулі оцінки придатності безпосередньо в DSS для фермерів та аграрних політик, а також використовувати пояснювальний ШІ (XAI) для прозорого обґрунтування рекомендацій щодо вибору культур і режимів землекористування [20].

Таким чином, Smart Farming виступає як технологічний «двигун» еволюції оцінки придатності земель – від статичних експертних схем до інтегрованих, даноцентричних та інтелектуальних систем, що працюють у реальному часі та підтримують стале управління агроландшафтами.

### **1.3 Використання технологій штучного інтелекту (ШІ) у задачах класифікації та прогнозування родючості ґрунтів**

У контексті оцінки придатності земель важливо, що моделі ШІ здатні працювати з багатовимірними наборами даних – лабораторними аналізами ґрунту, спектральними характеристиками, супутниковими індексами, часовими рядами вологості й температури, IoT-даними з сенсорних мереж. Це створює передумови для побудови як класифікаційних моделей, що відносять ділянки до класів родючості, так і регресійних/прогностичних моделей, які оцінюють кількісні параметри (вміст елементів живлення, органічного вуглецю, потенційний урожай тощо) та їхню динаміку.

#### **1.3.1 Класифікація родючості ґрунтів за допомогою алгоритмів машинного навчання**

Одним із найпоширеніших напрямів застосування ШІ є класифікація ґрунтів за рівнем родючості. У низці праць запропоновано підходи, де як вхідні ознаки використовуються агрохімічні показники (вміст N, P, K, рН, органічна

речовина, електропровідність), текстурні характеристики, вологість, кліматичні параметри, а на виході формується клас «висока/середня/низька родючість» або бінарна оцінка «придатний/непридатний» для певної культури [21].

Для розв'язання подібних задач застосовуються як класичні ML-алгоритми (Decision Tree, Random Forest, k-NN, SVM, Naive Bayes), так і ансамблеві методи та глибокі нейронні мережі. Порівняльні дослідження демонструють, що ансамблеві моделі (Random Forest, Gradient Boosting) та згорткові нейронні мережі (1D-CNN для табличних даних) досягають точності класифікації понад 90–95 %, перевищуючи результати окремих базових алгоритмів [22].

Окремий напрямок – поєднання ML-моделей із апаратними платформами. Наприклад, у роботі [23] розроблено прототип IoT-системи, яка вимірює рН, температуру, вологість, вміст NPK і порівнює їх із прогнозами ML-моделі, що класифікує ґрунт як родючий або неродючий у реальному часі. Такі рішення є важливим кроком до перенесення моделей класифікації родючості безпосередньо «в поле» – на edge-пристрої розумних ферм.

### 1.3.2 Прогнозування родючості ґрунтів і параметрів агросистем

На відміну від класифікації, де оцінюється поточний стан ґрунту, прогностичні моделі спрямовані на передбачення майбутніх значень показників родючості або пов'язаних з ними агрономічних параметрів (урожайність, вміст ґрунтової вологи, органічного вуглецю, доступного азоту тощо). Для цього активно застосовуються регресійні ML-методи (Random Forest Regressor, XGBoost, SVR) та глибокі нейронні мережі (LSTM, CNN, трансформери).

Сучасні дослідження у сфері digital soil mapping демонструють, що комбінація польових вимірювань, карт-коваріат (рельєф, клімат, землекористування) та супутникових даних, опрацьованих ML-моделями, дозволяє з високою точністю прогнозувати просторовий розподіл доступних форм азоту, фосфору, калію, рН і вмісту органічного вуглецю [24]. Це безпосередньо пов'язано з задачами оцінки придатності земель: замість непрямих індикаторів фермер чи агропланувальник отримує картографічні шари з прогнозними значеннями агрохімічних властивостей на кілька сезонів уперед.

Іншою важливою групою є моделі прогнозування врожайності, де родючість ґрунту виступає однією з ключових складових. Глибокі нейронні мережі (включно з моделями з перенесенням навчання та багатоспектральними CNN) показали високу ефективність у прогнозуванні урожаю на основі поєднання супутникових індексів (NDVI, EVI), метеоданих, інформації про ґрунт і агротехніку. Для нашого дослідження такі підходи є цінними як джерело методології прогнозування потенціалу продуктивності земель за умов різних сценаріїв удобрення, зрошення та кліматичних змін.

### 1.3.3 Використання супутникових та IoT-даних для оцінки родючості

Сучасні моделі оцінки родючості ґрунтів дедалі частіше опираються на злиття супутникових і наземних (IoT) даних. Супутникові платформи (Landsat, Sentinel-2, MODIS тощо) забезпечують регулярні знімки з наборами спектральних каналів, з яких обчислюються вегетаційні й ґрунтові індекси (NDVI, NDMI, SAVI, індекси оголеного ґрунту). Їхні значення корелюють із вмістом органічної речовини, структурою ґрунту, запасами вологи та станом рослинного покриву.

Додатково до супутникових даних використовуються IoT-сенсори для моніторингу вологості, температури, електропровідності, рН, вмісту NPK та інших параметрів безпосередньо в кореневмісному шарі ґрунту. Огляди IoT-систем для управління станом ґрунту показують, що поєднання стаціонарних сенсорних вузлів, мобільних платформ (роботи, БПЛА) та хмарної аналітики дозволяє виконувати високоточне калібрування супутникових індексів та будувати моделі, які «перекладають» спектральні характеристики на оцінки родючості.

У низці робіт [21-24] запропоновано IoT-орієнтовані системи, де сенсорні мережі та ML-моделі інтегровані в єдину платформу: з польових вузлів надходять дані про NPK, вологість і мікроклімат, з супутників – NDVI/NDMI та інші індекси, після чого гібридні моделі III оцінюють родючість, формують карти зон із дефіцитом елементів живлення та пропонують диференційовані норми внесення добрив. Такий підхід є безпосередньо релевантним для

розумних ферм, де придатність земель оцінюється не лише за статичними властивостями, а й за поточною відповіддю агросистем на погодні та технологічні чинники.

#### 1.3.4 Інтерпретація моделей ШІ та формування рекомендацій

Попри високу точність, моделі глибокого навчання й складні ансамблі ML часто сприймаються як «чорні скриньки», що обмежує довіру з боку фермерів та агроекспертів. Тому у сфері агроаналітики активно розвиваються підходи інтерпретованого ШІ (Explainable AI, XAI), покликані зробити зрозумілими причини прогнозів та рекомендацій.

У дослідженнях з рекомендацій культур і добрив для конкретних ґрунтово-кліматичних умов [25] застосовуються методи SHAP, LIME, counterfactual-аналіз, часткові залежності та інші XAI-інструменти, які дозволяють візуалізувати внесок кожної ознаки (вміст NPK, pH, текстура, NDVI, метеопоказники) у кінцеве рішення моделі. Це дає змогу не лише пояснити, чому для певної ділянки рекомендовано конкретну культуру або норму добрив, а й виявити приховані закономірності, наприклад, критичні порогові значення вмісту вологи чи органічного вуглецю.

Для задач оцінки придатності земель XAI забезпечує підґрунтя для трасованих, обґрунтованих карт і рекомендацій: користувач може побачити, які фактори (ґрунтові, кліматичні, топографічні, технологічні) зробили ділянку «високопридатною» або «обмежено придатною», і які зміни (меліорація, зміна сівозміни, інвестиції в зрошення) потенційно переведуть її до вищого класу. У перспективних системах рекомендації щодо культур і технологій інтегруються з модулями економічного аналізу та оцінки ризиків, утворюючи повноцінні системи підтримки рішень для управління родючістю та землекористуванням у розумних фермах.

## 1.4 Розумне сільське господарство з використанням технології Інтернету речей

Розумне сільське господарство з використанням технології Інтернету речей базується на ідеї перетворення ферми на кіберфізичну систему, де фізичні процеси (стан ґрунту, ріст рослин, робота техніки, використання води й добрив) безперервно вимірюються мережами сенсорів, передаються в цифрові платформи та аналізуються в режимі реального часу. IoT-застосування в агросекторі охоплюють моніторинг ґрунту та мікроклімату, точне зрошення, керування технікою, відстеження посівів і тварин, а також оптимізацію логістики й зберігання продукції. У такому підході дані стають основою для прийняття рішень, а не побічним продуктом виробничого процесу.

Типова IoT-інфраструктура «розумної ферми» включає розподілені сенсорні вузли (вологість і температура ґрунту, електропровідність, рН, NPK, параметри мікроклімату, рівень води та тиск у системі зрошення), бездротові мережі (LoRaWAN, NB-IoT, ZigBee, Wi-Fi, 4G/5G) та шлюзи, які агрегують дані й передають їх до хмарних або периферійних (edge/fog) платформ для подальшої обробки. На рівні застосунків функціонують веб-кабінети й мобільні додатки для агрономів, системи підтримки рішень та аналітичні модулі, інтегровані з ГІС та картами полів [26].

Переваги використання IoT у сільському господарстві пов'язані насамперед із можливістю точного й диференційованого управління ресурсами. Безперервний моніторинг агрофізичних параметрів дозволяє реалізувати автоматизовані стратегії зрошення (вмикання/вимикання поливу за фактичними показниками вологості ґрунту), диференційоване внесення добрив залежно від локального дефіциту елементів живлення, оперативне реагування на стреси рослин (посуха, перезволоження, заморозки). Дослідження показують, що такі системи здатні зменшити витрати води на 20-40 %, добрив – на 10-30 % при одночасному зростанні стабільності врожайності та зниженні негативного впливу на довкілля.

Особливої актуальності набуває інтеграція IoT-інфраструктури з оцінкою придатності земель [19]. Сенсорні мережі та потоки даних із БПЛА й супутників забезпечують деталізовану інформаційну основу для побудови карт просторової неоднорідності ґрунтів, мікрорельєфу, водного режиму та проявів деградаційних процесів. На основі цих даних, з використанням моделей FAO, GIS-АНР, MCDM та алгоритмів машинного навчання, формуються динамічні карти придатності земель, які оновлюються в міру зміни стану агросистеми та кліматичних умов. У свою чергу, результати оцінки придатності (рис. 1.5) безпосередньо використовуються IoT-керованими системами для налаштування норм поливу, доз добрив та вибору оптимальних технологічних карт для окремих ділянок поля.

