

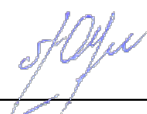
**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ ТАРАСА ШЕВЧЕНКА**

Факультет комп'ютерних наук та кібернетики
Кафедра теоретичної кібернетики

Кваліфікаційна робота
на здобуття ступеня бакалавра
за спеціальністю 122 Комп'ютерні науки
на тему:

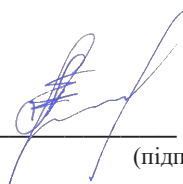
**АНАЛІЗ ЕФЕКТИВНОСТІ ВИКОРИСТАННЯ НЕЙРОННИХ
МЕРЕЖ ДЛЯ КЛАСИФІКАЦІЇ ЗНІМКІВ ДИСТАНЦІЙНОГО
ЗОНДУВАННЯ**

Виконала студентка 4-го курсу
Олена МОСКАЛЕНКО



(підпис)

Науковий керівник:
професор кафедри теоретичної кібернетики
доктор фіз.-мат. наук, професор
Анатолій ПАШКО



(підпис)

Засвідчую, що в цій роботі
немає запозичень з праць інших авторів
без відповідних посилань.

Студент



(підпис)

Роботу розглянуто й допущено до захисту
на засіданні кафедри теоретичної кібернетики
«____» _____ 2022 р.,
протокол № ____
Завідувач кафедри
доктор фіз.-мат. наук, професор
Юрій КРАК

(підпис)

РЕФЕРАТ

Обсяг роботи 75 сторінок, 20 ілюстрацій, 17 таблиць, 72 джерел посилань.

ШТУЧНІ НЕЙРОННІ МЕРЕЖІ, НЕЙРОННІ МЕРЕЖІ ПРЯМОГО ПОШИРЕННЯ, БАГАТОШАРОВИЙ ПЕРСЕПТРОН, ДАНІ ДИСТАНЦІЙНОГО ЗОНДУВАННЯ ЗЕМЛІ, БАГАТОКЛАСОВА КЛАСИФІКАЦІЯ, АЛГОРИТМ ВИПАДКОВОГО ЛІСУ, АЛГОРИТМ ОПОРНИХ ВЕКТОРІВ, МАШИННЕ НАВЧАННЯ.

Об'єктом роботи є методи керованої класифікації, а саме штучні нейронні мережі, методи опорних векторів та випадкового лісу. Предметом роботи є дослідження ефективності зазначених методів у застосуванні до попиксельної класифікації ДДЗ.

Метою роботи є порівняння ефективності застосування штучних нейронних мереж до попиксельної класифікації ДДЗ з іншими сучасними методами керованої класифікації ДДЗ, такими як метод опорних векторів та випадкового лісу.

Методи розроблення: проведення експерименту з класифікації ДДЗ, обчислення метрик якості класифікації та їх порівняльний аналіз. Інструменти розроблення: в якості апаратного засобу дослідження було використано комп'ютер з чотириядерним процесором, а програмним засобом дослідження було вільно поширюване середовище розробки для статистичних обчислень R та низка розширень до нього, зокрема пакетів з реалізацією алгоритмів машинного навчання (caret, nnet, randomForest) та паралельних обчислень (parallel, doParallel).

Результати роботи: виконано огляд методів керованої класифікації, розглянуто існуючі архітектури, принцип роботи та доцільність застосування штучних нейронних мереж для класифікації ДДЗ. Встановлено в ході аналізу та власного експериментального дослідження, що використання штучних нейронних мереж є ефективним та сучасним методом для класифікації ДДЗ.

Порівняння методу штучних нейронних мереж та інших методів керованої класифікації (методу опорних векторів та методу штучного лісу) показало, що за показниками точності цей метод не поступається методу випадкового лісу та істотно перевищує метод опорних векторів.

Також, встановлено, що при застосуванні методу штучних нейронних мереж до класифікації ДДЗ можна спостерігати більші витрати часу, ніж при застосуванні методу випадкового лісу.

Загалом, результати дослідження показують перспективність застосування штучних нейронних мереж до класифікації ДДЗ, особливо враховучи можливість їх налаштування за рахунок підбору гіперпараметрів та широкого спектру вибору різноманітних архітектур, що існують на сьогодні.

ЗМІСТ

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАЧЕННЯ	5
ВСТУП	6
РОЗДІЛ 1 ОГЛЯД ЛІТЕРАТУРИ.....	8
1.1 Дані дистанційного зондування і їх практичне значення.....	8
1.2 Огляд методів та технік класифікації даних дистанційного зондування .	14
1.3 Штучні нейронні мережі та їх застосування в обробці даних дистанційного зондування.....	21
РОЗДІЛ 2 МАТЕРІАЛИ ТА МЕТОДИ ДОСЛІДЖЕННЯ	30
2.1 Модельний регіон і його коротка ландшафтна характеристика.....	30
2.2 Дані дистанційного зондування і їх підготовка	32
2.3 Вибір класів наземного покриття та підготовка навчальної вибірки	33
2.4 Схема експериментального дослідження.....	35
2.5 Засоби проведення та обробки результатів експериментального дослідження. Налаштування гіперпараметрів досліджуваних моделей	39
2.6 Методика порівняння ефективності різних методів керованої класифікації даних дистанційного зондування.....	40
РОЗДІЛ 3 РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ НЕЙРОННИХ МЕРЕЖ ДЛЯ КЛАСИФІКАЦІЇ ДАНИХ ДИСТАНЦІЙНОГО ЗОНДУВАННЯ	42
ВИСНОВКИ	53
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	54
ДОДАТКИ	62
ДОДАТОК А ЛІСТИНГ КОДУ З КЛАСИФІКАЦІЇ ДДЗ НА МОВІ R.....	63
ДОДАТОК Б МАТРИЦІ НЕВІДПОВІДНОСТІ РЕЗУЛЬТАТІВ КЛАСИФІКАЦІЇ ДДЗ	69

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАЧЕННЯ

ГІС	—	Геоінформаційні системи
ДЗЗ	—	Дистанційне зондування Землі
ДДЗ	—	Дані дистанційного зондування
NIR	—	Ближній інфрачервоний
Pan	—	Панхроматичний
SWIR	—	Короткохвильовий інфрачервоний
TIR	—	Тепловий інфрачервоний

ВСТУП

Оцінка сучасного стану об'єкта розробки. Дистанційне зондування Землі є наукоємною технологією отримання даних про земну поверхню віддаленими сенсорними системами встановленими на борту штучних супутників Землі [1]. Отримані з його допомогою ДДЗ — це багате джерело інформації для моніторингу поверхні Землі, наприклад, для аналізу кліматичних змін, контролю забудови, різноманітного застосування у лісівництві, сільському господарстві тощо [2]. Втім, від моменту отримання сенсором супутника первинного супутникового зображення земної поверхні до його практичного застосування воно має пройти довгий і складний шлях цифрової обробки, який включає етап попередньої обробки (геометричної корекції, реєстрації — географічної прив'язки зображення, атмосферної корекції — видалення атмосферних ефектів на зображенні, топографічної корекції — видалення ефектів зумовлених нерівністю поверхні Землі тощо), етап покращення зображення (збільшення контрастності, зміна роздільності), етап зміни зображення шляхом застосування різних фільтрів, етап класифікації зображень тощо [3]. З огляду на великий запит продуктів ДЗЗ, цифрова обробка ДДЗ в наш час стала зрілою міждисциплінарною дослідницькою областю [4].

Актуальність роботи та підстави для її виконання. Серед усіх етапів обробки ДДЗ фахівці відводять чільне місце дослідженню і розробці методів класифікації ДДЗ, оскільки, з одного боку, саме результати класифікації, якими є тематичні мапи, є основою для багатьох екологічних та соціально-економічних застосувань ДДЗ, а з іншого боку, — сам успіх класифікації ДДЗ залежить від вибору методів класифікації [5]. Як наслідок, останніми роками актуальність порівняльних досліджень ефективності тих чи інших методів класифікації ДДЗ лише зростає.

Мета й завдання роботи. Метою роботи є порівняння ефективності

штучних нейронних мереж для класифікації ДДЗ з окремими іншими сучасними методами керованої класифікації ДДЗ (методами випадкового лісу та опорних векторів). Для її досягнення були поставлені наступні завдання:

1. визначити модельний регіон для дослідження;
2. підібрати для визначеного регіону набір ДДЗ;
3. окреслити схему проведення дослідження з порівняння методів керованої класифікації ДДЗ. Підібрати метрики для оцінювання ефективності визначених методів класифікації;
4. за визначеною схемою провести експерименти з класифікації ДДЗ різними методами, проаналізувати їх результати та оцінити ефективність досліджуваних методів керованої класифікації.

Об'єкт, методи й засоби дослідження. Об'єктом дослідження є методи керованої класифікації, а саме штучні нейронні мережі, метод опорних векторів та метод випадкового лісу. Предметом дослідження була ефективність зазначених методів у застосуванні до попиксельної класифікації ДДЗ. Методами дослідження були проведення експерименту з класифікації ДДЗ, обчислення метрик якості класифікації та їх порівняльний аналіз. Апаратним засобом дослідження був комп'ютер з чотириядерним процесором. Програмним засобом дослідження було середовище розробки для статистичних обчислень R [6] та низка розширень до нього, зокрема пакетів з реалізацією алгоритмів машинного навчання (caret [7], nnet [8], randomForest [9]) та паралельних обчислень (parallel, doParallel [10]).

