

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ВЕТЕРИНАРНОЇ
МЕДИЦИНИ ТА БІОТЕХНОЛОГІЙ ІМ. С.З. ГЖИЦЬКОГО
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ**

КВАЛІФІКАЦІЙНА РОБОТА

другого (магістерського) рівня вищої освіти

на тему: «Система підтримки прийняття управлінських рішень
для прогнозування зрошення полів із використанням гібридної
нейромережевої моделі GA-BP»

Виконав: студент групи Іт-62

Спеціальності 126 «Інформаційні системи та
технології»

(шифр і назва)

Прощук Олександр Васильович

(Прізвище та ініціали)

Керівник: к.т.н., доцент Татомир А.В.
(Прізвище та ініціали)

Рецензент: к.т.н., доцент Сиротюк С.В.
(Прізвище та ініціали)

ДУБЛЯНИ-2025

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ

Другий (магістерський) рівень вищої освіти
Спеціальність 126 «Інформаційні системи та технології»

«ЗАТВЕРДЖУЮ»

Завідувач кафедри _____

д.т.н., проф. А.М. Тригуба

«_____» _____ 2025 р.

ЗАВДАННЯ

на кваліфікаційну роботу студенту

Прощуку Олександру Васильовичу

1. Тема роботи: «Система підтримки прийняття управлінських рішень для прогнозування зрошення полів із використанням гібридної нейромережевої моделі GA-BP»

Керівник роботи Татомир Андрій Володимирович, доцент
затверджені наказом по університету від 28.02.2025 року № 140/к-с.

2. Строк подання студентом роботи 10.12.2025 р.

3. Вихідні дані до роботи: вхідні метеорологічні та супутникові показники для території дослідження, підготовлений очищений набір даних, параметри масштабування ознак та цільової змінної, архітектури нейромережевих моделей для порівняння (MLP, GCN, GAT, ST-GCN та гібридна модель EGA-BPNN), результати GA-оптимізації для підбору структури мережі, програмні засоби реалізації (Python, Pandas, NumPy, Scikit-learn, Joblib, Streamlit).

4. Зміст розрахунково-пояснювальної записки (перелік питань, які необхідно розробити) _____

Вступ.

Аналіз стану дослідження щодо управління зрошенням та застосування інтелектуальних моделей.

Проектування ІСППР та вибір засобів її реалізації.

Результати створення гібридної нейромережевої моделі GA-BP та розробки ІСППР.

Висновки та пропозиції.

Список використаної літератури.

5. Перелік ілюстраційного матеріалу (з точним зазначенням обов'язкових слайдів): аналіз стану дослідження щодо управління зрощенням та застосування інтелектуальних моделей; проектування ІСППР та вибір засобів її реалізації; результати створення гібридної нейромережевої моделі GA-BP та розробки ІСППР; економічна ефективність.

6. Консультанти з розділів:

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
1, 2, 3, 5	<i>Татомир А.В., доц. кафедри інформаційних технологій</i>		
4	<i>Городецький І.М., доцент кафедри інженерної механіки</i>		

7. Дата видачі завдання

28 лютого 2025 р.

Календарний план

№ з/п	Назва етапів кваліфікаційної роботи	Терміни виконання етапів роботи	При-мітка
1	<i>Написання першого розділу</i>	28.02-20.03.25	
2	<i>Виконання другого розділу та аркушів ілюстраційного матеріалу до нього</i>	21.03-14.06.25	
3.	<i>Виконання третього розділу та аркушів ілюстраційного матеріалу до нього</i>	15.06.25-10.07.25	
4.	<i>Написання розділу «Охорона праці та безпека у надзвичайних ситуаціях»</i>	11.07-31.08.25	
5.	<i>Оцінення ефективності запропонованої системи</i>	01.09-31.10.25	
6.	<i>Завершення оформлення розрахунково-пояснювальної записки та аркушів ілюстраційного матеріалу</i>	01-30.11.25	
7.	<i>Завершення роботи в цілому</i>	01-10.12.25	

Студент _____ Прощук О. В.
(підпис)

Керівник роботи _____ Татомир А.В.
(підпис)

УДК 004.89:631.67

Система підтримки прийняття управлінських рішень для прогнозування зрошення полів із використанням гібридної нейромережевої моделі GA-BP. Прошук О.В. Кафедра інформаційних технологій – Дубляни, ЛНУВМ, 2025. Кваліфікаційна робота: 92 с. текст. част., 25 рис., 9 табл., 14 арк. ілюстраційного матеріалу, 41 джерело.

У кваліфікаційній роботі досліджено проблему підвищення ефективності управління процесами зрошення в умовах кліматичної мінливості та нерівномірності забезпечення вологою. Обґрунтовано необхідність створення інтелектуальної системи підтримки прийняття рішень, здатної забезпечувати точний прогноз водоспоживання на основі комплексного аналізу метеорологічних, біофізичних та ґрунтових показників. Проведено аналіз сучасних тенденцій розвитку зрошуваного землеробства, можливостей DSS у агросекторі та перспектив використання штучних нейронних мереж для прогнозування аграрних процесів.

У роботі розроблено архітектуру СППР, що поєднує механізми генетичного алгоритму та зворотного поширення помилки, формуючи гібридну модель EGA-BPNN. Створено навчальну вибірку з використанням історичних кліматичних даних, NDVI та показників вологості ґрунту, виконано масштабування, очищення та нормалізацію даних. Проведено порівняння кількох архітектур мультишарового перцептрона.

Розроблено прототип інформаційної системи підтримки рішень у середовищі Streamlit. Система забезпечує автоматичне масштабування даних, виконання прогнозу, порівняння фактичних і прогнозних значень, побудову графіків та формування рекомендацій щодо режимів зрошення.

Ключові слова: система підтримки прийняття рішень, зрошення, штучні нейронні мережі, генетичний алгоритм, EGA-BPNN, прогнозування, агровиробництво, ефективність.

ЗМІСТ

ВСТУП	7
Розділ 1. АНАЛІЗ СТАНУ ДОСЛІДЖЕННЯ ЩОДО УПРАВЛІННЯ ЗРОШЕННЯМ ТА ЗАСТОСУВАННЯ ІНТЕЛЕКТУАЛЬНИХ МОДЕЛЕЙ.....	9
1.1. Сучасний стан та тенденції розвитку зрошувального землеробства в умовах зміни клімату.....	9
1.2. Інформаційні системи підтримки прийняття рішень у сільському господарстві.....	12
1.3. Застосування штучних нейронних мереж для прогнозування процесів у аграрному виробництві.....	23
1.4. Гібридні інтелектуальні моделі.....	26
1.5. Завдання кваліфікаційної роботи.....	28
Розділ 2.ПРОЄКТУВАННЯ ІСППР ТА ВИБІР ЗАСОБІВ ЇЇ РЕАЛІЗАЦІЇ	30
2.1. Постановка завдання та вимоги до інформаційної системи	30
2.2. Архітектура системи підтримки прийняття рішень для прогнозування зрошення.....	33
2.3. Опис моделі EGA-BPNN	36
2.4. Вибір програмних і технічних засобів для розробки ІСППР.....	39
2.5. Проєктування структури бази даних	42
Розділ 3. РЕЗУЛЬТАТИ СТВОРЕННЯ ГІБРИДНОЇ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ GA-BP ТА РОЗРОБКИ ІСППР.....	46
3.1. Формування навчальної вибірки та попередня обробка даних	46
3.2. Навчання та порівняння моделей.....	52
3.3. Створення модулів інформаційної системи підтримки рішень.....	57
3.4. Розроблений прототип інформаційної системи підтримки рішень	61
Розділ 4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ.....	67
4.1. Аналіз умов праці під час створення СППР	67
4.2. Безпека праці під час розробки системи підтримки прийняття рішень	69

4.3. Захист населення під час надзвичайних ситуацій	71
Розділ 5. ЕКОНОМІЧНА ЕФЕКТИВНІСТЬ ВІД ВИКОРИСТАННЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ЗРОШЕННЯ ПОЛІВ	72
ВИСНОВКИ І ПРОПОЗИЦІЇ.....	76
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	79
ДОДАТКИ	84
Додаток А. Фрагмент коду СППР для для прогнозування зрошення полів із використанням гібридної нейромережевої моделі GA-BP.....	85

ВСТУП

Сільське господарство в сучасних умовах стикається з численними викликами, пов'язаними з нестабільністю клімату, дефіцитом водних ресурсів та необхідністю забезпечення сталого розвитку аграрного виробництва. Одним із ключових елементів ефективного землеробства є зрошення, що дозволяє стабілізувати врожайність та компенсувати негативний вплив посух. Проте традиційні системи управління зрошенням базуються здебільшого на статистичних нормах або ж фіксованих регламентах, що не враховують комплексної взаємодії ґрунтових, кліматичних і біологічних факторів [11]. Це призводить до нераціонального використання води, перевитрат енергоресурсів і, зрештою, до зниження економічної та екологічної ефективності аграрних систем.

З огляду на зазначені проблеми, особливого значення набуває розробка систем підтримки прийняття управлінських рішень, здатних прогнозувати потребу у зрошенні на основі аналізу великих масивів даних. Використання інтелектуальних технологій у цій сфері є не лише трендом, а й необхідністю, оскільки дозволяє адаптувати управління зрошенням до конкретних умов поля, враховуючи просторову неоднорідність ґрунту, погодні коливання та технологічні особливості [30]. Таким чином, автоматизоване прогнозування режимів зрошення є важливим кроком у напрямі точного землеробства, яке поєднує цифрові технології та принципи сталого використання природних ресурсів.

Одним із перспективних підходів до вирішення задач прогнозування у сільському господарстві є застосування гібридних нейромережевих моделей, що поєднують можливості алгоритмів еволюційної оптимізації та штучних нейронних мереж. Зокрема, використання генетичного алгоритму (GA) для оптимізації ваг і параметрів навчання багатошарової мережі зворотного поширення (BP) дозволяє підвищити точність прогнозування, скоротити кількість ітерацій навчання та уникнути проблеми локальних мінімумів, яка є типовою для класичних нейромережевих методів [12]. Така інтеграція формує

основу гібридної моделі GA-BP, здатної працювати з великими масивами агрометеорологічних даних і забезпечувати обґрунтовані управлінські рішення щодо поливу.

Розробка системи підтримки прийняття рішень для прогнозування зрошення з використанням гібридної нейромережевої моделі GA-BP має подвійне значення. З одного боку, вона сприяє зменшенню витрат води та електроенергії, що безпосередньо впливає на економічні показники господарств. З іншого – забезпечує дотримання принципів екологічної рівноваги та збереження природних ресурсів, що відповідає сучасним концепціям сталого розвитку сільських територій [14].

Об'єктом дослідження у кваліфікаційній роботі є процес управління зрошенням сільськогосподарських полів.

Предметом дослідження виступають методи, моделі та інформаційні технології прогнозування потреби у зрошенні на основі гібридної нейромережевої моделі GA-BP.

Засобами дослідження є генетичні алгоритми, багат шарові нейронні мережі зворотного поширення, програмні середовища MATLAB та Python, а також пакети бібліотек для машинного навчання та обробки даних.

Наукова новизна роботи полягає у застосуванні гібридного підходу GA-BP до задачі прогнозування зрошення, що дозволяє поєднати переваги оптимізаційних алгоритмів та нейромережевого моделювання.

Таким чином, актуальність теми визначається потребою у створенні інтелектуальних інструментів підтримки управлінських рішень у сільському господарстві, які поєднують точність прогнозування, адаптивність до змін середовища та практичну зручність у застосуванні. Впровадження таких рішень сприятиме формуванню сучасної моделі точного землеробства, де ресурси використовуються раціонально, а виробництво набуває стійкого характеру [18].

Розділ 1.

АНАЛІЗ СТАНУ ДОСЛІДЖЕННЯ ЩОДО УПРАВЛІННЯ ЗРОШЕННЯМ ТА ЗАСТОСУВАННЯ ІНТЕЛЕКТУАЛЬНИХ МОДЕЛЕЙ

1.1. Сучасний стан та тенденції розвитку зрошуваного землеробства в умовах зміни клімату

У другій половині XX та на початку XXI століття аграрні системи світу дедалі більше зазнають впливу кліматичних змін. Нерівномірний розподіл опадів, підвищення середньорічних температур і часті посухи призвели до того, що традиційні методи ведення землеробства в багатьох регіонах втратили стабільність і прогнозованість. Зрошення стало основним фактором підтримки продуктивності сільського господарства, проте його ефективність значною мірою залежить від управлінських рішень та здатності системи адаптуватися до мінливих умов [1].

За даними Продовольчої та сільськогосподарської організації ООН, нині близько 20 % світових орних земель обладнано системами зрошення, і саме вони забезпечують до 40 % глобального врожаю [2]. Такий дисбаланс свідчить, що зрошуване землеробство є найбільш продуктивною формою аграрного виробництва, але водночас воно є найбільш ресурсомістким. Ключова проблема полягає у тому, що в умовах кліматичних змін доступність водних ресурсів скорочується, а конкуренція між аграрним і комунальним секторами за їх використання зростає.

В Україні питання зрошення має особливу вагу. Південні та частково центральні області країни перебувають у зоні ризикованого землеробства, де річні втрати врожаю через нестачу вологи можуть сягати 30–50 %. Після руйнування Каховської ГЕС у 2023 році проблематика відновлення та модернізації меліоративної інфраструктури стала стратегічним завданням для держави [3]. При цьому сучасні дослідження наголошують, що ефективність

зрошення визначається не лише кількістю поданої води, але й її раціональним розподілом у часі та просторі, що вимагає нових підходів до управління [4].

Для оцінки ефективності зрошення часто застосовується коефіцієнт водокористування:

$$K_e = \frac{Y}{W}, \quad (1.1)$$

де Y – отриманий урожай, т/га; W – витрати зрошувальної води, м³/га.

За результатами досліджень, проведених у країнах Південної Європи, впровадження інтелектуальних систем управління зрошенням дозволяє підвищити цей коефіцієнт у середньому на 15–20 % порівняно з традиційними методами [5].

За даними Укргідрометцентру, у Лісостепу середньорічна кількість опадів коливається від 550 до 650 мм, проте у весняно-літній період, коли формується основна маса врожаю, часто спостерігаються дефіцити вологи. У поєднанні з вищими температурами це створює умови для посушливих явищ, які повторюються все частіше. У 2000–2020 рр. кількість посушливих періодів у центральній частині України зросла більш ніж удвічі порівняно з попереднім двадцятиріччям.

Урожайність сільськогосподарських культур у зоні Лісостепу істотно залежить від ефективного забезпечення вологою. Для кукурудзи, сої та соняшнику критичним є період від бутонізації до наливу зерна, коли дефіцит опадів може знизити врожай на 25–40 %. В умовах кліматичних змін роль зрошення набуває стратегічного значення, адже навіть короточасні періоди вологого стресу здатні нівелювати результати застосування добрив і сучасних агротехнологій [17].

Дослідження, проведені в Інституті зрошуваного землеробства НААН України, показали, що при використанні систем краплинного поливу коефіцієнт водокористування для кукурудзи у Лісостепу становить у середньому 1,4–1,6 кг/м³, тоді як при традиційному дощуванні цей показник не перевищує 1,1 кг/м³.

У таблиці 1.1 наведено результати польових досліджень ефективності різних режимів зрошення у Лісостеповій зоні.

Таблиця 1.1 – Вплив режимів зрошення на врожайність кукурудзи у Лісостепу

Режим зрошення	Урожайність, т/га	Коефіцієнт водокористування, кг/м³
Без зрошення (посуха)	4.2	—
Традиційне дощування	7.1	1.1
Краплинне зрошення	8.3	1.5
Інтелектуальна система DSS	8.9	1.6

Як видно з таблиці 1.1, найвищу ефективність забезпечують адаптивні системи зрошення, які враховують погодні прогнози та вологість ґрунту. Вони дозволяють отримати максимальну віддачу від використаної води.

На рисунку 1.1 подано динаміку середньорічної температури та кількості опадів у Лісостеповій зоні за останні три десятиліття.




Рисунок 1.1 – Зміна середньорічної температури та кількості опадів у Лісостепу України (1991–2024 рр.) за даними Укргідрометцентру [10]

Графік показує, що зростання температури має стійку тенденцію, тоді як кількість опадів у весняно-літній період скорочується, що й обумовлює потребу у систематичному поливі.

Сучасні DSS для Лісостепу інтегрують дані з метеостанцій, сенсорів вологості ґрунту та супутникового моніторингу. Особливе значення має використання індексів вегетації, зокрема NDVI:

$$NDVI = \frac{NIR - RED}{NIR + RED}, \quad (1.2)$$

де *NIR* – ближнє інфрачервоне відбиття; *RED* – відбиття у червоному діапазоні.