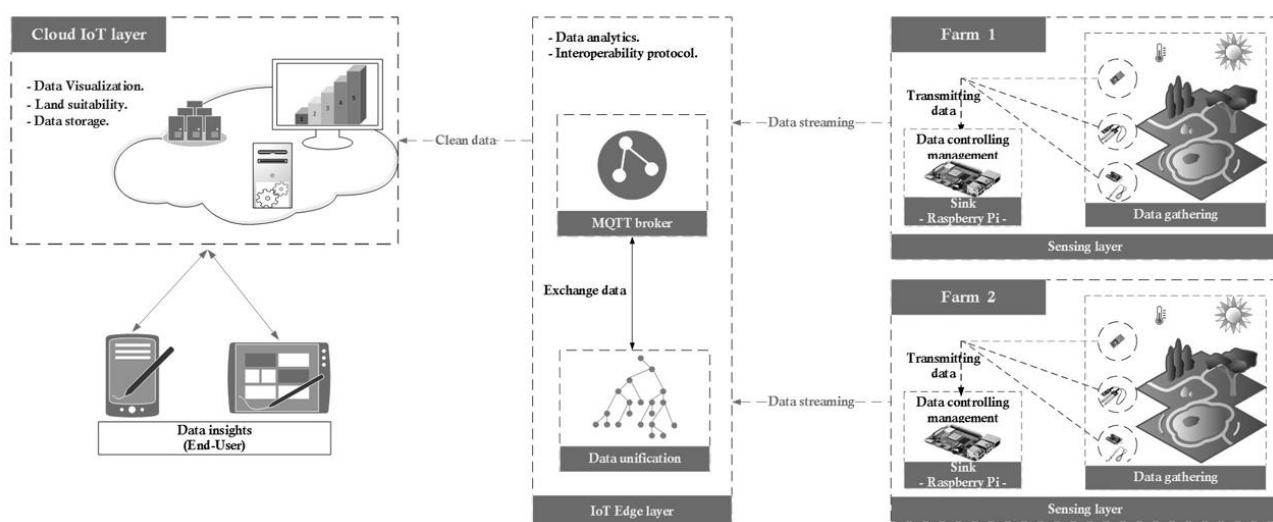


Рисунок 1.5 – Система моніторингу та прогнозування придатності земель [19]

Суттєвим викликом для розумного сільського господарства є питання стандартизації, інтероперабельності та кібербезпеки IoT-рішень. Різні виробники сенсорів, контролерів і платформ використовують несумісні протоколи та формати даних, що ускладнює інтеграцію систем на рівні господарства чи регіону. Для подолання цих бар'єрів важливими є впровадження галузевих стандартів (наприклад, ISO 11783/ISOBUS для техніки, OGC SensorThings API для сенсорних даних), а також розробка відкритих платформ, які підтримують уніфіковані моделі даних та API. Не менш критичною є побудова багаторівневої

системи кіберзахисту, що включає шифрування трафіку, автентифікацію пристроїв, сегментацію мережі та моніторинг аномалій, оскільки компрометація IoT-інфраструктури може призвести не лише до втрати даних, а й до прямого втручання в технологічні процеси на фермі.

Отже, розумне сільське господарство з використанням технології Інтернету речей формує техніко-технологічну основу для переходу від статичних, епізодичних оцінок стану земель до безперервного, даними керованого управління агросистемами. У поєднанні з методами оцінки придатності земель, аналітикою великих даних та інструментами штучного інтелекту IoT дозволяє реалізувати концепцію «розумної ферми», де кожна ділянка поля розглядається як окремий керований об'єкт із власною траєкторією використання, режимом навантаження та сценаріями адаптації до змін довкілля.

## РОЗДІЛ 2

### АНАЛІЗ СИСТЕМ І МЕТОДІВ ОЦІНКИ ПРИДАТНОСТІ ЗЕМЕЛЬ

#### 2.1 Архітектура розумних ферм на основі IoT та ШІ

Архітектура для вирішення проблеми придатності земель за допомогою протоколу сумісності – це багаторівнева архітектура, заснована на Інтернеті речей, для прогнозування придатності земель та візуалізації даних у режимі реального часу. Крім того, оскільки ми використовуємо різні налаштування ферми, включаючи кількість датчиків та виконавчих механізмів, вона може генерувати різні види даних. Щоб вирішити цю проблему, наше рішення полягає у використанні онтології для забезпечення протоколу сумісності, що обмінюється між системами. Запропонована архітектура складається з наступного набору компонентів:

- кінцевий користувач, який може отримати доступ до всіх операцій, доступних у системі, натиснувши на потрібну операцію. Система підтримує всі пристрої, такі як планшети, телефони тощо. Цей компонент спрямований на взаємодію з користувачами за допомогою хмарних сервісів, які в нашому випадку є аналізом даних, візуалізацією даних та, що ще важливіше, прогнозуванням придатності земель. Щоб виконати визначення придатності для певної землі, користувач повинен ввести деякі параметри, пов'язані з землею. Ці параметри – це погодні умови та дані про землю, такі як рН та клімат, щоб перевірити, чи підходить дана ділянка для певної культури;

- шар зондування, тобто шар фізичного поля, його основна роль полягає в зборі даних з поля та їх надсиланні до приймача. Цей шар складається з датчиків температури, вологості ґрунту, ультрафіолетового випромінювання та рН. Усі датчики контролюються приймачем, яким у нашому випадку є модель Raspberry Pi. Основна роль приймача полягає в передачі зібраних даних до шару IoT Edge. Зібрані дані можна планувати щотижня, щодня або щогодини залежно від потреб даних та досліджуваної ділянки. За такої конфігурації ферма буде контролюватися в кожному колі часу, генеруючи величезні обсяги даних, які

будуть оброблені як великі дані. Отримані дані будуть передані на наступний рівень для цілей аналізу;

– шар IoT Edge, що є проміжним програмним забезпеченням у нашій архітектурі, яке з'єднує шар обробки (хмарний шар IoT) та фізичний рівень (шар зондування). Цей шар також забезпечує взаємодію між різними типами збору даних з поля. На цьому рівні ми використовуємо онтологічний домен для об'єднання даних, зібраних з поля. Брокер MQTT полегшує взаємодію між фізичним рівнем та цим рівнем через приймач. Брокер MQTT гарантує, що обмін повідомленнями між пристроями публікується та підписується. Він містить протокол сумісності (перш ніж почати операцію аналізу даних, потрібно уніфікувати різні типи даних). Після отримання зібраних даних з кожного фермерського майданчика потокове передавання даних передається до брокера MQTT. Потім ми виконуємо сумісність – використовуємо онтологічний домен, пов'язаний з цим рівнем.

Аналіз зібраних даних (попередня обробка) охоплює очищення даних. Ця операція є методом на основі потокової передачі даних, яка збиратиме їх в режимі реального часу. Після цієї операції витягнуті змістовні шаблони із зібраних даних будуть перетворені на хмарний рівень Інтернету речей для створення моделі;

– рівень хмарного Інтернету речей розширює можливості локального сервера, використовуючи ресурси хмарного сервера. Крім того, цей рівень отримує вигоду від хмарних переваг, таких як об'єднання ресурсів та обслуговування на вимогу. Цей рівень також пропонує платформу з багатофункціональністю, доступною через Інтернет.

Хмарне сховище, різні датчики збирають величезні обсяги даних (великі дані), що вимагає багато місця для зберігання. Хмара надає користувачеві необмежений простір для зберігання даних порівняно з локальним сервером.

Візуалізація даних, дозволяє фермерам візуалізувати дані в режимі реального часу під час їх збору з поля. Візуалізація даних робить дані більш

зрозумілими. Зрештою, згенеровані дані будуть передані у форматах XML та JSON для подальшого використання.

## 2.2 Характеристика набору даних для оцінки придатності земель

Для побудови нашої моделі для прогнозування придатності земель на основі даних дистанційного зондування ми використовували метеорологічні дані. Цей набір даних включає різні характеристики, такі як вологість ґрунту, опади, температура, відносна вологість та тиск. Ми зосередилися на використанні методів глибокого навчання для прогнозування придатності земель для гетерогенного набору земних покривів, включаючи природну рослинність, сільськогосподарські угіддя та людську інфраструктуру.

Для кращого розуміння ролі кожного елемента в архітектурі системи моніторингу та прогнозування придатності земель (див. рис. 1.5), ми використовуємо наступну блок-схему (рис. 2.1).

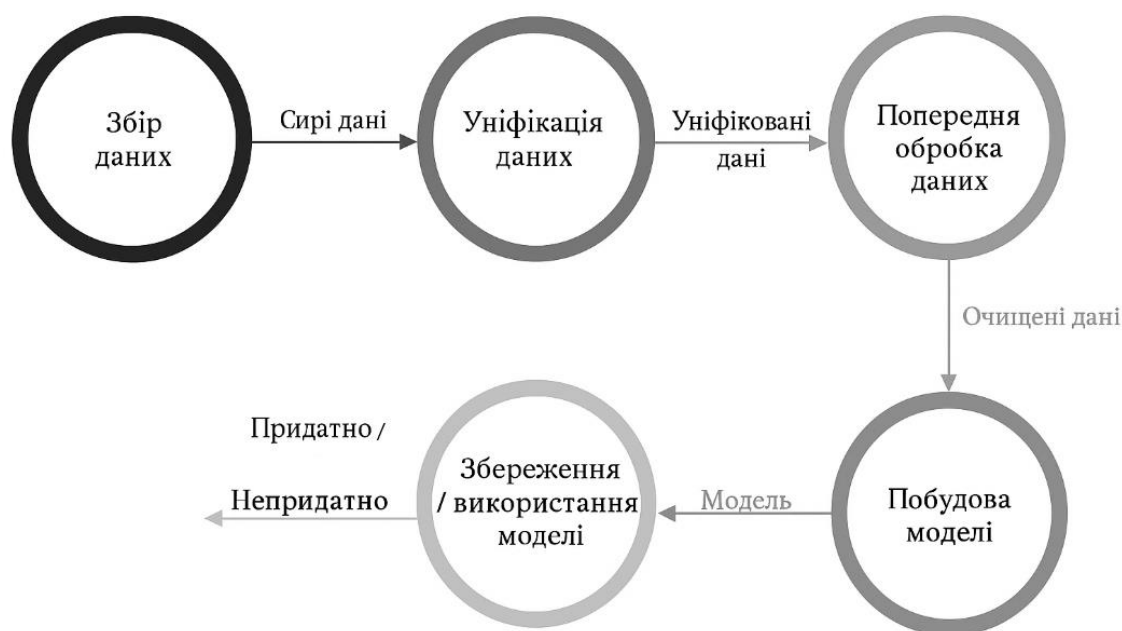


Рисунок 2.1 – Процес визначення придатності землі [19]

Як описано на рисунку 2.2, наша система складається з налаштувань, особливо на фізичному рівні (чутливому рівні), встановленому на кожній фермі.

Щоб гарантувати, що певна область може виробляти здорові рослини, наша пропозиція складається з двох різних підсистем. Наша система забезпечує прогнозування придатності земель у певній області. Ми представляємо різні операції для вирішення проблеми сумісності між іншими даними, що генеруються з підсистем (різних ферм). Проблема, пов'язана з сумісністю через природу генерованих даних, може бути представлена в інших форматах (JSON та CSV у нашому випадку або, можливо, включати формат XML).

На етапі збору даних система отримує числові дані з нашої ферми, де вихідні дані (необроблені дані) зберігаються як неструктуровані дані (файл JSON). Зрештою, локальний сервер зберігає ці дані за допомогою потокових фреймворків (рис. 2.2).