Можливі сфери застосування. Результати дослідження будуть корисними у сфері підготовки мап ландшафтного покриття та землекористування на основі ДДЗ, зокрема для прийняття рішення щодо обґрунтованого вибору алгоритму класифікації супутникових зображень.

Взаємозв'язок з іншими роботами. Експериментальне дослідження виконувалося сумісно з освоєнням низки методів машинного навчання у середовищі R.

РОЗДІЛ 1 ОГЛЯД ЛІТЕРАТУРИ

1.1 Дані дистанційного зондування і їх практичне значення

Дистанційне зондування Землі (ДЗЗ) визначають як метод вимірювання властивостей об'єктів на земній поверхні за допомогою штучних супутників Землі [11]. ДЗЗ може також здійснюватись засобами авіації, але цей спосіб є більш дорогим і не таким масовим, оскільки застосовується в основному при реалізації вузькоспеціалізованих локальних проєктів [12]. Тож у подальшому огляді мова йтиме саме про ДЗЗ за допомогою сенсорів встановлених на борту штучних супутників.

В залежності від джерела сигналу який використовується для дослідження об'єкту виділяють два основних методи ДЗЗ: пасивний та активний. В основі пасивних методів лежить використання сенсорів, які вимірюють відбите від Землі сонячне випромінювання і не потребують використання додаткових джерел випромінювання [13, 14]. Прикладом ДДЗ, які отримані за пасивною технологією, є дані з сенсорів встановлених на супутниках, що виведені на орбіту в рамках програми Landsat (наприклад, Landsat-7, Landsat-8; рис. 1.1А) [15, 16], чи з сенсорів встановлених на супутниках Європейської Космічної Агенції (ESA) Sentinel-2A та Sentinel-2B (рис. 1.1Б) [17, 18]. Активні методи ґрунтуються на опроміненні поверхні Землі власним джерелом випромінювання, що встановлений на борту штучного супутника Землі, та реєстрації сенсором супутника відбитого від поверхні Землі сигналу.

Так як активні сенсори не потребують природного освітлення, вони здатні робити супутникові знімки як вдень, так і вночі. Хмарність та погодні умови теж ніяк не впливають на якість (в активних сенсорах використовується випромінювання мікрохвильового діапазону, яке вільно проходить через хмари)

[13, 19]. Прикладом ДДЗ отриманих за такою технологією є дані з радару із синтезованою апертурою, який встановлений на супутнику Sentinel-1 (рис. 1.1В) [20]. Втім, з використанням цих технологій знімки виходять порівняно низької якості і візуально дають відносно мало інформації, радіолокаційний сигнал взагалі не містить спектральних характеристик.




Рисунок 1.1 — Приклади ДДЗ із зображенням м. Гола Пристань та околиць
 А — ДДЗ Landsat-8, комбінація спектральних каналів — 6-5-4 (далекий інфрачервоний, інфрачервоний та червоний канали), дата отримання 15.VII.2016; Б — ДДЗ Sentinel-2B, комбінація спектральних каналів — 11-8-2 (далекий інфрачервоний, інфрачервоний та синій канали); дата отримання 2.VIII.2021; В — ДДЗ Sentinel-1 у вигляді RGB композиту, в якому в якості червоного каналу використане зображення у VH поляризації, а у якості зеленого — у VV поляризації; синій канал не використовувався; Г — охоплений наведеними прикладами ДДЗ регіон на топографічній мапі).

Перш ніж перейти до власне огляду методів класифікації ДДЗ, чому буде

присвячений наступний підрозділ, варто розглянути деякі базові поняття і характеристики ДДЗ, які наведемо за [3, 21, 22]. Основними технічними характеристиками ДДЗ є роздільна здатність або роздільність — просторова, спектральна, радіометрична і часова. Під просторовою роздільністю розуміють лінійний розмір земної поверхні, який відповідає пікселю — мінімальному елементу зображення ДДЗ. Відповідно цей параметр вимірюється у метрах на піксель. Наприклад, у ДДЗ Landsat-8 просторова роздільність для більшості каналів становить 30 м/піксель, для панхроматичного каналу — 15 м/піксель, а для термальних каналів — 100 м/піксель (табл. 1.1) [16]. Просторова роздільність ДДЗ Sentinel-2 в залежності від каналу становить 10, 20 або 60 м/піксель (табл. 1.2) [17, 18].

У вузькому сенсі спектральна роздільність ДДЗ визначається шириною спектральних зон (каналів) зйомки. Частіше ж під спектральною роздільністю ДДЗ мають на увазі комплексну характеристику, яка включає не тільки ширину, але і конкретний набір спектральних каналів, їх кількість (див., наприклад, характеристики спектральної роздільності ДДЗ Landsat-8 та Sentinel-2А у табл. 1.1–1.2.

Таблиця 1.1 — Характеристики просторової та спектральної роздільності ДДЗ Landsat-8

Канал	Назва каналу	Просторова роздільність, м/піксель	Спектральний діапазон, нм
1	Coastal/Aerosol	30	435–451
2	Blue	30	452–512
3	Green	30	533–590
4	Red	30	636–673
5	NIR	30	851–879
6	SWIR-1	30	1566–1651
7	SWIR-2	30	2107–2294

Канал	Назва каналу	Просторова роздільність, м/піксель	Спектральний діапазон, нм
8	Pan	15	503–676
9	Cirrus	30	1363–1384
10	TIR-1	100	10600–11190
11	TIR-2	100	11500–12510

Таблиця 1.2 — Характеристики просторової та спектральної роздільності ДДЗ Sentinel-2A

Канал	Назва каналу	Просторова роздільність, м/піксель	Спектральний діапазон, нм
1	Aerosol	60	430–457
2	Blue	10	448–545
3	Green	10	537–582
4	Red	10	645–683
5	Red Edge 1	20	694–713
6	Red Edge 2	20	731–749
7	Red Edge 3	20	768–796
8	NIR	10	763–908
8a	Narrow NIR	20	848–883
9	Water vapour	60	932–958
10	SWIR-Cirrus	60	1336–1411
11	SWIR	20	1542–1685
12	SWIR-2	20	2081–2323

Радіометрична роздільність ДДЗ визначається числом градацій яскравості, що реєструються сенсором і фактично визначає точність вимірювання яскравості. Радіометричну роздільність зазвичай позначають у бітах. Ще донедавна радіометрична роздільність більшості ДДЗ становила 8 біт (тобто 256 градацій яскравості; наприклад, ДДЗ Landsat-7 [15]). Сучасні ж ДДЗ

зазвичай мають більшу радіометричну роздільність, наприклад, для ДДЗ Landsat-8 та Sentinel-2 вона становить 12 біт (тобто 4096 градацій яскравості) [16, 18].

Під часовою роздільністю ДДЗ розуміють періодичність, з якою можна отримувати дані для обраної ділянки земної поверхні. Так супутник Landsat-8 одну і ту ж ділянку земної поверхні знімає з періодом 16 днів [16], а супутники Sentinel-2A та Sentinel-2B — з періодичністю 10 днів [18] [18]. Цікаво, що у випадку супутників Sentinel-2A та Sentinel-2B їх орбіти рознесені на 180° . Враховуючи, що на цих супутниках встановлені ідентичні сенсори, частота отримання цілком порівнюваних ДДЗ з цих супутників для обраної ділянки земної поверхні становить раз на 5 днів. Тобто сукупна часова роздільність ДДЗ Sentinel-2A та Sentinel-2B є майже втричі вищою, ніж, наприклад, ДДЗ із супутника Landsat-8.

Чи не найголовнішою характеристикою ДДЗ у сенсі їх класифікації і наступного створення мап земного покриття є спектральна роздільність. Це зумовлено тим, що відбивальна здатність будь-якого матеріалу залежить від довжини хвилі електромагнітного випромінювання, причому ця залежність для різних матеріалів є різною [3, 15]. Відмінності у відбитті добре помітні на графіках спектральних сигнатур (профілів), які є по суті графіками відбивальної здатності як функції від довжини хвилі. Як можна бачити з рис. 1.2, різні типи земного покриття мають унікальні криві спектральних профілів.

З наведеної діаграми добре видно, що, наприклад, для зеленої рослинності характерна низька відбивальна здатність у видимому діапазоні і висока — у ближньому інфрачервоному діапазоні. Для спектрального профілю чистої води характерне помітне збільшення поглинання електромагнітного випромінювання з довжиною хвилі вище 500 нм аж до практично повного його поглинання у діапазоні вище 800 нм. Для спектрального профілю оголеного ґрунтового покриття характерна висока відбивальна здатність як у видимому, так і у короткохвильовому інфрачервоному діапазонах.




Рисунок 1.2 — Спектральні профілі поверхні голого ґрунту, зеленої рослинності та водойм (за [23]). Примітка: сірими вертикальними смугами позначені, відповідно, 1–4, 5 та 7-й канали ДДЗ Landsat-7

В контексті сказаного вище, кожену сцену ДДЗ можна уявити як набір з n вимірювань відбитого від земної поверхні електромагнітного випромінювання кожне з яких відноситься до одного зі спектральних каналів сенсора. Оскільки зображення ДДЗ складається з пікселів (тобто елементарних одиниць зображення), що мають різні значення одиниць відбиття електромагнітного випромінювання від поверхні Землі для різних діапазонів довжин хвиль, кожен піксель окремої сцени можна уявити як точку у n -вимірному гіперпросторі ознак, або ж як n -вимірний вектор X , у якому x_i відповідає i -тому вимірюванню (тобто вимірюванню в i -тій зоні спектру чи каналі сенсора) [24, 25]:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix}$$

Таке уявлення пікселя ДДЗ дає можливість застосовувати потужний апарат векторного чи матричного аналізу для розробки класифікаційних процедур [25].