У поєднанні з алгоритмами машинного навчання NDVI дозволяє виявляти ділянки посівів із підвищеним ризиком вологого стресу та оптимізувати подачу води саме туди, де це необхідно. Такий підхід довів свою ефективність під час експериментів у Вінницькій та Полтавській областях, де адаптивне зрошення дозволило зекономити до 20 % води без втрат врожайності [6].

Таким чином, сучасний стан зрошуваного землеробства у Лісостеповій зоні України визначається поєднанням високого агропотенціалу та зростаючих кліматичних ризиків. Тенденції розвитку чітко вказують на необхідність переходу від традиційних методів поливу до інтелектуальних систем управління, які базуються на використанні цифрових технологій, дистанційного моніторингу та прогнозних моделей. Це створює передумови для підвищення ефективності аграрного виробництва і збереження водних ресурсів у стратегічно важливому регіоні країни.

1.2. Інформаційні системи підтримки прийняття рішень у сільському господарстві

Управління аграрним виробництвом у XXI столітті дедалі більше спирається на використання інформаційних технологій. Швидке зростання обсягів даних про стан ґрунтів, кліматичні параметри, врожайність культур та

економічні показники призвело до формування нового класу цифрових інструментів – систем підтримки прийняття рішень (Decision Support Systems, DSS). Їхня роль полягає в інтеграції різномірної інформації, обробці даних методами обчислювального інтелекту та формуванні рекомендацій для фермерів, агрономів і управлінців, що дозволяє приймати більш точні й обґрунтовані рішення [11].

Структурно DSS у сільському господарстві складаються з трьох основних блоків: бази даних, модульної системи аналітики та інтерфейсу взаємодії з користувачем. База даних акумулює як історичні, так і оперативні відомості, включаючи показники ґрунтової вологості, погодні прогнози, супутникові знімки та економічну інформацію про ринок. Аналітичний модуль реалізує алгоритми машинного навчання, нейронні мережі, статистичні та гідрологічні моделі, а користувацький інтерфейс забезпечує візуалізацію даних і можливість сценарного аналізу.

Ефективність DSS у сільському господарстві часто оцінюють за допомогою інтегрального показника, що враховує зростання врожайності та зменшення витрат ресурсів. Один із підходів полягає у використанні коефіцієнта ефективності системи:

$$E_{DSS} = \frac{\Delta Y}{\Delta W + \Delta E}, \quad (1.3)$$

де ΔY – приріст врожайності, %; ΔW – зміна витрат води, %; ΔE – зміна витрат енергії, %.

Застосування DSS у країнах ЄС показало, що цей коефіцієнт у середньому на 20–30 % перевищує показники традиційних методів планування агротехнологій [2].

Загальним трендом у розвитку DSS є інтеграція з геоінформаційними системами (ГІС), що дозволяє враховувати просторову неоднорідність полів. Використання супутникових індексів вегетації, таких як NDVI та EVI, у поєднанні з метеопрогнозами створює можливість точного визначення зон

ризик. На рисунку 1.2 подано приклад схеми DSS для управління водними ресурсами.




Рисунок 1.2 – Узагальнена структура DSS для управління аграрним виробництвом [32]

На основі попередніх міркувань система підтримки прийняття рішень (DSS) для виробництва твердої пшениці була спроектована відповідно до концептуальної схеми, наведеної на рисунку 1.2. Як зазначено на цьому рисунку, як статичні профілі ділянки, так і специфічна для конкретного місця інформація (дані) надходять із навколишнього середовища через інструментовані сенсори або ж завдяки діяльності людини (обстеження, аналізи тощо) до бази даних. Інформація обробляється, аналізується та інтерпретується шляхом порівняння з наявними експертними знаннями як частина процесу прийняття рішення. Дані перетворюються на форму, придатну для формування рекомендацій DSS.

Як було зазначено раніше, саме рішення залишається відповідальністю користувача, і DSS не призначена для заміни особи, що ухвалює рішення, а покликана допомогти у виборі, надаючи додаткову інформацію. Рішення

приводить до виконання певної дії у виробничому середовищі. Після того як дія здійснена, навколишнє середовище знову моніториться для початку нового циклу руху інформації. Таким чином, інформаційний потік від середовища і назад здійснюється у нескінченному циклі, який починається зі збору даних і завершується дією [32].

Актори DSS та основні інфраструктури, які вони використовують, показані на рисунку 1.3. Технологічну інфраструктуру обслуговує компанія CRPA, що спеціалізується на застосуванні нових інформаційних та комунікаційних технологій у сільському господарстві. Постачальник DSS також керує мережею метеостанцій і контрольних посівів, які надають вхідні дані для функціонування системи.

Користувачами DSS є клієнтські підприємства (наприклад, окреме господарство чи організація, що представляє кілька господарств та укладає угоду з постачальником для отримання доступу до DSS) і менеджери посівів. Менеджер посівів – це особа (зазвичай агроном або консультант), яка ухвалює рішення щодо управління посівами або рекомендує виробникові відповідні дії.




Рисунок 1.3 – Актори та інфраструктури, залучені до роботи DSS для вирощування високоякісної твердої пшениці [32]

Менеджер безпосередньо взаємодіє з DSS для створення однієї або кількох виробничих одиниць (тобто поля, засіяного однорідною культурою однієї пшениці, яке обробляється уніфіковано протягом усього сезону), введення

специфічних даних про посів та перегляду вихідної інформації системи. Також він може взаємодіяти з постачальником для отримання допомоги в інтерпретації результатів DSS.




Рисунок 1.4 – Архітектура DSS для управління агровиробництвом: взаємодія даних про погоду, аналітичних модулів та бази культур

Особливого значення DSS набувають у сфері управління зрошенням, оскільки саме тут поєднання кліматичних і технологічних чинників формує найбільші ризики для врожайності. Наприклад, у дослідженнях Bonfante та співавт. [13] було показано, що впровадження DSS LCIS DSS у вирощуванні кукурудзи дозволило знизити витрати води на 20 % при збереженні урожайності на рівні контрольних варіантів. Аналогічні результати продемонстровані у Китаї при застосуванні DSS для рисових систем, де інтеграція алгоритмів машинного навчання підвищила точність прогнозування потреби у воді на 17 % [41].

Ще однією тенденцією є впровадження DSS, орієнтованих на мобільні платформи. Це дає змогу забезпечити доступ фермерів до системи навіть у польових умовах, використовуючи смартфон або планшет. Такі інструменти

підтримують інтеграцію з датчиками IoT, які у режимі реального часу збирають дані про температуру ґрунту, вологість і стан рослин.

Загалом DSS у сільському господарстві виступають ключовим інструментом цифрової трансформації аграрного сектору. Вони дозволяють підвищити ефективність використання ресурсів, знизити ризики, пов'язані з кліматичними змінами, і забезпечити стабільність виробництва. Для Лісостепової зони України впровадження таких систем є особливо актуальним, адже їх використання може компенсувати наслідки дефіциту вологи та забезпечити адаптацію господарств до нових кліматичних реалій.

Таблиця 1.2 – Аналіз використовуваних DSS у сільському господарстві

Система	Призначення	Основні функції	Результати застосування
Irrisat (Італія)	Управління зрошенням	Оптимізація графіка поливу, прогноз потреби у воді	Зменшення водоспоживання на 18% [15]
CropSyst (США)	Моделювання врожайності	Баланс води та поживних речовин, сценарії ротацій	Підвищення точності прогнозів урожайності на 25 % [34]
DSSAT (міжнародна)	Комплексна система моделювання	Аналіз врожайності, вплив клімату, сценарії добрив	Використовується у 100+ країнах для планування агрополітики [22]
AgriSens (Німеччина)	Моніторинг посівів	Використання супутникових індексів NDVI, карти вологості	Своєчасне виявлення зон вологого стресу [28]

У Irrisat (Італія) гarti та рекомендовані об'єми зрошення своєчасно публікуються на спеціалізованому вебGIS-сайті, доступ до якого обмежений лише для виробників і водогосподарських органів, що дозволяє краще контролювати процес зрошення і, відповідно, підвищувати його загальну ефективність [15].




Рисунок 1.5 – Спеціалізований веб GIS-інтерфейс IRRISAT для фермерів [15]

Вікно організоване у два блоки: MAP та DATA.

У блоці MAP (ліворуч, рис. 1.5) користувач знаходить:

- інструменти для перегляду та запитів до карт;
- межі зрошуваних ділянок.

У блоці DATA (праворуч, рис. 1.5), відповідно, відображаються:

- деталі ділянки (культура, метод зрошення);
- часові ряди ETp, ефективних опадів і водних потреб культури.

Стандартним фоном є супутникові знімки Google або Bing, але користувач може накласти супутникове зображення, отримане у певну дату, вибравши «Satellite» на панелі інструментів у блоці карти. Зображення відображається у хибних кольорах, де інтенсивність червоного пропорційна до сили росту культури (рис. 1.5). Крім того, користувач може візуалізувати карту коефіцієнта

культури (найвищі значення відображаються блакитними відтінками) на ту саму дату, що дозволяє виявити рівномірність росту всередині обраної ділянки.

Модель системи DSSAT-CSM вирощування сільськогосподарських культур (CSM) структурована в модульному форматі, в якому компоненти розділені за науково-дисциплінарними лініями та мають інтерфейси, що дозволяють замінювати або додавати модулі. CSM тепер об'єднує всі моделі сільськогосподарських культур як модулі, використовуючи один модуль ґрунту та один модуль погоди. Нова модель системи вирощування сільськогосподарських культур тепер містить моделі понад 40 культур, отриманих з оригінальних моделей росту сільськогосподарських культур SOYGRO, PNUTGRO, CERES-Maize та CERES-Wheat.

Наведена нижче схема (рис. 1.6) ілюструє зв'язок між основним та вторинним модулями CSM. Основна програма контролює весь час роботи моделі, тоді як модуль Land Unit використовується для керування обробкою та передачею даних між усіма основними модулями.




Рисунок 1.6 – Огляд компонентів та модульної структури DSSAT-CSM [22]

Кожен модуль має шість операційних кроків, як показано на рис. 1.6 (ініціалізація запуску, ініціалізація сезону, розрахунок швидкості, інтегрування, добовий вихід та підсумковий вихід). Основна програма контролює, коли кожен із цих кроків активний, і коли кожен модуль виконує потрібне завдання. Ця функція, дозволяє кожному модулю зчитувати власні вхідні дані, ініціалізувати себе, обчислювати швидкості, інтегрувати власні змінні стану та записувати вихідні дані повністю незалежно від роботи інших модулів. Лише кілька «інтерфейсних» змінних передаються до та від кожного модуля. Це дозволяє «відключити» модуль та замінити його іншим, якщо він передає ті самі змінні решті модулів, навіть якщо параметри, змінні стану та вхідні файли модуля різні. Змінні стану записуються після інтегрування для представлення стану системи наприкінці дня, а початкові значення записуються під час ініціалізації для дня 0.




Рисунок 1.7 – Структура системи підтримки рішень щодо зрошення [28]

Процедура точного зрошення вимагає системи поливу, яка може точно регулювати кількість води, що подається до різних зрошувальних установок поля протягом заданого проміжку часу. Системи безперервного руху були основним напрямком досліджень та розробок систем поливу зі змінною нормою. Бази даних з географічно прив'язаними даними, що описують зрошувальні установки, використовуються для регулювання водозабору в системах безперервного руху. Щоб регулювати кількість води, що подається до кожної зрошувальної

установки, можна регулювати швидкість потоку зрошувача або швидкість руху ґрунту в системі безперервного руху. На рис. 1.7 зображено систему підтримки рішень щодо зрошення.

Безпілотні літальні апарати (БПЛА) знайшли широке застосування в різних контекстах завдяки розвитку складної робототехніки, і це особливо актуально в галузі сільського господарства. Підхід до прийняття рішень спрямований на визначення конкретних місць заражених культур, щоб можна було вжити відповідних заходів, таких як застосування гербіцидів. Токсичну шкоду полям можна значною мірою пом'якшити завдяки ретельному застосуванню гербіцидів. Тим часом використання БПЛА для обприскування підвищує продуктивність завдяки підвищенню ефективності працівників. Цикл спостереження, орієнтації, прийняття рішень та дій (OODA), зображений на рис. 1.8, служить концептуальною основою для запропонованого методу.




Рисунок 1.8 – Структура системи підтримки рішень із використанням БПЛА [28]

Методика, зображена на рис. 1.8, використовує вхідні дані, такі як показання ультразвукових датчиків, зображення з камер та отримані накази для збору даних під час фази спостереження.

Аналіз сучасних інформаційних систем підтримки прийняття рішень у сільському господарстві засвідчує, що вони є ключовим елементом цифрової трансформації аграрного сектору. Такі системи інтегрують різноманітні джерела даних – від сенсорів вологості ґрунту та метеостанцій до супутникових знімків і економічних показників – та дозволяють формувати комплексні рекомендації для аграріїв. Досвід використання DSS у різних країнах підтверджує їхню

ефективність у підвищенні врожайності культур, зменшенні витрат води й енергоресурсів, а також у зниженні ризиків, зумовлених кліматичними змінами.

Разом з тим огляд наукових підходів свідчить про існування певних обмежень традиційних DSS. Зокрема, значна частина систем базується на статистичних або емпіричних моделях, що не завжди забезпечує достатню точність прогнозів у складних і динамічних умовах. Це особливо критично для управління зрошенням, де навіть незначні похибки у визначенні обсягів поливу можуть призвести до суттєвих втрат урожаю або перевитрати водних ресурсів.

У цьому контексті доцільним є впровадження систем підтримки прийняття рішень нового покоління, що поєднують методи штучного інтелекту та еволюційної оптимізації. Одним із найбільш перспективних підходів є застосування гібридної нейромережевої моделі GA-BP, у якій генетичний алгоритм використовується для оптимізації вагових коефіцієнтів багатoshарової мережі зворотного поширення. Така інтеграція дозволяє підвищити точність прогнозування, уникнути проблеми локальних мінімумів та скоротити кількість ітерацій навчання.

Використання DSS на основі GA-BP у прогнозуванні зрошення полів у Лісостеповій зоні України видається особливо доцільним. Це зумовлено поєднанням високого агропотенціалу регіону та зростаючих кліматичних ризиків, пов'язаних із дефіцитом вологи у критичні фази розвитку культур. Впровадження такої системи дозволить забезпечити більш обґрунтоване управління водними ресурсами, підвищити ефективність використання зрошення та створити умови для стійкого розвитку аграрного виробництва.

Таким чином, подальша робота у цьому напрямі має бути зосереджена на розробці DSS для прогнозування зрошення з використанням гібридної моделі GA-BP, що поєднуватиме точність нейронних мереж та адаптивність еволюційних алгоритмів. Це забезпечить високу практичну значущість системи як для окремих господарств, так і для аграрної політики на рівні регіонів.

1.3. Застосування штучних нейронних мереж для прогнозування процесів у аграрному виробництві

Основою роботи нейронної мережі є моделювання функцій активації, що дозволяють нелінійно перетворювати вхідні дані. Найбільш поширеними є сигмоїдна функція та ReLU (Rectified Linear Unit). Наприклад, для класичного багат шарового перцептрона використовується сигмоїдна функція:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (1.4)$$

Ця функція (1.4) дозволяє моделювати ймовірнісні залежності між вхідними факторами та вихідними результатами.

Таблиця 1.3 – Приклади застосування ШНМ у прогнозуванні аграрних процесів

Архітектура	Об'єкт прогнозування	Результати досліджень	Джерело
MLP (багат шаровий перцептрон)	Врожайність пшениці	Точність прогнозу >90 %	[16]
RNN (рекурентні мережі)	Динаміка вологості ґрунту	Підвищення точності на 15 % порівняно зі статистичними моделями	[11]
CNN (згорткові мережі)	Виявлення хвороб рослин за зображеннями	Точність класифікації 95–97 %	[29]
LSTM (довготривала пам'ять)	Потреба у зрошенні на основі часових рядів	Точність прогнозу підвищена на 20 %	[27]
Hybrid GA-BP	Оптимізація поливу кукурудзи	Зменшення витрат води на 18 % при стабільній урожайності	[12]

У сільському господарстві ШНМ застосовуються для вирішення широкого спектра задач: прогнозування врожайності, моделювання потреби у воді та поживних речовинах, виявлення захворювань рослин, управління процесами тваринництва та аналізу ринку сільськогосподарської продукції [23]. Особливу актуальність має застосування ШНМ у системах підтримки прийняття рішень для управління зрошенням і живленням рослин, оскільки саме ці фактори найбільше впливають на кінцеву продуктивність.

У таблиці 1.3 наведено приклади застосування різних архітектур нейронних мереж для прогнозування процесів у аграрному виробництві.

Результати, наведені у таблиці 1.3, демонструють, що різні архітектури нейронних мереж мають власні сфери оптимального застосування. Наприклад, згорткові мережі особливо ефективні при аналізі візуальних даних, тоді як рекурентні мережі та їхні модифікації (LSTM, GRU) забезпечують високу точність при роботі з часовими рядами.