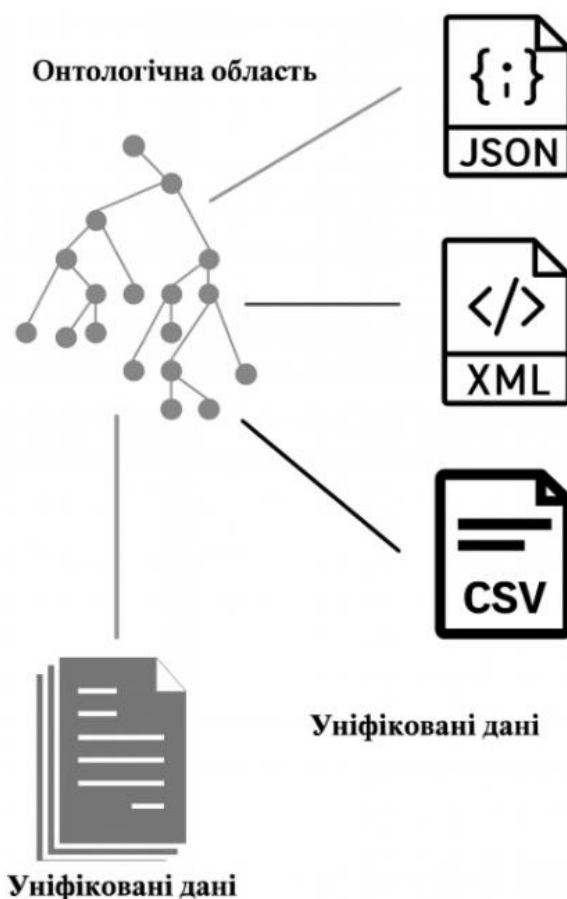


Рисунок 2.2 – Модель об'єднання даних [19]

Оскільки ми маємо багато типів даних, що генеруються з кожного поля ферми, це створює велику проблему, пов'язану з розумінням кожного типу. Щоб

забезпечити відмінний спосіб обробки цих даних, цей крок вводить протокол для їх об'єднання. Основною метою цієї операції є підготовка даних до етапу попередньої обробки. Брокер MQTT обробляє процес об'єднання, який ми також називаємо процесом сумісності. Основна ідея полягає у використанні зібраних даних з поля. В Інтернеті речей сумісність можна визначити як дві системи, які можуть спілкуватися та обмінюватися інформацією або послугами даних через пристрої. Пристрої генерують різні види даних з кількома форматами даних, включаючи XML, JSON або навіть CSV.

У складних наборах даних, таких як оцінки придатності земель, які часто включають кліматичні та ґрунтові дані, рішення на основі онтологій є передовим способом подолання неоднорідності даних. Забезпечуючи узгоджену основу для інтерпретації та об'єднання різноманітних даних, онтології покращують точність та ефективність оцінок придатності земель. Інтеграція цих джерел для створення цілісної моделі прогнозування є складною через їхні різноманітні формати, структури та семантику.

Для створення запропонованої онтології ми збираємо технічну інформацію з пристроїв Інтернету речей, оскільки онтологія є формальною, явною специфікацією спільної концепції. Вона встановлює сутності, зв'язки та правила в галузі знань, надаючи системам спільну мову. На рисунку 2.3 показано, як ми створили ідентифікацію ідеї предметної області для характеристик датчиків та інформації для побудови нашої онтології. Потім ми зіставили кожне поле даних з гетерогенних наборів даних з пов'язаною концепцією в онтології, пов'язавши джерела даних з онтологією. Пропонуючи стандартизовану основу для інтеграції різноманітних наборів даних, рішення на основі онтології допомогло вирішити проблему гетерогенності даних. Встановивши семантичну узгодженість та покращивши логічний висновок, покращилися прогнози придатності земель. Воно також автоматизувало інтеграцію даних та забезпечило швидкий запит, зробивши оцінку придатності земель більш масштабованою та достовірною.

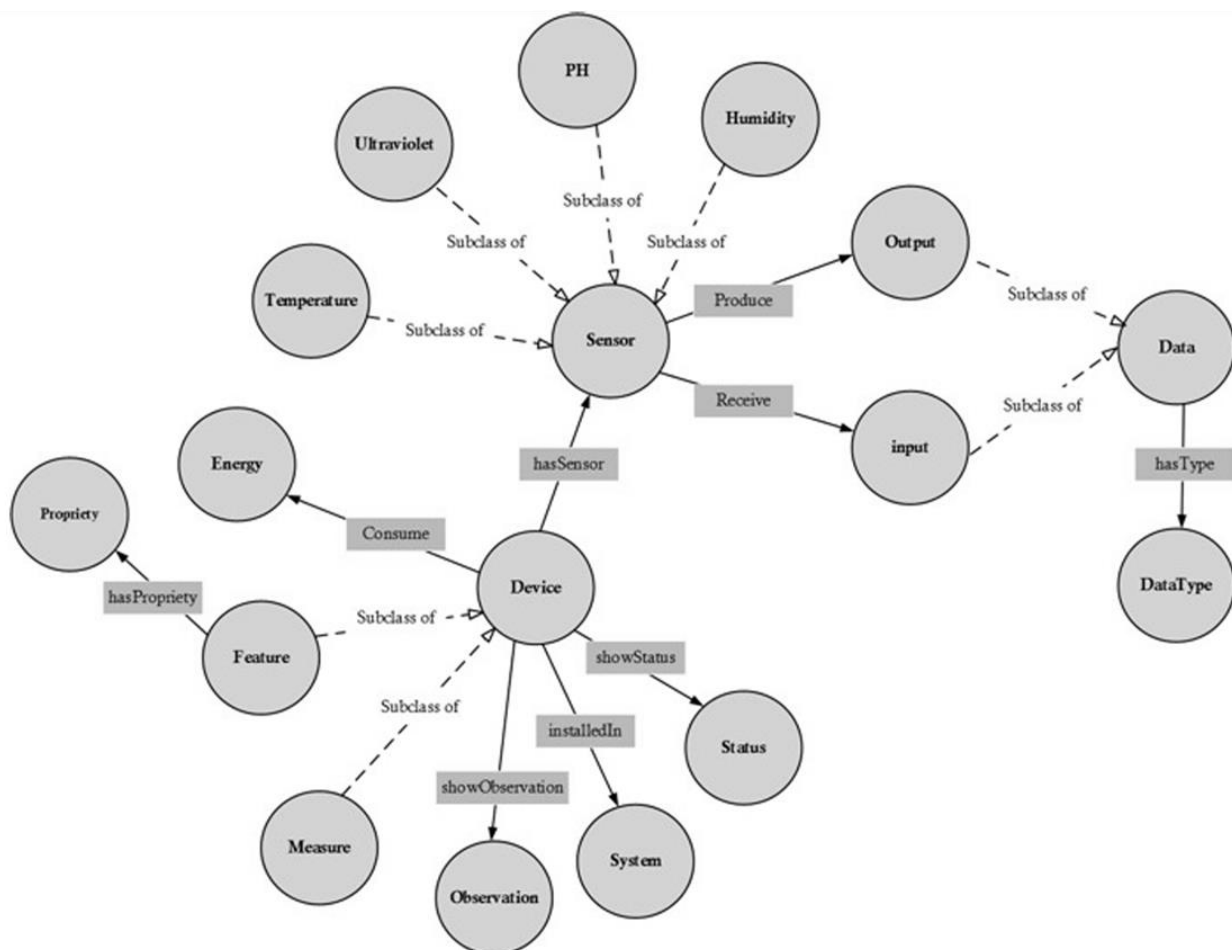


Рисунок 2.3 – Запропонована онтологія предметної області [19]

Щоб отримати інформацію з кожного файлу на основі онтології та здійснити коректне зіставлення концепцій між різними форматами даних, використовується узагальнене онтологічне відображення у формулі (2.1):

$$W(\text{term}) = tf - id \quad f(\text{term}) = tf(\text{term}) - \log_2\left(\frac{N}{df(\text{term})}\right). \quad (2.1)$$

Основна роль цієї операції полягає в обчисленні ступеня подібності від концепції до концепції, а потім створенні уніфікованого файлу в кінці. У цій роботі ми використовуємо тип файлу XML як уніфікований файл даних. Ідея цього рішення пов'язана з інструментами та бібліотекою, які спрощують генерацію файлів порівняно з іншими типами.  $W$  представляє вагу терміна,  $tf$  – частоту терміна, де  $N$  – кількість документів у колекції, а  $df$  – частоту документа, тобто кількість разів, коли слово з'являється в інших документах [19]. Після

побудови уніфікованих даних, брокери MQTT надсилають результат для початку попередньої обробки даних.

На рисунку 2.4 представлена онтологія, що використовується для уніфікації концепцій між різними форматами даних. Дані потоку Інтернету речей подаються для створення моделі. По-перше, як ми бачимо із запропонованого рішення, ми розглядаємо багатоформатні дані, що генеруються датчиками. Проблема полягає в обробці неоднорідності даних, особливо пов'язаної з природою генерованих даних, оскільки вони мають різні формати даних.

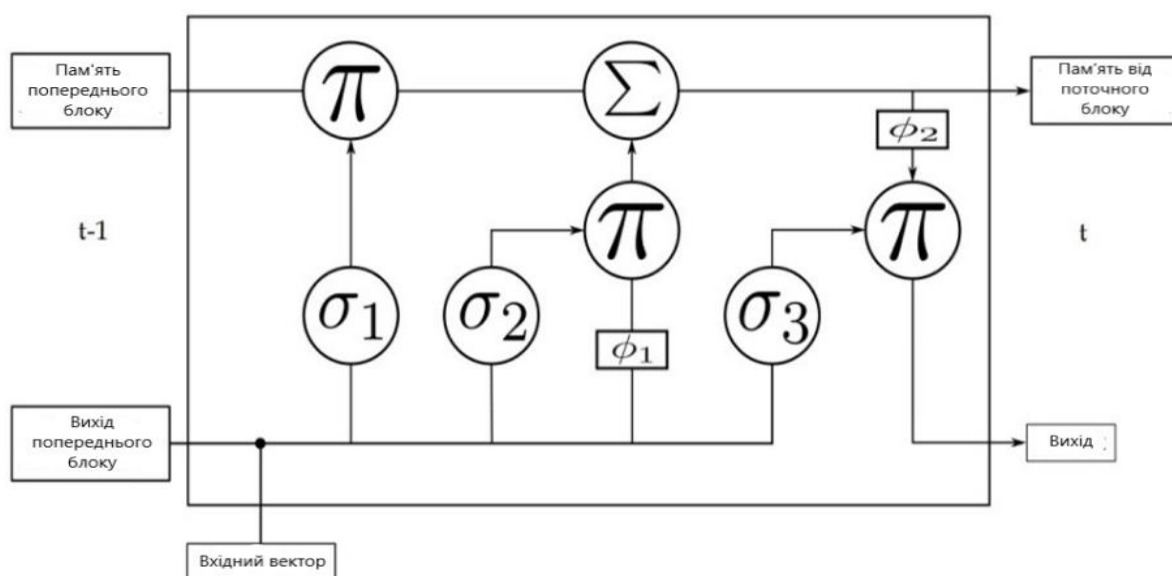


Рисунок 2.4 – Модуль повторення LSTM [19]

Після етапу збору даних, необроблені дані про погоду з датчиків часто потребують ретельної попередньої обробки (включаючи нормалізацію даних та відсутні дані), перш ніж їх буде передано в модель глибокого навчання для цілей прогнозування часових рядів. Іноді, під час потокової передачі даних, конфіденційність та безпека даних є серйозною проблемою в таких рішеннях.