ДДЗ має надзвичайно широке застосування у практичній діяльності людини [26], зокрема для моніторингу і оцінки стану навколишнього середовища (спостереження за станом озонового шару, динамікою лісового покриву, кліматичними змінами тощо) [27], у сільському господарстві (аналіз стану сільськогосподарських культур, прогнозування врожаю, дослідження ерозії ґрунтів тощо) [28], для добування корисних копалин, у метеорології (моніторинг переміщення атмосферних фронтів, дослідження динаміки температури повітря та поверхні океану, посух, прогнозування погоди тощо) [29, 30], у картографії [31]. Також ДДЗ використовують у гуманітарній сфері, наприклад, у археологічних дослідженнях [32], засобах масової інформації (як джерело ілюстративних даних, для аналізу) [11].

1.2 Огляд методів та технік класифікації даних дистанційного зондування

Класифікація ДДЗ і наступне створення тематичних мап земного покриву є чи не найбільш поширеним загальним застосуванням ДДЗ, оскільки результати класифікації є основою управління в соціо-економічній сфері, використання природних ресурсів, збереження довкілля тощо [4, 5]. Сутність класифікації ДДЗ полягає в тому, щоб на основі спектральної інформації із різних каналів проаналізувати кожен піксель і віднести його до того чи іншого класу земельного покриву [21, 33]. Як зазначають А.М. Чандра та С.К. Гош [33], коли йде мова про класифікацію ДДЗ, слід розрізняти інформаційні і спектральні класи. Інформаційні класи — це ті об'єкти, які слід розпізнати на знімку, наприклад, різні типи рослинного покриву, певні геологічні структури, типи гірських порід тощо. Що ж до спектрального класу, то під ним розуміють

групу пікселів, яка має приблизно однаковий рівень яскравості у деякому спектральному діапазоні. Основною метою класифікації ДДЗ є суміщення спектральних класів з інформаційними. А.М. Чандра та С.К. Гош наголошують, що взаємно однозначна відповідність між цими типами класів спостерігається вкрай рідко; частіше одному інформаційному класу можуть відповідати два чи більше спектральних класи [33]. І справді, якщо взяти, наприклад, природні водойми, то цьому інформаційному класу влітку можуть відповідати різні спектральні класи в залежності від їх тропності і, відповідно, від різної концентрації *a*-хлорофілу (на цьому, до речі, ґрунтується метод непрямої оцінки за допомогою ДДЗ ступеню забруднення водойм біогенними елементами [34]). Аналогічно, інформаційному класу «рослинність» будуть відповідати різні спектральні класи, в залежності від того, чи це степ, хвойний чи листяний ліс тощо. Ба більше, здоровий однопородний ліс матиме відмінний спектральний клас від такого ж лісу, але ураженого шкідниками, що використовується у практиці моніторингу пошкоджень лісових насаджень комахами [35].

Завдання класифікації ДДЗ відноситься до сфери теорії розпізнавання образів, яка бурхливо розвивається останні десятиліття [36]. Відповідно, для класифікації ДДЗ наразі послуговуються величезною кількістю її методів, огляд і типологія яких у контексті застосування саме для ДДЗ міститься у роботі Д. Лю та К. Венга [5].

Всі методи класифікації ДДЗ діляться на дві групи — методи некерованої класифікації та методи керованої класифікації [3].

Методи некерованої класифікації (або кластеризації) засновані на статистиці розподілу каналів ДДЗ і не використовують жодної апріорної інформації стосовно відповідності пікселів ДДЗ тим чи іншим класам земного покриву [11, 37]. Ці методи відносять той чи інший піксель зображення ДДЗ до того чи іншого кластеру шляхом вимірювання подібності між пікселями в процесі виконання ітеративного алгоритму. Після вимірювання подібності між

пікселями алгоритм об'єднує окремі пікселі в групи [21]. Тобто, спочатку за тим чи іншим алгоритмом на основі тільки тієї інформації, яка представлена у даних, виділяються спектральні класи і лише потім оператор намагається зіставити їх з реальними просторовими об'єктами [33]. Групування даних на першому етапі відбувається шляхом кластерного аналізу, при цьому оператор зазвичай вказує, на яку кількість груп (кластерів) можна розділити весь набір вихідних даних. З огляду на це, некерована класифікація не є повністю автоматичною [33].

Існує багато методів некерованої класифікації які, до того ж, можуть використовувати різні міри відстані (у застосуванні до ДДЗ найчастіше застосовують Евклідову чи Мангеттенську відстані [25]). Втім одним із найпопулярніших у застосунку до некерованої класифікації ДДЗ є метод К-середніх, який імплементований у багатьох десктопних ГІС, наприклад QGIS [38], SAGA GIS [39], GRASS GIS [40] тощо.

Методи керованої класифікації засновані на використанні еталонних областей, які обираються оператором на сцені ДДЗ у відповідності з їх належністю до того чи іншого інформаційного класу [33]. При їх виборі оператор спирається на свої знання території і розміщених на ній об'єктів, які базуються на польових дослідженнях області інтересу, вивченні аерофотографій, мап тощо [3]. Значення пікселів еталонних областей у різних спектральних діапазонах використовується в якості навчальних вибірок для налаштування розпізнавання. В результаті, для кожної області визначається еталон — сукупність спектральних ознак, які задають один клас пікселів. В процесі класифікації, на підставі послідовного порівняння з усіма створеними еталонами, кожен піксель сцени ДДЗ відноситься до того чи іншого класу. Таким чином, при керованій класифікації спочатку визначаються інформаційні класи, а потім відповідні їм спектральні [33].

До недавня одними із найбільш часто використовуваних алгоритмів керованої класифікації для обробки ДДЗ були алгоритми мінімальної відстані,

паралелепіеда, найбільшої правдоподібності [33]. В останні два десятиліття у сфері класифікації ДДЗ все більшого поширення набувають більш сучасні алгоритми, наприклад, метод опорних векторів [41, 42] та метод випадкового лісу [43].

Керована класифікація ДДЗ — це багатоетапний процес, який, незалежно від обраного методу, складається з наступних основних кроків [25, 33]:

1. вибір підходящого класифікатора;
2. підготовка тренувальної вибірки;
3. вибір спектральних ознак;
4. використання тренувальних даних для навчання моделі;
5. використання тренуваної моделі для розподілу пікселів по інформаційним класам;
6. оцінка точності класифікації.

На етапі вибору класифікатора, у відповідності до поставленої мети, оператор обирає набір інформаційних класів, для яких він формуватиме на сцені ДДЗ еталонні ділянки для тренувальної вибірки. Це можуть бути якісь вузькоспеціалізовані класифікатори, наприклад по сільськогосподарським культурам чи породам деревостанів тощо. Існують також стандартні класифікатори, які від початку розроблені таким чином, щоб їх легко можна було застосовувати у класифікації ДДЗ [33]. Одним із найбільш широко вживаних таких класифікаторів є створений Європейською комісією в рамках «Програми з координації інформації про навколишнє середовище» класифікатор CORINE [44–47]. Це трирівневий ієрархічний класифікатор, у якому найбільш узагальнений перший рівень включає 5 груп земель (штучні поверхні, сільськогосподарські землі, ліси та напівприродні території, болота, водні об'єкти), другий рівень – 15 категорій, третій — найбільш детальний — 44 категорії земель [44, 45].

Підготовка тренувальної вибірки є дуже відповідальним етапом від якого залежить успіх класифікації ДДЗ [33, 48, 49]. Він передбачає вибір розміру

тренувальної вибірки, вибір області, де вона буде здійснюватися, та власне вибір протоколу формування вибірки [50]. Відносно розміру тренувальної вибірки існує рекомендація, що для класифікації сцени ДДЗ із n спектральних каналів слід брати для кожного спектрального класу щонайменше $10n$ пікселів для тренувальної вибірки, а краще близько $100n$ пікселів [25]. Підходи до вибору області, де буде здійснюватися відбір пікселів тренувальної вибірки та власне способу (протоколу) цього відбору можуть бути різними, однак вони мають задовольняти низці вимог, серед яких С. В. Стегман [51] називає наступні: випадковість відбору, практичність (формування вибірки має бути здійсненним за розумний проміжок часу), просторова збалансованість вибірки, низька варіативність значень пікселів в межах одного класу.

В ході формування навчальної вибірки зазвичай йде підготовка ще одного етапу класифікації — оцінки її точності. Як відомо, одним із ключових моментів створення моделей машинного навчання полягає в тому, що оцінка моделей має здійснюватися на окремому тестовому наборі даних, який не використовувався для навчання моделі. Тому у протоколі формування еталонної вибірки слід передбачити її поділ на навчальну і тестову [33, 49].

Вибір спектральних ознак полягає у відборі спектральних каналів ДДЗ (або похідних від них метрик), які будуть задіяні у класифікації [33]. Необхідність цього етапу зумовлена тим, що різні комбінації спектральних каналів мають різну ефективність для виділення тих чи інших інформаційних класів. Крім того цей етап покликаний вирішити проблему надлишковості ознак — мультиколінеарності, яка, як відомо, в деяких алгоритмах машинного навчання може призводити до помітного погіршення якості класифікації [52]. Мультиколінеарності у наборі спектральних каналів ДДЗ позбавляються або видаленням частини сильно корельованих ознак (тобто ознак з коефіцієнтом кореляції між якими по модулю більший деякого порогового значення, яке у сфері класифікації ДДЗ зазвичай приймають рівним 0.7 [53]). Також з цією метою можна використовувати методи зниження розмірності, серед яких чи не

найбільш широкого вжитку набув аналіз головних компонент [54]. Зниження розмірності спектрального простору ознак тим чи іншим способом особливо актуальне для класифікації гіперспектральних ДДЗ, які можуть налічувати до декількох десятків спектральних каналів. У цьому випадку зниженням розмірності запобігають не тільки мультиколінеарності, а ще й ефекту Х'юза, або так званого «прокляття розмірності» [25].

