


## КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

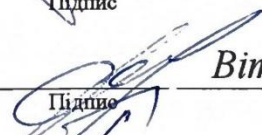
на тему Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання


Галузь знань 12 – Інформаційні технології  
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки  
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки  
Назва освітньої програми

Виконав: студент групи КН-22-2  Антон СТЕПАНЮК  
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: к.ф-м.н., доц. каф. КН  Віталій МІХАЛЕВСЬКИЙ  
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

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

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

13 черва 2026 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інформаційних технологій

Кафедра комп'ютерних наук

Освітній ступінь бакалавр

Галузь знань 12 – Інформаційні технології

Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук

  
(підпис)

д.т.н., професор Олександр БАРМАК

«22» січня 2026 року

**ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА**

1. Тема кваліфікаційної роботи бакалавра: «Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання»

2. Завдання видано студенту Антону СТЕПАНЮКУ  
(ім'я, прізвище)

3. Керівник роботи доцент кафедри КН Віталій МІХАЛЕВСЬКИЙ  
(посада, ім'я, прізвище)


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

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

6. Зміст пояснювальної записки (перелік задач) та вихідні дані: Мета роботи – підвищення точності класифікації земельних ділянок для планування сільськогосподарської діяльності виробників агропродукції. Для досягнення цієї мети слід провести аналіз сучасних методів планування такої діяльності, розробити метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання, інтегрувати його в інформаційну систему та провести експериментальне тестування для оцінки точності методу. Вхідні дані передбачають можливість повного опису предметної області, результатом роботи методу є рекомендації для планування сільськогосподарської діяльності.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

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

Виконавець: студент групи КН-22-2  Антон СТЕПАНЮК  
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: к.ф-м.н., доц. каф. КН  Віталій МІХАЛЕВСЬКИЙ  
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

## Анотація

Тема кваліфікаційної роботи бакалавра: «Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання»

Виконавець кваліфікаційної роботи бакалавра: студент групи КН-22-2 Антон СТЕПАНЮК

Керівник кваліфікаційної роботи бакалавра: к.ф-м.н., доцент кафедри КН Віталій МІХАЛЕВСЬКИЙ

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
53	10	6	48	2

Метою кваліфікаційної роботи бакалавра є автоматизація та підвищення точності класифікації придатності земельних ділянок для планування сільськогосподарської діяльності. Проведено аналіз сучасних методів планування такої діяльності, розроблено метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання, інтегровано його в інформаційну систему та проведено експериментальне тестування для оцінки точності методу.

Напрямами практичного використання розробленого та інтегрованого методу визначено автоматизоване планування сільськогосподарської діяльності з використанням картографічних даних, автоматизований підбір сівозміни культур з урахуванням агрохімічних властивостей ґрунту та рельєфу поля.

Програмну реалізацію методу виконано мовою Python (із застосуванням TensorFlow, Scikit-learn та GeoPandas).

Ключові слова: точне землеробство, просторовий аналіз, машинне навчання, сівозміна культур, багатошаровий перцептрон, ерозія ґрунту.

Виконавець: студент групи КН-22-2

Група виконавця

  
Підпис

Антон СТЕПАНЮК  
Ім'я, ПРІЗВИЩЕ

## Зміст

Перелік скорочень.....	3
Вступ.....	4
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій.....	6
1.1 Аналіз предметної області використання картографічних даних у задачах планування сільськогосподарської діяльності.....	6
1.2 Огляд існуючих рішень та інформаційного забезпечення.....	7
1.3 Аналіз існуючих публікацій та наукових підходів.....	11
1.4 Мета та завдання кваліфікаційної роботи.....	14
Розділ 2 Розробка методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.....	15
2.1 Формалізація задачі та математична модель.....	15
2.2 Метод планування сільськогосподарської діяльності на основі багатосарового перцептрона.....	19
2.3 Опис набору даних.....	24
2.4 Метрики оцінювання ефективності методу.....	27
2.5 Реалізація методу та навчання нейромережевої моделі.....	29
2.6 Висновки до розділу 2.....	32
Розділ 3 Експериментальне дослідження методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.....	33
3.1 Опис прикладного застосування.....	33
3.2 Сценарії експериментального тестування.....	35
3.3 Аналіз отриманих результатів.....	39
3.4 Обмеження методу та напрями вдосконалення.....	43
3.5 Висновки до розділу 3.....	45
Загальні висновки.....	46
Перелік посилань.....	48
Додатки	

## Перелік скорочень

Скорочення, термін, позначення	Пояснення
ІІІ	Штучний інтелект
ГІС	Геоінформаційні системи
NDVI	Нормалізований диференційний індекс рослинності
ML	Машинне навчання
MLP	Багатошаровий перцептрон
CNN	Згорткові нейронні мережі
RNN	Рекурентні нейронні мережі
ReLU	Функція активації
TIN	Нерегулярна триангуляційна сітка
API	Прикладний програмний інтерфейс
ІоТ	Інтернет речей
KNN	Метод К-найближчих сусідів
WGS 84	Всесвітня геодезична система
UTM	Універсальна поперечна проєкція Меркатора
EPSG	База геодезичних параметрів та систем координат
KML/SHP	Формати просторових даних
PVGIS	Геоінформаційна система сонячної енергії
TP	Істинно позитивні
TN	Істинно негативні
FP	Хибно позитивні
FN	Хибно негативні
N	Азот
P	Фосфор
K	Калій
pH	Рівень кислотності ґрунту

## Вступ

Кваліфікаційна робота бакалавра присвячена розробці методу планування сільськогосподарської діяльності на основі машинного навчання з використанням картографічних даних.

**Актуальність.** Сучасне агровиробництво потребує високоточних рішень через кліматичні зміни та обмеженість земельних ресурсів. Традиційне планування посівів без глибокого аналізу стану ґрунту та рельєфу призводить до неефективного використання полів, виснаження землі та екологічної деградації. Хоча технології точного землеробства дозволяють збирати детальні кадастрові дані та відомості про склад ґрунту, існує проблема відсутності інструментів для їх комплексної інтелектуальної обробки.

Розробка методу на основі машинного навчання та геоінформаційного аналізу дозволяє автоматично визначати найкращу культуру для посіву, виходячи з конкретних агрохімічних параметрів ділянки та її топографії, при цьому запобігаючи ерозії ґрунтів. Це робить створення такого методу планування сільськогосподарської діяльності вкрай актуальним для сучасного агросектору.

Отже, тема роботи є актуальною, оскільки вона поєднує завдання прибутку від сільськогосподарської діяльності та врахування екологічних проблем із сучасними технологіями аналізу даних, що сприяє сталому розвитку та збереженню біорізноманіття.

**Мета кваліфікаційної роботи бакалавра** полягає в автоматизації та підвищенні точності класифікації земельних ділянок для планування сільськогосподарської діяльності.

**Об'єкт дослідження** – процес інтелектуальної обробки та класифікації геопросторових і агрокліматичних даних.

**Предмет дослідження** – методи та технології машинного навчання для автоматизації планування сільськогосподарської діяльності з використанням картографічних даних.

**Завдання кваліфікаційної роботи бакалавра.** Для досягнення поставленої мети визначено наступні задачі.

1. Провести аналіз предметної області та відомих підходів до планування сільськогосподарської діяльності з використанням картографічних даних.

2. Розробити метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

3. Розробити програмну реалізацію методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

4. Виконати тестування розробленого методу, провести функціональне та прикладне дослідження точності запропонованого методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

Практичне значення розробленого методу полягає у використанні картографічних даних та наявних множин, що характеризують вимоги до сівозміни культур та збереження ґрунтів від ерозії та виснаження, для планування сільськогосподарської діяльності. При цьому, використання засобів машинного навчання дозволяє інтелектуалізувати процес агрономічного планування. Такий підхід дозволяє не лише швидко отримувати об'єктивні рекомендації щодо структури посівів, розраховувати фактичну 3D-площу полів зі складним рельєфом, а й запобігати екологічній деградації земель шляхом блокування посівів на ерозійно небезпечних схилах. Це суттєво економить час на обробку картографічних матеріалів та підвищує загальну економічну ефективність землекористування.

Напрямами практичного використання розробленого та інтегрованого методу визначено автоматизоване планування сільськогосподарської діяльності з використанням картографічних даних, автоматизований підбір сівозміни культур з урахуванням агрохімічних властивостей ґрунту та рельєфу поля.

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

### **1.1 Аналіз предметної області використання картографічних даних у задачах планування сільськогосподарської діяльності**

Глобальні виклики у сфері продовольчої безпеки та обмеженість земельних ресурсів зумовили перехід аграрного сектору до точного землеробства [1, 2]. Сучасне планування сільськогосподарської діяльності базується на детальному врахуванні просторової неоднорідності кожної ділянки [3]. Предметною областю даного дослідження є картографічні дані та геопросторові параметри земельних угідь [4, 5]. Базовим інструментом для прийняття рішень виступають цифрові топографічні та ґрунтові карти [6].

Здатність коректно читати векторні контури полів та алгоритмічно зменшити їхні масштабні спотворення тісно пов'язана з точним визначенням площі території [7, 8, 9]. Використання виключно двовимірних координат є недостатнім, оскільки фактична площа земельної поверхні залежить від рельєфу [10].

Визначальним просторовим параметром виступає топографічний рельєф, зокрема просторова кривизна, кут схилу та загальна рівномірність місцевості [11]. Згідно з агротехнічними рекомендаціями, проведення базової оранки допускається лише за умови, що кут нахилу схилу не перевищує  $10^\circ$  [12]. На ділянках, де крутизна становить від  $10^\circ$  до  $30^\circ$ , класичний обробіток уздовж схилу заборонений через критичний ризик водної ерозії; такі землі орють виключно перпендикулярно до лінії спуску для затримання вологи [13, 14]. Якщо ж кут нахилу перевищує  $30^\circ$ , територія відводиться для специфічного використання [15].

Невід'ємною характеристикою також є просторовий розподіл властивостей ґрунту (кислотність, вміст азоту, фосфору, калію), які тісно залежать від рельєфу [16].

Супутникові платформи дозволяють отримувати багатоспектральні зображення земної поверхні [17, 18]. На основі таких даних формуються тематичні індекси стану рослинності (NDVI) [19]. Інтеграція супутникових спостережень із цифровими моделями рельєфу та агрохімічними

характеристиками ґрунтів формує багатовимірну геоінформаційну систему аналізу [20]. Такий підхід забезпечує виконання державних вимог щодо раціонального використання та охорони земельних ресурсів [21].

Ручне опрацювання розрізаних топографічних та ґрунтових карт є вкрай трудомістким процесом, оскільки фахівцям доводиться візуально співставляти пласкі двовимірні контури з тривимірними матрицями висот. Такий підхід неминуче призводить до значної частки суб'єктивних помилок [22]. Неправильне обчислення фактичної 3D-площі або ігнорування локальних кутів нахилу спричиняє прямі економічні збитки та веде до серйозних екологічних наслідків у вигляді деградації ґрунтів [23].

Актуальним завданням є розробка методів алгоритмічного зчитування картографічних даних, автоматичної корекції площі з урахуванням картографічної проєкції та рельєфу для подальшого високоточного підбору сільськогосподарських культур [24, 25].

Для розв'язання цього завдання виділено основні сутності предметної області:

- «земельна ділянка» – географічні координати меж, базова 2D-площа, фактична 3D-площа;
- «топографічний рельєф» – висота над рівнем моря, кут нахилу схилу;
- «ґрунтове середовище» – рівень рН, вміст ключових макроелементів;
- «сільськогосподарська культура» – тип рослини, допустимі межі кута нахилу.

Отже, предметна область опрацювання картографічних даних у землеробстві є складною багатовимірною системою знань. Масштабність цих просторових завдань категорично вимагає впровадження новітніх комп'ютерних систем – зокрема, алгоритмів 3D-моделювання фізичної поверхні та засобів машинного навчання для інтелектуального планування.

## **1.2 Огляд існуючих рішень та інформаційного забезпечення**

Для обґрунтування необхідності розробки власної інформаційної системи було проведено аналіз сучасного ринку програмного забезпечення у сфері точного

землеробства. Основна увага приділялася системам, які працюють із картографічними даними, здатні зчитувати координати меж полів, розраховувати площу та враховувати рельєф місцевості [26]. Нижче наведено огляд найбільш поширених програмних рішень у сфері точного землеробства.

*Soft.Farm* [27] – це вітчизняний хмарний сервіс, створений для комплексного управління агропідприємством та ведення кадастрового обліку.



Рисунк 1.1 – Інтерфейс визначення координат меж поля у системі Soft.Farm [27]

Головним завданням картографічного модуля системи є оцифрування земельного банку. Програма надає користувачеві інструменти для ручного малювання контурів полів на супутниковій карті або завантаження готових KML/SHP файлів. Також система дозволяє формувати «Агрохімічний паспорт поля», записуючи туди дані про кислотність ґрунту та макроелементи.

В результаті отримуємо сформовану електронну карту господарства з чіткими межами, кадастровими номерами та розрахованою площею кожного контуру.

До переваг використання цього сервісу належить зручний інтерактивний інтерфейс для ручного виділення меж на карті та повна адаптація до законодавства України та Публічної кадастрової карти.

Недоліками цього сервісу є те, що обчислення площі здійснюється тільки у плоскій 2D-проекції, тобто, ігнорується реальний рельєф, та відсутність інтелектуальних моделей для автоматизованої оцінки придатності землі.

*OneSoil* [28] – це популярний безкоштовний застосунок для точного землеробства, який активно використовується агрономами по всьому світу, зокрема і в Україні. Головною функцією системи є автоматичний моніторинг стану посівів за допомогою супутникових знімків Sentinel. На відміну від ручного

малювання, OneSoil використовує власні алгоритми машинного навчання для автоматичного розпізнавання меж полів на оптичних знімках. Програма розраховує вегетаційні індекси та будує зони продуктивності.

В результаті отримуємо автоматично згенеровані векторні контури полів та теплові карти стану вегетації рослин.

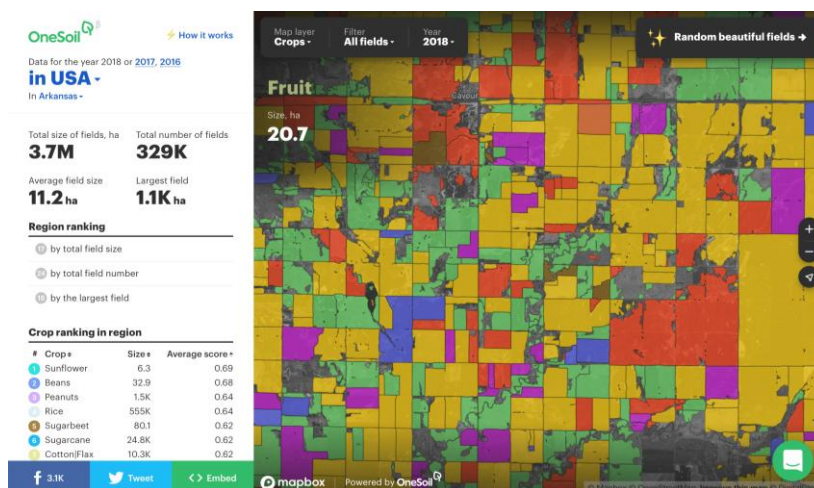


Рисунок 1.2 – Автоматизоване розпізнавання меж у системі OneSoil [28]

Перевагами системи OneSoil є висока швидкість автоматичної екстракції меж полів без ручних вимірів та доступність, зручність використання і наявність мобільного застосунку. До недоліків цієї системи можна віднести ігнорування топографічного рельєфу та відсутність аналізу крутизни схилів, тобто, система не попереджає про перевищення кута в  $15^\circ$  для оранки.

*Trimble Ag Software* [29] – це потужне професійне програмне забезпечення доступне як у десктопній, так і в хмарній версіях, орієнтоване на глибокий просторовий аналіз для точного землеробства.