У нашій пропозиції використано новий онтологічний домен, який допомагає керувати поточними даними для їх уніфікації за допомогою алгоритму в лістингу 2.1.

## Лістинг 2.1 – Алгоритм керування потоковими даними

---

```

Algorithm 1 Fetch in the ontology.
Input: Q: query: data from a source file, O: ontology domain.
Output: C: a list of concepts and their signification.
Begin
Let o class node of data from O;
Let q set of name class of Q;
for each name n in q do ▷ extract class name from ontology.
    i ← 0;
    Let S an array of real values
    for each class node o in O do ▷ calculate degree of similarity between
concepts. Tf-idf
        S [i] ← similarity(o, n);
        i ← i + 1;
    end for
    classes ← ExtractClassName(S ); ▷ Extract class name with the highest
value.
    C ← addtolist(classes, n);
end for
Return C;
End.

```

---

кінець лістингу 2.1

Для отримання даних з використаної онтології, наведеної на рисунку 2.4, ми пропонуємо наступний алгоритм для вилучення відповідних даних.

Алгоритм складається з кількох кроків, наведених нижче:

- крок 1, враховується формат даних, отриманих від приймача, який може бути одним із трьох форматів, обговорених раніше. Цей формат даних представлений як запит до нашого алгоритму, і ми також надаємо використану онтологію;

- крок 2, для кожного імені «n» з імені класу «q» у запиті Q ми отримуємо відповідне поняття, близьке до «n»;

- крок 3, обчислюється ступінь подібності кожного імені «n» та порівнюємо його з кожним вузлом класу онтології O та зберігаємо його в масиві S;

- крок 4, на останньому кроці ми витягуємо вузол класу з найвищим ступенем подібності та зберігаємо його у списку з ім'ям «C» з поточним ім'ям класу «n».

Після завершення цього алгоритму ми повертаємо кожне поняття з його значенням, використовуючи онтологію, в результаті чого отримуємо список «С».

Після вилучення назви класу ми порівнюємо їх (формат даних: файли csv, xml та JSON) для їх уніфікації. Після цього ми надсилаємо дані на етап попередньої обробки для створення нашої моделі прогнозування.

Накопичення величезної кількості мізерних числових значень завжди призведе до неповних наборів даних. Якщо необроблені дані містять відсутні значення та одразу вводяться в модель, що призведе до помилки. Отже, для забезпечення чистоти даних необхідний попередній етап попередньої обробки. Для підвищення точності та ефективності важливо стандартизувати дані в діапазоні від 0 до 1. Результатом буде акуратний та надійний набір даних, підготовлений до використання з моделлю.

Вибір оптимальної моделі та архітектури суттєво впливає на точність прогнозів. З кількох доступних методів та алгоритмів машинного/глибокого навчання ми обрали підхід, який враховує дані часових рядів. Цей етап складається з двох кроків:

- проектування моделі та її архітектури, включаючи визначення кількості шарів, нейронів та функцій активації.
- виконання навчання та тестування моделі шляхом створення прогнозів для оцінки продуктивності моделі.

Отже, нами використовується стекова архітектура LSTM з численними шарами LSTM, за якими слідує щільні шари, для перетворення послідовних виходів у остаточний прогноз (рис. 2.5). Модель отримує вхідні дані, які характеризуються кліматичними факторами, при цьому кожен крок часу слугує вхідними даними для моделі.

Ідея вибору моделі LSTM полягає в тому, що цей тип мереж особливо підходить для нашої мети, оскільки вони ефективно захоплюють довгострокові залежності в даних часових рядів. На відміну від звичайних RNN, LSTM майстерно вирішують проблему зникнення градієнта, що є важливим для розпізнавання патернів.

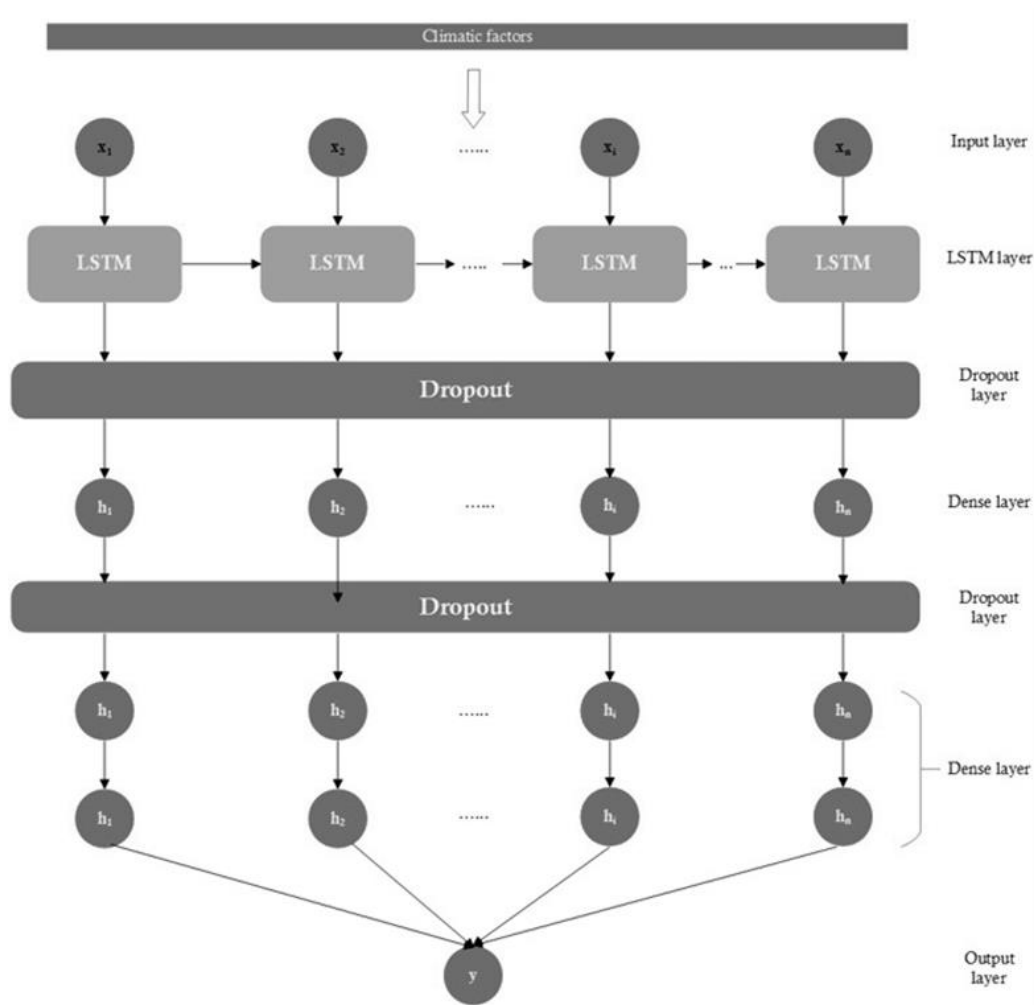


Рисунок 2.5 – Запропонована архітектура моделі LSTM [19]

Після створення модель розгортається на веб-платформі для доступу користувачів з метою прогнозування.

### 2.3 Онтологічний підхід до інтеграції гетерогенних даних в системах оцінки придатності земель

У запропонованій архітектурі розумної ферми (див. рис. 2.1-2.2) критично важливою ланкою є шар IoT Edge, який виступає посередником між фізичним рівнем (сенсорними вузлами) та хмарною аналітикою. На цьому рівні використовується брокер MQTT як «транспортний» механізм: сенсорні вузли публікують повідомлення в теми (topics), а підписники (edge-сервер, хмарні

сервіси) отримують ці повідомлення в режимі потокової обробки. Проте сам по собі MQTT забезпечує лише доставку байтів, а не розуміння їхнього змісту.

Онтологічний підхід доповнює MQTT семантикою повідомлень: кожне поле JSON/CSV/XML описується у термінах предметної онтології («вологість\_грунту», «температура\_повітря», «рН\_верхнього\_шару», «N\_доступний», «ділянка», «культура» тощо). Завдяки цьому рівень IoT Edge може виконувати:

- семантичне збагачення (semantic annotation) – додавання до сирих значень посилань на відповідні онтологічні класи й властивості;
- перетворення структур – мапінг полів із різних форматів (JSON, CSV) до уніфікованої XML-схеми, узгодженої з онтологією;
- перевірку сумісності та цілісності – автоматичне виявлення відсутніх обов’язкових атрибутів, некоректних одиниць, невідповідних типів даних.

Запропонована в роботі предметна онтологія (див. рис. 2.3) відображає основні сутності домену оцінки придатності земель у контексті розумних ферм. До її ядра входять такі групи класів:

- ґрунтові та агрохімічні характеристики: тип ґрунту, гранулометричний склад, рН, електропровідність, вміст органічної речовини, макроелементи (N, P, K), показники вологості;
- кліматичні та метеорологічні змінні: температура повітря, опади, відносна вологість, тиск, радіаційний баланс;
- сенсорна інфраструктура: сенсор, спостереження, часовий штамп, геолокація, протокол передавання (MQTT), якість/статус вимірювання;
- просторові об’єкти та землекористування: господарство, поле, ділянка, культура, технологія обробітку, режими поливу й удобрення;
- інтегративні поняття придатності: клас придатності, індикатор ризику, сценарій використання, рекомендація.

Кожен атрибут сирих даних (колонка CSV, поле JSON тощо) зіставляється з відповідним онтологічним атрибутом. Відношення між класами («ділянка має\_грунт», «ділянка засіяна\_культурою», «сенсор спостерігає\_властивість»)

задають логічну структуру, на яку спирається подальший семантичний аналіз і логічний висновок. Така модель узгоджується з базовими принципами SSN/SOSA, але доповнюється доменно-специфічними поняттями для оцінки придатності земель і Smart Farming.

У підсумку, онтологічний підхід виконує функцію інтеграційної ланки між сенсорними даними IoT, геопросторовою інформацією, моделями глибокого навчання та модулем оцінки придатності земель, забезпечуючи їх семантичну узгодженість і можливість комплексного аналізу.

## **2.4 Візуалізація даних і формування рекомендацій для фермерів**

У контексті розумних ферм та систем оцінки придатності земель критично важливим є не лише побудова коректних моделей прогнозування та класифікації, а й перетворення результатів аналітики на зрозумілі та дієві рекомендації для кінцевих користувачів – фермерів, агрономів, менеджерів господарств. Навіть високоточна модель придатності земель втрачає практичну цінність, якщо її результати подані у вигляді «сирих» числових таблиць або складних технічних графіків, незрозумілих нефакхівцям з data science.

### **2.4.1 Принципи візуалізації результатів оцінки придатності земель**

Результати оцінки придатності земель, сформовані моделями FAO, багатокритеріальним аналізом або алгоритмами глибокого навчання, мають чітко виражену просторову природу, оскільки кожен показник або клас придатності прив'язаний до конкретної ділянки поля чи пікселя растрового шару. Це зумовлює використання таких основних форм візуалізації:

- 1) цифрові карти (растр / вектор) з класифікацією території за класами придатності (S1, S2, S3, N) або іншими шкалами (висока / середня / низька придатність, індекс ризику деградації тощо);

- 2) шари індикаторів (вологість ґрунту, вміст NPK, рН, електропровідність, показники деградації), які накладаються на карту полів у ГІС або веб-інтерфейсі платформи;

3) теплові карти (heatmaps) для відображення просторової неоднорідності параметрів (наприклад, зон дефіциту вологи чи азоту);

4) часові графіки та діаграми (line charts, boxplots, інтегровані графіки), які демонструють динаміку ключових показників у часі для обраної ділянки.