Для класифікації ДДЗ, окрім власне спектральних каналів, часто застосовують похідні метрики, найперше, різноманітні спектральні індекси під якими розуміють прості параметричні комбінації окремих спектральних каналів, що мають підвищену чутливість до тих чи інших біофізичних явищ, як то вміст хлорофілу, води тощо [4]. Існує величезна кількість спектральних індексів [55], втім найпопулярнішим із них є нормалізований різницевий вегетаційний індекс (NDVI) [37]. Він обчислюється за формулою (1.1).

$$NDVI = (NIR - Red) / (NIR + Red) \quad (1.1)$$

В основі цього індексу лежить той факт, що різниця між видимими червоним (Red) та ближнім інфрачервоним (NIR) діапазонами для ділянок покритих зеленою рослинністю буде великою через низьке поглинання хлорофілом випромінювання у ближньому інфрачервоному діапазоні і сильне поглинання випромінювання у видимому червоному діапазоні [4]. Як наслідок, NDVI для земельних ділянок вкритих зеленою рослинністю набуває значень більше 0,2; для оголеного ґрунту значення NDVI становить 0,1–0,2; нарешті для водних поверхонь, які сильно поглинають випромінювання у ближньому інфрачервоному діапазоні, цей індекс набуває значень менше 0,1. Таким чином, в ході класифікації ДДЗ ті чи інші спектральні індекси дають можливість надійніше відрізнити різні типи земельного покриття. Інколи для кращого розрізнення різних типів земельного покриття в ході класифікації, ДДЗ та похідні від них метрики можуть поєднуватися із шарами допоміжних даних

іншого походження, як то різні геоморфологічні змінні-похідні від цифрової моделі рельєфу (висота, нахил, експозиція), категорійні мапи землекористування, типів ґрунтів тощо [36].

Після тренування класифікаційної моделі та власне класифікації ДДЗ останнім етапом є оцінка точності класифікації. Однією з найпоширеніших форм оцінки точності керованої класифікації ДДЗ є матриця невідповідностей [4, 33, 37, 56]. Приклад матриці невідповідностей наведений на рис. 1.3 Вона складається з m стовпчиків та m рядків, де m — кількість інформаційних класів. Рядки матриці — класи, виділені в ході керованої класифікації сцени ДДЗ, а стовпці — це істинні класи. Відповідно, у комірках по основній діагоналі вказано число правильно класифікованих пікселів тестової вибірки. У комірках поза основною діагоналлю вказано, відповідно, кількості неправильно класифікованих пікселів. Наприклад, з матриці наведеної на рис. 1.3 можна встановити, що із 75 пікселів тестової вибірки, які відносяться до класу «Листяний ліс» (Deciduous), неправильно було класифіковано 10 пікселів, з яких 6 було помилково віднесено до класу «Хвойний ліс» (Conifer), а 4 пікселі — до класу «Чагарники» (Shrub). Крім того, зі 115 пікселів, які в ході класифікації були віднесено до класу «Листяний ліс», помилково до цього класу було віднесено 50 пікселів з інших класів, у т.ч. 4 пікселі, які належать до класу «Хвойний ліс», 22 пікселі з класу «Сільгоспугіддя» (Agriculture) та 24 пікселі з класу «Чагарники».

На основі матриці невідповідностей обчислюють низку показників, що характеризують точність класифікації, наприклад, загальну точність (overall accuracy), точність користувача (user's accuracy) та точність виробника (producer's accuracy) [56, 57].

Загальна точність обчислюється як відношення суми правильно класифікованих пікселів до загальної суми пікселів тестової вибірки. Точність користувача обчислюється як відношення кількості правильно віднесених в ході класифікації пікселів до певного класу до загальної кількості пікселів, які

були віднесені в ході класифікації до цього класу. Точність виробника обчислюється як відношення кількості правильно віднесених в ході класифікації пікселів до певного класу до загальної кількості пікселів цього класу у тестовій вибірці.

Слід також наголосити, що загальна точність може бути оманливою оцінкою точності класифікації ДДЗ, оскільки цілком ймовірна ситуація, коли той чи інший піксель в ході класифікації був віднесений до правильного класу випадково [4]. Для того щоб врахувати можливість випадкових збігів і оцінити істинну узгодженість між результатом класифікації та еталонною вибіркою, використовують коефіцієнт каппа Коена [33].

		Reference Data				Row	<u>Land Cover Categories</u>
		D	C	AG	SB	Total	
Classified Data	D	65	4	22	24	115	D = deciduous C = conifer AG = agriculture SB = shrub
	C	6	81	5	8	100	
	AG	0	11	85	19	115	
	SB	4	7	3	90	104	
Column Total		75	103	115	141	434	OVERALL ACCURACY = (65 + 81 + 85 + 90)/434 = 321/434 = 74%

PRODUCER'S ACCURACY

$$D = 65/75 = 87\%$$

$$C = 81/103 = 79\%$$

$$AG = 85/115 = 74\%$$

$$SB = 90/141 = 64\%$$

USER'S ACCURACY

$$D = 65/115 = 57\%$$

$$C = 81/100 = 81\%$$

$$AG = 85/115 = 74\%$$

$$SB = 90/104 = 87\%$$

Рисунок 1.3 — Приклад матриці невідповідностей (за [56])

1.3 Штучні нейронні мережі та їх застосування в обробці даних дистанційного зондування

Розглядаючи сцену ДДЗ, людина здатна досить точно визначити до якого інформаційного класу відноситься та чи інша ділянка регіону інтересу, особливо в разі належного застосування спектральних індексів, що покращує її візуальну інтерпретацію. Спільна робота людського ока та мозку є неперевершеною «системою» по класифікації об'єктів на зображенні та самих зображень. Тож, повторення такої ефективності шляхом спроби зімітувати наявний механізм на противагу застосування статистичних методів є логічною ідеєю, яка розвинулася у створення математичної програмної моделі, а саме штучної нейронної мережі, побудованої за принципом функціонування людського мозку [58]. Проте, з розвитком нейронних мереж, не дивлячись на першочергове джерело натхнення саме біологічною будовою мозку, надалі не ставили за мету відтворення точних біологічних структур та процесів, а замість цього розроблялася своя власна статистична та обчислювальна логіка [59].

Типова нейронна мережа складається із сукупності зв'язних штучних нейронів, аналогічно до нейронів у головному мозку людини чи тварини. Зв'язки між цими нейронами, знову ж таки, аналогічно до синапсів, передають сигнали. Штучний нейрон здатний обробляти сигнали що надійшли до нього на вхід і в разі необхідності передавати його далі, тим нейронам які з ним пов'язані [33, 58]. Власне кажучи, штучний нейрон є простим автоматом, що перетворює вхідний сигнал на вихідний.

Якщо говорити більш математично, штучний нейрон представляє собою функцію аргументами якої є вектор x вхідних сигналів від попередніх нейронів та ваг відповідних синапсів w . Визначається ця функція так [60]:

$$f(x_i, w_i) = \phi\left(\sum_i x_i w_i\right)$$

Кожне значення ваг перемножується з відповідним вхідним сигналом, а

результат цієї операції подається на вхід функції активації, яка в даному випадку зображена грецькою літерою ϕ . Функція активації може бути різною, як от лінійна, логістична, гіперболічна, чи експоненційна. Втім, завдання в ній одне і воно полягає у перетворенні вхідного сигналу на вихідний, а саме встановлені проміжку, в якому має знаходитися обчислений нейроном вихід. Зазвичай, в результаті застосування цієї функції вихідне значення стає дійсним числом, яке лежить у проміжку $(0, 1)$ або ж $(-1, 1)$ [60]. Таким чином формується єдине вихідне значення штучного нейрону (рис. 1.4).




Рисунок 1.4 — Зображення моделі базового штучного нейрону, який отримує на вхід декілька вхідних сигналів з відповідними вагами зв'язків, обробляє ці дані шляхом застосування функції активації до лінійної комбінації аргументів що прийшли на вхід нейрону та сформувавши таким чином вихідний сигнал x_i , передає його далі, на вхід іншим нейронам. Примітка: така математична модель нейрону була запропонована МакКалоком та Пітсом ще в 1943 році [59]

Зв'язні штучні нейрони, в свою чергу, поєднуються у шари формуючи повноцінну штучну нейронну мережу. В залежності від того, якому шару

належить той чи інший нейрон, розрізняють декілька типів нейронів, і хоч здебільшого їх принцип роботи досить схожий на описану вище модель, поведінка та роль цих нейронів у мережі є різною. Так, нейрони вхідного шару лише приймають дані на вхід з програми та не мають функції активації. Вхідними даними нейронної мережі, зазвичай, виступає вектор компонентами якого є дійсні числа. Розмірність цього вектора визначає кількість нейронів вхідного шару мережі. Натомість, нейрони вихідного шару надають вихідні оброблені дані назад до програми [60]. В деяких типах нейронних мереж ці шари не є окремими і нейрони можуть виконувати роль як вхідних так і вихідних одночасно. Прикладом такої мережі є мережа Гопфілда [61].