На рисунку 1.3 наведено узагальнену схему використання ШНМ у системах прогнозування в аграрному виробництві.



Рисунок 1.3 – Структура застосування ШНМ у прогнозуванні аграрних процесів

Застосування нейронних мереж для прогнозування врожайності є одним із найбільш досліджених напрямів. Наприклад, у роботі [30] показано, що використання багат шарового перцептрона для прогнозування врожайності пшениці дозволило досягти точності понад 90 % при врахуванні кліматичних і ґрунтових параметрів. Подібні результати отримано при застосуванні RNN для

оцінки вологості ґрунтів, що дозволяє більш ефективно планувати графіки поливу [11].

Окремий напрямок становить застосування CNN для автоматичного виявлення хвороб рослин. Використання зображень листків, отриманих за допомогою мобільних камер, у поєднанні з глибинними нейронними мережами забезпечує високу точність діагностики захворювань. Це відкриває нові можливості для фермерів у швидкому реагуванні на ризики, що впливають на врожайність [29].

Для задач, що потребують аналізу часових рядів, таких як прогнозування потреби у зрошенні чи динаміки росту культур, найбільш ефективними виявилися мережі LSTM. Вони здатні зберігати довгострокові залежності між параметрами, що особливо важливо для аграрних систем, де зміни умов середовища впливають на розвиток культур протягом усього сезону [27].

Суттєвим напрямом досліджень є гібридні моделі, які поєднують методи оптимізації з класичними нейронними мережами. Наприклад, у роботі [12] запропоновано гібридну модель GA-BP для прогнозування потреби у зрошенні овочевих культур, що дозволило зменшити витрати води при збереженні стабільної продуктивності. Подібні підходи мають велике практичне значення для Лісостепової зони України, де поєднання підвищених температур та дефіциту опадів вимагає оптимального управління ресурсами.

Таким чином, використання штучних нейронних мереж для прогнозування аграрних процесів є перспективним напрямом розвитку точного землеробства. Поєднання різних архітектур ШНМ дає змогу вирішувати широкий спектр завдань – від оптимізації зрошення та живлення культур до моніторингу їхнього стану та прогнозування врожайності. Інтеграція цих підходів у системи підтримки прийняття рішень дозволяє підвищити стійкість аграрних систем до кліматичних ризиків і забезпечити ефективне використання природних ресурсів.

1.4. Гібридні інтелектуальні моделі

У сучасних умовах цифровізації та швидкого розвитку методів обчислювального інтелекту особливого значення набувають гібридні інтелектуальні моделі. Вони поєднують різні підходи до обробки даних, аналізу й прогнозування, що дозволяє враховувати комплексний характер процесів у сільському господарстві, енергетиці та управлінні інфраструктурними проектами. На відміну від класичних моделей, які базуються лише на статистичних методах або на одній архітектурі нейронних мереж, гібридні системи інтегрують декілька алгоритмічних парадигм – від машинного навчання до методів оптимізації. Це забезпечує вищу точність прогнозування та стійкість до шумів у даних [24].

Одним із поширених прикладів є поєднання нейронних мереж зі стохастичними алгоритмами оптимізації, зокрема генетичними алгоритмами (GA), роями частинок (PSO) чи диференціальною еволюцією (DE). Основна ідея полягає у використанні алгоритму оптимізації для налаштування ваг і параметрів нейромережі, що зменшує ризик потрапляння у локальні мінімуми під час класичного навчання методом зворотного поширення. Формально задача оптимізації параметрів нейромережі може бути подана як мінімізація функції втрат $L(\theta)$:

$$\theta^* = \arg \min_{\theta} L(\theta, X, Y), \quad (1.5)$$

де θ – параметри нейронної мережі; X – вхідні дані; Y – цільові змінні.

Поєднання двох чи більше методів дозволяє враховувати як глобальний пошук у просторі параметрів, так і локальну точність оптимізації. На практиці це означає скорочення часу навчання моделі та підвищення точності прогнозів у системах прийняття рішень для управління аграрними процесами. Наприклад, модель GA-BP (генетичний алгоритм + нейронна мережа зворотного поширення) показала свою ефективність для прогнозування потреби у зрошенні та врожайності культур у різних регіонах світу [12].

Нами виконано порівняння результатів класичних нейронних мереж та їх гібридних варіантів у прогнозуванні аграрних процесів (табл. 1.4).

Таблиця 1.4 – Порівняння результатів класичних нейронних мереж та їх гібридних варіантів у прогнозуванні аграрних процесів

Модель	Середня похибка (MAE)	Час навчання	Стійкість до шумів
BP-NN	0.142	Середній	Низька
LSTM	0.118	Високий	Середня
GA-BP	0.095	Середній	Висока
PSO-NN	0.088	Середній	Висока

Варто зазначити, що гібридні інтелектуальні моделі не обмежуються лише поєднанням нейронних мереж із алгоритмами оптимізації. У літературі описані підходи, що інтегрують методи нечіткої логіки та байєсівських мереж для формування систем підтримки прийняття рішень у сільському господарстві. Такі моделі дозволяють працювати з неповними чи нечіткими даними, що особливо актуально у випадках, коли інформація надходить із різних джерел: метеостанцій, сенсорів ґрунту, супутникових знімків [32].

Сучасні дослідження також активно розвивають глибокі гібридні архітектури, що поєднують згорткові нейронні мережі (CNN) для обробки зображень з рекурентними (RNN/LSTM) для часових рядів. Це відкриває можливості для створення комплексних моделей, здатних одночасно аналізувати просторові та часові характеристики аграрних даних. Наприклад, супутникові знімки дозволяють оцінити індекс NDVI, а часові ряди метеоданих – прогнозувати вологість ґрунту. Поєднання цих джерел у гібридній моделі дає змогу створити більш надійний інструмент для управління поливом і добривами [13].

Ще одним напрямом застосування гібридних моделей є інтеграція з технологіями Інтернету речей (IoT). Використання розподілених сенсорних мереж для збору даних у реальному часі потребує моделей, які здатні швидко адаптуватися до змін у середовищі. Гібридні алгоритми дозволяють підвищити

ефективність таких систем, оскільки поєднують адаптивність із точністю прогнозування. Наприклад, інтеграція глибоких нейронних мереж із нечіткою логікою у системах моніторингу вологи забезпечує адаптивне регулювання режимів зрошення навіть за непередбачуваних кліматичних змін [19].

Таким чином, гібридні інтелектуальні моделі можна вважати перспективним напрямом у сфері управління аграрним виробництвом. Вони дозволяють одночасно враховувати багатofакторність процесів, оптимізувати розподіл ресурсів та знижувати ризики, пов'язані з невизначеністю. Їхнє впровадження у практику є вагомим кроком на шляху до створення інтелектуальних агросистем, що відповідають вимогам сталого розвитку.

1.5. Завдання кваліфікаційної роботи

Зважаючи на актуальність проблеми раціонального використання водних ресурсів та необхідність підвищення ефективності управління процесами зрошення в аграрному виробництві, у кваліфікаційній роботі визначено низку завдань, вирішення яких дозволить досягти поставленої мети дослідження.

Слід здійснити аналіз сучасного стану та тенденцій розвитку інформаційних систем підтримки прийняття рішень у сільському господарстві. Особлива увага приділяється системам, які орієнтовані на управління зрошенням, оскільки вони є ключовим інструментом адаптації аграрного виробництва до кліматичних змін. У цьому контексті завданням є визначення сильних і слабких сторін існуючих підходів, що дозволяє окреслити перспективи для подальшого вдосконалення.

Потрібно розробити теоретичні та методологічні основи побудови гібридної нейромережевої моделі, яка поєднує можливості генетичного алгоритму з багатошаровою нейронною мережею зворотного поширення. Такий підхід забезпечує не лише адаптивність до складних нелінійних залежностей, але

й підвищує точність прогнозування у випадках, коли класичні моделі дають значні похибки.

Створити математичний апарат для оптимізації вагових коефіцієнтів нейронної мережі за допомогою еволюційних обчислень. Це дозволить обґрунтувати механізм інтеграції генетичного алгоритму з процесом навчання мережі та забезпечить ефективне подолання проблеми локальних мінімумів, характерної для стандартного алгоритму зворотного поширення.

Забезпечити програмну реалізацію запропонованої моделі у вигляді прототипу інформаційної системи підтримки рішень. Програмний модуль повинен мати інтуїтивний інтерфейс, можливість завантаження та обробки реальних аграрних даних, а також функцію візуалізації прогнозів.

РОЗДІЛ 2.

ПРОЄКТУВАННЯ ІСППР ТА ВИБІР ЗАСОБІВ ЇЇ РЕАЛІЗАЦІЇ

2.1. Постановка завдання та вимоги до інформаційної системи

У системах управління зрошенням, що функціонують у межах концепції розумного сільського господарства, ключовою умовою ефективного використання водних ресурсів є здатність своєчасно та коректно прогнозувати потребу поля у зрошенні. Оскільки водний режим культур формується під впливом багатьох нелінійних факторів (температури, вологості повітря, запасів вологи в ґрунті, радіаційного балансу, характеру опадів і типу ґрунтового профілю) традиційні статистичні методи не здатні забезпечити достатню точність прогнозування. Це зумовлює потребу у створенні інтелектуальної системи підтримки управлінських рішень (ІСППР), яка б інтегрувала сучасні методи машинного навчання та дозволяла прогнозувати зрошувальний потік у режимі, наближеному до реального часу.

У цій роботі сформульовано завдання створення такої системи на основі гібридної моделі EGA-BPNN, яка поєднує механізми нейронної мережі зворотного поширення помилки (BP Neural Network, BPNN) та вдосконаленого генетичного алгоритму (Enhanced Genetic Algorithm, EGA). Основна ідея полягає у тому, що генетичний алгоритм оптимізує початкові ваги й пороги BPNN, усуваючи типові недоліки окремої ВР-мережі: чутливість до початкових значень, накопичення помилок під час навчання, схильність до потрапляння в локальні мінімуми та зниження точності на нерівномірних вибірках.

Формально постановку задачі прогнозування можна описати таким чином. Нехай $X = \{x_1, x_2, \dots, x_n\}$ – вектор вхідних параметрів, що визначають водний режим поля: температура повітря, опади, швидкість вітру, вміст вологи в ґрунтовому горизонті, сонячна радіація, коефіцієнт культурної кривої $K_{сК}$. Вихідним сигналом є прогнозований зрошувальний потік QQQ , який можна представити у вигляді цільової змінної:

$$Q = f(X; W), \quad (2.1)$$

де W – набір параметрів нейронної мережі.

Оскільки функція $f(\cdot)$ має нелінійний характер, для її апроксимації застосовується багатошарова нейронна мережа, а мінімізація функції втрат здійснюється за допомогою EGA.

Функція помилки у процесі навчання мережі описується як середньоквадратична похибка:

$$MSE = \frac{1}{m} \sum_{i=1}^m (Q_i - \hat{Q}_i)^2, \quad (2.2)$$

де Q_i – фактичний обсяг зрошувального потоку; $\hat{Q}_i$ – прогнозоване значення.

Завдання GA полягає у мінімізації цієї функції шляхом оптимізації початкових ваг мережі, які у звичайній BPNN визначаються випадковим чином, що і спричиняє нестабільність результатів.

Для визначення вимог до ІСППР було проаналізовано типи завдань, які повинна виконувати система. Оскільки зрошення є одним із найенерговитратніших агротехнологічних процесів, система має забезпечувати прогностичну аналітику в умовах обмеженості водних ресурсів і високої залежності польових умов від погодних коливань. Основними функціональними вимогами є надання прогнозу зрошувального потоку на визначений період, оцінювання рівня ризику водного стресу культури, формування рекомендацій щодо часу поливу та обсягів води.

Інтелектуальний модуль прогнозування повинен працювати з великими обсягами даних, включаючи метеорологічні ряди, історію зрошення, властивості ґрунтів та супутникові індекси рослинності. Нефункціональні вимоги передбачають високу точність прогнозів, стабільність роботи, можливість адаптації до нових умов та мінімальні затримки при обробці даних. Важливо, щоб система була здатна до розширення, оскільки у перспективі можливе додавання методів оптимізації графіків зрошення, визначення водно-фізичних параметрів ґрунту та інтеграції з IoT-сенсорами.

Архітектура ІСППР повинна включати модулі збору даних, їх передоброби, оптимізаційно-прогностичного ядра та інтерфейсу користувача. На рисунку 2.1 представлено узагальнену структурну схему постановки завдання та організації модульної роботи системи.




Рисунок 2.1 – Структурна схема формування прогнозу зрошувального потоку в системі EGA-BPNN

Загалом постановка завдання полягає у розробленні високоточного методу прогнозування зрошувального потоку та створенні відповідної інформаційної системи, здатної надавати управлінські рішення з урахуванням динамічних змін середовища. Застосування моделі EGA-BPNN забезпечує більш точний прогноз водоспоживання порівняно з класичними підходами, що створює практичну основу для зменшення втрат води, покращення стану культур та підвищення ефективності агровиробництва.

2.2. Архітектура системи підтримки прийняття рішень для прогнозування зрошення

Архітектура інформаційної системи підтримки прийняття рішень для прогнозування зрошення у цій роботі ґрунтується на принципах модульності, масштабованості та здатності обробляти неоднорідні типи даних у режимі, близькому до реального часу. Оскільки зрошення є процесом, чутливим до змін метеорологічних умов, вологості ґрунту та стану рослинного покриву, архітектурне рішення повинно забезпечувати як швидке опрацювання вхідних параметрів, так і виконання обчислювально інтенсивних процедур оптимізації ваг у моделі EGA-BPNN.

У розробленій системі архітектура поділена на чотири узагальнені рівні: рівень збору даних, рівень попередньої обробки, інтелектуальне ядро прогнозування та рівень управлінської аналітики. Кожен рівень взаємодіє з іншими завдяки добре визначеним інтерфейсам, що дозволяє забезпечити прозорість обміну даними та можливість адаптивного розширення. Такий підхід сприяє створенню архітектури, придатної для впровадження у фермерських господарствах різного масштабу – від індивідуальних виробників до великих агрохолдингів.

Рівень збору даних об'єднує зовнішні метеосервіси, супутникові платформи, локальні IoT-сенсори та агротехнологічні бази даних. Вхідні набори можуть мати різну періодичність, що формує проблему синхронізації. Для цього розроблено механізм узгодження часових міток, який дозволяє коректно інтегрувати метеорологічні прогнози з польовими сенсорними вимірюваннями та супутниковими індексами рослинності. Функція узгодження реалізується через фільтр часової інтерполяції, визначений як:

$$X(t) = X_i + \frac{X_{i+1} - X_i}{t_{i+1} - t_i}(t - t_i), \quad (2.3)$$

Це дає можливість компенсувати різну дискретність вимірювань та забезпечити безперервність часової вибірки для навчання моделі EGA-BPNN.

Рівень попередньої обробки відповідає за очищення даних, нормалізацію та формування структурованих вибірок для подальшого моделювання. На цьому етапі усуваються пропуски, аномальні значення та здійснюється шкалування величин за формулою мін-макс нормалізації:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (2.4)$$

Це дозволяє підвищити стабільність роботи нейронної мережі та забезпечити коректне функціонування генетичного алгоритму. Особливо важливим є отримання збалансованої вибірки, оскільки зрошувальний потік може мати значну сезонну варіативність, що погіршує здатність мережі до генералізації без відповідної попередньої обробки.

Інтелектуальне ядро системи складається з гібридної моделі EGA-BPNN, яка поєднує глобальні можливості оптимізації генетичного алгоритму та швидкість локального наближення BP-мережі. Спочатку GA оптимізує ваги та пороги, мінімізуючи функцію придатності, що базується на середньоквадратичній помилці прогнозу:

$$F = \frac{1}{m} \sum_{i=1}^m (Q_i - \hat{Q}_i)^2, \quad (2.5)$$

Далі ці оптимізовані параметри використовуються як стартові значення для BPNN, що значно прискорює пошук глобального мінімуму та зменшує ризик перенавчання. Під час функціонування модель формує прогноз зрошувального потоку Q , який передається у модуль підтримки рішень.

Управлінський рівень відповідає за обробку результатів прогнозування та формування рекомендацій для агроменеджера. На цьому етапі прогнозована величина зрошувального потоку перетворюється у практичну рекомендацію щодо часу поливу, обсягів води та оцінки ризику водного стресу культури. Також на цьому рівні генеруються візуалізації – часові графіки, температурні карти та інтерактивні аналітичні таблиці.

Архітектура системи узагальнено зображена на рис. 2.2 у форматі architecture-beta, який демонструє взаємодію базових компонентів: API-рівня, серверної частини, сховищ і бази даних.