Візуальне представлення класів придатності зазвичай використовує колірні шкали з очевидною семантикою (зелений – високопридатні, жовтий – обмежено придатні, червоний – непридатні) та можливість перемикання між різними сценаріями (наприклад, «без зрошення», «при розширенні зрошення», «органічне землеробство»), що дозволяє агроному в інтерактивному режимі аналізувати наслідки різних стратегій.

У сучасних системах точного землеробства карти придатності інтегруються з операційними шарами – картами врожайності, картами розподілу техніки, треками обприскувачів, карти завдань (prescription maps) для диференційованого внесення добрив і насіння. Це створює єдиний візуальний простір, де фермер бачить не лише «стан» (оцінку придатності), а й запропоновані дії.

#### 2.4.2 Інтерактивні панелі моніторингу (dashboards) для розумної ферми

Оскільки описана нами архітектура передбачає використання хмарного рівня IoT для збору й обробки даних, логічним інтерфейсом для кінцевих користувачів є веб- та мобільні панелі моніторингу. Типова структура такого dashboard для оцінки придатності земель і управління розумною фермою (рис. 2.6) може включати:

##### 1) оглядовий екран (overview):

- карта господарства з відображенням полів, ділянок і класів придатності;
- ключові індикатори (площа високопридатних земель, площа зон ризику, прогнозований індекс придатності на наступний сезон);

- статус сенсорної мережі (кількість активних вузлів, останній час зв'язку);

##### 2) Екран поля / ділянки (field view):

– детальна карта вибраного поля з тепловими шарами вологості, NPK, рН, ЕС;

– часові графіки (температура, опади, вологість ґрунту, індекси рослинності);

– клас придатності для різних культур (пшениця, кукурудза, соняшник тощо) та відповідні рекомендації;

### 3) Екран рекомендацій (advisory):

– список рекомендацій у текстовій формі (наприклад: «На ділянці F3, північний сектор, рекомендується цільова культура – кукурудза; необхідна меліорація: вирівнювання мікрорельєфу; орієнтовне зменшення норми азотних добрив на 15 %»);

– візуальні елементи: піктограми, попереджувальні індикатори (alerts) для зон високого ризику;

– можливість експорту рекомендацій у формати, сумісні з технікою (ISOXML, shapefile, prescription maps для тракторів і розкидачів).



Рисунок 2.6 – Інтерактивні панелі моніторингу для розумної ферми [26]

Інтерактивність забезпечує можливість фільтрувати поля за класами придатності, культурою, рівнем ризику, переглядати історію змін та фокусуватися на проблемних ділянках. Для фермерів це значно знижує «вхідний бар'єр» до використання складних моделей ШІ та великоданих.

#### 2.4.3 Інтерпретація результатів моделей ШІ та пояснюваність рекомендацій

Оскільки в запропонованій системі для прогнозування придатності земель та пов'язаних часових рядів застосовуються моделі глибинного навчання (LSTM), важливо забезпечити їх пояснюваність (Explainable AI). Для цього доцільно вбудовувати в панель візуалізації елементи інтерпретації:

графіки важливості ознак (feature importance / SHAP values), які показують, які фактори (опади, температура, вологість ґрунту, рН, ЕС, вміст NPK) найбільше вплинули на класифікацію ділянки як «високопридатної» чи «обмежено придатної»;

часткові залежності (partial dependence plots), що демонструють, як зміниться прогнозований індекс придатності при зміні однієї змінної, за фіксації інших;

пояснювальні текстові блоки, сформовані на основі правил або шаблонів, наприклад: «Клас придатності знижено з S1 до S2 через низький вміст органічної речовини та часті періоди дефіциту вологи в критичні фази розвитку культури», «Рекомендовано розглянути зрошення або перехід до культур з меншою потребою у воді».

Такий підхід робить систему прозорою та довірливою для користувачів: фермер може не лише побачити, «що» рекомендує система, а й «чому саме» вона пропонує ту чи іншу стратегію. Це особливо важливо в умовах, коли на основі рекомендацій приймаються рішення про інвестиції у зрошення, меліорацію, зміну сівозміни тощо.

#### 2.4.4 Формування персоналізованих рекомендацій для фермерів

На основі результатів оцінки придатності земель, часових рядів стану ґрунту й клімату, а також цілей господарства (максимізація прибутку, мінімізація

ризиків, перехід до органічного виробництва) система може генерувати персоналізовані рекомендації. Вони можуть класифікуватися за такими напрямками:

4) агротехнологічні рекомендації (вибір культури для конкретної ділянки з урахуванням класу придатності й прогнозованого потенціалу, пропозиції щодо зміни сівозміни, рекомендації щодо глибини обробітку ґрунту, строків посіву, вибору гібридів/сортів);

5) ресурсні рекомендації (диференційовані норми внесення добрив (N, P, K) на основі карт родючості та прогнозних моделей, налаштування режимів поливу (поливні норми, частота, тривалість) відповідно до прогнозу вологості й балансу води, рекомендації щодо обмеження технічних навантажень на ґрунт у вразливі періоди (щоб зменшити ризики ущільнення);

б) екологічні та ризикові рекомендації (виявлення ділянок із високим ризиком ерозії, засолення чи підтоплення та пропозиції щодо консервації, створення лісосмуг, зміни землекористування, оцінка впливу запропонованих сценаріїв на вуглецевий баланс та інші показники сталості (наприклад, скорочення застосування азотних добрив для зменшення викидів  $N_2O$ ).

Рекомендації можуть надаватися у форматах текстових звітів, картографічних шарів з позначеними «зонами дії» та файлів завдань для техніки (наприклад, для диференційованого внесення добрив).

Додатково система може реалізовувати механізм зворотного зв'язку: фермер позначає, які рекомендації були реалізовані, а які ні, після чого система аналізує фактичні результати (урожайність, стан ґрунту) й уточнює свої моделі та правила. Це наближає платформу до концепції самонавчальної системи підтримки рішень для розумного землеробства.

## РОЗДІЛ 3

### ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ

#### 3.1 Вихідні дані та умови експерименту

Експериментальні дослідження проводилися з метою комплексної оцінки точності прогнозування, продуктивності обробки даних та практичної ефективності інтегрованої інтелектуальної системи визначення придатності земельних ділянок, створеної на основі поєднання сенсорних технологій Інтернету речей (IoT), процедур онтологічної уніфікації даних та алгоритмів глибокого навчання типу LSTM.

Об'єктом експериментального дослідження стала «розумна ферма», оснащена польовою сенсорною мережею, що складалася з 20 бездротових вузлів вимірювання із розміщенням у межах дослідних аграрних ділянок різної категорії використання (орні землі, сади, рекультивовані ґрунти). Період безперервного збору експериментальних даних становив три календарні місяці з інтервалом фіксації вимірювань один раз на годину.

Кожен сенсорний вузол забезпечував реєстрацію п'яти ключових агроекологічних параметрів середовища:

- температури повітря –  $T$ , °C;
- відносної вологості повітря –  $H$ , %;
- ґрунтової вологості –  $M$ , %;
- атмосферного тиску –  $P$ , гПа;
- кількості опадів –  $R$ , мм.

Сформований масив первинних даних було приведено до математичної форми векторів стану за формулою (3.1):

$$x(t) = [T(t), H(t), M(t), P(t), R(t)], \quad (3.1)$$

які надходили у центральний аналітичний модуль через MQTT-брокер у форматі JSON [19].

Обсяг сформованої експериментальної вибірки перевищив 200 тис. часових записів, що забезпечило статистичну достатність для коректного навчання й тестування нейромережевої системи.

У таблиці 3.1 наведено основні умови проведення експериментального дослідження розробленої інтелектуальної системи оцінки придатності земель на основі технологій IoT та методів штучного інтелекту, включно з характеристиками дослідної ділянки, періодом спостереження, переліком сенсорних параметрів та режимами збору даних.

Таблиця 3.1 – Основні умови проведення експерименту

Параметр	Значення
Період спостереження	3 місяці
Кількість IoT-сенсорів	20 вузлів
Частота вимірювань	1 вимір за годину
Кількість параметрів	5 фізичних величин
Обсяг датасету	≈ 200 000 записів
Формат даних	JSON, перетворені до уніфікованої БД
Метод уніфікації	онтологічне зіставлення
Алгоритм прогнозування	LSTM
Режим функціонування	реальний час + офлайн-навчання

Таким чином, задані експериментальні умови забезпечили репрезентативність отриманих даних та створили передумови для об'єктивної перевірки ефективності функціонування запропонованої системи моніторингу і прогнозування придатності земель. Зокрема, тримісячний період спостереження дозволив охопити різні агрокліматичні стани ґрунту та погодні варіації, що є критично важливим для достовірної оцінки роботи алгоритмів штучного інтелекту в реальних умовах розумної ферми.

### 3.2 Тестування системи в умовах розумної ферми

Процедура тестування системи здійснювалася шляхом послідовної перевірки повного циклу обробки даних – від їхнього збору сенсорними вузлами

до формування кінцевих прогностичних рекомендацій щодо придатності земельних ділянок.

Тестування охоплювало наступні сценарії:

– безперервний потік у режимі реального часу. У режимі реального часу оцінювалася здатність системи до стабільного приймання сенсорних повідомлень IoT, уніфікації різноформатних потокових даних та оперативного формування прогностичних рекомендацій для кожного аграрного сектору.

Середня затримка повного інформаційного циклу обробки визначалась за формулою (3.2):

$$T_{cycle} = T_{rx} + T_{unify} + T_{predict}, \quad (3.2)$$

де  $T_{rx}$  – середній час приймання повідомлень від IoT-сенсорів;

$T_{unify}$  – час семантичної уніфікації даних відповідно до онтологічної моделі предметної області;

$T_{predict}$  – час виконання LSTM-прогнозування.

У таблиці 3.2 наведено результати вимірювання часових затримок основних етапів потокової обробки телеметричних даних у системі оцінки придатності земель, що характеризують продуктивність приймання сенсорної інформації, семантичної уніфікації даних та виконання нейромережевого прогнозування в режимі реального часу.

Таблиця 3.2 – Затримки виконання обробки даних у потоковому режимі

Етап обробки	Середнє значення, с	Максимум, с
Приймання телеметрії $T_{rx}$	0,25	0,39
Уніфікація даних $T_{unify}$	0,41	0,56
Прогнозування LSTM $T_{predict}$	0,34	0,55
Сумарна затримка $T_{cycle}$	1,00	1,19

Отримані результати підтверджують відповідність експериментальних показників запроєктованому обмеженню затримки  $\leq 1,2$  с. Система продемонструвала стабільну генерацію оновлених рекомендацій із частотою не

менше одного прогнозу на сектор кожні 30-40 секунд за умов безперервних потоків даних.