Нейрони прихованого шару приймають на вхід сигнали від вхідних нейронів, або ж від інших прихованих нейронів. Саме вони здійснюють основний процес обробки сигналів та, безпосередньо, навчання нейронної мережі.

Навчанням нейронної мережі є процес підбору значень ваг. Він здійснюється шляхом подачі тренувальних даних на вхід мережі та подальшим порівнянням очікуваного виходу з реальним. Якщо між ними є різниця, то ваги зв'язків між нейронами які складають штучну нейронну мережу, мають бути скоригованими [3, 60].

На рис. 1.4 можна бачити додаткове коло (позначене як x_0). Це нейрон, що називається зсувом. Він присутній лише у прихованих та вихідних шарах. Зсув, зазвичай, додають до нейронної мережі, щоб покращити результативність її навчання шляхом збільшення можливості «руху» моделі, тобто зсуву функції активації по горизонтальній вісі. Значення сигналу такого нейрону завжди дорівнює 1 [60].

Окрім різних типів нейронів, які об'єднуються у певні шари, також, відрізняються способи розповсюдження сигналу між шарами та нейронами в складі цих шарів. За таким принципом існують два підходи до формування мереж, а саме, мережі прямого поширення та рекурентні мережі. Для

нейронних мереж прямого поширення характерним є розповсюдження сигналу лише в одному напрямку [59], в той час як у рекурентних мережах є зворотні зв'язки, які забезпечують можливість мережі передавати вже певним чином оброблені вихідні сигнали знову на вхід нейронів. Це дозволяє створити динамічну систему, яка може досягати стабільного стану, демонструвати коливання, або ж, проявляти хаотичну поведінку. Більше того, відгук мережі на задані вхідні дані залежить від початкового стану мережі, який в свою чергу залежить від попередніх вхідних даних. Тобто, рекурентні мережі здатні підтримувати свою внутрішню пам'ять. Завдячуючи саме цій здатності, мережі такого типу найбільше підходять до задач, в яких є необхідність запам'ятовувати важливі дані та передбачати, що буде далі. Саме з цієї причини, найкраще обирати таку мережу для роботи з послідовними даними [59, 61]. Прикладом таких даних може бути часовий ряд, мовлення, тексти, відео тощо.

Мережі прямого поширення, на відміну від рекурентних, не мають жодних зворотних зв'язків та циклів. Як вже зазначали вище, сигнал йде чітко в одному напрямку: від нейронів вхідного шару через приховані шари до вихідного, формуючи таким чином ациклічний спрямований граф [59]. Схематично нейронну мережу такого типу можна зобразити як, показано на рис. 1.5.

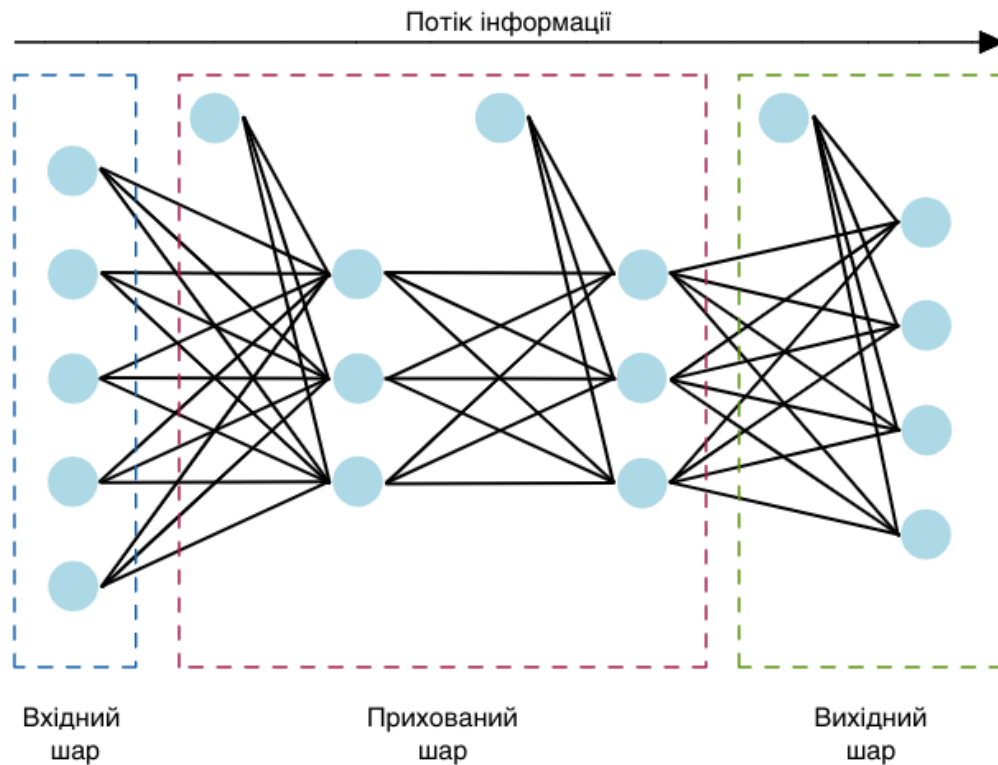


Рисунок 1.5 — Схематичне зображення моделі нейронної мережі прямого поширення з вхідним шаром, який складається з п'ятих нейронів, двома прихованими повнозв'язними шарами по три нейрони з додатковими двома нейронами зсуву та вихідним шаром, що включає 4 вихідні нейрони та 1 нейрон зсуву.

Нейронні мережі прямого поширення зазвичай використовують саме у задачах розпізнавання образів [62]. Вони ідеально підходять для моделювання залежності між набором предикторів або вхідних змінних та одним або декількома відгуками або ж еталонними виходами. Тобто, навчання мережі прямого поширення здебільшого стосуються навчання з учителем, особливо у випадках, коли дані, на яких треба навчитися, не є ні послідовними, ні тими, що залежать від часу. Такі мережі обчислюють функцію f на вхідних даних x фіксованого розміру, так що $f(x) \approx y$ для навчання пар (x, y) . Іншими словами, мережі прямого поширення підходять для будь-якої задачі функціонального відображення, де треба знати як ряд вхідних змінних впливає на вихідну змінну [63].

Таким чином, і в задачах класифікації земного покриття найбільше

застосовуються саме нейронні мережі прямого поширення та їх модифікації [62, 64]. Застосування нейронних мереж у такій задачі дозволяє, на відміну від статистичних методів, приймати на вхід будь-які дані не залежно від того чи вони відповідають якомусь закону розподілу чи ні [3]. Тобто, нейронні мережі належать до родини непараметричних методів класифікації, які, як показують численні дослідження, є більш ефективними у порівнянні з параметричними, тобто залежними від статистичних припущень, методами класифікації [5].

Також, слід наголосити, що класифікація ДДЗ є лише, загальним терміном. Зараз розрізняють три паралельних гілки класифікації ДДЗ: попиксельна класифікація, об'єктна та класифікація самої сцени загалом [65]. Таке розділення, перш за все, пов'язане з поступовим технічним вдосконаленням ДЗЗ та збільшенням просторової роздільності ДДЗ. Попиксельна класифікація є найдавнішою, оскільки не потребує високої просторової роздільності. Наприклад, як вже зазначали у розділі 1.1, знімки з супутника Sentinel з просторовою роздільністю 10 та 20 м/піксель і, такий об'єкт як будинок на цих знімках матиме розмір, приблизно, в один піксель.

В залежності від того, про яку саме класифікацію ДДЗ йде мова, обирають належну архітектуру нейронної мережі. Так, наприклад, для об'єктної класифікації найбільш придатною є згорткова нейронна мережа. Остання відноситься до все тих же мереж прямого поширення, проте на відміну від розглянутої вище їх класичної архітектури, згорткова мережа, окрім повнозв'язних шарів, має додатково згортковий та агрегувальний шари [60]. За рахунок цих шарів, що передують повнозв'язному, згорткова мережа здатна виділяти особливості зображення та зменшувати його розмірність без втрати важливих характеристик. Це дозволяє боротися з ефектом «прокляття розмірності», який є майже неминучим при застосуванні мереж прямого поширення з повністю повнозв'язними нейронами для класифікації зображень високої роздільності [66]. Недоліком згорткової мережі є те, що для її навчання необхідний великий набір тренувальних даних, зібрати достатній обсяг яких, у

випадку класифікації ДДЗ, буває досить проблематично [60].

Натомість, коли мова йде про попиксельну класифікацію, де кожному пікселю присвоюється деякий інформаційний клас, зазвичай, класичної мережі прямого поширення з лише повнозв'язними шарами (її ще називають багатошаровим персептроном) виявляється достатньо для ефективної класифікації земного покриву [3].

У випадку застосування такої нейронної мережі до ДДЗ вхідний шар містить елементи, кількість яких дорівнює числу спектральних діапазонів, що використовуються для класифікації, а кількість класів визначає число елементів вихідного шару [33]. Натомість, розмірність прихованого шару є не такою очевидною і визначення оптимальної кількості елементів шару є важливим для ефективного навчання мережі. Так, занадто мала кількість може призвести до невірної класифікації, а занадто велика до втрати невипраданно великої кількості часу на навчання. До того ж, якщо обрати надто багато елементів у прихованому шарі, може виникнути проблема з перенавчанням [64]. Існує багато евристик покликаних вирішувати цю проблему, проте жодна з них не є універсальною. Загалом, оптимальну кількість обирають методом спроб та помилок та із застосуванням емпіричного методу, який каже, що число нейронів прихованого шару має бути в два рази більшим за кількість вхідних нейронів, в якості відправної точки [3].