Програма призначена для обробки великих масивів геоданих, зібраних безпосередньо з датчиків сільськогосподарської техніки. На відміну від попередніх рішень, Trimble Ag дозволяє імпортувати матриці висот (топографічні дані) та будувати 3D-моделі рельєфу поля. Система аналізує напрямки стоку води та крутизну схилів для створення карт диференційованого посіву.

В результаті отримуємо тривимірну топографічну карту поля, високоточний розрахунок фактичної площі криволінійної поверхні, карти-завдання для тракторів.




Рисунок 1.3 – Побудова 3D-моделі рельєфу та аналіз схилів у Trimble Ag Software [29]

Перевагами програмного забезпечення Trimble Ag Software є висока математична точність розрахунку фактичної 3D-площі та повноцінне врахування кривизни землі і побудова моделей мікрорельєфу.

До недоліків можна віднести високий поріг входження і складний інтерфейс та відсутність алгоритмів ШІ, тобто, система потребує ручного аналізу агрономом і не класифікує придатність ґрунтів.

Для більш наочного порівняння функціональних можливостей розглянутих систем складемо порівняльну таблицю 1.1.

Таблиця 1.1 – Порівняльна характеристика існуючих програмних рішень

Критерій порівняння	Soft.Farm [27]	OneSoil [28]	Trimble Ag Software [29]
Отримання координат і меж	Ручне на мапі	Автоматичне (оптичне)	Імпорт ГІС-файлів
Метод розрахунку площі	Плоска (2D)	Плоска (2D)	Об'ємна (3D)
Врахування рельєфу	Ні	Ні	Так
Оцінка придатності землі (ШІ + схили + ґрунти)	Відсутня	Відсутня	Відсутня (тільки візуалізація)
Сфера застосування	Малі / середні фермери	Глобальний мас-маркет	Великі корпорації

Підсумовуючи результати огляду, можна стверджувати, що на ринку відсутнє комплексне та доступне рішення, яке б задовольняло всі вимоги просторового планування. Українські та масові світові сервіси надають дуже зручний інтерфейс для зчитування координат з карти, але розраховують площу з двовимірними похибками і зовсім ігнорують рельєф місцевості.

Отже, розробка власного методу є науково та практично обґрунтованою. Він має поєднати у собі зручність ручного виділення ділянки на карті, математично точний розрахунок фактичної площі з урахуванням 3D-рельєфу та інтегрований алгоритм для автоматичної оцінки придатності угідь на основі геометрії схилів і складу ґрунту.

### **1.3 Аналіз існуючих публікацій та наукових підходів**

Сучасні наукові дослідження у сфері картографії та геоінформаційних технологій зосереджені на вирішенні фундаментальної проблеми просторового планування – подоланні математичних похибок, що виникають при проєктуванні тривимірного фізичного рельєфу на двовимірну площину карти. Лише після вирішення цієї суто картографічної задачі та обчислення фактичної площі поверхні стає можливим ефективно використання цих даних у прикладних галузях, зокрема для точного землеробства.

Аналіз міжнародних і українських наукових публікацій дозволяє виділити три основні напрями сучасних досліджень: математичні підходи до обчислення 3D-площі рельєфу, інтеграція топографічних даних з картами ґрунтів та застосування машинного навчання для оцінки сільськогосподарської придатності земель.

*Напрямок 1. Подолання похибок 2D-карт та обчислення фактичної площі рельєфу.*

Головним викликом, який розглядається в сучасних статтях з геоінформатики, є економічні та екологічні наслідки ігнорування мікрорельєфу на кадастрових картах. Традиційні системи розраховують площу сільськогосподарського поля як плоского багатокутника.

У статті [30] досліджується необхідність переходу від 2D-карт до тривимірних моделей рельєфу. Доведено, що використання цифрової моделі рельєфу для розрахунку справжньої криволінійної площі та крутизни схилу є критично необхідним. Дослідження показує, що на горбистих територіях розбіжність між площею на карті та фізичною площею поверхні призводить до значних похибок при закупівлі посівного матеріалу.

Математичний апарат для вирішення цієї проблеми деталізується у праці [31]. У ній аналізуються методи просторової тріангуляції та ГІС-моделювання, які дозволяють розбити виділений на карті контур на множину 3D-трикутників, враховуючи висоту кожної точки. Це дозволяє зменшити похибки, характерні для плоских картографічних моделей.

### *Напрямок 2. Інтеграція просторових даних рельєфу з картами ґрунтів.*

Отримавши точну інформацію про 3D-площу та кути нахилу поверхні, науковці переходять до наступного етапу – збагачення топографічних карт агрохімічними даними. У дослідженні [32] розглядається проблема накладання просторової геометрії рельєфу на векторні карти типів ґрунтів. Зазначається, що фізичний рельєф (напрямок стоку води, крутизна) безпосередньо впливає на вимивання поживних речовин. Тому просторові координати поля необхідно аналізувати виключно в комплексі з атрибутивними даними (наприклад, рівнем рН, азотом, фосфором), створюючи багатошарову цифрову модель ділянки.

### *Напрямок 3. Застосування машинного навчання для агрономічного планування.*

Після того, як алгоритми розраховували фактичну 3D-площу, кути нахилу та об'єднали їх з даними про ґрунт, ці дані передаються до моделей машинного навчання.

У роботі [33] досліджується використання алгоритмів Random Forest та Support Vector Machines для кінцевої класифікації територій. На вхід алгоритмів машинного навчання подаються розраховані ГІС-алгоритмом топографічні та ґрунтові параметри. Модель автоматично генерує висновок щодо придатності ділянки для сільськогосподарської діяльності, враховуючи рельєфні обмеження (наприклад, забороняючи вирощування просапних культур на схилах понад 15°).

Для порівняння ефективності різних ML-моделей у роботі з картами, у публікації [34] проведено оцінку алгоритмів машинного навчання та штучних нейронних мереж для прогнозування динаміки землекористування. Доведено, що штучний інтелект значно перевершує людину у здатності одночасно аналізувати 3D-рельєф та хімічний склад ґрунту.

Специфіка вітчизняних публікацій повністю підтверджує критичну необхідність врахування рельєфу. Українські вчені зосереджені на проблемах деградації ґрунтів, спричинених тим, що фермери орієнтуються на плоскі карти.

У публікації [35] досліджується просторовий аналіз ерозійних процесів на Рівненському плато. Наголошується: через те, що розорювання крутосхилів планується виключно за плоскими кадастровими картами (без урахування кута нахилу), посилюється нищівна водна ерозія. Відтак, алгоритмічне зчитування кута схилу з мапи є першочерговою задачею для збереження українських чорноземів.

Цю ж проблематику піднято у дослідженні Карпатського регіону [36]. За допомогою ГІС-методів та цифрових моделей висот доведено, що саме фізичний 3D-рельєф має диктувати правила сільськогосподарської діяльності, а не юридичні межі на плоскій карті.

Аналіз актуальних досліджень дозволяє зробити висновок, що у сучасній науці фундаментально обґрунтовано необхідність використання цифрових моделей рельєфу для обчислення фактичної 3D-площі та крутизни схилів замість використання традиційних плоских 2D-карт. Крім того, доведено високу ефективність алгоритмів машинного навчання, які здатні аналізувати ці складні топографічні масиви даних і видавати готові рекомендації для сільського господарства. Водночас виявлено недолік, що ці математичні та інтелектуальні методи рідко об'єднані у зручні програмні рішення. Це формує головне завдання для даної роботи: розробити метод, який забезпечить зчитування координат з інтерактивної карти, алгоритмічно розрахує 3D-площу з урахуванням рельєфу та використає ці параметри для роботи моделі машинного навчання, що автоматично оцінить придатність землі.

Поєднання машинного навчання з картографічними даними дає можливість створювати інтелектуальні системи підтримки прийняття рішень, які

здатні аналізувати супутникові знімки, погодні умови, характеристики ґрунтів та інші геопросторові показники. Це дозволяє аграрним підприємствам більш точно планувати сільськогосподарську діяльність, зменшувати витрати ресурсів, підвищувати продуктивність та забезпечувати стабільність виробництва. Важливість машинного навчання полягає також у його здатності адаптуватися до змінних умов середовища та постійно вдосконалювати результати прогнозування на основі нових даних. Завдяки цьому сучасні інформаційні системи стають не лише інструментами обробки даних, а й засобами інтелектуального аналізу та стратегічного планування.

#### **1.4 Мета та завдання кваліфікаційної роботи**

В результаті проведеного аналізу метою кваліфікаційної роботи є автоматизація та підвищення точності класифікації земельних ділянок для планування сільськогосподарської діяльності виробників агропродукції. Повний опис предметної області, а саме: облік картографічних даних рельєфу, множини ознак сільськогосподарських культур, параметри впливу на ерозію ґрунтів тощо, передбачено вхідними даними.

Для досягнення мети роботи необхідно реалізувати виконання наступних задач.

1. Провести аналіз предметної області та відомих підходів до планування сільськогосподарської діяльності з використанням картографічних даних.

2. Розробити метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

3. Розробити програмну реалізацію методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

4. Виконати тестування розробленого методу, провести функціональне та прикладне дослідження точності запропонованого методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

## Розділ 2 Розробка методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання

### 2.1 Формалізація задачі та математична модель

Процес планування сільськогосподарської діяльності в сучасних умовах точного землеробства вимагає обробки великих масивів різнорідних даних. Для автоматизації цього процесу необхідно здійснити перехід від фізичних параметрів земельних ділянок до абстрактних математичних структур.

У межах даного дослідження задача формалізується як задача багатокласової класифікації. Метою є побудова інтелектуального відображення  $F : X \rightarrow Y$ , де кожному вхідному вектору характеристик поля  $X$  ставиться у відповідність мітка класу  $y$ , що позначає найбільш перспективну культуру для вирощування. Проте, враховуючи вимоги екологічної безпеки та запобігання водній ерозії ґрунтів, класичні нейромережеві підходи є недостатніми, якщо вони не враховують геоморфологію відкритого рельєфу. Тому загальний метод формалізується як гібридна система: нейромережева апроксимація біологічної придатності доповнюється детермінованим просторовим фільтруванням на основі 3D-моделі рельєфу.

Якість прогнозу прямо залежить від репрезентативності вхідних даних. Вхідний простір  $X$  декомпозиється на два функціональні підпростори.

1. Агрокліматичний підпростір ( $X_{agro}$ ): Вектор ознак, що подається на вхід нейронної мережі. Включає агрохімічні показники ґрунту (N, P, K, pH) та кліматичні параметри.

2. Топографічний підпростір ( $X_{topo}$ ): Вектор просторових ознак, отриманих із цифрової моделі рельєфу. Представлений вектором  $(X_{topo}) = [\alpha, A_{3D}]$ , що відповідають середньому куту нахилу схилу  $\alpha$  та фактичній 3D-площі ділянки  $A_{3D}$  (га). Формально вхідний агрокліматичний вектор записується як:

$$X_{agro} = \{x_1, x_2, \dots, x_n\} \in R^n, \quad (2.1)$$

де  $x_i$  – компоненти вектора ознак, що кількісно відображають конкретні географічні, агрохімічні та кліматичні показники обраної земельної ділянки;  $n$  – загальна кількість таких параметрів.

У контексті точного землеробства використання невідкаліброваних географічних систем координат (наприклад, базової WGS 84 / EPSG:4326) [37], де координати вимірюються в градусах, є неприпустимим. Без коригування цих спотворень масштабу система отримуватиме хибні дані про розмір поля, що унеможливило коректний просторовий аналіз та розрахунок обсягів посівного матеріалу.

Для розв'язання цієї проблеми у межах розроблюваного методу повинно бути передбачено обов'язковий етап просторової репроекції даних. Перед обчисленням площі всі координати векторної карти мають програмно конвертуватися у плоску метричну систему координат зокрема, (наприклад, UTM зона 35N / EPSG:32635 для центральної України) або європейську рівновелику проєкцію (EPSG:3035). Це дозволить ліквідувати візуальні ілюзії масштабу, зберегти метричну точність та забезпечити коректне обчислення реальної площі кожного поля у гектарах.

Особливістю сформованого простору вхідних даних є наявність тісних, але прихованих кореляцій між параметрами. Наприклад, рівень кислотності ґрунту (рН) безпосередньо впливає на здатність кореневої системи рослин засвоювати фосфор та калій із добрив. Завдяки багатошаровій архітектурі, нейронна мережа здатна самостійно виявляти ці неочевидні взаємозв'язки.

Оскільки параметри вхідного вектора  $X_{agro}$  мають різну фізичну природу та масштаби, пряме використання їх значень призведе до зміщення градієнтів під час навчання. Для усунення цього ефекту застосовується метод стандартизації Математичне перетворення кожної ознаки  $x_i$  здійснюється за формулою:

$$z_i = \frac{x_i - \mu_i}{\sigma_i}, \quad (2.2)$$

де  $z_i$  – стандартизоване значення ознаки,  $\sigma_i$  – її стандартне відхилення.  $\mu_i$  – середнє арифметичне значення ознаки у вибірці. Це перетворює простір даних

таким чином, що кожна ознака має нульове середнє та одиничну дисперсію, що критично важливо для стабільної роботи шарів нейронної мережі.

Множина вихідних рішень  $Y$  є дискретною і складається з  $m$  міток класів. На відміну від задач регресії, тут ми шукаємо не числове значення, а ймовірнісний розподіл. Для цього на вихідному шарі мережі реалізована функція Softmax:

$$P(y = c_i | X) = \frac{e^{z_i}}{\sum_{j=1}^m e^{z_j}}, \quad (2.3)$$

де  $z_i$  – вихідний сигнал нейрона, що відповідає  $i$  –тій культурі. Даний підхід дозволяє інтерпретувати вихід моделі як рівень впевненості у доцільності посадки тієї чи іншої культури. Специфіка предметної області планування сільськогосподарської діяльності полягає у суворій взаємовиключності класів: на одній фізичній посівній площі в межах одного вегетаційного сезону може вирощуватися лише одна монокультура. Саме тому використання незалежних активаційних функцій наприклад, Sigmoid є математично некоректним, оскільки вони можуть видати високу ймовірність одночасно для кількох несумісних культур. Використання функції Softmax вирішує цю проблему, створюючи конкурентне середовище між нейронами вихідного шару.

Процес формування фінального рішення складається з трьох послідовних математичних етапів: геопросторового моделювання, нейромережевої апроксимації та топографічної корекції. Загальна логіка функціонування розробленого методу та візуалізація цих етапів представлена на рисунку 2.1.

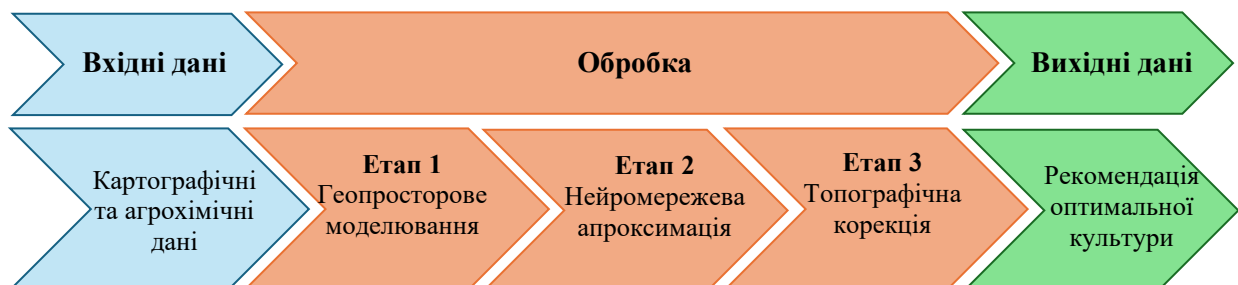


Рисунок 2.1 – Схема математичних етапів формування фінального рішення

*Етап 1. Геопросторове моделювання (TIN-рельєф).* Для усунення картографічних спотворень, базова 2D-площа полігона поля спочатку обчислюється на поверхні референсного еліпсоїда WGS84. Далі, для розрахунку фактичної 3D-площі  $A_{3D}$  (яка є компонентою вектора  $X_{topo}$ ), будується

нерегулярна триангуляційна сітка на основі матриці висот. Процес розбиття полігона на множину симплексів здійснюється за алгоритмом триангуляції Делане у двовимірному просторі з подальшим проектуванням вершин у 3D-простір. Площа кожного утвореного просторового трикутника обчислюється через векторний добуток його сторін. Записується як:

$$A_{3D} = \sum_{m=1}^M \frac{1}{2} \|\overrightarrow{A_m B_m} \times \overrightarrow{A_m C_m}\|, \quad (2.4)$$

де  $A_{3D}$  – фактична тривимірна площа земельної ділянки з урахуванням рельєфу.  $\overrightarrow{A_m B_m} \times \overrightarrow{A_m C_m}$  – вектори, що утворюють сторони  $m$ -го просторового трикутника у системі координат (довгота, широта, абсолютна висота).  $M$  загальна кількість трикутників у побудованій TIN-моделі поля.