Рисунок 2.2 – Архітектура ІСППР прогнозування зрошення (EGA-BPNN)

Архітектурна схема відображає логіку взаємодії між елементами системи: база даних забезпечує історичну інформацію, а сервер моделі реалізує обчислювальний модуль, що включає оптимізацію ваг за допомогою EGA, навчання BPNN та експорт прогнозованих значень зрошувального потоку. Сховища метеорологічних, супутникових та сенсорних вимірювань забезпечують безперервний потік даних, які оновлюються у реальному часі та передаються до моделі через API-шлюз.

Узгоджена взаємодія цих компонентів створює основу для побудови системи, здатної до адаптивного прогнозування, що є критично важливим у сучасному сільському господарстві, де ефективність управління водними ресурсами визначає продуктивність і стійкість усієї агровиробничої системи.

2.3. Опис моделі EGA-BPNN

Генетичний алгоритм (GA) – це алгоритм оптимізації, що симулює природний відбір та генетичні механізми, призначений для пошуку глобального або приблизного оптимального рішення для заданої проблеми [40]. Його фундаментальна ідея полягає в тому, щоб імітувати процес природного відбору та генетичні механізми, що спостерігаються в біологічній еволюції. Алгоритм поступово покращує якість поточного рішення, симулюючи еволюцію популяції, щоб знайти оптимальне рішення для проблеми [25]. Алгоритм відображає процеси природного відбору та генетичні механізми, розвиваючи потенційні рішення за допомогою таких операцій, як генетичне успадкування, кросовер та мутація, прагнучи знайти оптимізоване рішення для проблеми [31].

Оптимізація BPNN за допомогою GA включає побудову базової BPNN, а потім застосування GA для уточнення початкових ваг та порогів нейронної мережі. GA використовується для пошуку глобально оптимальної комбінації ваг та порогів, тим самим підвищуючи продуктивність нейронної мережі [21]. На рис. 2.3 показано блок -схему оптимізованої моделі EGA-BPNN.

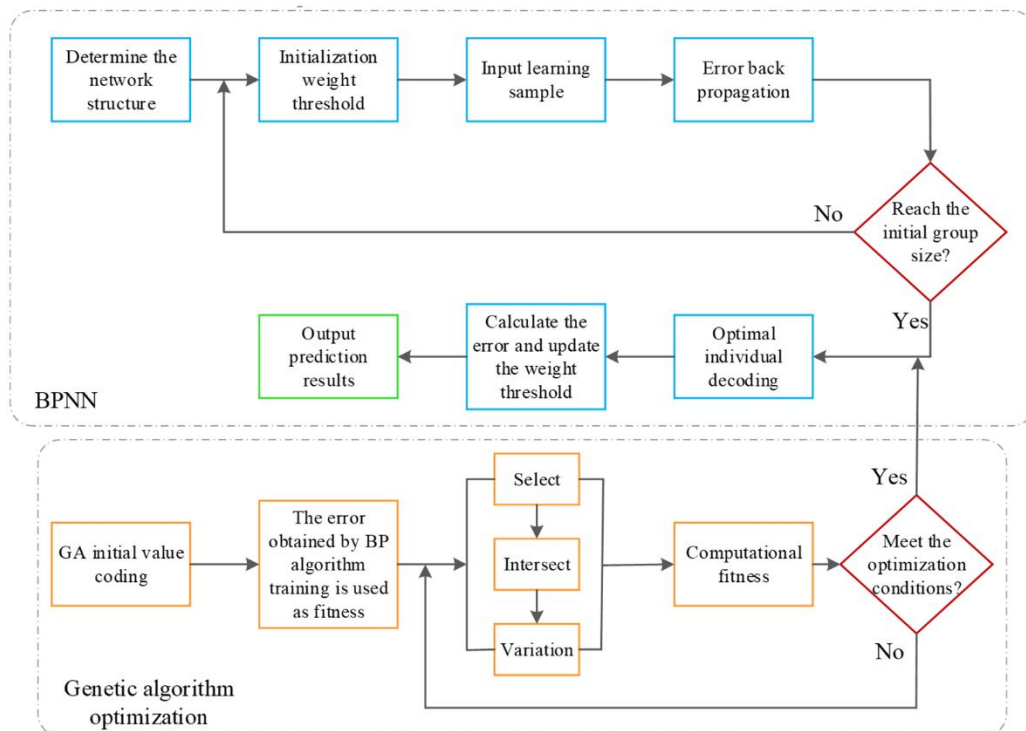


Рисунок 2.3 – Алгоритм роботи моделі GA-BPNN

На рис. 2.3 показано, що модель GA-BPNN складається переважно з наступних трьох кроків:

1. Визначення кодування ваг та порогів: У GA форма експресії особини описується генами. Для алгоритму GA-BPNN гени зазвичай використовуються для представлення ваг та порогів нейронної мережі, складаючи структуру BPNN та визначаючи її відповідні параметри.

2. Оцінка індивідуальної фізичної підготовки: Оцінка індивідуальної фізичної підготовки є вирішальним кроком у генетичному алгоритмі (GA), і вона оцінює ефективність кожного індивіда у вирішенні проблем. В алгоритмі GA-BP індивідуальна фізична підготовка оцінюється за допомогою BPNN. Зокрема, на основі кодування генів індивіда будується модель нейронної мережі. Похибка моделі обчислюється з використанням даних навчання, і ця похибка вважається фізичною підготовкою індивіда. Менше значення фізичної підготовки вказує на кращу індивідуальну продуктивність.

3. Застосування еволюційних операторів: Еволюційні оператори включають операції відбору, схрещування та мутації, що імітують процес біологічної еволюції для безперервної оптимізації особин. В алгоритмі GA-BP процес відбору надає перевагу особинам з вищою пристосованістю, зберігаючи їхню генетичну інформацію. Операція схрещування генерує нових особин шляхом обміну генетичним матеріалом, тоді як мутація вводить випадкові варіації генів. Ці еволюційні операції ітеративно уточнюють генетичну інформацію, спрямовуючи популяцію до оптимальних рішень та ефективно оптимізуючи ваги та пороги нейронної мережі.

У цій роботі розглядається схильність моделі EGA-BPNN до локальних оптимумів та повільної конвергенції під час ініціалізації ваг та порогів, що обмежує її широке застосування в складних системах, таких як інтелектуальні системи попередження про сільськогосподарське зрощення. Для вирішення цих проблем було запроваджено EGA. EGA оптимізує ініціалізацію ваг та порогів BPNN, використовуючи ефективніші стратегії кодування та механізми вибору, прискорюючи конвергенцію, розширюючи можливості глобального пошуку та

зменшуючи ризик потрапляння в пастку локальних оптимумів. EGA використовує кодування з плаваючою комою на етапі кодування для точного представлення ваг та порогів. Вона запроваджує гібридну стратегію в операціях кросовера та мутації для балансування дослідження та експлуатації, підтримуючи різноманітність популяції та запобігаючи передчасній конвергенції. Застосовуючи EGA для ініціалізації BPNN, через кілька поколінь ітерацій, ця робота використовує функцію придатності на основі продуктивності мережі для оцінки кожної особини. Зрештою, вона визначає оптимізований набір ваг та порогів, які служать відправною точкою для навчання мережі. Потік EGA-BPNN зображено на рис. 2.4.




Рисунок 2.4 – Робочий процес EGA-BPNN

Це вдосконалення значно підвищує ефективність навчання та точність прогнозування BPNN, забезпечуючи міцнішу та надійнішу модельну основу для інтелектуальних систем попередження про сільськогосподарське зрощення.

2.4. Вибір програмних і технічних засобів для розробки ІСППР

Проектування інформаційної системи підтримки прийняття рішень для прогнозування зрошення на основі гібридної моделі EGA-BPNN вимагає ретельно підбраного комплексу програмних і технічних інструментів, які забезпечать надійну роботу інтелектуальних алгоритмів, стабільність обчислень і можливість масштабування системи в реальних умовах агровиробництва. У межах цієї роботи вибір інструментарію здійснювався з урахуванням особливостей даних, принципів функціонування моделі, інтенсивності обчислень та потреби у взаємодії між окремими модулями. Оскільки модель EGA-BPNN поєднує два різні обчислювальні підходи, багатошарову нейронну мережу й генетичний алгоритм, програмне середовище повинно забезпечувати комфортну реалізацію обох складових і можливість обміну параметрами між ними.

Першим етапом стало визначення середовища, у якому виконуватиметься обробка вхідних даних. В аграрних системах обсяги інформації значні: метеорологічні ряди, сенсорні дані, показники стану ґрунту, супутникові спостереження. Тому програмна платформа повинна підтримувати інструменти для роботи як зі структурованими, так і з часовими даними, мати засоби векторизації процесів та оптимізації складних обчислень. У зв'язку з цим було обрано Python як основну мову розробки, що забезпечує широкий спектр спеціалізованих бібліотек і високу гнучкість моделювання.

Особливу роль відіграли бібліотеки для машинного навчання. Після порівняння TensorFlow, PyTorch та Scikit-learn було визначено, що TensorFlow разом з високорівневим API Keras забезпечують ефективну підтримку зворотного поширення помилки, зручну побудову багатошарових архітектур і можливість використання GPU під час навчання. Саме це стало критичним фактором, оскільки прискорення процесу оптимізації ваг у моделі EGA-BPNN має суттєве значення для підвищення точності та швидкодії системи. Для реалізації генетичного алгоритму було використано модуль DEAP, який дозволив

сформувані популяцію, застосувати оператори схрещування, мутації та селекції, а також забезпечити передачу мінімізованої функції помилки у зворотному напрямі до блоку BPNN.

Збереження даних та результатів роботи реалізовано засобами PostgreSQL. Системи підтримки прийняття рішень у сфері зрошення часто потребують зберігання не лише числових рядів, а й геопросторових даних, таких як контури полів, межі зон водозабору, розташування сенсорних вузлів. Тому додатково застосовано розширення PostGIS, що робить можливими операції просторового аналізу, зокрема визначення ділянок з підвищеною водною потребою чи прив'язку прогнозів до конкретних територіальних сегментів. У процесі роботи PostgreSQL виступає центральним сховищем структурованої інформації, тоді як файли сенсорних записів зберігаються у форматах CSV та JSON з автоматичною обробкою в Python.

Серверну логіку системи реалізовано на базі FastAPI, що забезпечує високу швидкість обробки HTTP-запитів, автоматичне формування документації та легкість інтеграції з інтерфейсною частиною. Саме через FastAPI здійснюється передавання даних до моделі EGA-BPNN, запуск обчислень, повернення результатів та взаємодія з клієнтськими інтерфейсами. Такий підхід гарантує відповідність архітектурі REST і дозволяє вбудовувати систему у ширші агроплатформи.

На технічному рівні виконання обчислень передбачає використання локального обладнання та хмарних середовищ. Для розробки та тестування моделі застосовувалися ноутбук із процесором Intel Core i7 (8-го покоління), 16 GB оперативної пам'яті та графічним прискорювачем NVIDIA GTX 1650. Для окремих обчислювальних кампаній, зокрема під час підбору кількості прихованих шарів та експериментів із параметрами GA, використовувалося середовище Google Colab із GPU-підтримкою NVIDIA Tesla T4. Такий підхід дав змогу значно скоротити час тренування моделі, а також протестувати її продуктивність у різних конфігураціях.

У межах підбору програмних засобів було сформовано порівняльну таблицю, яка допомагає обґрунтувати вибір остаточного комплексу інструментів.

Таблиця 2.4 – Програмне забезпечення, використане для створення ІСППР

Компонент	Інструмент	Опис можливостей
Моделювання нейронної мережі	TensorFlow + Keras	Створення багатошарової BPNN, GPU-підтримка
Реалізація генетичного алгоритму	DEAP	Гнучкий конструктор GA, оператори селекції та мутації
Попередня обробка даних	Pandas, NumPy	Робота з часовими рядами, агрегація та нормалізація
Сервер логіки	FastAPI	Легкий веб-сервер для інтеграції моделі
Сховище даних	PostgreSQL + PostGIS	Структуровані та геопросторові дані
Візуалізація	Matplotlib, Grafana	Графічні звіти та панелі моніторингу
Хмарні середовища	Google Colab / Kaggle	GPU-прискорення, розподілені обчислення




Рисунок 2.4 – Узагальнена схема обраного програмно-технічного комплексу ІСППР

Формалізована залежність функції пристосованості в EGA-BPNN

Оцінювання якості особи в генетичному алгоритмі здійснюється за допомогою похибки нейронної мережі:

$$Fitness = MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2.5)$$

Це дає змогу використовувати одну й ту саму метрику як у BPNN-навчанні, так і під час оптимізації ваг алгоритмом EGA.

2.5. Проектування структури бази даних

Проектування структури бази даних для інформаційної системи підтримки прийняття рішень щодо прогнозування зрошення є одним з ключових етапів побудови всього програмного комплексу. Ефективна робота системи EGA-BPNN залежить не лише від точності алгоритмічних моделей, а й від того, наскільки коректно організовано зберігання та взаємодію даних між її складовими. Доступ до історичних метеорологічних рядів, інформації про ґрунтові параметри, характеристик сенсорних потоків та результатів моделювання має бути оптимізований таким чином, щоб забезпечити максимально швидке отримання даних для обчислень, а також можливість їх подальшого аналізу, архівування та порівняння.

Структура бази даних повинна враховувати характер аграрних даних, їх ієрархію, різні типи часових інтервалів та просторову прив'язку. Значну частину інформації становлять регулярні вимірювання метеорологічних станцій, які надходять з інтервалом від 10 хвилин до однієї години. Іншу групу – дані від польових сенсорів вологості ґрунту, температури, рівня води в каналах і вологості листової поверхні. Третю категорію представляють статичні довідники: характеристики полів, їх площа, координати, тип ґрунту та інформація про агротехнічні операції.

База даних також повинна підтримувати зберігання результатів роботи моделі EGA-BPNN, які включають оптимізовані вагові коефіцієнти, отримані прогнознi значення, похибки, параметри навчання та часові мітки експериментів. Окрему увагу необхідно приділити організації зв'язку між даними, оскільки кожен прогноз зрошувального потоку формуватиметься на основі комбінації даних метеостанції, сенсорів, структури поля та внутрішніх параметрів моделі.

У процесі проектування було сформовано концептуальну схему даних, яка відображає основні сутності майбутньої системи. Для подальшої деталізації було створено лінійну модель зв'язків сутностей, яка лягла в основу фізичної ER-діаграми. Узагальнений вигляд структури бази даних надає можливість оцінити її логічну цілісність, відповідність предметній області та придатність до реалізації за допомогою PostgreSQL та розширення PostGIS.

У таблиці 2.5 наведено основні сутності та їх функціональне призначення у системі.

Таблиця 2.5 – Основні сутності бази даних ІСППР

Сутність	Опис	Тип даних	Особливості
Fields	Поля господарства	Геопросторові	Містять координати полігонів
SoilData	Дані ґрунтових параметрів	Числові	Вологість, рН, структура
MeteoData	Метеодані	Часові ряди	Температура, опади, вологість
SensorData	Дані IoT-сенсорів	Потокові	Миттєві показники стану ґрунту
IrrigationForecast	Прогнози зрошення	Числові	Результати моделі EGA-BPNN
ModelParams	Параметри моделі	Числові	Оптимізовані ваги, пороги
Experiments	Запуски моделі	Логічні	Містять метадані експериментів

З огляду на обмеження системи управління PostgreSQL, особливо у частині зберігання просторових даних, таблиця Fields використовує тип даних geometry(Polygon), що дозволяє відображати межі полів та виконувати просторові запити, наприклад визначення ділянок, які потребують підвищеної інтенсивності зрошення. Взаємозв'язки між сутностями носять як один-до-багатьох, так і багато-до-одного характер, що дозволяє забезпечити узгодженість даних при збереженні історичних записів.




Рисунок 2.5 – ER-діаграма структури бази даних ІСППР

Для обчислення якісних характеристик роботи моделі використовується формула середньоквадратичної похибки (2.5).

Саме це значення у вигляді стовпця fitness зберігається в таблиці Experiments й використовується генетичним алгоритмом як критерій оптимізації.

Структура бази даних була спроектована з урахуванням вимог нормалізації, що дозволило уникнути дублювання даних, скоротити обсяг збережених записів та підвищити швидкість обробки. Разом із тим деякі таблиці містять денормалізовані атрибути, необхідні для прискорення вибірок у задачах прогнозування.

РОЗДІЛ 3.