Також, крім кількості нейронів у прихованому шарі, часто постає питання оптимальної кількості самих прихованих шарів. Менше з тим, як правило, вважається, що одного шару достатньо для вирішення більшості проблем пов'язаних із класифікацією, оскільки багатошаровий персептрон з одним прихованим шаром може наблизитися до будь-якої неперервної функції [64]. Звичайно, є випадки коли два шари можуть допомогти вирішити задачу більш ефективно, проте в аналізі ДДЗ зазвичай використовується саме один прихований шар з різною кількістю елементів в ньому [3].

Слід також зазначити, що окрім класифікації є ще низка важливих задач

дистанційного зондування, які можуть бути вирішені за допомогою штучних нейронних мереж, а саме: розділення та відновлення біофізичних параметрів покриття для різноманітних моделей екосистем, виявлення змін, злиття мультиспектральних даних, розпізнавання об'єктів, прогнозування тощо [62, 64].

Загалом, ріст популярності застосування саме штучних нейронних мереж до таких задач легко помітити провівши аналіз кількості публікацій за ключовими словами «Artificial neural networks» та «remote sensing» в сукупності. Так, графік зображений на рис. 1.6 наочно свідчить про експоненційне зростання кількості наукових статей в цій області. Це однозначно говорить про рівень зацікавленості у використанні нейронних мереж при роботі з даними дистанційного зондування, особливо за останні п'ять років.




Рисунок 1.6 — Динаміка кількості публікацій проіндексованих у науковій пошуковій системі ScienceDirect за роками за запитом «"Artificial neural networks" and "remote sensing"»

РОЗДІЛ 2 МАТЕРІАЛИ ТА МЕТОДИ ДОСЛІДЖЕННЯ

2.1 Модельний регіон і його коротка ландшафтна характеристика

Для експериментальної частини роботи був обраний модельний регіон у Скадовському районі Херсонської області з орієнтовною площею близько 780 км² та в межах як показано на рис. 2.1. Основними причинами вибору саме цього регіону були досить висока його ландшафтна різноманітність і, що найголовніше, добре особисте знання цієї місцевості, що має ключове значення для підготовки еталонної навчальної вибірки.

Модельний регіон входить до Нижньдніпровської терасово-дельтової рівнини [67]. Його ландшафти представлені заплавою Дніпра, піщаними аренами (Збур'ївською та Олешківською), а також сільськогосподарськими угіддями (ріллею). Також в межах регіону знаходиться низка населених пунктів, з яких найбільшими є м. Гола Пристань та селища Нова Збур'ївка, Стара Збур'ївка, Чулаківка та Гладківка.

У заплаві Дніпра, з точки зору підготовки еталонної навчальної вибірки, добре виділяються водні поверхні, представлені у модельному регіоні верхів'ям Дніпровського лиману та численними руслами, протоками і озерами дельти Дніпра. Між водними поверхнями міститься велика кількість островів, що переважно вкриті суцільними очеретяними заростями. Крім того, в цій частині регіону трапляються ліси з вільхи (*Alnus glutinosa*).

Значна частка піщаних арен зайнята лісовими насадженнями, серед яких істотно переважають соснові ліси. Суттєво меншу площу займають насадження робінії (*Robinia pseudoacacia*). Як і у заплаві, тут трапляються вільхові ліси, проте їх площа в цій частині регіону мала. На безлісій частині піщаних арен переважає піщаний степ, що може мати різний ступінь розвитку степової рослинності (щільний, середньої щільності та розріджений). Трапляються також ділянки аренних пісків, які взагалі позбавлені рослинності.

Сільськогосподарські угіддя представлені полями, на яких вирощуються різноманітні зернові, овочеві та бахчеві культури.

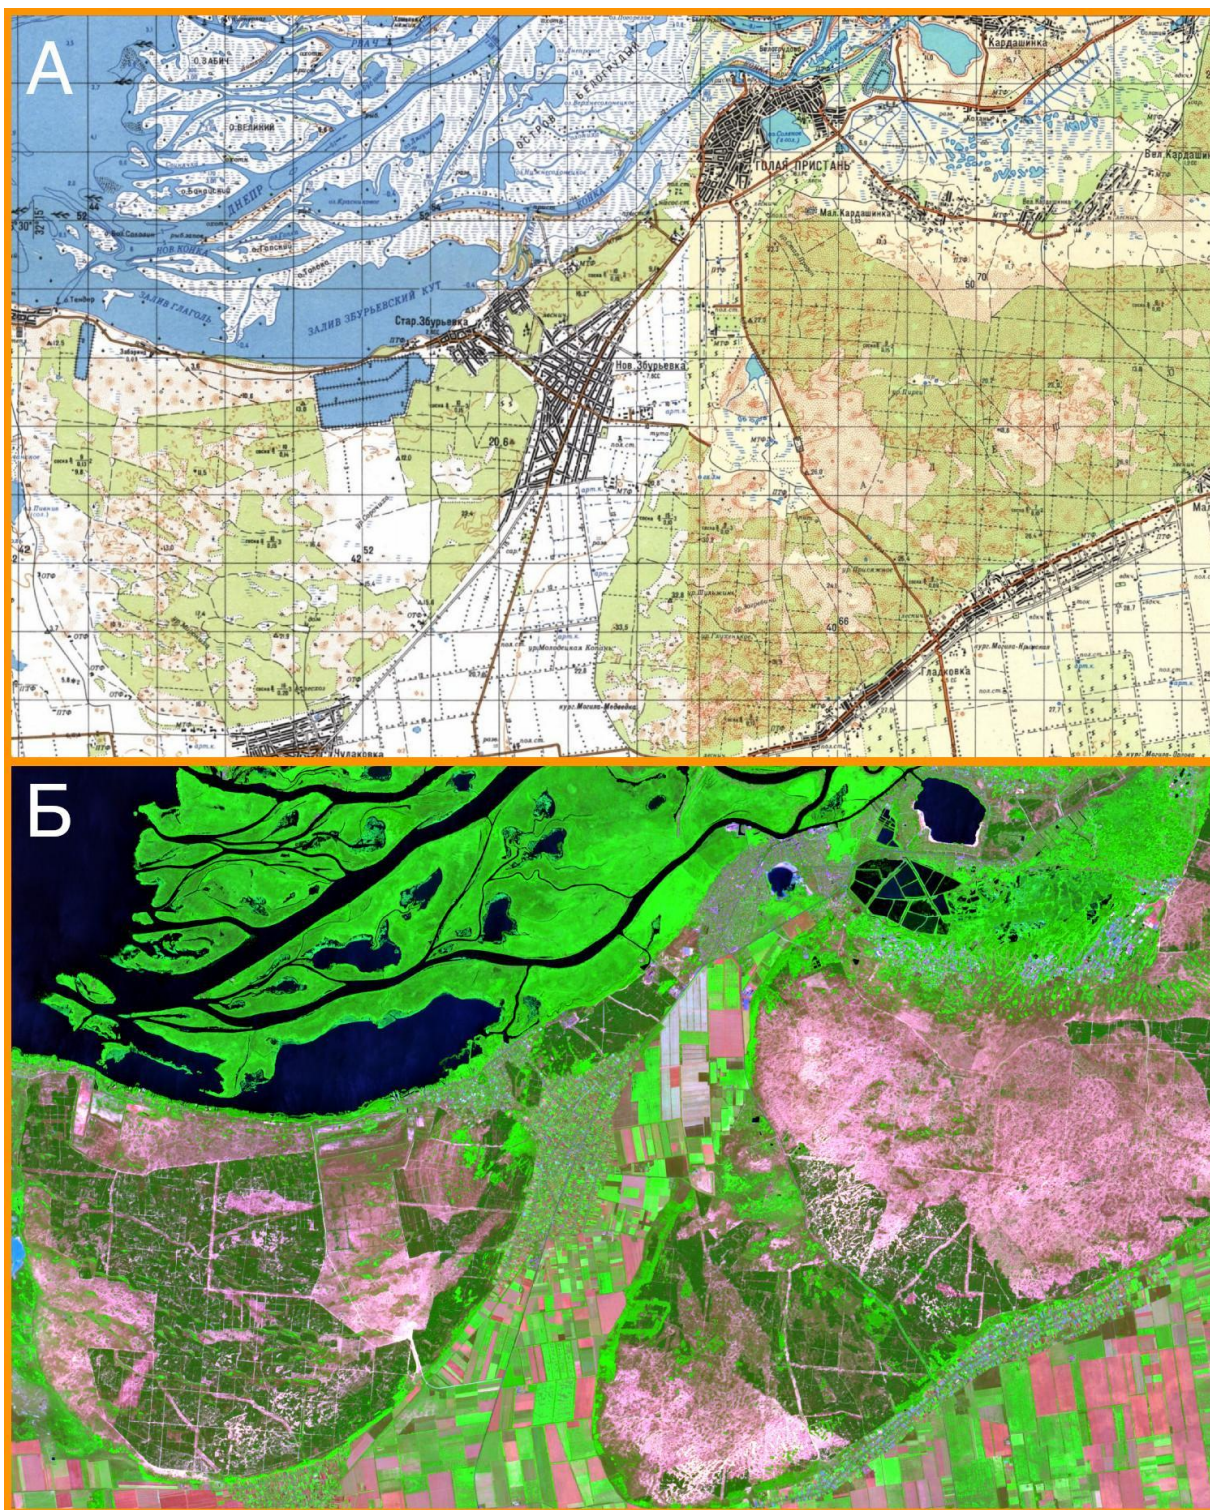


Рисунок 2.1 — Обраний модельний регіон на топографічній мапі (А) та супутниковому знімку Sentinel-2 від 2 серпня 2021 р. (комбінація спектральних каналів — 12-8-2) (Б)

2.2 Дані дистанційного зондування і їх підготовка

Для експериментальної частини роботи були обрані 3 безхмарні сцени ДДЗ із супутників Sentinel-2В рівня обробки L2A (2 сцени — за 4 травня та за 2 серпня 2021 р.) і Sentinel-2А (за 26 жовтня 2021 р.), які були завантажені із сайту програми Copernicus Європейської Космічної Агенції [68]. Вибір безхмарних сцен і саме рівня L2A дозволив провести експериментальну частину роботи з мінімальною кількістю операцій з попередньої підготовки ДДЗ, оскільки ці дані не потребували маскуванню хмарного покриття та атмосферної корекції (дані рівня L2A вже є атмосферно скоригованими [18]). З ДДЗ Sentinel-2 для класифікації використовували десять спектральних каналів, а саме канали 2–8, 8А, 11 та 12.