*Етап 2. Нейромережева апроксимація.* Штучна нейронна мережа приймає на вхід лише стандартизовані агрокліматичні вектори  $X_{agro}$  і розраховує базовий вектор ймовірностей  $P$ , що відображає біологічну успішність культур на основі ґрунту та клімату.

*Етап 3. Топографічна корекція (ГІС-фільтр).* Отримані ймовірності  $P$  коригуються математичним ГІС-фільтром  $X_{topo}$ , який накладає штрафи за перевищення допустимих кутів нахилу  $\alpha$ . Відповідно до агротехнічних вимог, якщо  $\alpha \leq 10^\circ$ , дозволено базову оранку; якщо  $10^\circ < \alpha \leq 30^\circ$ , дозволено контурний обробіток (просапні культури отримують штрафний множник, що прямує до нуля); при  $\alpha > 30^\circ$  ділянка підлягає залісненню.

Фінальний прогноз розраховується як добуток Адамара – поелементне множення з подальшим перенормуванням:

$$\hat{Y}_{final} = \frac{P \circ C(X_{topo})}{\Sigma(P \circ C(X_{topo}))}, \quad (2.5)$$

де  $\hat{Y}_{final}$  – фінальний вектор ймовірностей оптимальних культур.  $P$  – базовий вектор ймовірностей, отриманий від нейронної мережі.  $C(X_{topo})$  – вектор топографічних штрафних коефіцієнтів. « $\circ$ » – оператор поелементного множення.

Для корекції ваг моделі необхідно кількісно оцінити відстань між прогнозом  $\hat{y}$  та істинним значенням  $y$ . У класичному машинному навчанні для оцінки помилки часто застосовується середньоквадратична похибка. Проте для

нашої задачі її використання є математично недоцільним через проблему згасання градієнтів при роботі з імовірнісними виходами. Крос-ентропія, навпаки, забезпечує жорсткий логарифмічний штраф: якщо модель дуже впевнено з імовірністю близькою до 1.0 вказує на хибну культуру, значення втрат зростає експоненціально. Це критично важливо в агропромисловому комплексі, де ціна помилкового стратегічного рішення щодо посівної кампанії вимірюється значними фінансовими збитками, тому алгоритм має жорстко «каратися» за хибну впевненість. У роботі використано Sparse Categorical Crossentropy. Математична суть даної функції полягає у мінімізації інформаційної ентропії:

$$H(p, q) = - \sum_i p_i \log(q_i) \rightarrow \min, \quad (2.6)$$

де  $p$  – істинний розподіл,  $q$  – прогноз моделі.

Вибір саме «Sparse» версії функції обґрунтований тим, що вона дозволяє працювати з цілочисельними мітками класів без перетворення їх у One-Hot вектори, що значно прискорює процес навчання на великих картографічних масивах.

Отже, у даному підрозділі формалізовано задачу планування сільськогосподарської діяльності як гібридну систему. Визначено структуру багатовимірному простору вхідних даних та обґрунтовано необхідність їх попередньої стандартизації. Сформовано простір вихідних рішень із використанням імовірнісної функції Softmax, імплементовано правила топографічної корекції та обрано функцію втрат Sparse Categorical Crossentropy. Отримана математична база є вичерпною та достатньою для переходу до безпосереднього проєктування архітектури нейромережевої моделі.

## **2.2 Метод планування сільськогосподарської діяльності на основі багатозарового перцептрона**

Для вирішення задачі класифікації біологічної придатності сільськогосподарських культур на основі стандартизованих агрокліматичних даних обрано архітектуру штучної нейронної мережі прямого поширення –

багатошаровий перцептрон (MLP). Вибір даної архітектури обґрунтований її високою ефективністю при роботі з гетерогенними табличними даними високої розмірності. На відміну від згорткових мереж (CNN), які орієнтовані на просторові матриці пікселів (зображення), або рекурентних (RNN), що працюють із часовими рядами, MLP ідеально підходить для виявлення прихованих нелінійних кореляцій між параметрами ґрунту (N, P, K, рН) та кліматичними факторами у статичному вигляді.

Спроектвана нейронна мережа належить до класу повнозв'язних мереж і складається з трьох функціональних блоків.

1. *Вхідний шар* (Input Layer). Кількість нейронів детермінована розмірністю вхідного вектора і складає  $n = 7$  нейронів. Вхідний шар не виконує математичних перетворень, а лише приймає вектори даних після їх попередньої стандартизації та передає їх далі.

2. *Приховані шари* (Hidden Layers). Для забезпечення здатності моделі до глибокого навчання реалізовано каскад прихованих шарів. Математично пряме поширення сигналу від шару  $l - 1$  до шару  $l$  описується матричним рівнянням:

$$h^{(l)} = f(W^{(l)}h^{(l-1)} + b^{(l)}), \quad (2.7)$$

де  $h^{(l)}$  – вектор вихідних сигналів  $l$ -го шару;  $W^{(l)}$  – матриця вагових коефіцієнтів;  $b^{(l)}$  – вектор зміщень (bias).

Для уникнення проблеми згасаючого градієнта на всіх прихованих шарах використано функцію активації ReLU, яка визначається як:

$$f(x) = \max(0, x), \quad (2.8)$$

де  $x$  – зважена сума вхідних сигналів нейрона. Ця функція є обчислювально ефективною і створює ефект розрідженості активацій.

3. *Вихідний шар* (Output Layer). Складається з 22 нейронів за кількістю можливих класів культур. На цьому шарі застосовується активаційна функція Softmax для конвертації логітів у ймовірнісний розподіл.

Вихідний шар виконує ключову функцію інтерпретації результатів роботи нейронної мережі та формування фінального прогнозу щодо оптимальної сільськогосподарської культури. Кожен нейрон вихідного шару відповідає

окремому класу культури з навчального набору даних. Значення, сформовані нейронами перед застосуванням активаційної функції відображають ступінь відповідності вхідного агрокліматичного вектора певному класу.

Особливістю задачі планування сільськогосподарської діяльності є взаємовиключність класів. У межах однієї ділянки в конкретний вегетаційний період обирається лише одна основна культура, тому використання Softmax є математично та прикладно обґрунтованим. На відміну від незалежних сигмоїдальних активацій, Softmax формує конкурентне середовище між нейронами, де збільшення ймовірності одного класу автоматично зменшує ймовірності інших. Такий підхід забезпечує не лише автоматизований вибір культури, а й можливість аналізу альтернативних варіантів на основі рівня впевненості моделі. Це є важливим для практичних задач агрономічного планування, де остаточне рішення може враховувати додаткові економічні або екологічні фактори.

Для наочного представлення внутрішньої структури розробленої нейромережі було побудовано схему архітектури (рисунок 2.2). На схемі відображено всі ключові компоненти мережі, включаючи вхідний шар, два приховані шари з механізмами регуляризації Dropout (20%), та вихідний шар для 22 класів культур.

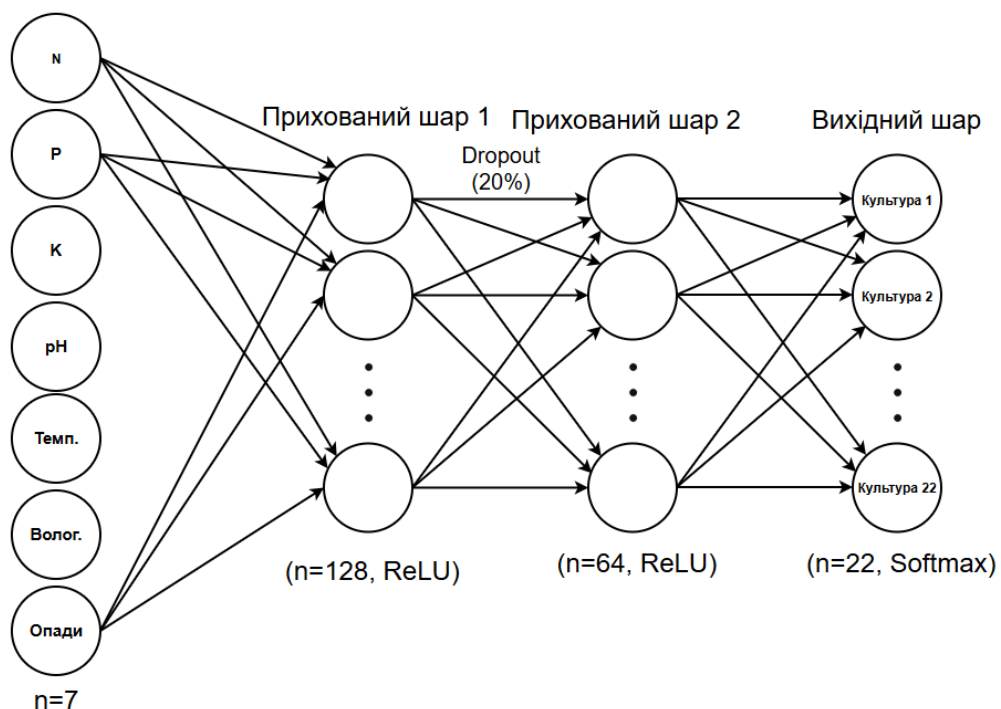


Рисунок 2.2 – Структурна схема архітектури нейронної мережі

Успішність навчання нейронної мережі прямо залежить від обраної стратегії оптимізації та методів ітеративного оновлення вагових коефіцієнтів. Оскільки задача класифікації сільськогосподарських культур передбачає роботу з багатовимірними векторами, алгоритм навчання повинен забезпечувати стабільну збіжність навіть за умов наявності шумів у вхідних даних.

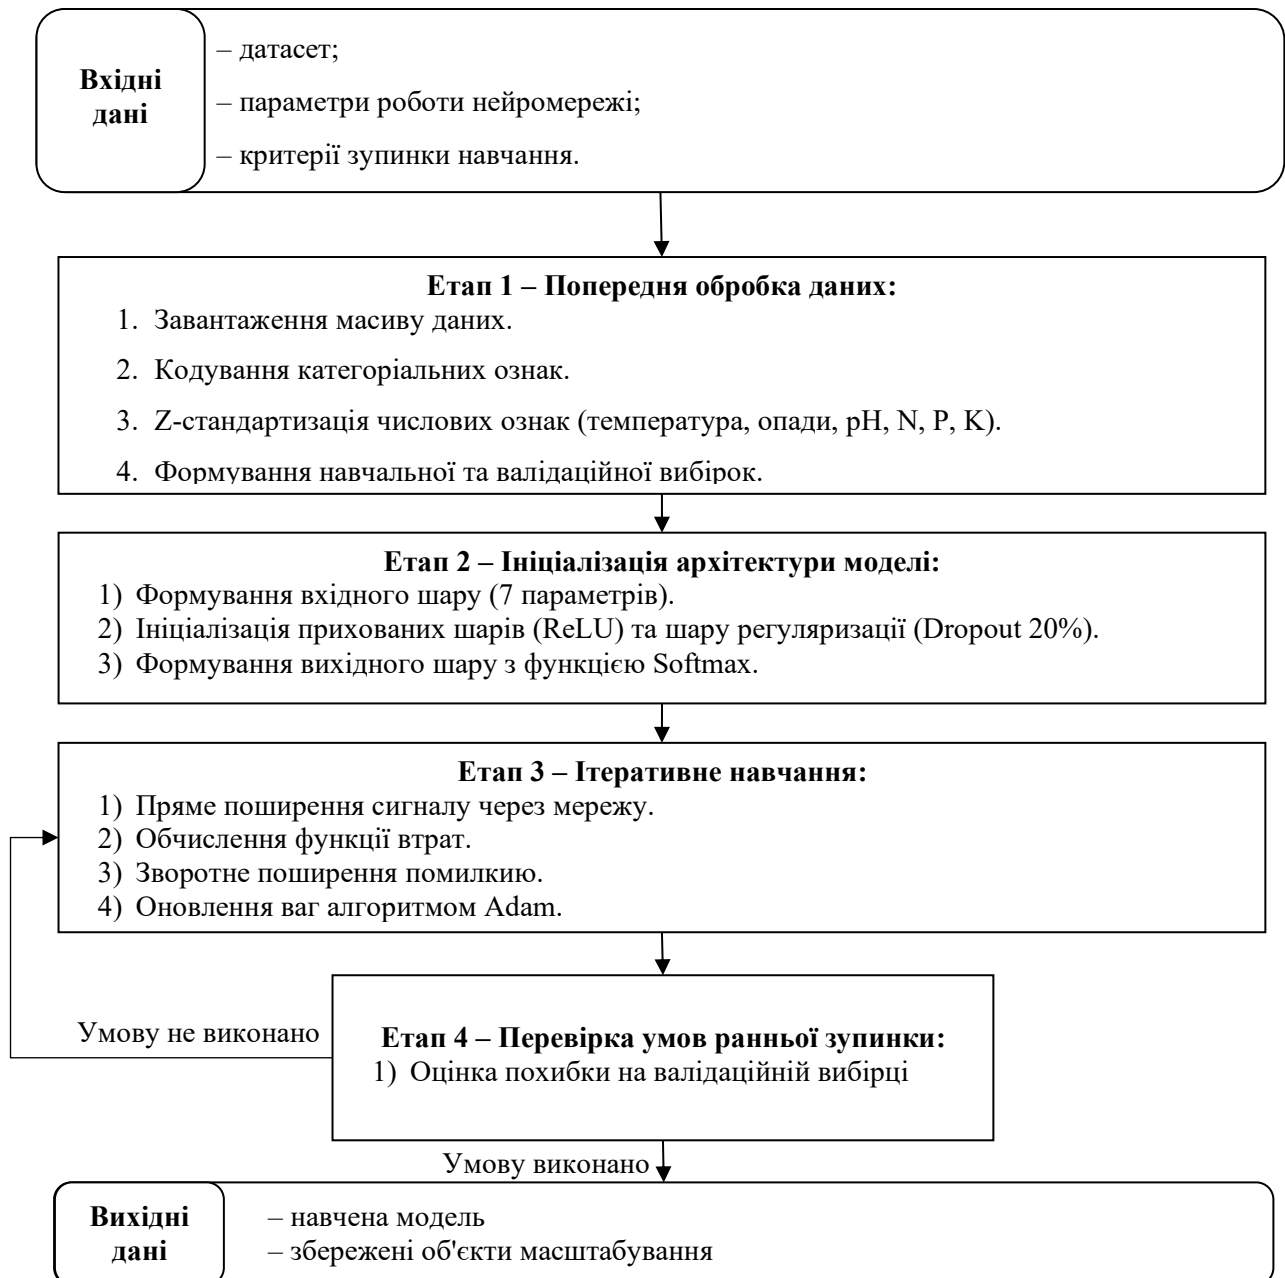


Рисунок 2.3 – Схема процесу попередньої обробки даних та навчання нейромережевої моделі

Розроблений підхід до навчання базується на використанні методу зворотного поширення помилки у поєднанні з адаптивним оптимізатором Adam, який дозволяє динамічно коригувати швидкість навчання для кожного вагового

параметра окремо. Це сприяє швидшому досягненню глобального мінімуму функції втрат та запобігає застряганню в локальних мінімумах. Логічну структуру цього ітеративного процесу, починаючи від ініціалізації параметрів до фінальної валідації моделі, відображено на рисунку 2.3.