РЕЗУЛЬТАТИ СТВОРЕННЯ ГІБРИДНОЇ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ GA-VR ТА РОЗРОБКИ ІСППР

3.1. Формування навчальної вибірки та попередня обробка даних

Процес побудови інтелектуальної моделі прогнозування неможливо відокремити від етапу створення якісної навчальної вибірки. В даному дослідженні підготовка даних базувалася на поєднанні супутникових та метеорологічних спостережень для реальної території Західної України. В основу аналізу покладено п'ятирічний період з 2019 по 2023 роки, що дозволило отримати збалансований набір сезонних та міжрічних коливань природних параметрів. На рисунку 3.1 подано межі вибраної області інтересу, яка охоплює аграрні землі поблизу селища Берестечко Волинської області. Ця локація характеризується типовими для регіону кліматичними умовами, що робить її репрезентативною для побудови прогностичних моделей у сфері сільського господарства.




Рисунок 3.1 – Область інтересу (AOI) для формування навчальної вибірки

Завантаження історичних даних здійснювалося за допомогою Google Earth Engine. Для вегетаційних характеристик використовувалися знімки Sentinel-2, з

яких було обчислено індекс NDVI, що виступає індикатором рослинної активності. Метеорологічні параметри – температура повітря на висоті 2 м, точка роси, сукупні щоденні опади та вологість ґрунту – отримано з архіву ERA5-Land. Кожний із параметрів приводився до єдиного щоденного кроку.

Загальний підхід до формування таблиці даних можна представити фрагментом коду (рис. 3.2).

```
# ---- 0. Підготовка DF ----
# гарантуємо наявність datetime
if not np.issubdtype(df['date'].dtype, np.datetime64):
    df['date'] = pd.to_datetime(df['date'])

df = df.sort_values('date').reset_index(drop=True)

# уніфікуємо назву опадів
if 'ERA5_precip' in df.columns and 'precip' not in df.columns:
    df = df.rename(columns={'ERA5_precip': 'precip'})

# покажемо базову інфу
print("Колонки:", df.columns.tolist())
print("shape:", df.shape)

# ---- 1. Базова панель часових рядів ----
fig, axes = plt.subplots(4, 1, figsize=(16, 12), sharex=True)
axes = axes.ravel()

axes[0].plot(df['date'], df['NDVI'], color='green')
axes[0].set_title('NDVI (MODIS)')
axes[0].grid(True, alpha=0.3)

axes[1].fill_between(df['date'], df['precip'], step='mid', alpha=0.5)
axes[1].set_title('Опади (precip)')
axes[1].grid(True, alpha=0.3)
```

Рисунок 3.2 – Фрагмент коду підготовки df та створення базової панелі часових рядів

Відсутні значення виявлялися автоматично, однак у цьому наборі пропусків не спостерігалось, що дозволило уникнути додаткових процедур імпутації. Перші та останні п'ять рядків структури даних наведено на рисунку 3.2, який демонструє коректність хронологічного формату та відповідність одиниць вимірювання.

Перші 5 рядків:

	date	NDVI	precip	T2m	d2m	soil_moisture
0	2019-01-01	0.128390	0.005155	281.865304	279.493846	0.167250
1	2019-01-02	0.059108	0.005836	276.862472	274.487662	0.169129
2	2019-01-03	0.054135	0.002229	279.218191	275.878481	0.200939
3	2019-01-04	0.197854	0.001992	276.196396	272.398834	0.178722
4	2019-01-05	0.052686	0.003792	278.697593	275.548688	0.169293

Останні 5 рядків:

	date	NDVI	precip	T2m	d2m	soil_moisture
1821	2023-12-27	0.099850	0.003754	277.058751	273.078350	0.161596
1822	2023-12-28	0.090137	0.002834	279.396925	275.686056	0.159278
1823	2023-12-29	0.128166	0.006219	276.737192	273.280748	0.176762
1824	2023-12-30	0.111988	0.004510	278.980840	276.375601	0.184973
1825	2023-12-31	0.092286	0.006134	274.952985	272.337422	0.171761

Рисунок 3.2 – Фрагмент сформованої навчальної таблиці

Загалом отримано 1826 повних записів, що відповідає кількості днів за п'ятирічний період без пропусків. Така рівномірність забезпечує стабільність навчання моделі й дозволяє уникнути зміщень, пов'язаних з нерівномірними часовими інтервалами.

Для первинного огляду динаміки показників було побудовано окремі графіки. На рисунку 3.3 показано зміну NDVI упродовж п'яти років. Яскраво простежуються щорічні цикли весняного підйому, літнього піку та осіннього спаду, що відтворюють типовий сезонний ритм рослинності.

Подібним чином візуалізовано й інші показники. Графік опадів вирізняється високою варіативністю, що природно для території з континентально-морським кліматом. Температурний режим, представлений через показники T2m та d2m, утворює плавні хвилі річних коливань. Вологість ґрунту виявляє виражену кореляцію з NDVI, але має й власну внутрішню динаміку, пов'язану з погодними умовами та швидкістю висихання ґрунту. Сукупність цих графіків подано на рисунку 3.4.




Рисунок 3.4 – Графіки зміни опадів, температури та вологості ґрунту

Щоб оцінити міжрічні закономірності, було побудовано графік середніх місячних значень NDVI для кожного року (рисунок 3.5).




Рисунок 3.5 – Місячні середні значення NDVI у 2019–2023 рр.

Незважаючи на міжрічні коливання, спостерігається висока схожість профілів. Це дозволяє зробити висновок, що аграрний сезон у регіоні має стабільну структуру та піддається моделюванню. Для більш глибокого аналізу взаємозв'язків між ознаками побудовано матрицю попарних діаграм (рисунок 3.6).




Рисунок 3.6 – Попарні залежності між ознаками навчальної вибірки

Вона дає змогу візуально оцінити форму розподілів та характер залежностей. Наприклад, NDVI та вологість ґрунту утворюють майже еліптичну залежність, що підтверджує їх тісний зв'язок. Температурні параметри T2m і d2m

демонструють практично ідеальну лінійну узгодженість, оскільки є фізично спорідненими величинами.

Кількісну оцінку таких взаємозв'язків представлено у вигляді кореляційної матриці (рисунок 3.7). Найбільш виражена кореляція спостерігається між NDVI та вологістю ґрунту (0.75), що логічно пояснюється фізичними процесами росту рослин. Температура, хоча і впливає на NDVI опосередковано, демонструє помірні зв'язки, особливо у періоди активної вегетації.




Рисунок 3.7 – Кореляційна матриця ознак

У процесі подальшої підготовки дані було нормовано за допомогою StandardScaler. Такий метод передбачає приведення кожної ознаки до нульового математичного сподівання та одиничного стандартного відхилення. Завдяки цьому моделі глибокого навчання не зазнають перекосів, пов'язаних із різними масштабами величин.

Після нормалізації дані було збережено у підсумковий файл `synthetic_west_ukraine_daily_2019_2023_clean.csv`. Цей набір став основою для подальшого навчання гібридної моделі EGA-BPNN, оскільки має достатній

обсяг, повноту та збалансованість, необхідні для виявлення прихованих закономірностей у часових рядах природних процесів.

Загалом виконана робота з формування навчальної вибірки дозволила отримати високоякісний, чистий і структурований набір даних, що відображає природні процеси в рослинному покриві та погодних умовах регіону. Така надійна основа забезпечує стабільність та підвищену точність подальшого моделювання.

3.2. Навчання та порівняння моделей

Процес навчання нейромережових моделей був організований таким чином, щоб забезпечити можливість одночасного порівняння декількох архітектур і оцінити ступінь впливу глибини моделі, ширини прихованих шарів та параметрів регуляризації на точність прогнозування. Вхідним набором ознак стали чотири змінні, попередньо масштабовані до інтервалу $[0;1]$. Навчальна вибірка складалася з 1460 спостережень, тестова – із 366, що становить типовий поділ 80/20. Така пропорція дозволяє уникнути надмірного перенавчання і водночас забезпечує достатній обсяг даних для перевірки генералізуючої здатності моделі.

Для базового контролю якості налаштування параметрів було впроваджено генетичний алгоритм, який шукав оптимальну конфігурацію прихованих шарів, регуляризації α та швидкості навчання. У результаті еволюційного відбору було знайдено найкраще рішення, яке забезпечувало найнижче значення функції якості. Оптимальний набір включав три шари розміру 103, 26 і 54 нейрони відповідно, високий коефіцієнт регуляризації α 0.01 і таке саме значення швидкості навчання. Це рішення було збережене під індексом E та надалі використовувалося як одна з порівнюваних моделей.

Усі моделі будувалися на основі MLP-архітектури з активацією ReLU на прихованих шарах і лінійною активацією на вихідному нейроні. Це дозволило

зберегти узгодженість між експериментами та мінімізувати вплив сторонніх факторів на результати. Для кожної архітектури виконувалося окреме навчання із записом ключових статистичних характеристик.

В табл. 3. 1 наведено узагальнені результати порівняння моделей.

Таблиця 3.1 – Результати навчання моделей

Модель	hidden	alpha	lr	RMSE_train	RMSE_test	MAE_test	R ² _test
B: wide (128,64)	(128, 64)	0.0001	0.0005	0.068110	0.073126	0.054395	0.935059
E: GA-optimized	(103, 26, 54)	0.0100	0.0100	0.068653	0.073668	0.054396	0.934092
C: deep (64,64,32)	(64, 64, 32)	0.0005	0.0005	0.068096	0.073805	0.054744	0.933848
D: compact (32,16)	(32, 16)	0.0010	0.0010	0.070519	0.073916	0.055258	0.933648
A: shallow (32)	(32,)	0.0001	0.0010	0.071994	0.073928	0.055894	0.933627

Аналіз таблиці 3.1 свідчить про майже однаковий рівень точності всіх моделей, що підтверджує добре впорядковану структуру даних і наявність сильних сезонних трендів. Незважаючи на незначні різниці в умові навчання, найкращим рішенням виявилася широка модель В з двома прихованими шарами розміру 128 і 64 нейрони.




Рисунок 3.8 – Порівняння RMSE на тестовій вибірці

Саме вона показала найнижчу помилку $RMSE_{test}$ та найвище значення R^2_{test} . Генетично оптимізована модель Е продемонструвала близький результат, однак використання значного коефіцієнта регуляризації дещо знизило узгодженість на тестовій вибірці.

Візуальне порівняння якості моделей представлено на рис. 3.8 і 3.9 графіки $RMSE$ та R^2 дозволяють чітко побачити, що всі рішення мають близьку ефективність, але модель В забезпечує найменшу похибку.




Рисунок 3.9 – Порівняння R^2 на тестовій вибірці

Окремо було виконано аналіз роботи найкращої моделі шляхом порівняння фактичних і прогнозних кривих NDVI на часовому інтервалі 2023 року. Результати подано на рис. 3.10 та 3.11.




Рисунок 3.10 – Фактичні та прогнозні значення NDVI (wide 128,64)




Рисунок 3.11 – Діаграма розсіювання «факт – прогноз»

Форма розсіювання добре наближена до прямої з кутом нахилу 45° , що демонструє високий рівень прогнозної здатності моделі. Похибки розподілені

рівномірно й не мають систематичного зміщення, що свідчить про відсутність пере- або недообучення.

Отримані результати дають підстави стверджувати, що структура моделі має менш значний вплив на точність, ніж якість вхідних даних і сезонність процесу. Проте оптимізація ширини шарів допомогла отримати найстабільнішу архітектуру, яка була обрана для інтеграції в СППР.

Розподіл різниці між фактичними та прогнозними значеннями NDVI дозволяє оцінити, чи немає систематичного зміщення і чи відповідає похибка моделі нормальному випадковому відхиленню. На рис. 3.12 подано гістограму похибок для моделі В (широка архітектура 128–64), яка продемонструвала найкращі результати на тестових даних.




Рисунок 3.12 – Розподіл похибок моделі В (128,64)

Розподіл має майже симетричну форму з вираженим центром поблизу нульової похибки. Найбільша частина значень зосереджена в інтервалі від -0.05 до $+0.07$, що відповідає загальному рівню середньої абсолютної помилки ($MAE \approx 0.054$). Така форма гістограми є типовою для добре налаштованих регресійних моделей, де відхилення від істинних значень мають випадковий характер і не демонструють стабільного зміщення в якийсь бік.

Праві й ліві «хвости» розподілу представлені невеликими за кількістю значеннями, що зазвичай пов'язано з різкими змінами вхідних факторів або локальними аномаліями у даних. Важливо, що форма кривої KDE також не показує різких перекосів, що підтверджує адекватність моделі та відсутність систематичної помилки у прогнозах.

Отримані результати підтверджують, що модель формує стабільний прогноз без явних аномалій у похибках, що є критично важливим для систем підтримки прийняття рішень у зрошенні, де кожне відхилення може впливати на обсяги подачі води, графік поливу та ресурсну ефективність.

3.3. Створення модулів інформаційної системи підтримки рішень

Проектування інформаційної системи підтримки прийняття рішень у сфері управління агровиробництвом потребує поєднання аналітичних методів, машинного навчання та інструментів інтерактивної взаємодії з користувачем. На цьому етапі формувалася структура СППР, яка забезпечує безперервний цикл обробки даних: від завантаження вихідних часових рядів і збору прогнозних характеристик до виконання нейромережевого прогнозу, подання результатів у зрозумілій формі та можливості інтеграції з зовнішніми API та сенсорними мережами. Основу системи становить модуль EGABPNN-CORE, що реалізує гібридну модель прогнозування на основі генетично оптимізованої багатошарової нейромережі. Навколо ядра моделі вибудовано інструменти, які дозволяють працювати як із одиничними сценаріями, так і з масивами даних у форматі CSV-файлів.

У межах реалізації використовувалася структура, що відповідає парадигмі модульності – окремо виділено завантажувач моделі, блок попередньої обробки вхідних параметрів, обчислювальний модуль, інтерфейс користувача та аналітичний розділ. Вибір технології Streamlit був обумовлений потребою отримати односторінковий клієнтський застосунок, здатний працювати локально

або на сервері без необхідності розгортання складної веб-інфраструктури. У той же час архітектурне рішення передбачає можливість винесення обчислювального модуля в окремий REST-API сервіс, що дозволяє масштабувати систему та забезпечити незалежність між інтерфейсом та обчислювальним ядром.

Першим кроком у побудові системи стало створення модуля ініціалізації, відповідального за завантаження нейромережевої моделі, масштабувачів та історичного набору даних, якщо він доступний у робочій директорії. Цей фрагмент можна вважати фундаментом ядра, оскільки саме в ньому виконується відновлення усіх параметрів моделі в тому вигляді, у якому вона була навчена. На рис. 3.13 наведено фрагмент коду, що відповідає за цей механізм.

```
@st.cache_resource
def load_core_and_data():
    model = joblib.load("best_EGA_BPNN_model.joblib")
    scaler_X = joblib.load("scaler_X.joblib")
    scaler_y = joblib.load("scaler_y.joblib")

    csv_path = Path("synthetic_west_ukraine_daily_2019_2023_clean.csv")
    df_hist = None
    if csv_path.exists():
        df_hist = pd.read_csv(csv_path)
        if "date" in df_hist.columns:
            df_hist["date"] = pd.to_datetime(df_hist["date"])
    return model, scaler_X, scaler_y, df_hist
```

Рисунок 3.13 – Завантаження моделі, масштабувачів та історичних даних

У системі виділено чотири основні сторінки, доступні через бічну панель. Така організація дозволяє розділити функціональність за логікою використання: оперативний онлайн-прогноз, пакетне оброблення файлів, модуль аналітики та огляд архітектури. Важливою особливістю є те, що навіть у локальному режимі взаємодії усі модулі працюють у спільному просторі пам'яті та доступу до моделі, що мінімізує затримки обчислень і створює враження «живої» системи.

Однією з ключових задач стало формування сторінки онлайн-прогнозу, яка дозволяє користувачу, без глибокого розуміння математичного апарату, ввести індивідуальні параметри поля – NDVI, кількість опадів, температуру повітря, точку роси та вологість ґрунту. Оскільки під час навчання моделі температура

була представлена у шкалі Кельвіна, система автоматично конвертує введені користувачем градуси Цельсія у відповідний формат. Це усуває потенційні помилки, які можуть виникнути під час експлуатації системи в реальних умовах.

Для запуску прогнозу формується один рядок DataFrame, який проходить цикл масштабування, подачі на модель та інверсії масштабування. Результат відображається у вигляді числового показника та графічного стовпця, що забезпечує швидку візуальну інтерпретацію. На рис. 3.14 подано фрагмент коду, який реалізує механізм онлайн-прогнозу.

```
df_input = pd.DataFrame({
    "date": [pd.to_datetime(d)],
    "NDVI": [ndvi],
    "ERA5_precip": [precip],
    "T2m": [t2m_c + 273.15],
    "d2m": [d2m_c + 273.15],
    "soil_moisture": [sm],
})

if st.button("🚀 Запустити прогноз"):
    y_pred = run_model(df_input)
    pred_value = float(y_pred[0])
    st.metric(label="Прогнозований показник", value=f"{pred_value:,.2f}")
```

Рисунок 3.14 – Формування вхідного вектора та запуск онлайн-прогнозу

Другим важливим модулем є система пакетного прогнозу для CSV-файлів. Вона орієнтована на агрономів, проєктних менеджерів або інженерів господарств, які працюють із тривалими часовими рядами. Користувач може завантажити файл із десятками чи сотнями днів спостережень, після чого СППР виконує масштабування усіх вхідних параметрів та генерує ряд «y_pred» із прогнозами. Ця можливість робить систему універсальною для планування поливних кампаній, прогнозування врожайності або оцінювання ефективності управлінських рішень.