Обрізку обраних сцен ДДЗ по межах модельного регіону здійснили у ГІС SAGA GIS [39]. Роботу з класифікації проводили з даними у роздільності 10 м/піксель. Як вже згадували вище (див. розділ 1, табл. 1.2), частина з використаних нами спектральних каналів має роздільність 20 м/піксель, тому перед подальшою роботою з ними їх роздільність привели до 10 м/піксель бікубічною інтерполяцією, яку виконали у SAGA GIS.

До даних, які подаються на вхід нейронних мереж, висуваються певні вимоги: вони повинні бути векторизовані та нормалізовані [69]. Дані дистанційного зондування є за визначенням векторизованими, тобто у цьому сенсі ніякої підготовки вони не потребували. Нормалізацію, тобто приведення кожної спектральної ознаки до форми із середнім значенням 0 та стандартним відхиленням 1, виконували в R за допомогою функції `scale()` із пакету `raster`.

Крім того, як вже згадували вище, багато методів керованої класифікації, у т.ч. і штучні нейронні мережі, є чутливими до мультиколінеарності. Аналіз обраних для дослідження сцен ДДЗ показав, що їх спектральні канали здебільшого сильно зкорельовані (рис. 2.2). Для позбавлення мультиколінеарності застосовували аналіз головних компонент і подальші

класифікаційні процедури здійснювали вже над головними компонентами.

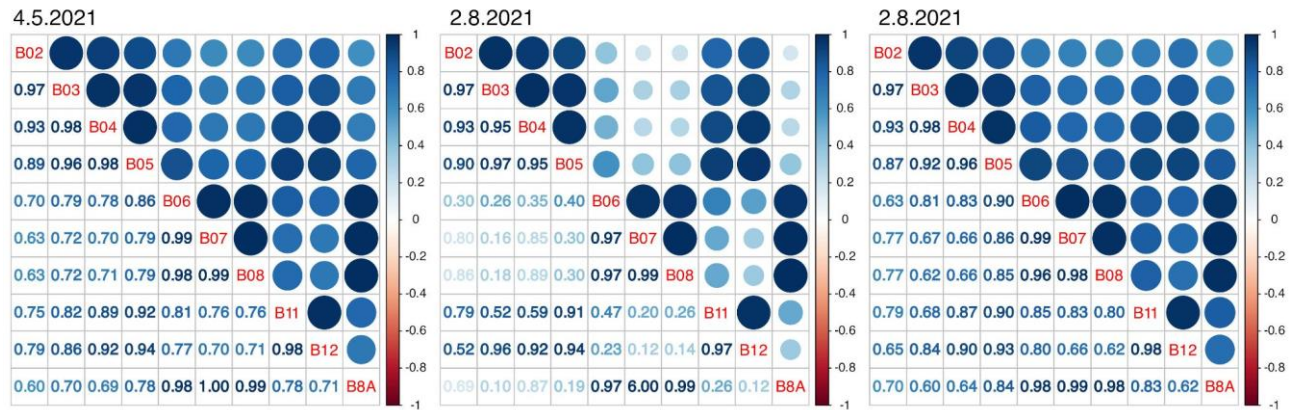


Рисунок 2.2 — Кореляція між спектральними каналами обраних сцен ДДЗ

2.3 Вибір класів наземного покриття та підготовка навчальної вибірки

Для вибору класів наземного покриття, на які передбачалося класифікувати ДДЗ в ході виконання експериментальної частини роботи, у середовищі десктопної ГІС QGIS детально вивчали RGB-композиції обраних сцен ДДЗ. При цьому для огляду використовували комбінації каналів 12-8-2 та 8-4-2. Крім того, для уточнення окремих класів земельного покриття, за допомогою спеціалізованого плагіна QuickMapServices, який дозволяє у вікні QGIS підвантажувати геопросторові шари тих чи інших геопросторових веб-сервісів (як то OpenStreetMap, Google Earth тощо), переглядали ДДЗ високої роздільності, що надає сервіс Google Earth. В ході ретельного візуального вивчення згаданих ДДЗ, а також керуючись власним знанням місцевості, вдалося виділити 11 класів земельного покриття, перелік яких наведений у табл. 2.1.

Еталонну вибірку формували вручну у середовищі QGIS шляхом окреслення полігонів на тих чи інших виділених класах земельного покриття. Еталонну вибірку намагалися зробити просторово збалансованою розміщуючи по всій площі модельної ділянки велику кількість полігонів малої площі. Потім всім пікселям ДДЗ, які потрапляли у межі полігонів, були призначені відповідні

класи земельного покриття. Всього у межі еталонних полігонів потрапило 33793 пікселі, з яких 70 % або 23659 пікселів були використані в якості навчальної вибірки, а решта 30 %, або 10134 пікселі — в якості тестової вибірки (табл. 2.2).

Таблиця 2.1 — Класи земного покриття, які використали для класифікації ДДЗ в ході виконання експериментальної частини роботи

Номер класу	Назва класу	Позначення (повне)	Позначення (скорочене)
1	Сільськогосподарські угіддя (рілля)	Agriculture	AG
2	Вільхові ліси	Alnus	AL
3	Штучні поверхні	BuiltUp	BU
4	Очеретяні зарості	Phragmites	Ph
5	Соснові ліси	Pinus	P
6	Ліси робінії	Robinia	R
7	Оголені піски	Sands	S
8	Щільний піщаний степ	SandsSteppe	SSt
9	Піщаний степ середньої щільності	SandsSteppe1	SSt1
10	Розріджений піщаний степ	SandsSteppe2	SSt2
11	Водойми	Water	W

Таблиця 2.2 — Обсяг еталонної вибірки

Номер класу	Клас	Кількість еталонних полігонів	Кількість еталонних пікселів		
			Навчальна вибірка	Тестова вибірка	Разом:
1	Agriculture	46	2261	969	3230
2	Alnus	24	2649	1134	3783
3	BuiltUp	72	2309	989	3298
4	Phragmites	24	2224	953	3177
5	Pinus	43	2401	1029	3430
6	Robinia	43	2527	1083	3610
7	Sands	45	1622	695	2317
8	SandsSteppe	31	1461	625	2086

Номер класу	Клас	Кількість еталонних полігонів	Кількість еталонних пікселів		
			Навчальна вибірка	Тестова вибірка	Разом:
9	SandsSteppe1	17	1959	839	2798
10	SandsSteppe2	49	1770	758	2528
11	Water	83	2476	1060	3536
Разом:		477	23659	10134	33793

2.4 Схема експериментального дослідження

Порівняння ефективності обраних методів керованої класифікації здійснили в ході чотирьох експериментів, кожен з яких був виконаний за певною схемою.

Для експерименту 1 було взято всі спектральні канали трьох обраних сцен (всього 30 каналів) і здійснене зменшення розмірності простору ознак шляхом аналізу головних компонент. Як видно з рис. 2.3, де зображена діаграма варіювання значень перших восьми головних компонент за виділеними класами земельного покриття, інформативними для диференціації окремих класів земельного покриття є лише шість перших головних компонент. Таким чином, в ході першого експерименту ми порівняли ефективність обраних методів керованої класифікації класифікуючи перші шість головних компонент.

У експерименті 2, як і у експерименті 1, перед класифікацією ДДЗ ми зменшили розмірність простору ознак шляхом аналізу головних компонент з тією відмінністю, що цього разу була взята лише одна сцена ДДЗ (за 4.5.2021 р.). Для дослідження ефективності обраних методів керованої класифікації у цьому випадку взяли перші три головні компоненти додавши до них четвертою ознакою нормалізований різницевий вегетаційний індекс (NDVI) (рис. 2.4).

Експерименти 3 і 4 були аналогічні експерименту 2 з тією відмінністю, що у експерименті 3 взяли сцену ДДЗ за 2.8.2021 (рис. 2.5), а у експерименті 4

— за 26.10.2021 р. (рис. 2.6).