Для оновлення вагових коефіцієнтів мережі використовується алгоритм зворотного поширення помилки із застосуванням оптимізатора Adam. Правило оновлення ваг для цього оптимізатора має вигляд:

$$W_{t+1} = W_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t, \quad (2.9)$$

де  $\eta$  – швидкість навчання;  $\hat{m}_t$  та  $\hat{v}_t$  – експоненційні ковзні середні градієнтів першого та другого порядку.

Процес оптимізації параметрів багат шарового перцептрона базується на алгоритмі зворотного поширення помилки із застосуванням оптимізатора Adam. Формалізований процес навчання нейромережевої компоненти представлено у вигляді математичного псевдокоду (Алгоритм 2.1)

### Алгоритм 2.1 – Псевдокод алгоритму навчання нейромережевої моделі

---

**Вхідні дані:** Навчальна вибірка агрокліматичних векторів  $X_{train}$ , вектор істинних міток культур  $Y_{true}$ , кількість епох  $N_{epochs}$ , розмір міні-батчу  $B$ , швидкість навчання  $\eta$ .

**Вихідні дані:** Навчена модель (оптимізовані матриці ваг  $W$  та вектор зміщень  $b$ ).

---

1. Ініціалізація: Матриці ваг  $W$  та зміщення  $b$  ініціалізуються випадковими малими значеннями із нормальним розподілом.
2. Передобробка: Виконати Z-стандартизацію вхідних даних  $X_{train}$  (за формулою 2.2)
3. Для епохи  $epoch = 1$  до  $N_{epochs}$  виконувати:
  - перемішати навчальну вибірку  $X_{train}, Y_{true}$
  - для кожен міні-батч  $X_{batch}$  розміром  $B$  виконувати:
    - обчислити стан прихованих шарів  $H$  (за формулами 2.7 та 2.8)
    - обчислити прогнозовані ймовірності  $P$  (за формулою 2.3)
    - розрахувати значення функції втрат  $Loss$  (за формулою 2.6)

- обчислити матрицю градієнтів функції втрат  $\Delta W$
- оновити перші та другі моменти градієнтів
- оновити вагові коефіцієнти  $W$  (за формулою 2.9)

4. Кінець циклу епох

5. Повернути оптимізовані параметри моделі

---

Запропонований алгоритм оптимізації на базі зворотного поширення помилки дозволяє багатоваровому перцептроні ефективно виявляти приховані нелінійні закономірності у навчальній вибірці. Завдяки ітеративному налаштуванню вагових коефіцієнтів та використанню оптимізатора Adam, розроблений метод забезпечує високу здатність інтелектуальної системи до узагальнення, що гарантує точність і стабільність прогнозування сільськогосподарських культур для нових, раніше невідомих земельних ділянок.

### 2.3 Опис набору даних

Ефективність та точність роботи розробленого методу критично залежить від якості навчальної вибірки. Для тренування багатоварового перцептрона було використано репрезентативний набір даних, що відображає комплексні агрокліматичні умови. Основним джерелом даних для навчання нейромережевого класифікатора виступає спеціалізований відкритий набір даних «Crop Recommendation Dataset» [38]. Цей датасет містить консолідовані агрокліматичні спостереження, які дозволяють моделі виявити закономірності між хімічним складом ґрунту, погодними умовами та оптимальним типом сільськогосподарської культури.

Структурно вхідний набір даних являє собою табличний масив ознак. Для кожного екземпляра структура включає 7 ключових числових параметрів. Перші чотири атрибути репрезентують агрохімічні показники ґрунтового середовища, які є критично важливими для життєдіяльності рослин:

– вміст азоту (N) – базовий макроелемент, що відповідає за інтенсивний вегетативний ріст, формування біомаси та процеси фотосинтезу;

- вміст рухомого фосфору (P) – елемент, необхідний для розвитку міцної кореневої системи, формування суцвіть та прискорення дозрівання плодів;
- вміст обмінного калію (K) у мг/кг – компонент, що забезпечує стійкість культур до кліматичних стресів, посухи та інфекційних захворювань;
- рівень кислотності ґрунту (pH) – фундаментальний показник, який визначає доступність вищезгаданих поживних речовин для кореневої системи рослини.

Наступні три параметри формують кліматичний профіль середовища, в якому вирощується культура:

- середня температура навколишнього середовища (°C) – фактор, що визначає тривалість вегетаційного періоду та можливість вирощування теплолюбних культур;
- відносна вологість повітря (%) – показник, що впливає на інтенсивність випаровування води рослинами та ризик розвитку грибкових захворювань;
- середній рівень опадів (мм) – ключова метрика вологозабезпеченості, яка дозволяє розмежувати культури на вологолюбні та посухостійкі.

Загальний обсяг табличного датасету складає 2200 записів. Для візуального розуміння формату вхідної інформації та демонстрації високої варіативності параметрів між різними класами, у таблиці 2.1 наведено репрезентативний фрагмент сирих даних, які безпосередньо формують вхідний вектор ознак перед їх подачею в нейронну мережу.

Таблиця 2.1 – Фрагмент вибірки вхідного набору даних агрокліматичних показників

<b>N</b> <b>(мг/кг)</b>	<b>P</b> <b>(мг/кг)</b>	<b>K</b> <b>(мг/кг)</b>	<b>t</b> <b>(°C)</b>	<b>Вологість</b> <b>(%)</b>	<b>pH</b> <b>ґрунту</b>	<b>Опади</b> <b>(мм)</b>	<b>Клас</b>
90	42	43	20.87	82	6.5	202.93	рис
71	54	16	22.61	57.04	5.92	65.21	кукурудза
40	60	80	18.8	15	7.3	74.2	нут
100	17	50	25.5	85.04	6.4	50.9	кавун
20	120	200	22	90	5.9	110	яблуння

117	46	19	24	79	6.9	88	бавовна
104	18	30	23.6	60.39	6.73	140.93	кава

Цільова змінна містить 22 унікальні класи сільськогосподарських культур. Аналіз розподілу цільової змінної показав, що набір даних є ідеально збалансованим – на кожен із 22 класів культур припадає рівно по 100 екземплярів. Рівномірний розподіл класів є вкрай важливим для навчання нейронної мережі. У задачах машинного навчання використання незбалансованих наборів часто призводить до ефекту «парадоксу точності», коли алгоритм просто ігнорує рідкісні класи, віддаючи перевагу мажоритарним. Оскільки в даному дослідженні всі класи представлені однаковою кількістю екземплярів, це запобігає зміщенню ваг моделі та гарантує об'єктивність функції Softmax при формуванні кінцевого вектора ймовірностей.

Для більш глибокого розуміння природи даних, перевірки вибірки на наявність аномалій та оцінки дисперсії було проведено розвідувальний аналіз. У таблиці 2.2 представлено базові статистичні метрики для кожного числового параметра.

Таблиця 2.2 – Описова статистика ознак набору даних

Параметр	Мінімум	Максимум	Середнє значення	Стандартне відхилення
Азот (N)	0	140	50.55	36.91
Фосфор (P)	5	145	53.36	32.98
Калій (K)	5	205	48.14	50.64
Температура (°C)	8.82	43.67	25.61	5.06
Вологість (%)	14.25	99.98	71.48	22.26
Кислотність (pH)	3.5	9.93	6.46	0.77
Опади (мм)	20.21	298.56	103.46	54.95

Як свідчать результати статистичного аналізу, наведені у таблиці 2.2, агрохімічні та кліматичні параметри мають абсолютно різні одиниці виміру та математичні масштаби. Наприклад, рівень опадів може досягати майже 300 мм і

має високе стандартне відхилення (54.95), тоді як рівень рН варіюється у дуже вузькому діапазоні (від 3.5 до 9.9) з мінімальним відхиленням (0.77).

Подача таких «сирих» різномасштабних даних безпосередньо у вхідний шар нейронної мережі є помилковою практикою. У такому випадку оптимізатор почне приділяти непропорційно велику увагу ознакам із широким діапазоном значень таким як опади, ігноруючи при цьому критично важливі ознаки з вузьким діапазоном такі як кислотність ґрунту. Крім того, це призводить до формування витягнутих, еліптичних поверхонь функції втрат, що критично уповільнює збіжність алгоритмів.

Для розв'язання цієї проблеми до вхідної матриці застосовується алгоритм Z-стандартизації. Він приводить усі атрибути до нульового середнього та одиничної дисперсії. Це математично необхідна умова для стабільної збіжності алгоритму градієнтного спуску під час навчання. Процес стандартизації формує ізотропний простір ознак, у якому ваги нейронної мережі оновлюються рівномірно і ефективно.

Таким чином, сформований набір даних обсягом 2200 записів є репрезентативним та ідеально збалансованим, що мінімізує ризики зміщення моделі при класифікації 22 типів культур. Використання стандартизації ознак дозволяє привести різномірні агрокліматичні показники до єдиного математичного простору, забезпечуючи стабільність навчання нейронної мережі. Дана структура даних є оптимальною для вхідного шару багатослового перцептрона та дозволяє перейти до визначення критеріїв оцінки ефективності майбутньої моделі.

## **2.4 Метрики оцінювання ефективності методу**

Оцінювання якості роботи методу є невід'ємним етапом створення систем підтримки прийняття рішень у землеробстві. Оскільки запропонований метод вирішує задачу багатокласової класифікації (визначення однієї оптимальної культури з 22 альтернатив на основі багатовимірного вектора агрохімічних

даних), для об'єктивної перевірки його надійності застосовується комплекс спеціалізованих статистичних метрик.

Базовим аналітичним інструментом для оцінки багатокласових моделей виступає матриця помилок [39]. Вона є матричним представленням, яке наочно демонструє співвідношення між фактично оптимальними культурами та прогнозами, згенерованими системою. Матриця базується на чотирьох базових показниках:  $TP$  (істинно позитивні),  $TN$  (істинно негативні),  $FP$  (хибно позитивні) та  $FN$  (хибно негативні) результати. Аналіз цього інструменту дає змогу виявити, чи не має алгоритм системної схильності плутати культури зі схожими вимогами до вологи або рівня рН.

Загальна точність слугує первинним індикатором ефективності методу і відображає відсоток тестових випадків, для яких алгоритм правильно спрогнозував найкращий варіант посіву на основі поданих вхідних параметрів [40]. Математично обчислюється як:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (2.10)$$

Влучність є показником рівня довіри до згенерованої рекомендації. Вона демонструє, яка частка прогнозів, віднесених перцептроном до певного класу, дійсно спиралася на необхідний баланс макроелементів та кліматичних умов [41]. Високе значення влучності мінімізує хибнопозитивні рішення, які в реальному господарстві призводять до фінансових втрат:

$$Precision = \frac{TP}{TP+FP}, \quad (2.11)$$

Повнота характеризує здатність інтелектуального методу правильно ідентифікувати придатність конкретних умов для вирощування певної культури. Ця метрика показує, яку частку випадків алгоритм зміг коректно розпізнати, не «пропускаючи» сприятливі сценарії [42]:

$$Recall = \frac{TP}{TP+FN}, \quad (2.12)$$

Для забезпечення балансу між надійністю порад та здатністю знаходити всі доступні варіанти застосовується F1-міра. Вона розраховується як гармонічне

середнє між цими двома показниками, що робить її найоб'єктивнішим критерієм комплексної оцінки моделі:

$$F1 = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (2.13)$$

Оскільки модель оперує великим спектром сільськогосподарських культур, для підбиття підсумків використовуються методи усереднення. Макро-усереднення обчислює метрики для кожного класу окремо, а потім знаходить їхнє середнє арифметичне, змушуючи розробника приділяти однакову увагу як поширеним, так і рідкісним культурам. Оскільки навчальна вибірка є ідеально збалансованою, показники Macro avg та Weighted avg у даному випадку будуть математично тотожними.

Окрім фінальних показників, важливо контролювати сам процес оптимізації нейромережі. Для цього використовуються криві навчання – графіки динаміки функції втрат та загальної точності на тренувальній та валідаційній вибірках під час кожної епохи [43]. Візуальний аналіз цих кривих дозволяє оцінити стабільність збіжності вагових коефіцієнтів багатоваріантного перцептрона та вчасно запобігти ефекту перенавчання.

Таким чином, обраний комплекс статистичних критеріїв та функцій втрат забезпечує всебічну оцінку розробленого математичного методу, що дозволяє гарантувати високу достовірність рекомендацій при плануванні сільськогосподарської діяльності.

## 2.5 Реалізація методу та навчання нейромережевої моделі

Для практичної перевірки ефективності запропонованого методу та побудови моделі машинного навчання було створено відповідне алгоритмічне забезпечення. Експериментальна частина виконувалася у середовищі розробки Visual Studio Code. Базовою мовою програмування обрано Python, яка на сьогодні є стандартом у сфері аналізу даних, математичного моделювання та розробки систем штучного інтелекту [44].

Проектування програмної архітектури базується на використанні відкритого стека спеціалізованих бібліотек, кожна з яких відповідає за окремий етап обробки інформації:

- для структурування вхідних наборів даних, читання файлів та маніпуляцій з багатовимірними масивами агрохімічних показників (вміст азоту, фосфору, калію, рівень рН тощо) використовуються бібліотеки Pandas та NumPy [45], які забезпечують високу швидкість векторних обчислень;

- процеси передобробки даних, нормалізації, стратифікації вибірок та розрахунку статистичних метрик ефективності реалізовані за допомогою інструментарію Scikit-learn [46];

- для безпосереднього конструювання топології багатошарового перцептрона, налаштування процесу його навчання та експлуатації застосовується платформа TensorFlow та її високорівневе API Keras [47], що дозволяє ефективно працювати з графами обчислень.

Робота експериментального методу будується за принципом лінійного пайплайну. Оскільки вхідні параметри мають принципово різні математичні масштаби та одиниці вимірювання (наприклад, річна кількість опадів може вимірюватися сотнями міліметрів, тоді як рівень рН ґрунту варіюється у вузьких межах від 0 до 14), вони обов'язково проходять етап нормалізації. Без попереднього масштабування ознаки з більшими абсолютними значеннями будуть домінувати під час обчислення градієнтів, що неминуче призведе до нестабільності навчання та згасання вагових коефіцієнтів для інших важливих параметрів. Для усунення цієї проблеми обрано алгоритм стандартного масштабування [48]. Цей метод трансформує розподіл кожної вхідної ознаки таким чином, щоб її середнє значення дорівнювало нулю, а стандартне відхилення – одиниці.

Для забезпечення об'єктивної оцінки точності та уникнення ефекту перенавчання було застосовано класичну схему розбиття датасету. Загальний набір даних (2200 екземплярів) розподілено на навчальну вибірку (80%, або 1760 записів) для тренування моделі та валідаційну вибірку (20%, або 440 записів) для незалежної перевірки її здатності до генералізації. Оскільки модель прогнозує 22

різні класи культур, розбиття виконувалося із застосуванням механізму стратифікації. Це гарантує пропорційне представлення кожного класу як у навчальній, так і у валідаційній вибірках, унеможливаючи ситуацію, коли рідкісні культури потрапляють лише в один із наборів даних.

Під час конфігурації алгоритму навчання нейронної мережі були встановлені та обґрунтовані наступні гіперпараметри.