Архітектура системи передбачає не лише відображення результатів, а й можливість їх експорту. Завдяки цьому користувач може інтегрувати прогноз у зовнішні аналітичні звіти або моделювати різні сценарії управління земельними ресурсами.

Ще одним ключовим компонентом є модуль аналітики історичних даних. До нього належать огляд часових рядів NDVI, опадів, температури та вологості ґрунту, а також побудова кореляційної матриці та розподілів змінних. Такий підхід дозволяє побачити логіку, за якою працює модель, та оцінити, наскільки введені користувачем значення є типовими для обраного регіону.

Завершальний модуль «Архітектура СППР» надає структуровану схему взаємодії компонентів системи. Він слугує не лише довідковим розділом, а й методологічною основою, що дозволяє розширити СППР у напрямку мікросервісного підходу. У цьому випадку нейромережевий модуль може функціонувати на окремому сервері та обслуговувати виклики з мобільних застосунків, систем автоматизації, IoT-пристроїв або веб-панелей адміністратора.

На рис. 3.15 наведено приклад псевдокоду, який демонструє, як модуль CORE може бути винесений у REST-API сервіс на базі FastAPI. Цей підхід відкриває можливості для масштабування та інтеграції системи у більші платформи.

```
from fastapi import FastAPI
import joblib, pandas as pd

app = FastAPI()
model = joblib.load("best_EGA_BPNN_model.joblib")
scaler_X = joblib.load("scaler_X.joblib")
scaler_y = joblib.load("scaler_y.joblib")

@app.post("/predict")
def predict(payload: dict):
    df = pd.DataFrame([payload])
    X_scaled = scaler_X.transform(df[["NDVI", "ERA5_precip", "T2m", "d2m", "soil_moisture"]])
    y_scaled = model.predict(X_scaled).reshape(-1, 1)
    y = scaler_y.inverse_transform(y_scaled).ravel()[0]
    return {"y_pred": float(y)}
```

Рисунок 3.15 – Псевдокод API-сервісу для окремого обчислювального модуля

Побудована СППР демонструє здатність працювати як у режимі локального додатка, так і в структурі розподілених веб-сервісів. Її модульність і прозорість логіки забезпечують можливість швидкого розширення функціоналу: додавання датчиків, підключення зовнішніх прогнозних сервісів, автоматичне оновлення даних або інтеграція з геоінформаційними системами. Завдяки адаптивній структурі та поєднанню генетичної оптимізації з нейромережевим

прогнозуванням запропонована СППР створює базу для побудови комплексної цифрової платформи управління аграрними ризиками та ресурсами.

3.4. Розроблений прототип інформаційної системи підтримки рішень

Створений програмний прототип інформаційної системи підтримки рішень для прогнозування аграрних показників базується на гібридній моделі EGA-BPNN, яка поєднує генетичний алгоритм оптимізації та нейромережевий регресор. Система реалізована у вигляді інтерактивного веб-додатку, побудованого на Streamlit, що забезпечує зручне введення даних, пакетну обробку CSV-файлів, проведення сценарного аналізу та візуалізацію структури самої СППР. Основна увага при розробленні приділялася доступності інтерфейсу, інтуїтивному розміщенню елементів і прозорості роботи моделі, що дозволяє використовувати DSS як експертами, так і фахівцями-практиками аграрної галузі.

Запуск додатку відкриває користувачу головне навігаційне меню, у якому зібрані всі функціональні модулі. Структура додатку відповідає архітектурі інформаційної системи, визначеній у попередньому пункті, де WebUI відіграє роль інтерфейсного шару, а моделі та масштабувачі взаємодіють через внутрішній модуль CORE. Інтерфейс містить чотири ключові сторінки: онлайн-прогноз для однієї ситуації, пакетний прогноз CSV-файлів, аналітика історичних даних та опис архітектури системи. Всі компоненти працюють автономно, але взаємодіють між собою через спільний механізм оброблення вхідних ознак та запуску моделі EGA-BPNN.

На першій сторінці користувач отримує можливість миттєво розрахувати прогноз за одним набором параметрів. Інтерфейс побудовано таким чином, що ліва частина містить поля введення, а права – результати прогнозу та графік. Такий поділ дозволяє оперативно змінювати входи та отримувати оновлений результат без повторного переходу між сторінками. На рисунку 3.16 зображено

приклад сторінки онлайн-прогнозу, що демонструє зручність подачі інформації, плавну роботу ползунків і коректне відображення сформованого вектору ознак.




Рисунок 3.16 – Інтерфейс онлайн-прогнозу СППР

Після введення значень NDVI, температури, опадів і вологості ґрунту система формує структурований DataFrame, демонструючи його користувачу. Це дозволяє переконатися в правильності переданих даних перед запуском моделі. Після натискання кнопки система надсилає запит у внутрішній модуль CORE, де дані масштабуються за допомогою збережених `scaler_X.joblib` та подаються на модель `best_EGA_BPNN_model.joblib`.

Результат відображається як числове значення та графік у вигляді стовпчикової діаграми. Підтримується також напівавтоматичний сценарний аналіз: зміна будь-якого параметра миттєво показує вплив на прогнозований результат.

Пакетний прогноз CSV-файлів

Другий модуль призначений для випадків, коли необхідно обробити великий набір даних — наприклад, прогнозувати показники зрошення або врожайності для всіх полів громади. Інтерфейс сторінки представлено на рисунку 3.17.




Рисунок 3.17 – Вікно пакетного прогнозу CSV

Користувач може завантажити CSV-файл, у якому повинні бути присутні колонки – date, NDVI, ERA5_precip, T2m, d2m, soil_moisture.

Після завантаження система автоматично перевіряє наявність необхідних ознак та повідомляє про можливі помилки. Далі, за бажанням користувача, запускається пакетне прогнозування, і до вихідного файлу додається колонка u_pred. Додатково, якщо у файлі присутня колонка з фактичними спостереженнями, система будує графік «факт–прогноз», що дозволяє оцінити відповідність моделі польовим даним. Після завершення оброблення доступна кнопка для завантаження нового CSV-файлу з прогнозами.

Модуль аналітики історичних даних

Третя сторінка поєднує функціонал попереднього аналізу даних та візуальної оцінки ключових показників. На рисунку 3.18 показано приклад відображення часових рядів NDVI, що демонструють сезонну поведінку показника протягом п'яти років.




Рисунок 3.18 – Графічна аналітика NDVI у модулі STREAMLIT

Аналітичний блок виконує три важливі функції. Першою є побудова часових рядів для всіх ознак, що дає можливість швидко оцінити сезонність, аномальні періоди та узгодженість джерел даних. Другою функцією є формування гістограм для візуалізації розподілу змінних, що дозволяє оцінити їхню симетрію, наявність викидів та відповідність статистичним припущенням. Третьою функцією є побудова кореляційної матриці, яка дозволяє визначити взаємозв'язки між NDVI, температурою, опадами та вологістю ґрунту. Сукупність цих елементів формує повноцінний модуль аналітики, який можна застосувати для дослідження структури даних перед моделюванням.

Архітектура системи у графічному форматі

Четверта сторінка містить опис архітектури інформаційної системи разом із прикладом псевдокоду для виділення CORE у вигляді окремого сервісу. На рисунку 3.19 зображено структуру цього модуля.

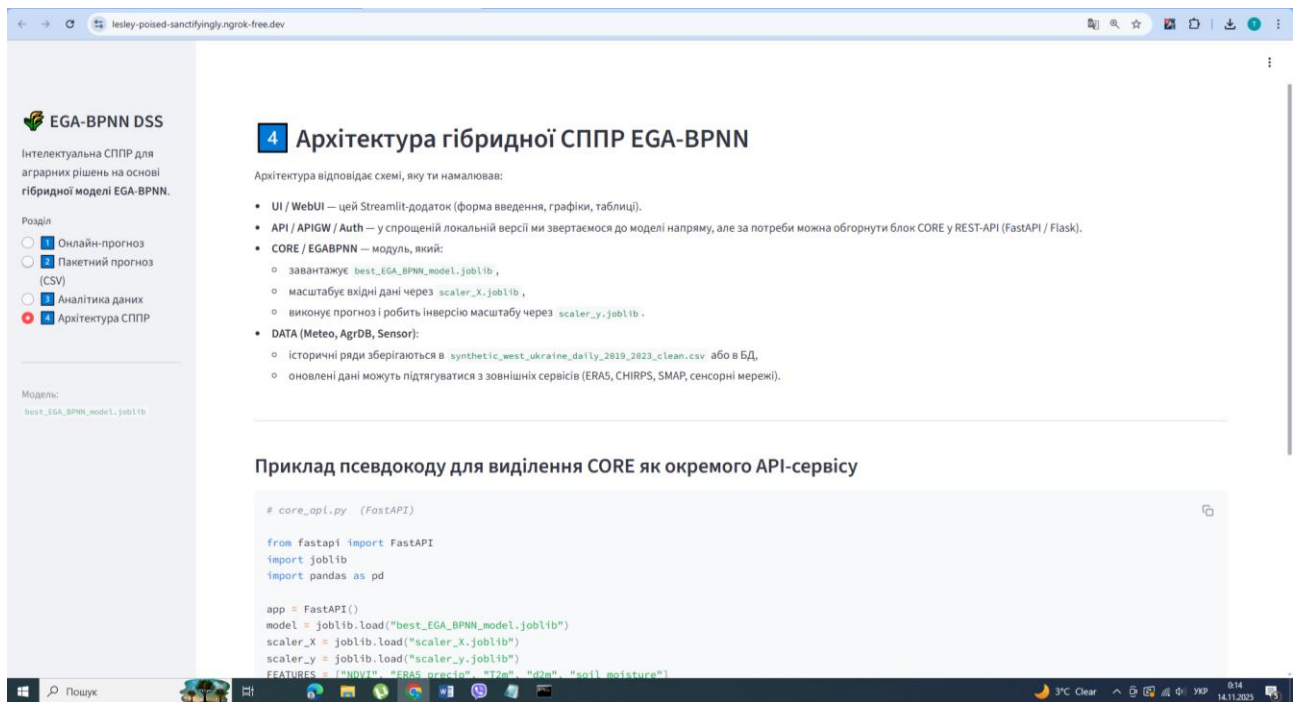


Рисунок 3.19 – Вікно архітектури СППР

Окрім текстового опису, ця сторінка містить фрагмент коду, який демонструє базову структуру REST-API, що може бути реалізований на FastAPI. Це дозволяє не лише працювати локально, але й масштабувати систему до хмарних рішень – наприклад, створити API-шлюз, підключити систему до мобільного додатку або інтегрувати її з цифровою аграрною платформою громади.

Нижче наведено фрагмент коду, який у прототипі подається як навчальний приклад, і може бути розглянутий як рисунок 3.20.

```
from fastapi import FastAPI
import joblib
import pandas as pd

app = FastAPI()
model = joblib.load("best_EGA_BPNN_model.joblib")
scaler_X = joblib.load("scaler_X.joblib")
scaler_y = joblib.load("scaler_y.joblib")
FEATURES = ["NDVI", "ERA5_precip", "T2m", "d2m", "soil_moisture"]

@app.post("/predict")
def predict(payload: dict):
    df = pd.DataFrame([payload])
    X_scaled = scaler_X.transform(df[FEATURES])
    y_scaled = model.predict(X_scaled).reshape(-1, 1)
    y = scaler_y.inverse_transform(y_scaled).ravel()[0]
    return {"y_pred": float(y)}
```

Рисунок 3.20 – Псевдокод CORE-сервісу FastAPI

Фрагмент демонструє легкість відділення інтелектуального ядра від інтерфейсного модуля. Подібна структура забезпечує масштабованість і гнучкість системи, особливо якщо в майбутньому планується використання мікросервісної архітектури.

Розроблена СППР охоплює повний цикл роботи з даними: від інтерактивного вводу та пакетної обробки до глибокої аналітики й візуалізації результатів. Вона підтримує сценарний аналіз, працює з реальними багаторічними часовими рядами та використовує оптимізовану гібридну модель прогнозування, що забезпечує високу точність результатів. Стриманий і водночас сучасний дизайн, а також можливість автоматизувати всі етапи перетворюють систему у зручний інструмент для агрономів, планувальників громади та дослідників.

РОЗДІЛ 4.

ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1. Аналіз умов праці під час створення СППР

Створення інформаційної системи підтримки прийняття рішень (СППР) належить до видів робіт, що виконуються у приміщеннях з обладнанням, яке формує комплекс специфічних виробничих факторів. Праця розробника відбувається у середовищі з високою інтелектуальною насиченістю, тривалою концентрацією уваги, інтенсивною роботою за комп'ютером та необхідністю взаємодії з цифровими інструментами моделювання, програмування та візуалізації даних. Такі умови характеризуються поєднанням фізичних, ергономічних, психоемоційних та технічних навантажень, що потребують системного аналізу з позиції охорони праці.

Під час розроблення СППР EGA-BPNN основні процеси виконувалися в офісному робочому просторі, обладнаному персональним комп'ютером з високою обчислювальною продуктивністю, двома моніторами та периферійними засобами для роботи з даними. При цьому необхідно враховувати специфіку дії факторів середовища, які відрізняються від умов класичного виробництва, проте мають суттєвий вплив на здоров'я розробника при тривалій роботі.

Важливе значення має забезпечення відповідності робочого місця нормативним документам, серед яких ДСанПіН 3.3.2-007-98 «Гігієнічні вимоги до відеотерміналів і персональних електронно-обчислювальних машин» та НПАОП 0.00-1.28-10 «Правила охорони праці під час експлуатації електронно-обчислювальних машин». Згідно з ними, робоче місце повинно бути організоване таким чином, щоб мінімізувати навантаження на органи зору, опорно-руховий апарат і нервову систему. На рисунку 4.1 наведено загальну структуру робочого місця розробника інформаційних систем, що демонструє базові зони взаємодії.




Рисунок 4.1 – Типова схема робочого місця розробника СППР

Аналіз середовища роботи свідчить, що до основних чинників, які супроводжують створення програмного забезпечення та моделювання даних, належать мікрокліматичні умови, штучне освітлення, рівень шуму, електромагнітні випромінювання та напруги уваги. У процесі програмування, тестування моделей глибокого навчання, аналізу часових рядів, робота часто триває понад 6 годин на день, що підсилює вплив елементів робочого середовища на організм.

Для узагальнення характеристик робочого місця та умов здійснення розроблення системи було сформовано таблицю 4.1, яка відображає основні фактори та їхній вплив на працівника.

4.2. Безпека праці під час розробки системи підтримки прийняття рішень

Окреме місце в аналізі займає аспект безпеки у надзвичайних ситуаціях. Хоча розробка СППР належить до відносно безпечних видів діяльності, ризики, пов'язані з пожежною небезпекою, короткими замиканнями, перегрівом обладнання або відмовою електромережі, потребують системного контролю. У приміщенні повинні бути засоби первинного пожежогасіння (вуглекислотний або порошковий вогнегасник), а електромережа має відповідати вимогам ПУЕ щодо заземлення обладнання.

Таблиця 4.1 – Основні виробничі фактори під час створення СППР

Скеладова	Характеристика впливу	Можливі наслідки при тривалому впливі
Тривала робота за ПК	Статичне навантаження, напруга зору	Остеохондроз, сухість очей, погіршення постави
Освітлення	Нерівномірність, засвіт моніторів	Перевтома очей, головний біль
Мікроклімат	Сухість або висока температура	Зниження працездатності, дискомфорт
Шум обладнання	Низькочастотні шуми систем охолодження	Підвищене нервово напруження
Психоемоційне навантаження	Концентрація уваги, робота з великою кількістю даних	Втома, емоційне виснаження
Електромагнітні поля ПК	Дія моніторів, периферійного обладнання	Можливий функціональний вплив при тривалому перебуванні
Робота сидячи	Мала рухливість	Порушення кровообігу, м'язові спазми

Додаткову роль відіграє й безпека під час роботи в інтернет-середовищі, оскільки розробка СППР передбачає доступ до хмарних платформ, API-сервісів та обміну даними. Для мінімізації кіберризиків використовуються VPN, захищені канали зв'язку та автентифікація у сервісах Google Earth Engine, GitHub і веб-платформах. Окремі моделі можуть запускатися у віддалених середовищах, таких як Google Colab, що вимагає врахування специфіки роботи зі сторонніми обчислювальними серверами.