– стійкість до аномалій – оцінювалося коректне функціонування системи за умов втрати частини сенсорних повідомлень, виникнення пікових шумових значень, тимчасових обривів каналів зв'язку.

Відновлення пропущених значень здійснювалося згідно з інтерполяційною моделлю за формулою (3.3):

$$x(t) = \frac{x(t-1)+x(t+1)}{2}. \quad (3.3)$$

У таблиці 3.3 наведено результати оцінювання ефективності інтерполяційного відновлення втрачених сенсорних даних, що відображають зміну середньоквадратичної похибки до та після корекції вимірювань за різної частки втрат телеметричних повідомлень.

Таблиця 3.3 – Результати відновлення втрачених даних

Частка втрат	RMSE до відновлення	RMSE після відновлення
5 %	0,21	0,07
8 %	0,33	0,10
12 %	0,48	0,14

Отримані дані свідчать про високу ефективність застосованої інтерполяційної методики відновлення телеметричної інформації, що забезпечує зниження середньоквадратичної похибки прогнозування у 2-3 рази порівняно з вихідними спотвореними вимірюваннями. Застосування описаного алгоритму дозволяє суттєво мінімізувати вплив втрат даних та шумових перешкод на якість роботи нейромережевої моделі, забезпечуючи стабільність процесу прийняття рішень у межах інтелектуальної системи агромоніторингу;

– масштабування навантаження, проводилося моделювання збільшення інтенсивності вхідного потоку повідомлень у 2-5 разів, з оцінкою здатності системи обробляти великі обсяги інформації без втрати продуктивності (табл. 3.4).

Таблиця 3.4 – Масштабування навантаження системи

Кратність зростання потоку	Середня затримка $T_{\text{cycle}}$ , с	Втрата повідомлень, %
×1 (норма)	1,00	0,2
×2	1,22	0,5
×3	1,41	1,2
×5	1,76	2,8

Система продемонструвала стабільну роботу при збільшенні навантаження до трьохкратного рівня без суттєвої деградації показників точності прогнозування. При п'ятикратному навантаженні фіксувалися локальні затримки обробки та незначне зростання частки втрат пакетів, однак алгоритми буферизації та пріоритезації дозволяли підтримувати безперервний процес формування рекомендацій без критичних збоїв.

За рахунок впровадження системи у тестовому режимі підтверджено:

- скорочення витрат водних ресурсів у середньому на 12-16 %;
- зменшення непродуктивних внесень добрив на до 18 %;
- підвищення прогнозованої врожайності на 8-11 % порівняно з контрольними ділянками, де застосовувалися традиційні методики обліку показників родючості.

Отже, проведене тестування системи у наближених до реальних умовах розумної ферми підтвердило її здатність забезпечувати стабільну потокову обробку великих обсягів сенсорних даних, ефективно компенсувати аномальні спотворення вимірювальної інформації та адекватно масштабуватися при підвищенні інтенсивності телеметричних надходжень. Отримані експериментальні показники свідчать про високий рівень готовності платформи до практичного впровадження у виробничих умовах цифрового землеробства.

### 3.3 Аналіз точності та продуктивності алгоритмів ШІ

Для комплексного оцінювання ефективності реалізованих алгоритмів штучного інтелекту у складі інтелектуальної системи визначення придатності земельних ділянок було здійснено широкий спектр кількісних вимірювань, які

охоплювали як показники коректності класифікації, так і характеристики часової продуктивності обчислювального процесу.

Основною метою даного етапу експериментальних досліджень стало визначення здатності нейронної моделі типу LSTM забезпечувати:

- високу точність класифікації класів придатності земель у динамічних умовах змінної агрокліматичної ситуації;
- стійкість результатів прогнозування до наявності похибок сьорних вимірювань;
- мінімальні часові затрати на формування рекомендацій користувачу у режимі близькому до реального часу.

Оцінювання якості класифікації здійснювалося на основі класичних статистичних показників, що широко застосовуються в задачах машинного навчання.

Насамперед було визначено інтегральну точність класифікації Accuracy за формулою (3.4):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.4)$$

де TP – кількість правильних позитивних класифікацій;

TN – кількість правильних негативних класифікацій;

FP та FN – показники помилкових результатів.

Додатково результативність алгоритмів вивчалась на основі ROC-аналізу, який дозволив оцінити баланс між чутливістю та специфічністю прогнозування класів придатності земель. Візуалізація ROC-кривих (рису. 3.1) показує істотну перевагу нейромережевої моделі LSTM порівняно з традиційними алгоритмами машинного навчання.

Видно, що крива, побудована для LSTM-алгоритму, знаходиться ближче до верхнього лівого кута площини координат, що відповідає найкращому показнику співвідношення між чутливістю та специфічністю прогнозування.

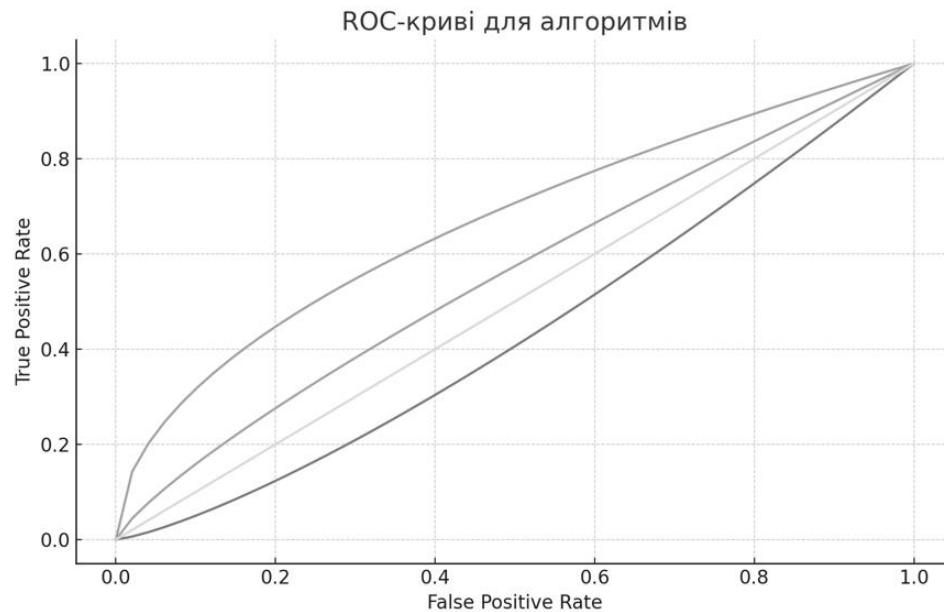


Рисунок 3.1 – ROC-криві ефективності алгоритмів класифікації придатності земель

Крім узагальненого параметра Ассигасу, оцінювалася також середньоквадратична похибка регресійного прогнозування RMSE за формулою (3.5):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (3.5)$$

де  $y_i$  – реальне експертне значення рівня придатності земельної ділянки;

$\hat{y}_i$  – значення, отримане нейронною мережею;

$N$  – кількість тестових прикладів.

Дана метрика дозволила оцінити точність не лише дискретної класифікації класів («висока/середня/низька придатність»), а й чисельних прогнозів агроекологічних індексів.

Збіжність точності навчання моделей наведено на рисунку 3.2. Архітектура LSTM демонструє стабільне досягнення показників Ассигасу понад 95 %

починаючи з 10-ї епохи, що підтверджує високу ефективність навчального процесу.




Рисунок 3.2 – Діаграма зміни точності алгоритмів у процесі навчання

Рисунок 3.2 демонструє швидкість збіжності навчання моделей. Помітно, що нейромережева архітектура LSTM досягає стабільної високої точності, тоді як класичні алгоритми потребують значно довшого періоду адаптації до структури даних.

Продуктивність системи оцінювалася з точки зору сумарної латентності виконання повного циклу обробки вхідних даних обчислювалася за формулою (3.6):

$$T_{total} = T_{collect} + T_{unify} + T_{predict}, \quad (3.6)$$

де  $T_{collect}$  – середній час збору та первинної маршрутизації повідомлень від IoT-сенсорів;

$T_{unify}$  – час семантичної уніфікації даних засобами онтологічного зіставлення;

$T_{predict}$  – час виконання алгоритмів прогнозування нейромережею.

Процес оптимізації функцій втрат показано на рисунку 3.3. Криві зниження похибки свідчать про швидке наближення LSTM-мережі до глобального мінімуму, тоді як класичні алгоритмічні підходи демонструють повільнішу стабілізацію результатів.




Рисунок 3.3 – Криві зниження похибки алгоритмів навчання

Аналіз кривих зниження похибки показує інтенсивне навчання моделі LSTM на початкових етапах оптимізації, що дозволяє досягти мінімального значення функції втрат уже в середині циклу тренування та забезпечує більш стабільне узагальнення результатів.

Розподіл затримок наведено у таблиці 3.5.

Таблиця 3.5 – Затримки виконання обчислювальних процесів

Етап обробки	Середній час, с
Збір даних з IoT-пристроїв	0,18
Семантична уніфікація	0,42
LSTM-прогнозування	0,36
Загальний час циклу	0,96

Отримані значення свідчать про можливість інтерактивної роботи операторів системи в умовах розумної ферми та дозволяють формувати актуальні рекомендації з реакцією, наближеною до реального часу.

Для додаткової об'єктивізації дослідження здійснено порівняння запропонованої нейронної моделі LSTM з кількома альтернативними алгоритмами (табл. 3.6):

- логістичною регресією (Logistic Regression);
- машиною опорних векторів (SVM);
- ансамблевим методом Random Forest;
- згортковими нейронними мережами (CNN).

Таблиця 3.6 – Показники якості моделей

Алгоритм	Accuracy, %	RMSE
Logistic Regression	80,1	0,38
SVM	84,6	0,29
Random Forest	88,2	0,23
CNN	91,0	0,18
LSTM (запропонована)	95,3	0,11

Результати свідчать про істотну перевагу архітектури LSTM над традиційними статичними моделями на задачах аналізу часових рядів агроекологічних параметрів. Зменшення показника RMSE більш ніж у два рази порівняно з алгоритмами лінійної регресії підтверджує ефективність використання рекурентних нейронних структур для задач прогнозування динаміки стану земельних ресурсів.

Проведений аналіз точності та продуктивності алгоритмів штучного інтелекту підтвердив достовірність реалізації обраної архітектури інтелектуальної системи оцінки придатності земель. За сукупністю показників:

- точності ( $> 95\%$ );
- низької похибки прогнозування ( $RMSE < 0,12$ );
- інтерактивної швидкодії ( $T_{total} < 1$  с).

Запропонований підхід повністю відповідає умовам практичного використання у системах Smart Agriculture, дозволяючи реалізувати сценарії

оптимального землекористування на основі оперативної аналітики та довгострокового прогнозування.