1. Оптимізатор ваг – адаптивний алгоритм Adam. На відміну від класичного стохастичного градієнтного спуску, він обчислює індивідуальні швидкості навчання для кожного параметра на основі оцінок першого та другого моментів градієнтів. Це забезпечує швидку збіжність моделі навіть на складних багатовимірних поверхнях функції втрат та мінімізує ризик застрягання алгоритму в локальних мінімумах [49].

2. Функція втрат – Sparse Categorical Cross-Entropy. Як було обґрунтовано на етапі математичного моделювання, вона є стандартом для задач багатокласової класифікації та дозволяє алгоритму працювати з цілочисельними мітками класів (від 0 до 21) без необхідності їх попереднього перетворення у громіздкі One-Hot вектори, що значно економить оперативну пам'ять під час навчання.

3. Розмір пакету – 32 екземпляри. Така порційна передача даних через мережу є оптимальним компромісом: цей розмір достатній для стабільного обчислення усередненого градієнта, але водночас вносить необхідну долю стохастичності, яка допомагає моделі уникати перенавчання.

4. Кількість епох та рання зупинка – 50 базових епох навчання. Однак, для захисту моделі від втрати здатності до узагальнення, у програмний пайплайн інтегровано механізм ранньої зупинки. Алгоритм налаштовано таким чином, що він постійно моніторить значення функції втрат на валідаційній вибірці. Якщо протягом 10 послідовних епох похибка на невідомих даних перестає зменшуватися, процес тренування автоматично переривається, а системі повертаються ваги тієї ітерації, на якій було досягнуто найвищої точності.

Отже, спроектований алгоритмічний пайплайн, застосування стратифікованої вибірки та обрані гіперпараметри створюють необхідні умови

для автоматизації процесу прогнозування. Отримана навчена багат шарова нейромережева модель здатна генерувати базовий вектор ймовірностей, який на наступному етапі інтегрується з топографічними даними для формування фінального рішення. Це дозволяє перейти від теоретичного обґрунтування методу до його практичної експлуатації та оцінки результатів.

## 2.6 Висновки до розділу 2

У другому розділі кваліфікаційної роботи було розроблено метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання. Проведено формалізацію задачі як задачі багатокласової класифікації, у межах якої кожному вектору агрокліматичних та просторових параметрів ставиться у відповідність оптимальна сільськогосподарська культура.

У процесі дослідження сформовано математичну модель гібридної системи, що поєднує методи геоінформаційного аналізу та нейромережевої класифікації. Обґрунтовано необхідність використання цифрових моделей рельєфу для усунення похибок традиційних плоских картографічних проєкцій та забезпечення точного розрахунку фактичної 3D-площі земельних ділянок. Визначено структуру вхідного простору даних, що включає агрохімічні, кліматичні та топографічні параметри.

Здійснено обґрунтування вибору багат шарового перцептрона як базової архітектури штучної нейронної мережі для розв'язання задачі класифікації. Визначено функціональне призначення вхідного, прихованих та вихідного шарів мережі, а також описано механізм прямого та зворотного поширення сигналу. Для забезпечення стабільного навчання застосовано метод стандартизації даних, функцію активації ReLU та оптимізатор Adam.

## **Розділ 3 Експериментальне дослідження методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання**

### **3.1 Опис прикладного застосування**

Предметною областю розробленого програмного забезпечення є процеси інформаційного супроводу та планування сільськогосподарської діяльності в умовах точного землеробства. Основна проблематика даної області полягає у необхідності переходу від класичних, усереднених методів планування до науково обґрунтованих підходів, що базуються на аналізі просторових даних.

Традиційний підхід до оцінки площ та вибору посівних культур здебільшого спирається на двовимірні кадастрові плани, що не враховують просторову гетерогенність рельєфу. Інтеграція методів машинного навчання з геоінформаційним аналізом (ГІС) дозволяє вирішити ключові прикладні задачі предметної області.

1. Підвищення точності розрахунку необхідних ресурсів (насінневого матеріалу, добрив) за рахунок визначення фактичної 3D-площі поверхні.

2. Автоматизація процесу прийняття рішень щодо вибору оптимальної посівної культури на основі багатовимірному аналізу локальних агрохімічних та кліматичних параметрів.

3. Мінімізація екологічних ризиків шляхом запровадження автоматизованого топографічного контролю ерозійно небезпечних ділянок.

Метод орієнтований на застосування в агропромисловому комплексі, архітектура та інтерфейс системи спроектовані з урахуванням потреб кінцевих користувачів, які не є фахівцями в галузі Data Science, проте потребують результатів інтелектуального аналізу даних. Цільову аудиторію розробленої системи становлять наступні категорії користувачів:

– агрономи-аналітики та ґрунтознавці, які використовують інформаційну систему для автоматизованої інтерпретації результатів лабораторних досліджень

грунту (вміст N, P, K, рівень рН) у комплексі з кліматичними даними для формування оптимальної сівозміни;

– керівники фермерських господарств, які виступають споживачами аналітичної інформації щодо фактичних площ обробітку, де отримані метрики криволінійної 3D-площі є базисом для економічного планування та розрахунку норм витрат матеріально-технічних ресурсів.

Практичний сценарій використання Базовий алгоритм експлуатації програмної системи моделює типовий процес підготовки фахівця до посівної кампанії та складається з послідовності таких кроків.

1. *Ініціалізація та геопросторовий запит.* Користувач здійснює запуск веб-застосунку та за допомогою графічного інтерфейсу (вбудованого картографічного модуля) виконує позиціонування на місцевості. Використовуючи інструментарій створення геометрій, користувач формує полігон, що відповідає фізичним межах досліджуваного поля. Система автоматично фіксує масив географічних координат вершин полігону.

2. *Формування вхідного вектора даних.* Користувач через відповідні елементи управління вносить кількісні показники агрохімічного складу ґрунту (азот, фосфор, калій, кислотність), отримані за результатами актуальних польових вимірювань.

3. *Агрегація просторових та кліматичних даних.* Після підтвердження введених даних програмний комплекс виконує автоматизований збір додаткового контексту.

Відбувається формування запиту до зовнішнього сервісу:

– трансформація географічних координат у метричну прямокутну систему;

– формування запиту до зовнішнього сервісу цифрової моделі рельєфу, генерування матриці висот, обчислення фактичної площі поверхні з урахуванням рельєфу та визначення максимального кута нахилу;

– звернення до метеорологічного API для отримання поточних показників температури та вологості за координатами центроїда виділеної ділянки.

4. *Робота модуля неймережевого прогнозування.* Зібраний багатовимірний вектор параметрів нормалізується та передається на вхідний шар попередньо навченої моделі багатошарового перцептрона. Модель виконує класифікацію та формує список найбільш релевантних сільськогосподарських культур із зазначенням ймовірності їх успішної вегетації.

5. *Верифікація результатів та генерація звіту.* Отримані прогнози проходять валідацію через блок просторових обмежень (ГІС-фільтр). У разі перевищення допустимого кута нахилу (наприклад,  $>15^\circ$ ), система генерує тригерне попередження про загрозу ерозії та блокує рекомендації щодо вирощування просапних культур. Кінцевий результат виводиться користувачеві у вигляді структурованого аналітичного звіту, що містить порівняльний аналіз площ, кліматичне зведення та агрономічні рекомендації.

Отже, розроблена інформаційна система є дієвим комплексним інструментом для підтримки прийняття рішень у сфері точного землеробства. Вона успішно трансформує складні технології машинного навчання та просторового ГІС-аналізу в інтуїтивно зрозумілий покроковий процес, доступний для фахівців агропромислового комплексу без спеціальних знань у галузі. Запропонований сценарій використання дозволяє автоматизувати процес підбору оптимальних посівних культур, мінімізувати економічні витрати завдяки точним розрахункам 3D-площі та забезпечити надійний топографічний контроль для запобігання деградації земель.

### **3.2 Сценарій експериментального тестування**

Метою даного етапу є верифікація працездатності розробленого методу та кількісна оцінка його ефективності в умовах, наближених до реальної експлуатації. Для аналізу було розроблено комплексний план тестування, який включає оцінку на ізольованих даних, порівняння з еталонними алгоритмами та абляційне дослідження для визначення вкладу кожного модуля системи.

Для навчання та тестування нейромережевої моделі використовувався набір агрокліматичних даних, що охоплює 22 класи сільськогосподарських культур. З метою уникнення перенавчання моделі та забезпечення об'єктивної оцінки її здатності до генералізації, загальний масив даних було розділено із застосуванням методу стратифікованої вибірки. Це дозволило зберегти однакове пропорційне співвідношення класів у кожному наборі. Структуру розподілу даних наведено у таблиці 3.1.

Таблиця 3.1 – Структура розподілу набору даних

<b>Вибірка</b>	<b>Відсоток від загального обсягу</b>	<b>Кількість екземплярів</b>	<b>Цільове призначення</b>
Навчальна	80%	1760	Ініціалізація та оновлення вагових коефіцієнтів моделі
Валідаційна	20%	440	Фінальна оцінка ефективності та розрахунок метрик точності

Для моніторингу процесу збіжності градієнтного спуску та своєчасного виявлення перенавчання, показники функції втрат та точності на кожній епосі паралельно відстежувалися на валідаційній вибірці. При цьому дані цієї вибірки не брали безпосередньої участі в оновленні вагових коефіцієнтів MLP, що дозволило зберегти об'єктивність фінальної оцінки ефективності алгоритму.

Для наукового обґрунтування вибору архітектури MLP як основи класифікатора було проведено порівняльне тестування з класичними алгоритмами машинного навчання: Випадковим лісом та Методом К-найближчих сусідів. Оцінка ефективності алгоритмів проводилася на валідаційній вибірці за метриками загальної точності та збалансованої F1-міри. Оскільки набір даних є практично збалансованим, показники макро-усередненої F1-міри математично збіглися із загальною точністю, тому для уникнення дублювання в підсумкову таблицю винесено лише показник загальної точності.

Додатково фіксувалися апаратні метрики: об'єм пам'яті, необхідний для збереження натренованої моделі, та час інференсу. Результати порівняльного аналізу наведено у таблиці 3.2.

Таблиця 3.2 – Порівняння ефективності алгоритмів машинного навчання

Модель (Алгоритм)	Загальна точність	Розмір збереженої моделі	Час інференсу (мс)
Метод К-найближчих сусідів (KNN)	0.980	230 КБ	4.1
Випадковий ліс (Random Forest)	0.996	3.41 МБ	12.3
Багатошаровий перцептрон (MLP)	0.991	159 КБ	1.5

Як свідчать результати, ансамблевий метод Random Forest продемонстрував вищу загальну точність (на 0.5%). Проте аналіз апаратних метрик повністю виправдовує вибір розробленої нейромережевої архітектури.

Багатошаровий перцептрон має найменший розмір збереженої моделі (159 КБ), що у 21 раз менше порівняно з ансамблем дерев рішень. Це є критичною перевагою для розгортання вебзастосунку на серверах з обмеженою оперативною пам'яттю. Крім того, завдяки оптимізованим матричним обчисленням фреймворку TensorFlow, модель MLP демонструє найшвидший час інференсу (1.5 мс). Таким чином, оптимальний баланс між високою точністю (99.1%), мінімальним споживанням ресурсів пам'яті та миттєвим відгуком робить багатошаровий перцептрон ідеальним ядром розробленого методу.

Оскільки розроблений метод є гібридним, для оцінки практичної цінності його структурних компонентів було реалізовано абляційне дослідження. Тестування передбачало почергове відключення інтелектуальних модулів системи та фіксацію змін у результатах планування.

1. *Сценарій повної ізоляції зовнішнього контексту.* Алгоритм був позбавлений можливості враховувати температурні межі та рельєф. На вхід подавалися лише ідеальні показники ґрунту (N, P, K, pH). Встановлено, що без температурного контексту модель хибно класифікує придатність земель, пропонуючи теплолюбні культури для регіонів з низькими середніми температурами.

2. *Сценарій відключення ГІС-фільтра.* Система працювала у режимі класичного ML-прогнозування без топографічних обмежень. При подачі координат земельної ділянки з кутом нахилу 18° (перевищення норми), ізольована нейромережа рекомендувала посів просапних культур (кукурудза, соняшник). Активація розробленого ГІС-фільтра успішно заблокувала цю рекомендацію, усунувши ризик виникнення активної водної ерозії ґрунту.

3. *Сценарій нівелювання рельєфу (2D vs 3D).* Було проведено серію розрахунків площі для полігонів зі складним рельєфом. Зафіксовано, що використання стандартної кадастрової 2D-площі призводить до систематичної похибки у розрахунках від 5% до 10% порівняно з фактичною 3D-площею поверхні. Це доводить економічну доцільність впровадження алгоритму триангуляції на основі матриці висот.

Підсумкові результати впливу відключення модулів на безпеку та точність планування зведено у таблицю 3.3.

Таблиця 3.3 – Результати абляційного дослідження архітектури системи

<b>Сценарій тестування</b>	<b>Точність рекомендації посівної культури</b>	<b>Запобігання ризику водної ерозії ґрунту</b>	<b>Похибка в розрахунку посівної площі</b>
Без клімату та ГІС	Низька (система ігнорує температурні межі регіону)	Не працює (дозволяє посів просапних культур на крутих схилах)	Відсутня (модель не розраховує площу поля)

Без ГІС-фільтра	Висока (рекомендація відповідає клімату та ґрунту)	Не працює (система не ідентифікує топографію ділянки)	До 10-15% (використовується плоска 2D-площа з похибкою)
Повна система	Висока	Активно (Автоматичне блокування при нахилі >15°)	Мінімальна похибка (використовується 3D-модель рельєфу)

Проведені експерименти доводять, що висока точність та екологічна безпека планування досягається виключно завдяки синергії нейромережевого прогнозування та детермінованого геоінформаційного аналізу, закладеної у розроблений метод.

За результатами проведеного експериментального тестування доведено працездатність та високу ефективність розробленого гібридного методу. Порівняльний бенчмаркінг підтвердив, що обрана нейромережева архітектура багат шарового перцептрона з точністю класифікації 99.09% забезпечує оптимальний баланс між якістю прогнозування та зручністю програмної інтеграції. Водночас, проведене абляційне дослідження експериментально обґрунтувало необхідність розробленої комплексної архітектури.

### 3.3 Аналіз отриманих результатів

Процес навчання розробленої нейромережевої моделі відстежувався за допомогою графіків динаміки функції втрат та загальної точності. Аналіз кривих демонструє стабільну збіжність алгоритму: функція втрат на валідаційній вибірці експоненційно спадає та стабілізується після 20-ї епохи, не демонструючи ознак дивергенції. Крива точності швидко досягає плато на рівні понад 0.99. Відсутність



Як видно з рис. 3.2, модель демонструє майже абсолютну точність (значення сконцентровані на головній діагоналі). Із 440 тестових екземплярів зафіксовано лише 3 хибні ідентифікації, у двох випадках алгоритм помилково класифікував «рис» як «джут», і в одному випадку розпізнав «джут» як «рис». Така похибка є біологічно обґрунтованою та не вважається критичною, оскільки обидві сільськогосподарські культури мають ідентичні вимоги до умов вирощування (надзвичайно високий рівень вологості ґрунту та висока кількість опадів).

Для більш глибокого кількісного аналізу дискримінаційної здатності нейромережі було згенеровано деталізований звіт класифікації. Результати показали, що для 20 із 22 класів культур модель досягла абсолютної точності (Precision = 1.000, Recall = 1.000, F1-Score = 1.000). Незначне зниження показників (збалансована F1-міра на рівні 0.92) спостерігається виключно у згаданій вище спорідненій парі «рис-джут», що у поєднанні із загальною точністю доводить вичерпну надійність системи.

Головною перевагою розробленого методу є інтеграція нейромережевого прогнозування з просторовим геоінформаційним аналізом. Для верифікації цього підходу було проведено тестування у вебзастосунку на реальних картографічних даних.