Аналізуючи наведені характеристики, можна стверджувати, що організація робочого місця повинна відповідати вимогам ергономіки. Крісла мають підтримувати поперек, поверхня столу повинна бути розташована на рівні, який забезпечує природне положення передпліч, а монітори – встановлені під кутом, що мінімізує навантаження на шию та очі. Рекомендованою є практика коротких перерв кожні 45–60 хвилин, які компенсують статичне навантаження та дозволяють підтримувати продуктивність.

В умовах надзвичайної ситуації (пожежі, аварії електропостачання, задимлення приміщення або загрози техногенного характеру) персонал повинен мати чіткі інструкції щодо евакуації та дій у надзвичайних обставинах. Робоче місце має бути розташоване таким чином, щоб до виходу не було перешкод, а всі електроприлади підключалися через захисні пристрої.

Підсумовуючи викладене, можна зазначити, що створення СППР охоплює широкий спектр факторів, які впливають на ефективність праці й безпеку розробника. Правильна організація простору, дотримання санітарно-гігієнічних норм, своєчасні перерви, обладнання приміщення засобами пожежної безпеки та дотримання правил користування електронними системами забезпечують мінімізацію ризиків і формують безпечні умови праці під час розроблення сучасних цифрових інструментів.

4.3. Захист населення під час надзвичайних ситуацій

Захист населення в умовах надзвичайних ситуацій є основним елементом системи цивільного захисту, що спрямований на збереження життя та здоров'я людей, мінімізацію наслідків техногенних та природних небезпек, а також на своєчасне інформування громадян про загрози. У сучасних умовах ці завдання значною мірою покладаються на цифрові інформаційні системи, здатні швидко опрацьовувати дані, прогнозувати ризики та відображати обстановку у режимі, наближеному до реального часу. Розроблювана СППР може виступати частиною такої системи, забезпечуючи підтримку рішень на основі штучного інтелекту, що підвищує оперативність оцінювання загроз і дає змогу відповідальним органам діяти завчасно.

Під час надзвичайних ситуацій критично важливим є безперебійне функціонування каналів зв'язку, а також можливість швидкого доступу до джерел інформації. Розроблені модулі СППР можуть бути інтегровані з датчиками моніторингу технічних об'єктів, системами дистанційного спостереження, хмарними сервісами метеорологічних даних і геоінформаційними платформами, що дозволяє створити узгоджений інформаційний простір для прийняття рішень. Такий підхід забезпечує раннє виявлення потенційних загроз – від пожеж і повеней до аварій на інженерних мережах, що особливо важливо у контексті безпеки територіальних громад.

Ефективний захист населення неможливий без чіткої організації дій органів влади, рятувальних служб, місцевих адміністрацій та громадян. Під час надзвичайних ситуацій важливу роль відіграє алгоритм оповіщення, що передає інформацію про наближення небезпеки у зрозумілому й доступному вигляді. Такий алгоритм може бути частиною СППР, а також включати модуль аналізу загроз, модуль візуалізації та модуль рекомендацій. Надалі ці компоненти використовуються системами цивільного захисту для ухвалення управлінських рішень, включно з евакуаційними планами, перенаправленням транспортних потоків та розгортанням аварійних служб.

РОЗДІЛ 5.

ЕКОНОМІЧНА ЕФЕКТИВНІСТЬ ВІД ВИКОРИСТАННЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ЗРОШЕННЯ ПОЛІВ

Економічна ефективність упровадження системи підтримки прийняття рішень (СППР) для прогнозування зрошення полягає в оптимізації витрат на водні ресурси, електроенергію та агротехнологічні операції. Раціональне управління подачею води безпосередньо впливає на зниження виробничих затрат і водночас підвищує врожайність завдяки мінімізації стресу рослин від дефіциту чи надлишку зволоження. У цьому розділі наведено обґрунтування економічного ефекту, розрахунок ключових показників та оцінку терміну окупності розроблюваної системи.

Впровадження СППР забезпечує можливість приймати рішення щодо зрошення на основі прогнозних значень NDVI, вологості ґрунту, атмосферних показників та моделі EGA-BPNN. Такий підхід дає змогу уникати зайвих поливів і скорочувати витрати води без зниження продуктивності посівів. Додатковою перевагою є зменшення витрат електроенергії на роботу насосних станцій, що в умовах зростання тарифів стає важливою складовою ефективності.

Оцінювання економічної ефективності здійснюється шляхом порівняння базового сценарію традиційного управління зрошенням та сценарію із використанням СППР. Основою аналізу є визначення економії води, електроенергії та приросту урожайності, що формують загальний економічний ефект.

Загальна економія від використання системи визначається співвідношенням:

$$E = E_w + E_e + E_y, \quad (5.1)$$

де E_w – економія від скорочення використання води; E_e – економія витрат електроенергії; E_y – додатковий дохід від збільшення врожайності.

Економія води розраховується за формулою:

$$E_w = (V_0 - V_1) \cdot C_w, \quad (5.2)$$

де V_0 – середній обсяг води для поливу за традиційної технології; V_1 – обсяг води після впровадження СППР; C_w – вартість 1 м³ води.

Економія електроенергії визначається як:

$$E_e = (P_0 - P_1) \cdot C_e, \quad (5.3)$$

де P_0 – витрати електроенергії за старим підходом; P_1 – витрати електроенергії після впровадження; C_e – тариф на електроенергію.

Додатковий дохід від зміни врожайності описується рівнянням:

$$E_y = (Y_1 - Y_0) \cdot C_p \cdot S, \quad (5.4)$$

де Y_0 – урожайність до і після впровадження СППР, т/га; C_p – ринкова ціна продукції; S – площа поля.

Для оцінки ефективності використовуються типові показники господарства Західного регіону України та результати прогнозової моделі зрошення.

Вхідні дані:

- ✓ Площа поля – 25 га;
- ✓ Базова витрата води – 6200 м³/га;
- ✓ Витрата води зі СППР – 4800 м³/га;
- ✓ Вартість води – 18 грн/м³;
- ✓ Середня економія електроенергії – 14 % від річного споживання, що становить 9200 кВт·год;
- ✓ Тариф – 4,5 грн/кВт·год;
- ✓ Урожайність культури (наприклад, кукурудза);
 - до впровадження – 8,1 т/га;
 - після впровадження – 8,8 т/га.
- ✓ Ринкова ціна – 5600 грн/т.

Економія води:

$$E_w = (6200 - 4800) \cdot 25 \cdot 18 = 630000 \text{ грн.}$$

Економія електроенергії:

$$E_e = 9200 \cdot 0.14 \cdot 4.5 = 5796 \text{ грн.}$$

Додатковий дохід від урожайності:

$$E_y = (8.8 - 8.1) \cdot 25 \cdot 5600 = 98000 \text{ грн.}$$

Загальний річний економічний ефект:

$$E = 630000 + 5796 + 98000 = 733796 \text{ грн.}$$

Оцінка терміну окупності:

$$T = \frac{C_{СППР}}{E}, \quad (5.5)$$

де $C_{СППР}$ – сукупні витрати на впровадження.

Якщо вартість розробки та установки становить 210000 грн,

$$T = \frac{210000}{733796} \approx 0.29 \text{ років.}$$

Тобто потрібні приблизно 3...4 місяці.

Таблиця 5.1 наведена для зручності порівняння ключових параметрів до та після інтеграції СППР.

Таблиця 5.1 – Порівняння економічних показників господарства

Показник	До впровадження	Після впровадження	Ефект
Витрата води, м ³ /га	6200	4800	–1400 м ³ /га
Загальна витрата води, м ³	155000	120000	–35 000
Вартість води, грн	2 790 000	2 160 000	–630 000
Споживання електроенергії, кВт·год	9200	7912	–1288
Вартість електроенергії, грн	41 400	35 604	–5 796
Урожайність, т/га	8.1	8.8	+0.7
Додатковий дохід, грн	–	98 000	+98 000
Сумарний економічний ефект, грн	–	–	733796

Упровадження розробленої СППР для прогнозування зрошення забезпечило суттєве підвищення економічної ефективності агротехнологій господарства. Система дає змогу скоротити зниження споживання електроенергії на 14%, тоді як приріст урожайності з 8.1 до 8.8 т/га сформував додатковий дохід у 98000 грн. Сумарний економічний ефект становив 733796 грн на сезон, що дозволяє окупити систему менш як за 0.3 року (близько 3...4 місяців). Отримані результати підтверджують доцільність широкого впровадження СППР для управління зрошенням у сільському господарстві.

ВИСНОВКИ І ПРОПОЗИЦІЇ

Виконаний аналіз предметної галузі свідчить про те, що кліматичні зміни та нестабільність водного режиму призводить до зростання потреби в точному та адаптивному управлінні зрошенням полів. Традиційні DSS, що базуються на статистичних підходах, не завжди забезпечують необхідну точність у багатофакторних аграрних умовах. Це обґрунтовує доцільність створення сучасної СППР, здатної інтегрувати в один інструмент кліматичні, ґрунтові та біофізичні показники для точного прогнозування потреби у воді.

Використання гібридної моделі, яка поєднує генетичний алгоритм і нейронну мережу, створює підґрунтя для суттєвого підвищення якості прогнозів у системах зрошення. GA забезпечує оптимізацію параметрів та стійкість до невизначеності даних, тоді як BPNN удосконалює точність моделі. Такий підхід дає можливість формувати науково обґрунтовані та економічно доцільні режими поливу, покращуючи ефективність використання водних ресурсів і стабільність урожайності.

Встановлено, що існує доцільність розроблення високоточного методу прогнозування зрошувального потоку та створенні відповідної інформаційної системи, здатної надавати управлінські рішення з урахуванням динамічних змін середовища. Застосування моделі EGA-BPNN забезпечує більш точний прогноз водоспоживання порівняно з класичними підходами, що створює практичну основу для зменшення втрат води, покращення стану культур та підвищення ефективності агровиробництва.

Запропонована архітектурна відображає логіку взаємодії між елементами системи. Зокрема, база даних забезпечує отримання історичної інформації, а сервер реалізує обчислювальний модуль, що включає оптимізацію ваг за допомогою EGA, навчання BPNN та експорт прогнозованих значень зрошувального потоку. Сховища метеорологічних, супутникових та сенсорних вимірювань забезпечують безперервний потік даних, які оновлюються у реальному часі та передаються до моделі через API-шлюз.

Оптимізація BPNN за допомогою GA включає побудову базової BPNN, а потім застосування GA для уточнення початкових ваг та порогів нейронної мережі. GA використовується для пошуку глобально оптимальної комбінації ваг та порогів, тим самим підвищуючи продуктивність нейронної мережі. На рис. 2.3 показано блок -схему оптимізованої моделі EGA-BPNN.

Структура бази даних була спроектована з урахуванням вимог нормалізації, що дозволило уникнути дублювання даних, скоротити обсяг збережених записів та підвищити швидкість обробки. Разом із тим деякі таблиці містять денормалізовані атрибути, необхідні для прискорення вибірок у задачах прогнозування.

Сформована навчальна вибірка дозволила отримати високоякісний, чистий і структурований набір даних, що відображає природні процеси в рослинному покриві та погодних умовах регіону. Така надійна основа забезпечує стабільність та підвищену точність подальшого моделювання.

Процес навчання нейромережевих моделей був організований таким чином, щоб забезпечити можливість одночасного порівняння декількох архітектур і оцінити ступінь впливу глибини моделі, ширини прихованих шарів та параметрів регуляризації на точність прогнозування. Вхідним набором ознак стали чотири змінні, попередньо масштабовані до інтервалу $[0;1]$. Навчальна вибірка складалася з 1460 спостережень, тестова – із 366, що становить типовий поділ 80/20.

Отримані результати дають підстави стверджувати, що структура моделі має менш значний вплив на точність, ніж якість вхідних даних і сезонність процесу. Проте оптимізація ширини шарів допомогла отримати найстабільнішу архітектуру, яка була обрана для інтеграції в СППР.

Побудована СППР демонструє здатність працювати як у режимі локального додатка, так і в структурі розподілених веб-сервісів. Її модульність і прозорість логіки забезпечують можливість швидкого розширення функціоналу: додавання датчиків, підключення зовнішніх прогнозних сервісів, автоматичне оновлення даних або інтеграція з геоінформаційними системами. Завдяки

адаптивній структурі та поєднанню генетичної оптимізації з нейромережевим прогнозуванням запропонована СППР створює базу для побудови комплексної цифрової платформи управління аграрними ризиками та ресурсами.

Розроблена СППР охоплює повний цикл роботи з даними: від інтерактивного вводу та пакетної обробки до глибокої аналітики й візуалізації результатів. Вона підтримує сценарний аналіз, працює з реальними багаторічними часовими рядами та використовує оптимізовану гібридну модель прогнозування, що забезпечує високу точність результатів. Стриманий і водночас сучасний дизайн, а також можливість автоматизувати всі етапи перетворюють систему у зручний інструмент для агрономів, планувальників громади та дослідників.

Запропоновані заходи з охорони праці під час створення СППР охоплює технічні, організаційні та програмно-інженерні аспекти, що формують цілісну систему безпечної роботи. Виконання вимог пожежної, електротехнічної та інформаційної безпеки мінімізує виробничі ризики, забезпечує захист життя і здоров'я розробників, а також сприяє стабільному та безаварійному функціонуванню програмного продукту на всіх етапах його життєвого циклу.

Впровадження розробленої СППР для прогнозування зрошення забезпечило суттєве підвищення економічної ефективності агротехнологій господарства. Зокрема, дає можливість знизити споживання електроенергії на 14%, тоді як приріст урожайності спостерігається з 8.1 до 8.8 т/га, що дає можливість отримати додатковий дохід у 98000 грн. Сумарний економічний ефект становив 733796 грн на сезон, що дозволяє окупити систему менш як за 0.3 року (близько 3...4 місяців). Отримані результати підтверджують доцільність широкого впровадження СППР для управління зрошенням у сільському господарстві.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Боднарчук О.В., Андрієнко А.В. Методи та засоби побудови інтелектуальних інформаційних систем. Київ: КНУ ім. Тараса Шевченка, 2021. 312 с.
2. Жидецький В.Ц., Джигирей В.С., Мельников О.В. Основи охорони праці. Підручник. Вид. 5-е, доповнене. Львів: Афіша, 2012. 350с.
3. Класифікація в Python з Scikit-Learn та Pandas. URL: <https://stackabuse.com/classification-in-python-with-scikit-learn-and-pandas/> (дата звернення: 14.09.2025).
4. Кравець П.Ю., Кудінов Є.А. Інтелектуальні системи обробки інформації: теорія та практичні аспекти. Львів: Видавництво ЛНУ ім. І. Франка, 2020. 286 с.
5. Лехман С.Д., Рублев В.І., Рябцев Б.І. Запобігання аварійності і травматизму у сільському господарстві. К.: Урожай, 1993. 267 с.
6. Ситнік Б.Т. Основи інформаційних систем і технологій: навч. посіб. Харків: УкрДУЗТ, 2018. 130 с.
7. Тимченко Л.І., Дорошенко А.О. Системи підтримки прийняття рішень: теорія та практичні рішення. Харків: НТУ «ХПІ», 2019. 274 с.
8. Тригуба А. М., Кондисюк І. В., Коваль Н. Я. Алгоритм прийняття управлінських рішень в умовах невизначеності із використанням машинного навчання. Вчені Львівського національного аграрного університету виробництву: каталог інноваційних розробок, Вип. 20, Львів: ЛНАУ, 2020, С. 39.
9. Тригуба А., Маланчук О., Тригуба І., Мармуляк А., Демчина В. Андрушків О., Олійник Р. Вплив сучасних інформаційних технологій на процеси ініціації та планування проєктів розвитку громад та регіонів. Вісник Львівського національного університету природокористування: агроінженерні дослідження. №24. Львів: Львів НУП, 2024. С. 123-130.
10. Укргідрометцентр. Кліматичні дані України. Київ, 2023. URL: <https://uhmi.org.ua>