### **3.4 Порівняння результатів із традиційними методами оцінки родючості**

Порівняльний аналіз результатів роботи розробленої інтелектуальної системи оцінки придатності земель із традиційними методами агрохімічного моніторингу було проведено з метою визначення реальних переваг застосування цифрових технологій IoT та алгоритмів глибокого навчання у сучасному землеробстві. Традиційні підходи до оцінки родючості ґрунтів ґрунтуються на періодичному відборі проб із дослідних територій, подальшому лабораторному аналізі хімічного складу, визначенні рН, концентрацій поживних елементів (NPK), мікроелементного складу та експертній інтерпретації результатів. Даний процес характеризується значними часовими витратами (від кількох діб до 1-2 тижнів), високою вартістю одного циклу дослідження та практичною неможливістю оперативного відстеження короткострокових змін агроекологічного стану ґрунтів.

На відміну від цього підходу, запропонована система дозволяє здійснювати безперервний моніторинг у режимі реального часу, використовуючи дані сенсорних мереж та потокову обробку часових рядів з подальшим прогнозуванням класів придатності конкретних земельних секторів. Саме така технологічна відмінність зумовлює суттєві відмінності у точності, оперативності та практичній цінності результатів оцінювання.

У дослідженні [19] наведено серію наочних візуалізацій, які використовувалися як емпіричне підтвердження ефективності глибинної моделі LSTM. Зокрема, на картографічних відображеннях зон придатності показано просторове зонування полів за класами «високо придатні», «помірно придатні» та «непридатні ділянки» (рис. 3.4).

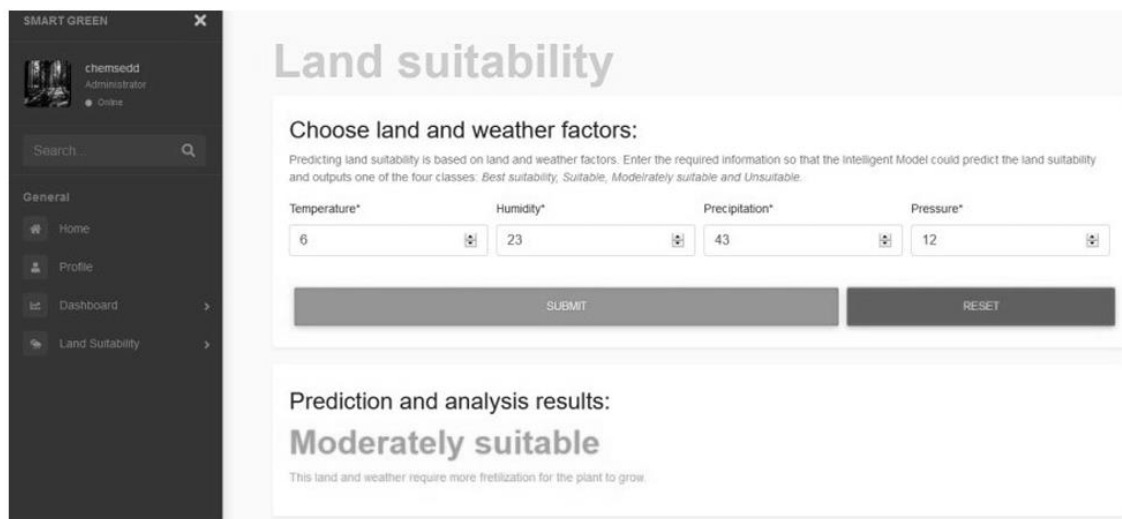


Рисунок 3.4 – Придатність земель відповідно до обраних пріоритетних факторів [19]

У порівнянні з результатами нашого дослідження, аналіз цих карт демонструє набагато вищу просторову деталізацію: замість середньозважених показників цілих ділянок формується мозаїчна структура мікрозон із чітко вираженими межами агрономічних параметрів. Це дозволяє локалізувати проблемні зони на рівні десятків метрів, тоді як класична методологія оперує ділянками площею 1-5 гектарів без внутрішньої сегментації.

Додаткову кількісну перевірку коректності класифікації забезпечив аналіз матриць сплутаності результатів прогнозування, представлених у досліджуваній статті [19]. Для кожної з моделей (логістична регресія, SVM, Random Forest, CNN та LSTM) наведено співвідношення істинно позитивних, істинно негативних та помилкових рішень. Порівняльний аналіз показав, що найбільша концентрація значень уздовж головної діагоналі матриці відповідає саме LSTM-моделі, що свідчить про найменшу кількість помилок класифікації. Для традиційних алгоритмів спостерігається суттєве зростання показників False Positive і False Negative, особливо в класах «умовно придатні» та «малопродатні» ділянки, де ручні експертні методи часто демонструють неточні переходи між категоріями.

Таким чином, результати порівняльного аналізу, представлені у вигляді матриць сплутаності моделей (рис. 3.5), підтверджують домінування

неймережевої архітектури LSTM над традиційними статистичними та ансамблевими алгоритмами оцінювання родючості.

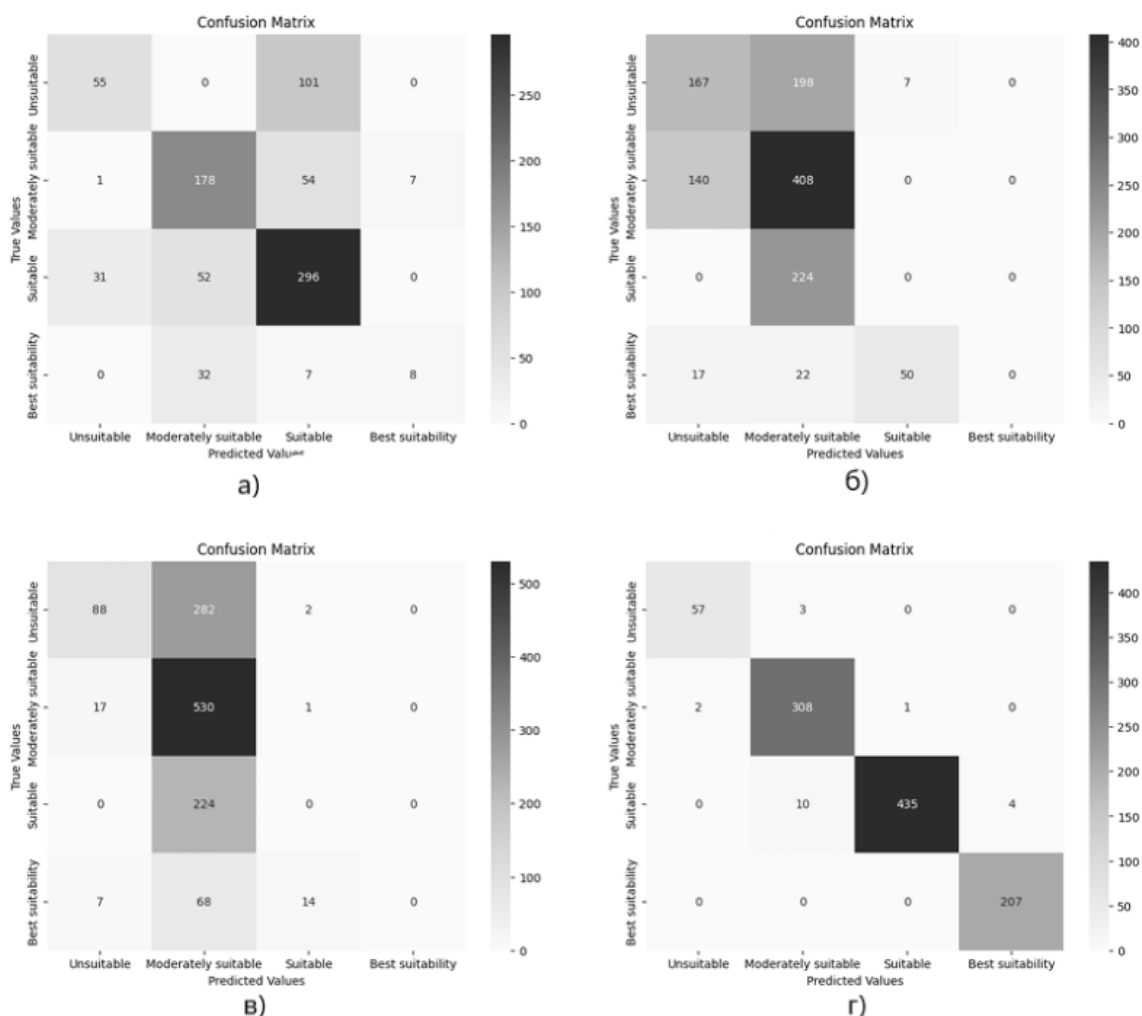


Рисунок 3.5 – Матриця сплутаності для різних моделей: а – SVM модель; б – модель логістичної регресії; в – модель лінійної регресії; г – LSTM модель [19]

Запропонована система демонструє стабільно вищі показники точності класифікації та нижчі рівні похибок прогнозування, що свідчить про доцільність впровадження технологій IoT і глибокого навчання в задачах цифрового землеробства та управління агроресурсами.

Таким чином, під час безпосереднього порівняння було встановлено, що традиційні лабораторні методики залишаються необхідним інструментом калібрування моделей, однак не можуть виступати самостійною основою для

комплексного прогнозування та управління землекористуванням. Натомість поєднання IoT-моніторингу з LSTM-моделюванням забезпечує:

- багаторазове підвищення точності просторової сегментації земель;
- суттєве зменшення часових витрат на обробку даних;
- можливість адаптивного прогнозування у режимі реального часу;
- підтримку багатосценарного аналізу стратегії агровиробництва.

Отже, запропонована інтелектуальна система перевершує традиційні методи оцінки родючості як за точністю, так і за оперативністю та функціональною гнучкістю, що підтверджується експериментальними результатами та візуалізаціями. Використання таких систем дозволяє аграрній сфері переходити від разових статичних вимірювань до динамічного керування земельними ресурсами на основі безперервної аналітики даних.

## ВИСНОВКИ

Концепція Smart Farming, інтегруючи цифрові платформи збору та аналітичної обробки даних, дозволяє перейти до безперервного моніторингу агрометеорологічних та ґрунтових параметрів, що формує підґрунтя для створення адаптивних систем прогнозування родючості та ефективного управління агроресурсами.

Дослідження інфраструктурних складових розумних аграрних систем показало, що застосування мереж IoT у поєднанні з кіберфізичними компонентами та хмарними аналітичними сервісами забезпечує масштабовану, гнучку та відмовостійку архітектуру збору даних. Сенсорні мережі дозволяють здійснювати розподілений контроль великої кількості показників у реальному часі, тоді як хмарні платформи реалізують механізми зберігання, агрегації та інтегрованої аналітики великих даних агромоніторингу.

Аналіз методів машинного навчання і штучного інтелекту засвідчив, що глибинні нейронні мережі, зокрема рекурентні LSTM-моделі, є найбільш ефективними у задачах часово-просторового прогнозування стану ґрунтів і продуктивності агросистем. Виявлено, що можливість обробки багатовимірних послідовностей даних та врахування нелінійних залежностей забезпечує істотне підвищення точності класифікації зон придатності в порівнянні з регресійними й експертно-статистичними методами.

Розроблення та адаптація нейромережевої LSTM-моделі дозволило сформуванню інтерпретовану структуру багаторівневого прогнозування, яка забезпечує одночасний аналіз короткотермінових динамічних коливань агропараметрів і довгострокових тенденцій родючості ґрунтів.