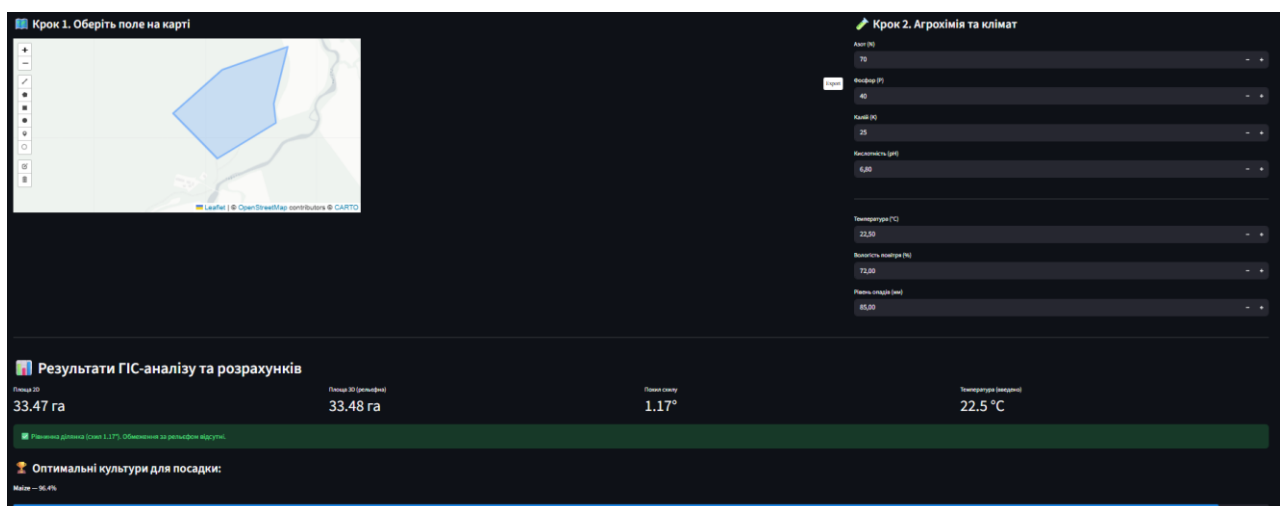


Рисунок 3.3 – Робота системи на рівнинній ділянці

На даному етапі проводився аналіз великої ділянки з типовим рівнинним рельєфом, де фактичний схил склав лише 1.17°. Завдяки такому низькому

показнику, програмний комплекс зафіксував відсутність будь-яких обмежень за рельєфом, підтвердивши безпеку ділянки для повноцінного агровиробництва. Алгоритм просторової триангуляції розрахував фактичну площу (33.48 га), що свідчить про ідеальну придатність поля для механізованого обробітку. Нейромережевий модуль, опрацювавши вхідний вектор агрохімічних даних та кліматичні умови, з високою впевненістю (98.4%) сформував рекомендацію щодо посіву кукурудзи.

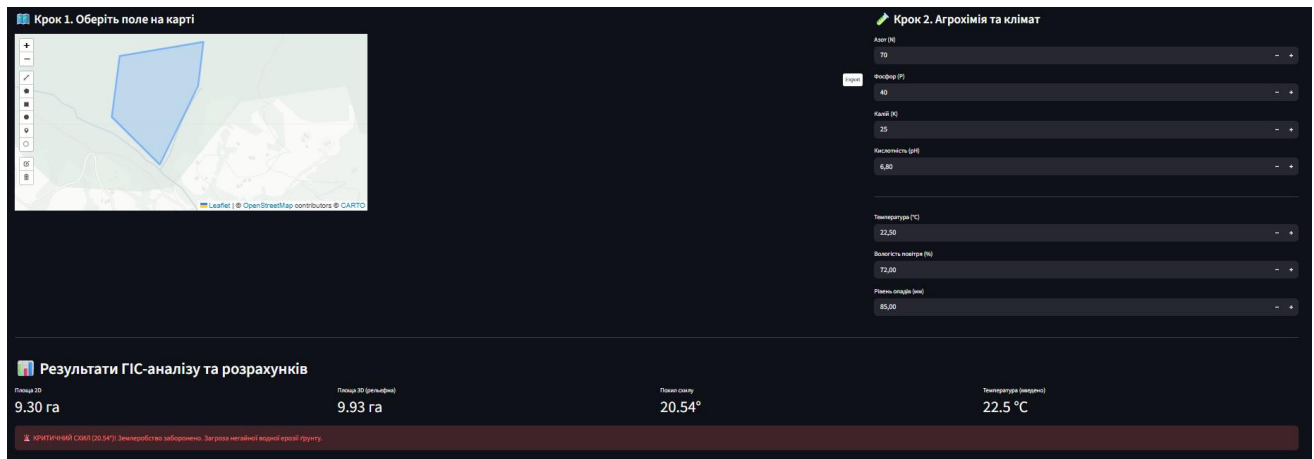


Рисунок 3.4 – Робота системи на крутому схилі

Під час моделювання другого сценарію досліджувалася ділянка зі складним рельєфом, де фактичний кут нахилу склав 20.54°. Такий показник значно перевищує встановлений критичний поріг (15°), що робить традиційне землеробство на цій території неможливим. Алгоритм просторової триангуляції зафіксував суттєву розбіжність між 2D-площею (9.30 га) та фактичною 3D-площею (9.93 га), що зумовлено значною кривизною земної поверхні. Попри внесені агрохімічні параметри та сприятливу температуру, ГІС-фільтр системи миттєво ідентифікував загрозу, заблокувавши висновок нейромережевого модуля, видавши критичне попередження про недопустимість посівів через високу ймовірність водної ерозії та деградації ґрунту. Використання традиційної 2D-площі призвело б до значної нестачі посівного матеріалу та добрив.

Отже, комплексний аналіз отриманих результатів підтверджує ефективність та практичну цінність розробленої інтелектуальної системи. На рівні машинного навчання багатосаровий перцептрон довів здатність з точністю понад 99% класифікувати агрокліматичні умови, уникаючи при цьому ефекту

перенавчання. На рівні практичного застосування інтеграція моделі з геоінформаційним модулем дозволила повністю усунути ризики екологічної деградації земель (водної ерозії), блокуючи хибні рішення на крутих схилах. Водночас імплементація 3D-алгоритму розрахунку площі забезпечує високу економічну точність при плануванні обсягів посівного матеріалу. Синергія цих інструментів робить гібридний метод повністю готовим до впровадження у реальний агропромисловий сектор.

### **3.4 Обмеження методу та напрями вдосконалення**

Незважаючи на високі показники точності нейромережевої класифікації та успішну апробацію алгоритмів геоінформаційного аналізу, розроблений метод має низку об'єктивних обмежень, характерних для сучасних систем підтримки прийняття рішень на етапі прототипування. Усвідомлення цих обмежень формує чіткий вектор для подальшого розвитку та практичного впровадження.

Основні обмеження розробленого методу наступні.

1. Відсутність апаратного «шуму» в даних. Навчання та тестування багатопараметричного перцептрона проводилося на репрезентативному, але попередньо очищеному наборі даних. У реальних польових умовах показники IoT-датчиків (особливо вологості та рівня рН) піддаються впливу зовнішніх факторів (ранкова роса, тимчасові апаратні збої, похибка калібрування). Застосування таких «сирих» емпіричних даних може призвести до певного зниження показників влучності та повноти, що вимагатиме запровадження алгоритмів попередньої фільтрації сигналів.

2. Статичність прогнозування у часі. Хоча система отримує актуальні кліматичні дані в режимі реального часу, прогноз генерується на основі поточних умов. Однак потреби рослини кардинально змінюються залежно від фази вегетації. Оскільки поточна архітектура MLP не розрахована на аналіз довгострокових часових рядів (прогнозів погоди на місяці вперед), це створює обмеження для планування повного сільськогосподарського циклу.

3. Регіональна специфіка датасету. Використана база значень оптимізована під специфічний набір культур (зокрема, тропічних та субтропічних, таких як кава, папайя, манго). Для повноцінного використання системи в умовах помірною клімату необхідне донавчання моделі на локальних ґрунтових базах (наприклад, для чорноземів лісостепової зони).

Для подолання описаних обмежень та розширення функціоналу гібридної системи пропонуються наступні напрями вдосконалення.

1. Інтеграція з реальними мережами IoT. Розробка API-шлюзів для отримання поточних даних безпосередньо з польових телеметричних станцій. Це дозволить перевести систему з режиму одноразового планування у режим динамічного моніторингу поля в реальному часі.

2. Розширення ГІС-модуля параметрами інсоляції. Перспективним вектором розвитку просторового аналізу є додавання модуля розрахунку сонячної радіації на основі топографії. Інтеграція зовнішніх баз даних (наприклад, API PVGIS) дозволить аналізувати щоденну генерацію сонячної енергії та рівень освітленості схилів для різних кліматичних зон (як-от Львів чи Харків). Це критично важливо для точного планування висадки світлолюбних культур на рельєфній місцевості.

3. Перехід до рекурентних або ансамблевих архітектур. Для врахування часової динаміки клімату доцільно впровадити рекурентні нейронні мережі, які здатні аналізувати послідовності погодних змін протягом усього сезону, або ж використовувати ансамблеві методи для підвищення стійкості до «зашумлених» даних з датчиків.

4. Мультимодальний аналіз. Доповнення системи модулем комп'ютерного зору для обробки мультиспектральних супутникових знімків або даних з дронів. Це дозволить верифікувати хімічний склад ґрунту не лише точково (через датчики), а й візуально (через аналіз вегетаційних індексів, таких як NDVI).

Отже, розроблений метод може бути основою для подальшого розвитку систем точного землеробства. Запропоновані кроки з модернізації архітектури, розширення джерел просторових даних та впровадження динамічного

моніторингу дозволять еволюціонувати поточній моделі до рівня комплексної автоматизованої системи управління агропромисловим підприємством.

### 3.5 Висновки до розділу 3

Підсумком третього розділу є експериментальна перевірка та валідація розробленого методу. Аналіз кривих навчання багатошарового перцептрона довів стабільну збіжність моделі без ознак дивергенції. Завдяки застосуванню оптимізованої архітектури з шарами регуляризації Dropout, нейромережа продемонструвала високу здатність до узагальнення на нових агрокліматичних даних без ефекту перенавчання.

Кількісна оцінка на валідаційній вибірці підтвердила високу роздільну здатність алгоритму: загальна точність склала 99%. Матриця помилок засвідчила високу статистичну точність класифікатора, виявивши лише дві хибні ідентифікації при розпізнаванні біологічно споріднених культур (рису та джуту) із 440 екземплярів валідаційної вибірки. Подібна похибка є науково обґрунтованою та цілком допустимою, оскільки обидва класи висувають майже ідентичні вимоги до екстремально високого рівня вологості та кількості опадів. Це гарантує надійне формування агрономічних рекомендацій у багатовимірному просторі ознак.

Апробація системи на реальних географічних координатах підтвердила ефективність інтеграції машинного навчання з просторовим ГІС-аналізом. Алгоритм 3D-тріангуляції успішно розрахував фактичну площу поверхні складного рельєфу, що має прямий економічний вплив на точність закупівлі посівного матеріалу та добрив. Окрім цього, детермінований ГІС-фільтр довів свою здатність автоматично блокувати предиктивні рішення на крутих схилах, виконуючи функцію екологічного запобіжника проти незворотної водної ерозії ґрунтів.

## Загальні висновки

У результаті виконання кваліфікаційної роботи бакалавра було досягнуто поставлену мету – автоматизація та підвищення точності класифікації придатності земельних ділянок шляхом розроблення методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

Запропонований метод було покладено в основу створеної інформаційної системи, що забезпечує автоматичну комплексну обробку картографічних та агрохімічних даних, їх просторову трансформацію.

Для реалізації поставленої мети при проектуванні системи використано сучасний стек інформаційних технологій та методів просторового аналізу:

- алгоритм інтелектуального підбору культур реалізовано за допомогою штучної нейронної мережі (багатошарового перцептрона), розробленої на базі фреймворку TensorFlow, що забезпечує високу точність розпізнавання прихованих закономірностей у масивах ґрунтових показників;

- процес геоінформаційної обробки побудовано з використанням бібліотек GeoPandas та Folium, що дозволило автоматизувати конвертацію систем координат та здійснити побудову цифрової моделі рельєфу;

- процеси стандартизації та нормалізації багатовимірних вхідних векторів виконано інструментарієм Scikit-learn.

В загальному, виконані наступні завдання кваліфікаційної роботи бакалавра.

1. Проведено аналіз предметної області та відомих підходів до планування сільськогосподарської діяльності з використанням картографічних даних.

2. Розроблено метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

3. Розроблено програмну реалізацію методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

4. Виконано тестування розробленого методу, проведено функціональне та прикладне дослідження точності запропонованого методу використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання.

Під час тестування підтверджено надійність роботи нейромережевого модуля: алгоритм досяг загальної точності класифікації на рівні 0.991. Водночас топографічний ГІС-фільтр підтвердив здатність коректно розраховувати фактичну (криволінійну) площу полів зі складним рельєфом, яка виявилася об'єктивно більшою за стандартні 2D-показники.

Розроблений метод має вагому практичну цінність: впровадження запропонованого методу дозволяє фахівцям-агрономам не лише автоматизувати процес підбору найбільш придатних сільськогосподарських культур, але й підвищити точність розрахунку площ обробітку та необхідних обсягів посівного матеріалу з урахуванням рельєфу місцевості, а також мінімізувати екологічні ризики шляхом автоматичного блокування посівів на ділянках, схильних до водної ерозії.

Загалом, отримані результати повністю верифікують працездатність створеного методу та підтверджують досягнення поставленої мети. Розроблений гібридний програмний комплекс є інноваційною, екологічно безпечною та економічно обґрунтованою системою, готовою до подальшого впровадження у процеси цифрового та точного землеробства.

Подальший розвиток системи передбачає розширення архітектури нейромережі шляхом додавання модуля прогнозування кліматичних змін, інтеграцію супутникових мультиспектральних знімків для моніторингу вегетації та оптимізацію мікросервісної архітектури для роботи в хмарних середовищах.

## Перелік посилань

1. Longley P. A., Goodchild M. F., Maguire D. J., Rhind D. W. Geographical Information Systems and Science. 4th ed. Chichester : Wiley, 2015. 480 p.
2. Digital Mapping of Soil Landscape Parameters: Geospatial Analyses using Machine Learning and Geomatics / P. K. Garg, R. D. Garg, G. Shukla, H. S. Srivastava. Singapore : Springer, 2020. 312 p. DOI: 10.1007/978-981-15-3238-2.
3. Triantakostas D. T., Tziachris P. (Eds.). Integrating GIS and Remote Sensing in Soil Mapping and Modeling. Basel : MDPI Books, 2022. URL: <https://www.mdpi.com/books/reprint/6428>.
4. Штучний інтелект. Наука. Бізнес : зб. матеріалів Всеукраїнської наук.-практ. конференції (Одеса, 22 жовт. 2024 р.). Одеса : ІКОСГ НААН, 2024. 63 с. URL: <https://icsanaas.com.ua/wp-content/uploads/2024/12/Збірник-матеріалів-конференції-22-жовтня-2024-року.pdf>.
5. Jensen J. R. Remote Sensing of the Environment: An Earth Resource Perspective. 2nd ed. Pearson, 2015. 620 p.
6. Про землеустрій : Закон України від 22 трав. 2003 р. № 858-IV : станом на 1 січ. 2024 р. URL: <https://zakon.rada.gov.ua/laws/show/858-15>.
7. Кирлик Д. В., Калинич І. В., Пічкарь Л. І. Основи картографування : курс лекцій. Ужгород : УжНУ «Говерла», 2024. 144 с. URL: <https://dspace.uzhnu.edu.ua/server/api/core/bitstreams/4f0dc6cc-08c3-4e68-8db6-07d8f7a3caa6/content>.
8. Кінь Д. О. Удосконалення методів геодезичних і картометричних обчислень у геоінформаційному середовищі : дис. ... д-ра філософії : 193 Геодезія та землеустрій. Київ : КНУБА, 2024. 278 с.
9. Зарицький О. В. Моделювання ерозійних процесів засобами ГІС // Сталій розвиток міст: поствоєнний період : матеріали XVII Всеукр. наук.-техн. конф. здобувачів вищої освіти (Харків, 15–16 квіт. 2024 р.). Харків : ХНУМГ ім. О. М. Бекетова, 2024. Ч. 3. С. 152–154.