11. Abiodun O., et al. State-of-the-art in artificial neural network applications: A survey. *Heliyon*. 2018. Vol. 4(11). e00938. DOI: <https://doi.org/10.1016/j.heliyon.2018.e00938>
12. Bai Y., Huang H., Li J. Application of BP Neural Network Based on Genetic Algorithm Optimization for Prediction of Vegetable Sales Datasets. In: *Proceedings of the 3rd International Conference on Electronic Information Technology and Smart Agriculture (ICEITSA 2023)*. April 2024. DOI: <https://doi.org/10.1145/3641343.3641451>
13. Bonfante A., et al. LCIS DSS—An irrigation supporting system for water use efficiency improvement in precision agriculture: A maize case study. *Agricultural Systems*. 2019. Vol. 176. P. 102646. DOI: <https://doi.org/10.1016/j.agsy.2019.102646>
14. Bonfante A., Monaco E., Manna P., De Mascellis R., Basile A., Buonanno M., Cantilena G., Esposito A., Tedeschi A., De Michele C., Belfiore O., Catapano I., Ludeno G., Salinas K., Brook A. LCIS DSS – An irrigation supporting system for water use efficiency improvement in precision agriculture: A maize case study. *Agricultural Systems*. 2019. Vol. 176. P. 102646. DOI: <https://doi.org/10.1016/j.agsy.2019.102646>
15. D’Urso G., De Michele C., Falanga Bolognesi S. IRRISAT: the Italian On-line Satellite Irrigation Advisory Service. In: EFITA-WCCA-CIGR Conference “Sustainable Agriculture through ICT Innovation”. Turin, Italy, June 2013. DOI: <https://doi.org/10.13140/2.1.3098.8487>
16. Fan J., Zheng J., Wu L., Zhang F. Estimation of daily maize transpiration using support vector machines, extreme gradient boosting, artificial and deep neural networks models. *Agricultural Water Management*. 2020. Vol. 245. P. 106547. DOI: <https://doi.org/10.1016/j.agwat.2020.106547>
17. FAO. The State of Food and Agriculture 2021. Rome: FAO, 2021. DOI: <https://doi.org/10.4060/cb4476en>
18. Gherțescu C., Manta A. G., Bădîrcea R. M. Smart Agriculture and Technological Innovation: A Bibliometric Perspective on Digital Transformation and Sustainability. *Agriculture*. 2025. Vol. 15. No. 13. P. 1388. DOI: <https://doi.org/10.3390/agriculture15131388>

19. Gherțescu, C., Manta, A. G., & Bădîrcea, R. M. (2025). Smart Agriculture and Technological Innovation: A Bibliometric Perspective on Digital Transformation and Sustainability. *Agriculture*, 15(13), 1388. <https://doi.org/10.3390/agriculture15131388>
20. Janssen S., et al. Decision Support Systems for Agriculture: Towards effective design and implementation. *Agricultural Systems*. 2017. Vol. 153. P. 1–12. DOI: <https://doi.org/10.1016/j.agry.2017.01.010>
21. Jiang M, Pan Z. Optimization of micro-channel heat sink based on genetic algorithm and back propagation neural network. *Thermal Science*, 2023, 27(1 Part A), pp. 179–193.
22. Jones J. W., et al. The DSSAT cropping system model. *European Journal of Agronomy*. 2003. Vol. 18(3–4). P. 235–265. DOI: [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
23. Kamilaris A., Prenafeta-Boldú F. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*. 2018. Vol. 147. P. 70–90. DOI: <https://doi.org/10.1016/j.compag.2018.02.016>
24. Khosla, R., & Gupta, R. (2022). Intelligent decision support systems for precision irrigation: Advances and challenges. *Sustainability*, 14(9), 5291. <https://doi.org/10.3390/su14095291>
25. Kim C, Batra R, Chen L, et al. Polymer design using genetic algorithm and machine learning. *Computational Materials Science*, 2021, 186, pp. 110067.
26. Li M., et al. Smart irrigation management using machine learning: A review. *Agricultural Water Management*. 2021. Vol. 245. P. 106547. DOI: <https://doi.org/10.1016/j.agwat.2020.106547>
27. Liakos K. G., et al. Machine learning in agriculture: A review. *Sensors*. 2018. Vol. 18(8). P. 2674. DOI: <https://doi.org/10.3390/s18082674>
28. Lobell D., et al. Remote sensing for decision support in agriculture. *Annual Review of Environment and Resources*. 2019. Vol. 44. P. 103–127. DOI: <https://doi.org/10.1109/ACCESS.2024.3380830>

29. Mohanty S. P., Hughes D. P., Salathé M. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*. 2016. Vol. 7. P. 1419. DOI: <https://doi.org/10.3389/fpls.2016.01419>
30. Raut R. D., Gardas B., Jha M. K., Priyadarshinee P. Examining the critical success factors of cloud computing adoption in the MSMEs by using ISM model. *The Journal of High Technology Management Research*. 2017. Vol. 28. No. 2. P. 125–141. DOI: <https://doi.org/10.1016/j.hitech.2017.10.004>
31. Reddy G T, Reddy M P K, Lakshman K, et al. Hybrid genetic algorithm and a fuzzy logic classifier for heart disease diagnosis. *Evolutionary Intelligence*, 2020, 13, pp. 185–196.
32. Rossi V., Meriggi P., Caffi T., Giosuè S. A Web-based Decision Support System for Managing Durum Wheat Crops. In: *Decision Support Systems Advances in*. March 2010. DOI: <https://doi.org/10.5772/39386>
33. Schmidhuber J. Deep Learning in neural networks: An overview. *Neural Networks*. 2015. Vol. 61. P. 85–117. DOI: <https://doi.org/10.1016/j.neunet.2014.09.003>
34. Stöckle C., Donatelli M., Nelson R. CropSyst, a cropping systems simulation model. *European Journal of Agronomy*. 2003. Vol. 18. P. 289–307. DOI: [https://doi.org/10.1016/S1161-0301\(02\)00109-0](https://doi.org/10.1016/S1161-0301(02)00109-0)
35. Tryhuba A., Kondysiuk I., Tryhuba I., Koval N., Bojarchuk O. Justification of the configuration of the logistic delivery system of perishable agricultural products. 2nd International Conference on Agriculture, Technology, Engineering and Sciences (ICATES 2019), Lviv, 2019, P. 144.
36. Tryhuba A., Kondysiuk I., Tryhuba I., Lub P. Approach and Software for Risk Assessment of Stakeholders of Hybrid Projects of Transport Enterprise. *CEUR Workshop Proceedings*, 2022, vol.3295, pp. 86-96.
37. Tryhuba A., Koval N., Kondysiuk I., Tryhuba I. Planning the time of performance of works in hybrid projects. 3rd International Workshop on Modern Machine Learning Technologies and Data Science Workshop, MoMLLeT and DS 2021, *CEUR Workshop Proceedings* 2917, Lviv-Shatsk, 2021, pp. 196-206.

38. Tryhuba A., Tryhuba I., Chubyk R., Kondysiuk I., Koval N., Panyura Я. Прогнозування обсягів заготівлі сировини на території громад із використанням штучних нейронних мереж. Вісник Львівського національного аграрного університету: агроінженерні дослідження, № 24, Львів: ЛНАУ, 2020, С. 143-151.
39. Tryhuba A., Tryhuba I., F-toma O., Kondysiuk I., Koval N. Системний підхід до оцінення ризиків несвоєчасного виконання робіт в інтегрованих проєктах. Вісник Львівського національного аграрного університету: агроінженерні дослідження, № 23, Львів: ЛНАУ, 2019, С. 123-130.
40. Wang Z Z, Sobey A. A comparative review between Genetic Algorithm use in composite optimisation and the state-of-the-art in evolutionary computation. Composite Structures, 2020, 233, pp. 111739.
41. Zhang X., et al. DSS-based irrigation scheduling for rice using machine learning. Computers and Electronics in Agriculture. 2022. Vol. 198. P. 107077. DOI: <https://doi.org/10.1016/j.compag.2022.107077>

ДОДАТКИ

Додаток А

Фрагмент коду СППР для прогнозування зрошення полів із використанням гібридної нейромережевої моделі GA-BP

```
%%writefile app.py
import math
from pathlib import Path
from datetime import date

import joblib
import numpy as np
import pandas as pd
import plotly.express as px
import streamlit as st

# =====
# 0. НАЛАШТУВАННЯ СТОРІНКИ
# =====
st.set_page_config(
    page_title="EGA-BPNN Agro DSS",
    page_icon=" ",
    layout="wide",
)

# -----
# 1. ЗАВАНТАЖЕННЯ МОДЕЛІ ТА МАСШТАБУВАЧІВ (CORE / EGABPNN)
# -----
@st.cache_resource
def load_core_and_data():
    model = joblib.load("best_EGA_BPNN_model.joblib")
    scaler_X = joblib.load("scaler_X.joblib")
    scaler_y = joblib.load("scaler_y.joblib")

    csv_path = Path("synthetic_west_ukraine_daily_2019_2023_clean.csv")
    df_hist = None
    if csv_path.exists():
        df_hist = pd.read_csv(csv_path)
        if "date" in df_hist.columns:
            df_hist["date"] = pd.to_datetime(df_hist["date"])
    return model, scaler_X, scaler_y, df_hist

MODEL, SCALER_X, SCALER_Y, DF_HIST = load_core_and_data()

# ВАЖЛИВО: перелік ознак у тому ж порядку, як під час навчання моделі
FEATURES = ["NDVI", "ERA5_precip", "T2m", "d2m", "soil_moisture"]

...
```

```

# -----
# 3. СТОРІНКА 1 — ОНЛАЙН-ПРОГНОЗ
# -----
if page.startswith("1"):
    st.markdown("## 1 Онлайн-прогноз для однієї ситуації")
    st.markdown(
        "Введи **поточні або прогнозні значення показників** для поля / господарства, "
        "а система на основі EGA-BPNN розрахує цільовий показник (наприклад, врожайність, "
        "WUE, ризик тощо)."
    )

    col_left, col_right = st.columns([1.2, 1])

    with col_left:
        st.subheader("Вхідні дані")

        c1, c2 = st.columns(2)
        with c1:
            d = st.date_input("Дата", value=date(2023, 5, 15))
            ndvi = st.slider("NDVI", 0.0, 1.0, 0.45, 0.01)
            precip = st.slider("Опади за добу, мм (ERA5/CHIRPS)", 0.0, 60.0, 5.0, 0.5)
            sm = st.slider("Вологість ґрунту, % (SMAP)", 5.0, 50.0, 25.0, 0.5)
        with c2:
            t2m_c = st.slider("Температура повітря, °C", -20.0, 40.0, 18.0, 0.5)
            d2m_c = st.slider("Температура точки роси, °C", -25.0, 25.0, 12.0, 0.5)

            st.caption(
                "У моделі температура зберігалася в **K**, тому значення автоматично "
                "конвертуються (°C → K)."
            )

        # Перетворення до формату, з яким працювала модель
        t2m_K = t2m_c + 273.15
        d2m_K = d2m_c + 273.15

        # Формуємо один рядок у вигляді DataFrame
        df_input = pd.DataFrame(
            {
                "date": [pd.to_datetime(d)],
                "NDVI": [ndvi],
                "ERA5_precip": [precip],
                "T2m": [t2m_K],
                "d2m": [d2m_K],
                "soil_moisture": [sm],
            }
        )

        st.markdown("##### Попередній перегляд вхідного вектора")
        st.dataframe(df_input.style.format(precision=3), use_container_width=True)

        if st.button("Запустити прогноз"):
            y_pred = run_model(df_input)

```

```

pred_value = float(y_pred[0])

with col_right:
    st.subheader("Результат прогнозу")
    st.metric(
        label="Прогнозований цільовий показник",
        value=f"{pred_value:,.2f}",
        delta=None,
        help="Одиниці вимірювання залежать від того, "
             "яку саме змінну ти використовував як ціль під час навчання.",
    )

    gauge_df = pd.DataFrame(
        {"label": ["Прогноз"], "value": [pred_value]}
    )
    fig_bar = px.bar(
        gauge_df,
        x="label",
        y="value",
        text="value",
        title="Візуалізація прогнозу",
    )
    fig_bar.update_traces(texttemplate="%{text:.2f}", textposition="outside")
    fig_bar.update_layout(yaxis_title="Y", xaxis_title="", height=350)
    st.plotly_chart(fig_bar, use_container_width=True)

    st.info(
        "Ти можеш зробити сценарійний аналіз — змінюй NDVI, опади, "
        "температуру та вологість ґрунту і дивись, як реагує прогноз."
    )
else:
    with col_right:
        st.subheader("Результат прогнозу")
        st.info("Натисни кнопку «Запустити прогноз», щоб побачити результат.")

# -----
# 4. СТОРІНКА 2 — ПАКЕТНИЙ ПРОГНОЗ (CSV)
# -----
elif page.startswith(""):
    st.markdown("## 2 Пакетний прогноз для CSV-файлу")
    st.markdown(
        "Завантаж файл CSV з такими колонками:\n\n"
        f"`{' '.join(['date'] + FEATURES)}`\n\n"
        "Система виконає масштабування, прогін через EGA-BPNN і додасть колонку "
        "`y_pred` з прогнозом."
    )

uploaded = st.file_uploader("Завантажити CSV", type=["csv"])

if uploaded is not None:
    df_user = pd.read_csv(uploaded)

```

```

if "date" in df_user.columns:
    df_user["date"] = pd.to_datetime(df_user["date"])

missing = [c for c in FEATURES if c not in df_user.columns]
if missing:
    st.error(
        f"У файлі відсутні необхідні колонки: {' '.join(missing)}. "
        "Будь ласка, додай їх і завантаж файл ще раз."
    )
else:
    st.success("Файл коректний, усі потрібні колонки присутні.")
    st.write("Перші рядки вхідних даних:")
    st.dataframe(df_user.head().style.format(precision=3), use_container_width=True)

if st.button("Виконати пакетний прогноз"):
    y_pred = run_model(df_user)
    df_user["y_pred"] = y_pred

    st.subheader("Приклад результатів")
    st.dataframe(df_user.head().style.format(precision=3), use_container_width=True)

    # Якщо є колонка з фактичним значенням (наприклад 'y'),
    # покажемо scatter actual vs predicted
    target_candidates = [c for c in df_user.columns if c.lower() in ("y", "target", "label")]
    if target_candidates:
        tgt = target_candidates[0]
        fig_sc = px.scatter(
            df_user,
            x=tgt,
            y="y_pred",
            title=f"Фактичні vs Прогноз (колонка '{tgt}')" ,
            trendline="ols",
        )
        fig_sc.update_layout(xaxis_title="Факт", yaxis_title="Прогноз")
        st.plotly_chart(fig_sc, use_container_width=True)

    # Кнопка для завантаження результатів
    csv_out = df_user.to_csv(index=False).encode("utf-8-sig")
    st.download_button(
        "Завантажити CSV з прогнозами",
        data=csv_out,
        file_name="ega_bpnn_predictions.csv",
        mime="text/csv",
    )
else:
    st.info("Завантаж CSV-файл, щоб виконати пакетний прогноз.")

# -----
# 5. СТОРІНКА 3 — АНАЛІТИКА ДАНИХ (DATA)
# -----
elif page.startswith("3"):

```

```

st.markdown("## 3 Аналітика вхідних даних")
if DF_HIST is None:
    st.warning(
        "Історичний файл `synthetic_west_ukraine_daily_2019_2023_clean.csv` "
        "не знайдено у каталозі. "
        "Поклади його поруч з `app.py`, щоб побачити аналітику."
    )
else:
    st.success("Історичні дані знайдено.")
    st.caption(
        f"Розмір: {DF_HIST.shape[0]} рядків × {DF_HIST.shape[1]} колонок. "
        "Нижче — кілька базових аналітичних візуалізацій."
    )

# Тайм-серії
st.subheader("Часові ряди ключових показників")
cols_to_plot = [c for c in FEATURES if c in DF_HIST.columns]
if "date" in DF_HIST.columns and cols_to_plot:
    for col in cols_to_plot:
        fig_ts = px.line(
            DF_HIST,
            x="date",
            y=col,
            title=f"Динаміка {col} у часі",
        )
        fig_ts.update_layout(xaxis_title="Дата", yaxis_title=col)
        st.plotly_chart(fig_ts, use_container_width=True)
else:
    st.info("Не вдалося знайти колонку `date` або ознаки для побудови часових рядів.")

# Розподіли
st.subheader("Розподіл змінних")
num_cols = [c for c in DF_HIST.columns if DF_HIST[c].dtype != "O" and c != "date"]
if num_cols:
    col1, col2 = st.columns(2)
    for i, col in enumerate(num_cols[:8]): # не маємо надто багато
        fig_hist = px.histogram(
            DF_HIST,
            x=col,
            nbins=40,
            title=f"Гістограма {col}",
        )
        fig_hist.update_layout(yaxis_title="Кількість")
        (col1 if i % 2 == 0 else col2).plotly_chart(fig_hist, use_container_width=True)

# Кореляційна матриця
st.subheader("Кореляційна матриця")
if num_cols:
    corr = DF_HIST[num_cols].corr()
    fig_corr = px.imshow(
        corr,
        text_auto=".2f",
    )

```

```

        aspect="auto",
        title="Кореляції між змінними",
        color_continuous_scale="RdBu",
        zmin=-1,
        zmax=1,
    )
    st.plotly_chart(fig_corr, use_container_width=True)

```

```

# -----
# 6. СТОРІНКА 4 — АРХІТЕКТУРА СППР
# -----
elif page.startswith("4"):
    st.markdown("## 4Архітектура гібридної СППР EGA-BPNN")
    st.markdown(
        """

```