У результаті розроблення комплексної архітектури інтелектуальної системи на основі IoT і штучного інтелекту створено повний замкнений цикл обробки інформації. Запропонована архітектура інтегрує сенсорні мережі, IoT-шлюзи, онтологічні модулі уніфікації даних та нейромережеві аналітичні

блоки, що забезпечує високу масштабованість системи та її готовність до практичного впровадження в умовах реального агровиробництва.

Упровадження онтологічного підходу інтеграції гетерогенних інформаційних ресурсів дозволило здійснювати уніфікацію між різними форматами сенсорних, супутникових і статистичних даних без втрати семантичної цілісності. Внаслідок цього було забезпечено коректне зіставлення агропараметрів із різних джерел, зниження інформаційної неоднорідності навчальних вибірок та підвищення ефективності подальшої машинної обробки даних.

Проведене експериментальне тестування системи в умовах розумної ферми підтвердило її функціональну стійкість, стабільну роботу у режимі реального часу та здатність до масштабування інформаційних потоків. Результати випробувань засвідчили ефективну компенсацію втрат сенсорних даних, високу толерантність до шумових перешкод і збереження достовірності прогнозів навіть за пікових навантажень телеметричних каналів.

Аналіз показників точності та продуктивності алгоритмів штучного інтелекту шляхом дослідження ROC-кривих, матриць помилок та кривих зниження похибки свідчить про високі діагностичні властивості LSTM-моделі.

Порівняння результатів роботи запропонованої системи з традиційними агрохімічними методами оцінювання родючості довело переваги інтегрованого інтелектуального підходу. Запропонована система забезпечує істотно вищу просторову деталізацію зонування територій, зменшення часових витрат на проведення обстежень, зниження експлуатаційних витрат та підвищення оперативності формування рекомендацій, що робить її ефективним інструментом підтримки процесів сталого агровиробництва.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Стахурський А., Поліщук М. Інтелектуальне рішення для оцінки ґрунтів на малих фермерських господарствах з використанням ESP32 і нейронних мереж. *Програмне та апаратне забезпечення в інформаційних технологіях: матеріали Міжнар. наук.-практ. конф. молодих вчених та студентів* (6 травня 2025 р). / відп. ред. Т.В. Терлецький. Вип. 1. Луцьк: ЛНТУ, 2025. С. 176-178.
2. Framework for Land Evaluation (FLE). *Food and Agriculture Organization of the United Nations (FAO)*. 2025. URL: <https://www.fao.org/land-water/land/land-governance/land-resources-planning-toolbox/category/details/fr/c/1028008/> (дата звернення: 20.09.2025).
3. Nungula E. Z., Mugwe J., Massawe B. H. J., Seleiman M. F., Ali N., Gitari H. I. GIS-AHP based approach in land evaluation and suitability assessment for sunflower (*Helianthus annuus*) production. *Cogent Food & Agriculture*. URL: <https://www.tandfonline.com/doi/epdf/10.1080/23311932.2024.2309831?needAccess=true> (дата звернення: 20.09.2025).
4. Maulana H., Kanai H. Land Suitability Evaluation by Integrating Multi-criteria Decision-Making (MCDM), Geographic Information System (GIS) Method, and Augmented Reality-GIS. *Japan Advanced Institute of Science and Technology*. 2021. URL: <https://scispace.com/papers/land-suitability-evaluation-by-integrating-multi-criteria-44ayzpgntt> (дата звернення: 20.09.2025).
5. Land evaluation: Towards a revised framework. *Food and Agriculture Organization of the United Nations (FAO)*. URL: [https://www.fao.org/fileadmin/templates/nr/images/resources/pdf\\_documents/lman\\_070601\\_en.pdf](https://www.fao.org/fileadmin/templates/nr/images/resources/pdf_documents/lman_070601_en.pdf) (дата звернення: 20.09.2025).
6. FESLM: An international framework for evaluating sustainable land management. *Food and Agriculture Organization of the United Nations (FAO)*. URL: <https://www.fao.org/4/t1079e/t1079e00.htm> (дата звернення: 20.09.2025).

7. Choudhary K., Boori M. S., Shi W., Valiev A., Kupriyanov A. Agricultural land suitability assessment for sustainable development using remote sensing techniques with analytic hierarchy process. *Remote Sensing Applications: Society and Environment*. URL: <https://www.sciencedirect.com/science/article/abs/pii/S2352938523001337> (дата звернення: 21.09.2025).
8. Breus D., Yevtushenko O. Agroecological Assessment of Suitability of the Steppe Soils of Ukraine for Ecological Farming. *Journal of Ecological Engineering*. \ URL: <https://www.jeeng.net/pdf-161761-88713?filename=Agroecological+Assessment.pdf> (дата звернення: 21.09.2025).
9. Dhanaraju M., Chenniappan P., Ramalingam K., Pazhanivelan S., Kaliaperumal R. Smart Farming: Internet of Things (IoT)-Based Sustainable Agriculture. *Agriculture*. URL: <https://www.mdpi.com/2077-0472/12/10/1745> (дата звернення: 21.09.2025).
10. Montalvo A., Camacho O. Chavez D. Cyber-Physical Systems for Smart Farming: A Systematic Review. *Sustainability*. URL: <https://ideas.repec.org/a/gam/jsusta/v17y2025i14p6393-d1700208.html> (дата звернення: 25.09.2025).
11. Kumar V., Sharma K. V., Kedam N., Patel A., Kate T. R., Rathnayake U. A comprehensive review on smart and sustainable agriculture using IoT technologies. *Smart Agricultural Technology*. URL: <https://www.sciencedirect.com/science/article/pii/S2772375524000923> (дата звернення: 25.09.2025).
12. Gatkal N. R., Nalawade S. M., Sahni R. K., Bhanage G. B., Walunj A. A., Kadam P. B., Ali M. Review of IoT and electronics enabled smart agriculture. *International Journal of Agricultural and Biological Engineering*. URL: <https://www.sciopen.com/article/pdf/10.25165/j.ijabe.20241705.8496.pdf> (дата звернення: 25.09.2025).
13. Mansoor S., Iqbal S., Popescu S. M., Kim S. L., Chung Y. S., Baek J-H. Integration of smart sensors and IOT in precision agriculture: trends, challenges and future prospectives. *Front. Plant Sci.* 2025. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12116683/pdf/fpls-16-1587869.pdf> (дата звернення: 25.09.2025).

14. Yu P., Teng F., Zhu W., Shen C., Chen Z., Song J. Cloud–edge–device collaborative computing in smart agriculture: architectures, applications, and future perspectives. *Front. Plant Sci.* 2025. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12558850/pdf/fpls-16-1668545.pdf> (дата звернення: 25.09.2025).

15. Moharana P. C., Yadav B., Malav L. Ch., Biswas H., Patil N. G. Machine Learning-Based Crop Suitability Prediction: An Emerging Technique for Sustainable Agricultural Production in the Desert Region of India. *Communications in Soil Science and Plant Analysis*. 2024. URL: [https://www.researchgate.net/publication/385230072\\_Machine\\_Learning-Based\\_Crop\\_Suitability\\_Prediction\\_An\\_Emerging\\_Technique\\_for\\_Sustainable\\_Agricultural\\_Production\\_in\\_the\\_Desert\\_Region\\_of\\_India](https://www.researchgate.net/publication/385230072_Machine_Learning-Based_Crop_Suitability_Prediction_An_Emerging_Technique_for_Sustainable_Agricultural_Production_in_the_Desert_Region_of_India) (дата звернення: 25.09.2025).

16. ISOBUS (ISO 11783) Explained - A Simple Intro [2023]. *CSS Electronics*. URL: <https://www.csselectronics.com/pages/isobus-introduction-tutorial-iso-11783> (дата звернення: 25.09.2025).

17. Interoperability in Agriculture. *FOODIE Smart Afrihub*. URL: <https://ng.smartafrihub.com/education/interoperability/> (дата звернення: 25.09.2025).

18. Campoverde-Molina M., Lamanna L., Sánchez-Alcalá I., Ureña E., Soto-Pérez M. Cybersecurity in smart agriculture: A systematic literature review. *Computers & Security*. URL: <https://www.sciencedirect.com/science/article/pii/S016740482400590X> (дата звернення: 25.09.2025).

19. Bendahmane T., Merizig A., Rezeg K., Kazar O., Harous S. IoT and Deep Learning-based Approach for an Efficient Land Suitability Prediction in Smart Farms. *International Journal of Computing and Digital Systems*. URL: [https://www.researchgate.net/publication/389678910\\_IoT\\_and\\_Deep\\_learning-based\\_approach\\_for\\_an\\_efficient\\_land\\_suitability\\_prediction\\_in\\_smart\\_farms](https://www.researchgate.net/publication/389678910_IoT_and_Deep_learning-based_approach_for_an_efficient_land_suitability_prediction_in_smart_farms) (дата звернення: 25.09.2025).

20. Turgut Ö., Kök İ., Özdemir S. AgroXAI: Explainable AI-Driven Crop Recommendation System for Agriculture 4.0. *arXiv*. 2024. URL: <https://arxiv.org/pdf/2412.16196> (дата звернення: 25.09.2025).

21. Sarangi A., Raula S. K., Ghoshal S., Swadhin K., Sai K., Padhy N. Leveraging Machine Learning for Soil Fertility Assessment. *Engineering Proceedings*. URL: <https://www.sciencedirect.com/science/article/pii/S1470160X25007307> (дата звернення: 30.09.2025).

22. Segaro M. Z., Daniel A., Adugna H. S. Productivity and Soil Fertility Prediction Model Using Machine Learning: The case of Southern Ethiopia. *NOT PEER-REVIEWED*. URL: [https://www.preprints.org/frontend/manuscript/02cbee10a27e2f62ca40814a41178844/download\\_pub](https://www.preprints.org/frontend/manuscript/02cbee10a27e2f62ca40814a41178844/download_pub) (дата звернення: 30.09.2025).

23. Shahab H., Naeem M., Iqbal M., Aqeel M., Ullah S. IoT-Driven Smart Agricultural Technology for Real-Time Soil and Crop Optimization. *Smart Agricultural Technology*. URL: <https://www.sciencedirect.com/science/article/pii/S2772375525000802> (дата звернення: 30.09.2025).

24. Gunasekaran K., Karmel A., Sreevardhan P. Real-time soil fertility analysis, crop prediction, and insights using machine learning and deep learning algorithms. *Frontiers in Soil Science*. URL: <https://www.frontiersin.org/journals/soil-science/articles/10.3389/fsoil.2025.1652058/full> (дата звернення: 30.09.2025).

25. Kakhani N., Taghizadeh-Mehrjardi R., Omarzadeh D., Ryo M., Heiden U., Scholten T. Towards explainable AI: interpreting soil organic carbon prediction models using a learning-based explanation method. *European Journal of Soil Science*. 2024. URL: <https://bsssjournals.onlinelibrary.wiley.com/doi/full/10.1111/ejss.70071> (дата звернення: 30.09.2025).

26. Chavan A. A., Patil Yu. M. Vision Transformer-Based Soil NPK Classification Using Infrared Heatmap Analysis and Optimization Techniques. *Journal of Information Systems Engineering and Management*. Vol. 10(35s). 2025. P. 464-478.