10. Li X., Zhou Y., Gong P. Assessment of land surface area correction using DEMs for precision agriculture // *Computers and Electronics in Agriculture*. 2020. Vol. 177. P. 105712. DOI: 10.1016/j.compag.2020.105712.
11. Ляшенко Г. В., Данілова Н. В. Ландшафтознавство : конспект лекцій. Одеса : ОДЕКУ, 2023. 143 с. URL: <https://files.znu.edu.ua/files/Bibliobooks/Inshi75/0056033.pdf>.
12. Земельний кодекс України : Закон України від 25 жовт. 2001 р. № 2768-III : станом на 1 січ. 2025 р. URL: <https://zakon.rada.gov.ua/laws/show/2768-14>.
13. Про Державний земельний кадастр : Закон України від 7 лип. 2011 р. № 3613-VI : станом на 1 січ. 2025 р. URL: <https://zakon.rada.gov.ua/laws/show/3613-17>.
14. Chlingaryan A., Sukkarieh S., Whelan B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review // *Computers and Electronics in Agriculture*. 2018. Vol. 151. P. 61–69. DOI: 10.1016/j.compag.2018.05.012.
15. Digital Soil Mapping using GIS and Remote Sensing / P. Tziachris [et al.] // *Land*. 2023. Vol. 12, No. 1. P. 154. URL: <https://www.mdpi.com/2073-445X/12/1/154>.
16. Remote Sensing of Soils. Oxford : Elsevier, 2024. 420 p. URL: <https://www.sciencedirect.com/book/9780443187735/remote-sensing-of-soils>.
17. ДСТУ ISO 19115-1:2024 Географічна інформація. Метадані. Частина 1. Основні положення. Київ : ДП «УкрНДНЦ», 2024. 80 с.
18. Сучасні дистанційні методи та геоінформаційні технології в дослідженні територій : конспект лекцій / С. Г. Нестеренко, О. В. Афанасьєв, В. В. Мироненко. Харків : ХНУМГ ім. О. М. Бекетова, 2023. 120 с. URL: <https://eprints.kname.edu.ua/67890/>.
19. Hammond J., Dube T. Harmonized NDVI Time Series from Landsat and Sentinel 2 for Phenological Patterns // *Remote Sensing Applications: Society and Environment*. 2024. Vol. 35. P. 101230. DOI: 10.1016/j.rsase.2024.101230.

20. Cropland Mapping in Tropical Smallholder Systems with Sentinel 1 and Sentinel 2 Features / M. B. Trivedi [et al.] // Remote Sensing. 2023. Vol. 15, No. 12. P. 3014. DOI: 10.3390/rs15123014.

21. Про основні засади державної екологічної політики України на період до 2030 року : Закон України від 28 лют. 2019 р. № 2697-VIII. URL: <https://zakon.rada.gov.ua/laws/show/2697-19>.

22. Utilizing GIS, GPS, Remote Sensing, and AI in the Study of Soil Characteristics / V. Zatserkovnyi [та ін.] // Visnyk of Taras Shevchenko National University of Kyiv. Geology. 2025. Vol. 3, No. 110. P. 98–107. DOI: 10.17721/1728-2713.110.11.

23. WeAgro. Точне землеробство в Україні: визначення та перспективи. 2024. URL: <https://weagro.ua/blog/tochne-zemlerobstvo-v-ukrayini-vyznachennya-ta-perspektyvu/> (дата звернення: 10.04.2026).

24. Порівняння та оцінка точності методів визначення площ земельних ділянок / М. Фис, Ю. Губар, А. Бридун, А. Согор // Технічні науки та технології. 2023. № 2 (32). С. 363–378. DOI: 10.25140/2411-5363-2023-2(32)-363-378.

25. Про затвердження Порядку ведення Державного земельного кадастру : постанова Кабінету Міністрів України від 17 жовт. 2012 р. № 1051. URL: <https://zakon.rada.gov.ua/laws/show/1051-2012-п>.

26. Скакун А. А. Науково-практичні аспекти створення тематичних карт землеустрою засобами ГІС-технологій. Луцьк : ВНУ імені Лесі Українки, 2025. 165 с. URL: <https://evnuir.vnu.edu.ua/handle/123456789/11223>.

27. Soft.Farm : офіційний сайт. URL: <https://soft.farm/uk> (дата звернення: 24.04.2026).

28. OneSoil : офіційний сайт. URL: <https://onesoil.ai/ua> (дата звернення: 24.04.2026).

29. Trimble Ag Software : офіційний сайт. URL: <https://agriculture.trimble.com> (дата звернення: 24.04.2026).

30. Advancing Agricultural Land Suitability in Urbanized Environments: Insights from Geospatial and Machine Learning Approaches / S. Sathiyamurthi [et al.]

// ISPRS International Journal of Geo-Information. 2024. Vol. 13, No. 12. P. 436. DOI: 10.3390/ijgi13120436.

31. Integrating random forest and irrigation management in geographic information systems-based land suitability modeling in tropical landscapes / S. Arif [et al.] // Ecological Engineering & Environmental Technology. 2025. Vol. 26, No. 7. P. 113–125. DOI: 10.12912/27197050/205069.

32. Mostafiz R. B., Noguchi R., Ahamed T. Agricultural land suitability assessment using satellite remote sensing derived soil–vegetation indices // Land. 2021. Vol. 10, No. 2. Art. 223. URL: <https://www.mdpi.com/2073-445X/10/2/223>.

33. Sallam A. M., El-Sayed S. Machine learning algorithms and geographic information system techniques to predict land suitability maps for wheat cultivation // Journal of Ecological Engineering. 2025. Vol. 26, No. 1. P. 20–35. DOI: 10.12911/22998993/196044.

34. A performance evaluation of random forest, artificial neural network, and support vector machine learning algorithms to predict spatio-temporal land use-land cover dynamics / Y. G. Yuh [et al.] // Frontiers in Environmental Science. 2024. Vol. 12. P. 1431645. DOI: 10.3389/fenvs.2024.1431645.

35. GIS and remote sensing methods in the investigation of modern soil erosion processes on the Rivne plateau / O. Krupskyyi [et al.] // 8th International Conference "GeoTerrace-2024" (Lviv, Ukraine, 2024). Lviv, 2024. DOI: 10.3997/2214-4609.2024510036.

36. Identification of Soil Erosion Risk Areas in the Carpathian Forests Using GIS Methods / O. Hnatiuk [et al.] // International Conference of Young Professionals «GeoTerrace-2024» (Lviv, Ukraine, 2024). Lviv, 2024. DOI: 10.3997/2214-4609.2024510039.

37. Coordinate Reference Systems // A Gentle Introduction to GIS / QGIS Development Team. Open Source Geospatial Foundation, 2024. URL: [https://docs.qgis.org/latest/en/docs/gentle\\_gis\\_introduction/coordinate\\_reference\\_systems.html](https://docs.qgis.org/latest/en/docs/gentle_gis_introduction/coordinate_reference_systems.html) (дата звернення: 08.05.2026).

38. Ingle A. Crop Recommendation Dataset // Kaggle. 2021. URL: <https://www.kaggle.com/datasets/atharvaingle/crop-recommendation-dataset>.
39. Оцінювання точності класифікації космічних знімків. Метод матриці помилок // 50 North Spatial. 2024. URL: <https://www.50northspatial.org.ua/ua/classification-accuracy-assessment-confusion-matrix-method/>.
40. Болюбаш Н. М. Інтелектуальний аналіз даних. Миколаїв : ЧНУ ім. П. Могили, 2024. URL: [https://www.researchgate.net/publication/379994907\\_Volubas\\_N\\_M\\_Intelektualnij\\_analiz\\_danih](https://www.researchgate.net/publication/379994907_Volubas_N_M_Intelektualnij_analiz_danih).
41. Хіль О. С., Яковина В. С. Аналіз проблеми застосування методів машинного навчання для оцінювання та прогнозування дефектів програмного забезпечення // Науковий вісник НЛТУ України. 2024. Т. 34, № 2. С. 45–52. URL: <https://nv.nltu.edu.ua/index.php/journal/article/view/2516>.
42. Денисюк Ю. О. Обрахунок економічного ефекту використання ансамблевих моделей // Збірник матеріалів науково-практичної конференції Національного університету «Острозька академія» (Острог, 15 трав. 2024 р.). Острог : Вид-во НаУОА, 2024. С. 42–45.
43. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook. Cham : Springer, 2018. 497p. URL: <https://link.springer.com/book/10.1007/978-3-319-94463-0>.
44. VanderPlas J. Python Data Science Handbook: Essential Tools for Working with Data. Sebastopol : O'Reilly Media, 2016. 548 p. URL: <https://jakevdp.github.io/PythonDataScienceHandbook>.
45. Array programming with NumPy / C. R. Harris [et al.] // Nature. 2020. Vol. 585. P. 357–362. DOI: 10.1038/s41586-020-2649-2.
46. Використання бібліотеки Scikit-Learn у методах класифікації машинного навчання / А. Антоненко [та ін.] // Вимірювальна та обчислювальна техніка в технологічних процесах. 2025. № 1. С. 45–51. URL: <https://vottp.khmnu.edu.ua/index.php/vottp/article/view/655>.
47. Реалізація згорткової нейронної мережі з використанням TensorFlow / Ю. Я. Томка [та ін.] // Оптико-електронні інформаційно-енергетичні технології.

2024. Вип. 1. С. 112–118. URL:  
<https://oeipt.vntu.edu.ua/index.php/oeipt/article/view/621>.

48. TensorFlow: A System for Large-Scale Machine Learning / M. Abadi [et al.] // Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16). 2016. P. 265–283. URL:  
<https://www.usenix.org/system/files/conference/osdi16/osdi16-abadi.pdf>.

# ДОДАТКИ

## Додаток А

### Програмні коди

Весь вихідний код, реалізований у межах дослідження, опубліковано у відкритому доступі на GitHub за посиланням:

[https://github.com/Anton-Stepanuk/agro-gis\\_ml](https://github.com/Anton-Stepanuk/agro-gis_ml)

**Вигляд репозиторію:**

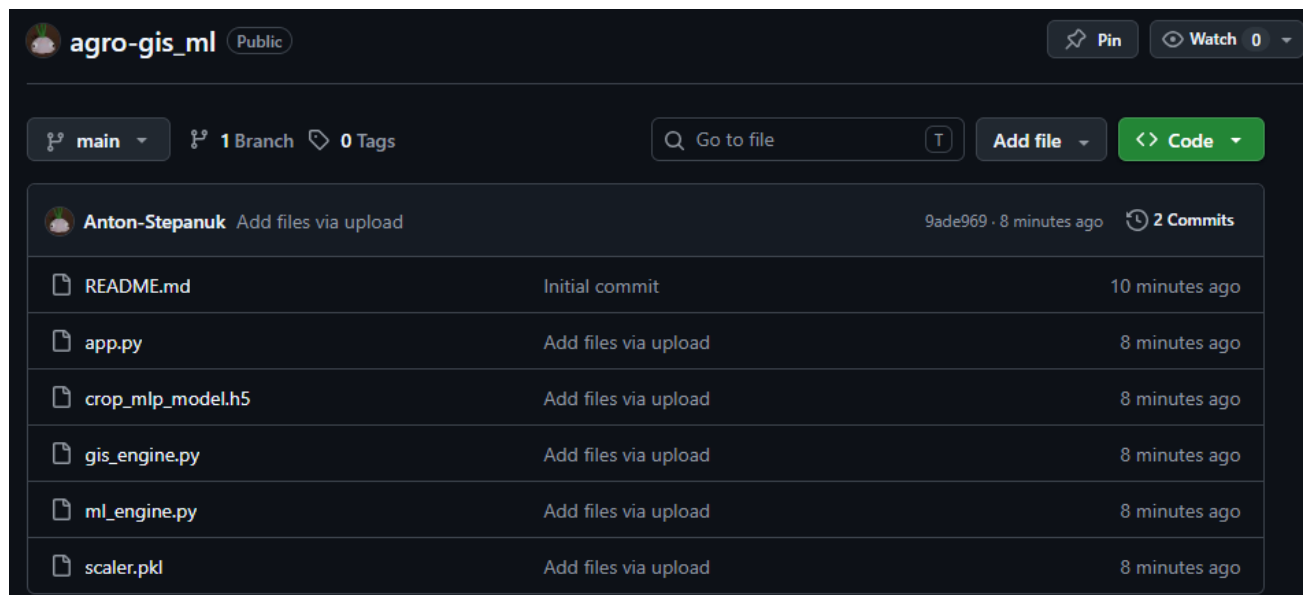


Рисунок – Скріншот сторінки репозиторія

Структура репозиторію має компонентну архітектуру та складається з наступних файлів:

*Файл запуску застосунку та графічного інтерфейсу (app.py).* Є стартовим файлом проєкту, реалізованим на базі фреймворку Streamlit. Його завдання – ініціалізувати вебзастосунок, відрендерити інтерактивну картографічну підкладку та елементи керування для введення агрохімічних даних, а також забезпечити виклик логіки обробки з інших компонентів.

*Компонент машинного навчання (ml\_engine.py).* Містить логіку предиктивної аналітики: завантажує попередньо натреновану модель багатошарового перцептрона, виконує масштабування вхідних параметрів, які передаються з графічного інтерфейсу, та генерує масив імовірностей біологічної успішності для кожної сільськогосподарської культури.

*Компонент просторового аналізу (gis\_engine.py).* Відповідає за обробку векторної геометрії виділеного користувачем полігону. Забезпечує реалізацію основних геоінформаційних функцій: трансформацію систем координат, розрахунок двовимірної та фактичної тривимірної площі ділянки, а також обчислення кута нахилу рельєфу та отримання базових кліматичних показників через звернення до зовнішнього API.

*Файл штучної нейронної мережі (crop\_mlp\_model.h5).* Збережена структура та вагові коефіцієнти навченої моделі машинного навчання. Використовується скриптом ml\_engine.py для класифікації багатовимірних агрокліматичних даних.

*Об'єкт масштабування ознак (scaler.pkl).* Серіалізований алгоритм попередньої обробки даних. Відповідає за приведення вхідних параметрів до єдиного масштабу перед їх подачею на вхід нейронної мережі, що є необхідною умовою для її коректної роботи.

## Додаток Б

### Презентаційний матеріал

# КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

## МЕТОД ВИКОРИСТАННЯ КАРТОГРАФІЧНИХ ДАНИХ ДЛЯ ПЛАНУВАННЯ СІЛЬСЬКОГОСПОДАРСЬКОЇ ДІЯЛЬНОСТІ ЗАСОБАМИ МАШИННОГО НАВЧАННЯ

### • Виконав:

• студент 4 курсу, група КН-22-2

• Антон **СТЕПАНЮК**

### • Керівник:

• к.ф-м.н., доц. каф. КН

• Віталій **МІХАЛЕВСЬКИЙ**



## Актуальність

2

Сучасне агровиробництво потребує високоточних рішень через кліматичні зміни, обмеженість земельних ресурсів та необхідність підвищення ефективності використання сільськогосподарських угідь. Традиційне планування посівів без урахування агрокліматичних показників, особливостей ґрунту та рельєфу місцевості може призводити до неефективного використання земель, зниження врожайності та деградації ґрунтів.

Сучасні геоінформаційні системи точного землеробства забезпечують доступ до великого обсягу картографічних, топографічних та агрохімічних даних. Проте залишається актуальною проблема їх комплексної обробки та аналізу для підтримки прийняття рішень. Використання методів машинного навчання у поєднанні з картографічними даними дозволяє автоматизувати оцінку характеристик земельних ділянок і формувати обґрунтовані рекомендації щодо вибору сільськогосподарських культур для вирощування.





## Мета і задачі роботи

**Об'єкт дослідження:** процес інтелектуальної обробки та класифікації геопросторових і агрокліматичних даних.

**Предмет дослідження:** методи та технології машинного навчання для автоматизації планування сільськогосподарської діяльності з використанням картографічних даних.

**Мета роботи** полягає в автоматизації та підвищенні точності класифікації земельних ділянок для планування сільськогосподарської діяльності.

**Задачі дослідження:**

- провести аналіз предметної області та відомих підходів з використанням картографічних даних;
- розробити метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання
- створити програмну реалізацію розробленого методу;
- виконати тестування та дослідити точність і ефективність запропонованого методу.




## Концептуальна схема розробленого методу

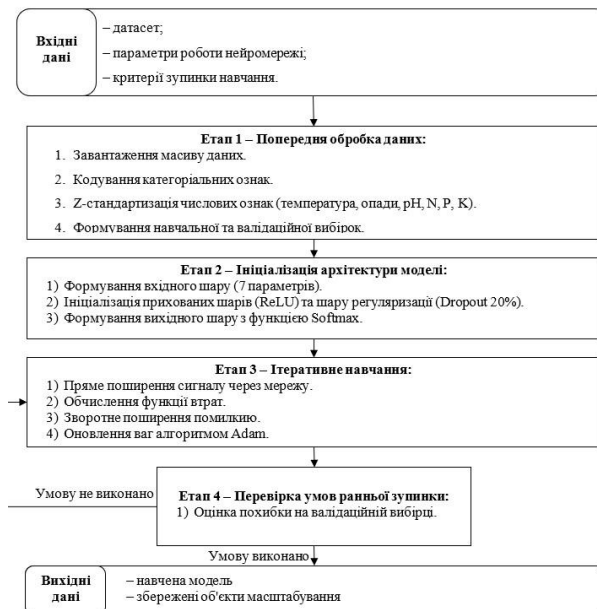




## Схема архітектури нейронної мережі



## Схема навчання нейромережевої моделі





## Оцінка ефективності моделі

7

Оцінка ефективності моделі класифікації сільськогосподарських культур базується на таких метриках:

- **Accuracy** – загальна точність передбачень оптимальної культури.
- **Precision** – влучність класифікації та рівень довіри до згенерованої рекомендації.
- **Recall** – повнота, або здатність алгоритму коректно ідентифікувати придатність конкретних умов.
- **F1-міра** – баланс між влучністю та повнотою.
- **Матриця помилок** – оцінка моделі на основі істинно та хибно позитивних/негативних результатів


$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad Recall = \frac{TP}{TP+FN}$$

$$Precision = \frac{TP}{TP+FP} \quad F1 = 2 * \frac{Precision*Recall}{Precision+Recall}$$



## Сценарій 1. Оптимальне планування

8

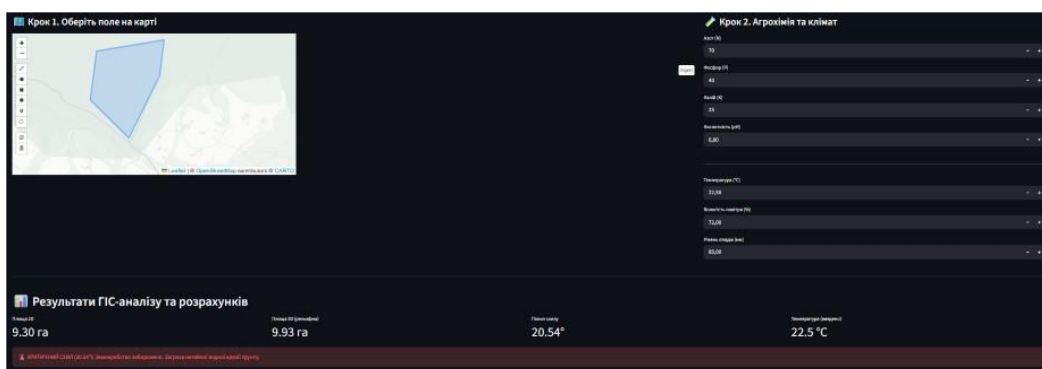


- **Рельєф:** 1.17° (Рівнина).
- **Площа:** 33.48 га.
- **Прогноз:** Кукурудза.
- **Впевненість:** 98.4%.





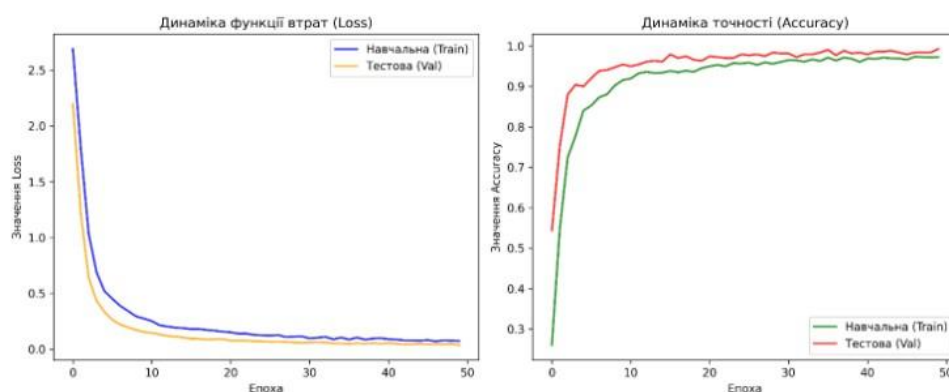
## Сценарій 2. Блокування зони ризику



- **Рельєф:** 20.54° (Крутий схил).
- **Площа:** 9.93 га.
- **Рішення:** Посів заборонено.
- **Причина:** Ерозійний ризик.



## Оцінка ефективності нейромережі



- **Висока точність:** коефіцієнт точності моделі становить 0.991
- **Стабільність навчання:** графіки демонструють швидку збіжність функції втрат без ознак перенавчання





## Висновки

Було розроблено метод планування сільськогосподарської діяльності що поєднує нейромережеву класифікацію з ГС-аналізом рельєфу. Експериментальне дослідження підтвердило високу ефективність методу: досягнуто точності класифікації **0.991**. Створений програмний комплекс автоматизує агрономічне планування, враховуючи просторові та агрохімічні параметри, і мінімізує екологічні ризики завдяки автоматичному блокуванню посівів на ерозійно небезпечних ділянках. Впровадження такого підходу дозволяє значно знизити вплив людського фактору та забезпечити обґрунтовану інтелектуальну підтримку прийняття рішень при управлінні земельним банком. Система є готовим до впровадження інструментом для цифрового землеробства з потенціалом масштабування через інтеграцію кліматичних моделей та супутникових даних.



# Дякую за увагу!



Sat Jun 13 12:45:55 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

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

**Максимальне співпадіння з одним документом 2.0%**

**Словники перевірки: UA, US, RU. Помилки в документах: 11%**

ID: 275057 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання Додано в БД: 2026-06-13 Автора: Антон СТЕПАНЮК Керівники: Віталій МІХАЛЕВСЬКИЙ Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	82489	691	3784 (5%)	54 (8%)

### Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

## Протокол аналізу звіту подібності науковим керівником

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

**Автор:** Антон СТЕПАНЮК

**Співавтор:**

**Назва:** КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання

**Науковий керівник:** Віталій МІХАЛЕВСЬКИЙ, к.ф-м.н., доц. каф. КН

**Підрозділ:** Кафедра комп'ютерних наук

**Коефіцієнт подібності 1:** 5.81%

**Коефіцієнт подібності 2:** 1.67%

**Мікропробіли:** 0

**Заміна букв:** 9

**Інтервали:** 0

**Білі знаки:** 143

**Дата створення звіту:** 2026-06-12 19:11:34.0

**Після аналізу Звіту подібності констатую наступне:**

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

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

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

**Обґрунтування:**

2026-06-13

Дата

експерт

*Петровський Р. С. et*

# РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

## ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання

Автор студент групи КН-22-2 Антон Степанюк

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: к.ф.-м.н., доц. каф. комп'ютерних наук Віталій Міхалевський

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

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

Підтвердження:

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

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

*- за системою Anti-Plagiarism: 2%;*

*- за системою StrikePlagiarism КП1: 5.81%, КП2: 1.67%.*

13.06.2026

Завідувач кафедри

Гарант освітньої програми

Керівник кваліфікаційної роботи

Олександр БАРМАК

Олександр МАЗУРЕЦЬ

Віталій МІХАЛЕВСЬКИЙ



## ВІДГУК НАУКОВОГО КЕРІВНИКА

### на кваліфікаційну роботу бакалавра

студента гр. КН-22-2 Антона СТЕПАНЮКА

за темою Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання

#### 1. Актуальність теми

Актуальним завданням, яке потребує аналізу і досліджується у даній роботі, є використання картографічних даних для планування сільськогосподарської діяльності. Традиційне планування посівів без глибокого аналізу стану ґрунту та рельєфу призводить до неефективного використання полів, виснаження землі та екологічної деградації. Хоча технології точного землеробства дозволяють збирати детальні кадастрові дані та відомості про склад ґрунту, існує проблема відсутності інструментів для їх комплексної інтелектуальної обробки. Розробка методу на основі машинного навчання та геоінформаційного аналізу дозволяє автоматично визначати найкращу культуру для посіву, виходячи з конкретних агрохімічних параметрів ділянки та її топографії, при цьому запобігаючи ерозії ґрунтів. Це робить створення такого методу планування сільськогосподарської діяльності вкрай актуальним для сучасного агросектору.

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

За стандартом, а саме описом предметної області, об'єктами вивчення та діяльності є математичні, інформаційні, імітаційні моделі реальних явищ, об'єктів, систем і процесів та методи і технології отримання, зберігання, обробки, передачі та використання інформації. Метою роботи саме є автоматизація та підвищення точності класифікації земельних ділянок для планування сільськогосподарської діяльності засобами машинного навчання. При вирішенні поставленої задачі використано методи та алгоритми розв'язання теоретичних і прикладних задач, що виникають при розробці інформаційних технологій. Тому результати виконання кваліфікаційної роботи бакалавра відповідають стандарту бакалавра спеціальності 122 – Комп'ютерні науки.

#### 3. Професійні та особистісні якості бакалавра

При роботі над кваліфікаційною роботою бакалавра Антон СТЕПАНЮК проявив себе кваліфікованим фахівцем та дисциплінованим студентом, вчасно виконуючи поставлені етапи дослідження. Як в процесі написання пояснювальної записки, так і при розробці методу та прикладного програмного забезпечення проявив достатні для одержання успішного результату компетентності та результати навчання. Опанував професійні скіли за напрямком «Комп'ютерні науки» та достатньо значний софт скіл.

Також серед особистісних якостей студента слід виділити відповідальність, здатність навчатися, нестандартність мислення.

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

Одержані в роботі результати є наслідком особистої діяльності студента, який самостійно виконував всі поставлені задачі.

#### **5. Ступінь оволодіння методами дослідження**

При реалізації кваліфікаційної роботи показав достатній рівень компетентностей та володіння необхідними інструментами та обладнанням, методами, методиками та технологіями предметної області комп'ютерних наук.

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

Тема роботи в достатній мірі обґрунтована й розкрита, проведено аналіз актуальності та відомих досліджень в межах обраної теми, поставлені завдання, які у роботі виконані, розроблено метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання та програмне забезпечення для перевірки функціональності розробленої системи і проведення експериментів.

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

Структура роботи та послідовність викладення логічні та відповідають поставленій меті. Викладення матеріалу послідовне, аргументоване, літературно грамотне.

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

Розроблений у роботі метод та його програмна реалізація можуть бути використані працівниками-агрономами для проведення досліджень та складання планів сівозмін, або інших заходів, пов'язаних із сільськогосподарською діяльністю. Ефективність застосування розробленого методу планування з використанням засобів машинного навчання за результатами проведених експериментів складає в середньому 99%.

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

Враховуючи достатній рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту.

Рекомендована оцінка «добре».

Керівник



к.фіз.-мат.н., доц. Віталій МІХАЛЕВСЬКИЙ



## РЕЦЕНЗІЯ

### на кваліфікаційну роботу бакалавра

студента гр. КН-22-2 Антона СТЕПАНЮКА

за темою: Метод використання картографічних даних для планування сільськогосподарської діяльності засобами машинного навчання

#### 1. Актуальність обраної теми

Впровадження інтелектуальних систем у сільське господарство сьогодні є одним із пріоритетних напрямків розвитку інформаційних технологій. Завдання підвищення ефективності аграрного сектору неможливо вирішити без швидкого та точного аналізу великих масивів просторових даних. Тому тема кваліфікаційної роботи, присвячена поєднанню методів машинного навчання з обробкою картографічної інформації для оптимізації агрономічного планування, є сучасною, своєчасною та безумовно актуальною.

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

У процесі виконання кваліфікаційної роботи бакалавра студент успішно впорався з поставленою метою, вирішивши всі заявлені в роботі завдання. Було досліджено інструментарій комп'ютерного моделювання агрокліматичних умов. Спроектовано та алгоритмізовано власний метод класифікації, а також створено дієвий програмний продукт для обробки даних, що свідчить про повне та глибоке розкриття теми дослідження.

#### 3. Зміст кожного розділу роботи

У першому розділі проведено детальний аналіз предметної області та сформульовано постановку задачі. Розглянуто основні підходи до використання геоінформаційних систем та алгоритмів машинного навчання в аграрному секторі, визначено їхні переваги та обмеження.

У другому розділі запропоновано та математично обґрунтовано метод класифікації агрокліматичних умов. Спроектовано архітектуру нейромережевої моделі, описано процеси передобробки набору даних, зокрема алгоритм стандартизації для збалансування різномасштабних хімічних та кліматичних показників.

У третьому розділі розглянуто особливості програмної реалізації розробленого методу. Проведено експериментальне тестування нейромережі, проаналізовано матрицю помилок та криві навчання. Описано роботу детермінованого ГІС-фільтра, який забезпечує блокування предиктивних рішень на крутих схилах для запобігання водній ерозії ґрунтів.

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

Створений метод демонструє високу роздільну здатність при обробці багатовимірних наборів даних. Практична значущість результатів полягає в тому, що запропоноване програмне рішення може бути інтегроване в роботу реальних агропідприємств. Це дозволить автоматизувати прийняття рішень щодо вибору сільськогосподарських культур та раціонального розподілу ресурсів залежно від особливостей конкретної ділянки.

#### 5. Якість оформлення кваліфікаційної роботи бакалавра

Текст роботи написано грамотною технічною мовою. Оформлення розділів, рисунків, графіків та лістингів повністю відповідає вимогам діючих стандартів ДСТУ. Матеріал структурований зручно для сприйняття, візуальні елементи доречні та інформативні. Мовних, граматичних, синтаксичних помилок не виявлено.

#### 6. Недоліки кваліфікаційної роботи бакалавра

Явних недоліків в роботі не виявлено. Можна було б узагальнити роботу методу та системи шляхом розширення кількості параметрів, які аналізуються системою, та враховувати історію зміни рел'єфу, складу та використання ґрунтів (сівозміни). Зазначені недоліки не знижують загальної цінності розробленого алгоритму.

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

Враховуючи рівень виконання роботи, актуальність дослідження та успішне вирішення поставлених завдань, кваліфікаційна робота бакалавра відповідає встановленим вимогам і може бути допущена до захисту.

Рекомендована оцінка «Добре».

Рецензент Канд. Техн. наук, доцент кафедри  
ІКТ та Р Траєкторик Тамара  
Жванічна 