Рисунок 2.3 — Варіювання значень головних компонент (для перших восьми компонент із результату аналізу головних компонент всіх спектральних каналів всіх обраних сцен ДДЗ)

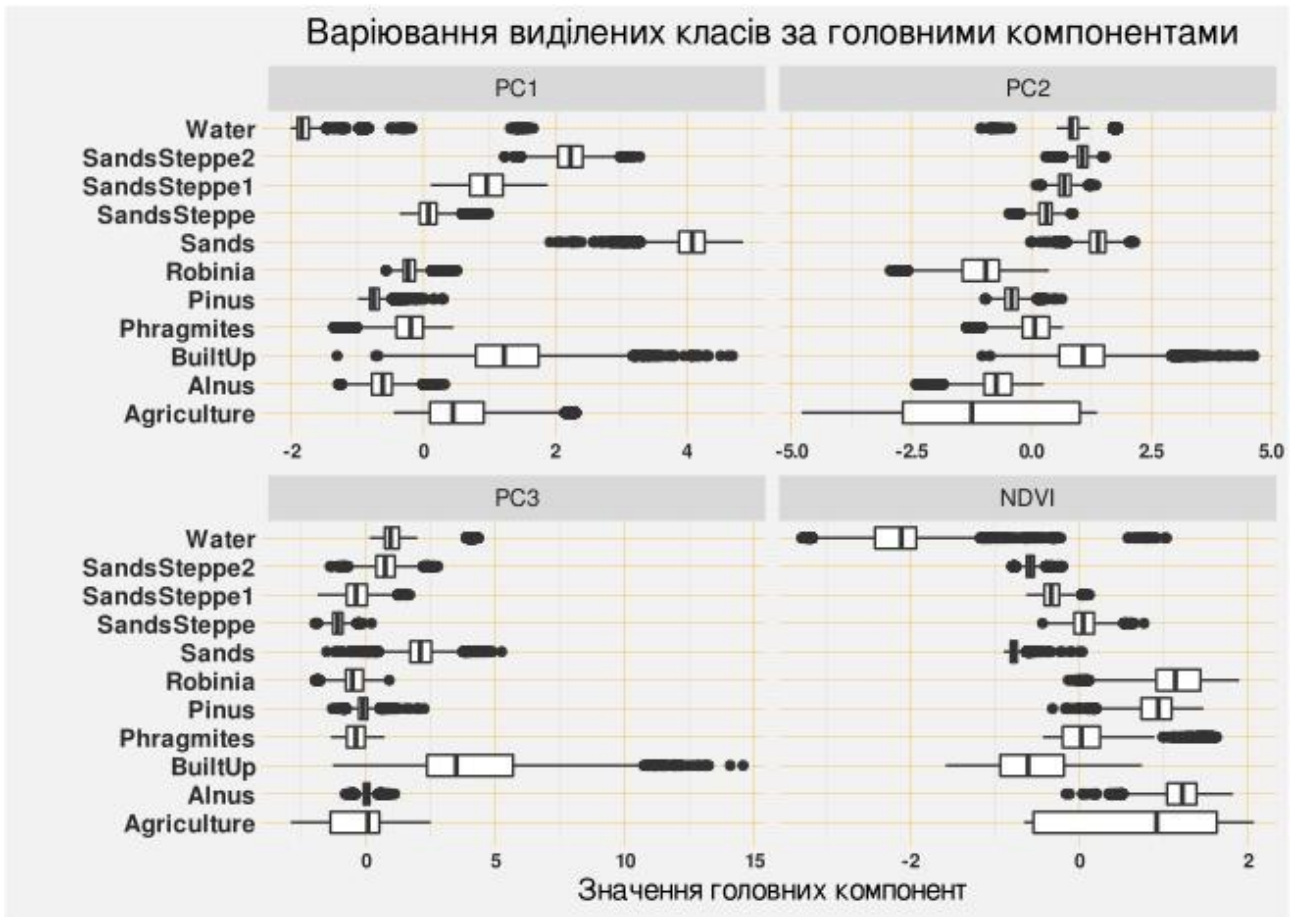


Рисунок 2.4 — Варіювання значень головних компонент (для перших трьох компонент із результату аналізу головних компонент) та NDVI для сцени ДДЗ за 4.5.2021 р.




Рисунок 2.5 — Варіювання значень головних компонент (для перших трьох компонент із результату аналізу головних компонент) та NDVI для сцени ДДЗ за 2.8.2021 р.

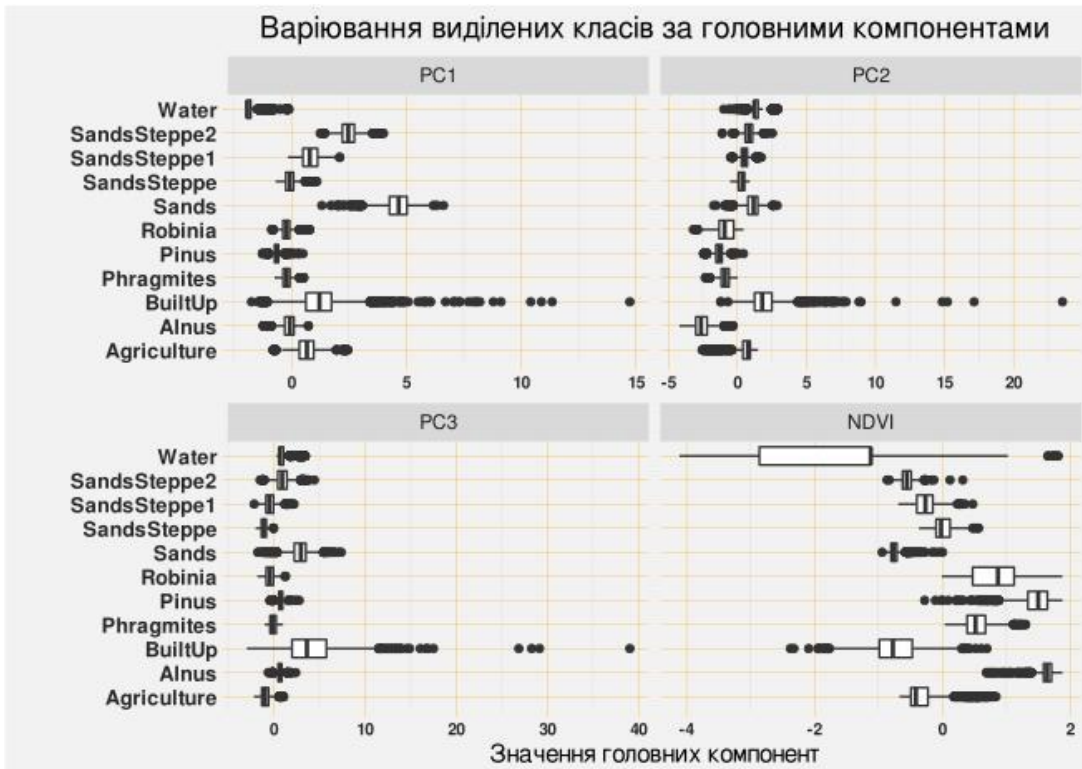


Рисунок 2.6 — Варіювання значень головних компонент (для перших трьох компонент із результату аналізу головних компонент) та NDVI для сцени ДДЗ за 26.10.2021 р.

2.5 Засоби проведення та обробки результатів експериментального дослідження. Налаштування гіперпараметрів досліджуваних моделей

Апаратним засобом дослідження був комп'ютер Asus K43E з чотириядерним процесором Intel® Core™ i3-2330M (2.20ГГц) та зі встановленою на ньому операційною системою Ubuntu Linux 20.04. Програмним засобом дослідження було середовище розробки для статистичних обчислень R V.4.1.2 [6] та низка розширень до нього, зокрема пакетів з реалізацією алгоритмів машинного навчання (caret V.6.0-88 [7], nnet V.7.3-16 [8], randomForest V.4.6-14 [9]) та паралельних обчислень (parallel V.4.1.2, doParallel V.1.0.16 [10]).

В ході навчання моделей вибір оптимальної комбінації гіперпараметрів для них здійснювався шляхом перехресної перевірки методом k-блоків ($k = 10$).

З огляду на те, що досліджувана задача класифікації ДДЗ є по суті задачею однозначної багатокласової класифікації, у штучній нейронній мережі застосовували функцію активації softmax [69]. При цьому в кожному експерименті з класифікацією ДДЗ штучною нейронною мережею використовувалися наступні гіперпараметри: кількість вузлів у прихованому шарі (параметр size для методу nnet) та скорочення вагових коефіцієнтів (L2-регуляризація; параметр decay для методу nnet). Оптимальна комбінація в ході перехресної перевірки методом k-блоків обиралася серед наступних значень гіперпараметрів: кількість вузлів у прихованому шарі — 5, 10 і 15; скорочення вагових коефіцієнтів — 0.1, 0.01 та 0.001. Тобто, оптимальне поєднання зазначених гіперпараметрів для класифікації ДДЗ штучною нейронною мережею у наших експериментах проводилося із дев'яти можливих їх комбінацій.

У кожному експерименті з класифікацією ДДЗ методом опорних векторів використовувалися наступні гіперпараметри: тип регуляризації (L1 або L2) та параметр штрафу C (параметр cost для методу svmLinear3; в експериментах цей

параметр обирався серед значень 0.2, 0.5 та 1). Тобто, оптимальне поєднання зазначених гіперпараметрів для класифікації ДДЗ методом опорних векторів у наших експериментах проводилося із шести можливих їх комбінацій.

Що ж стосується класифікації ДДЗ за алгоритмом випадкового лісу, то у всіх експериментах в ході перехресної перевірки методом k-блоків здійснювався вибір лише одного гіперпараметра — кількості ознак, які випадково обираються на кожному розгалуженні.

Приклад коду на мові R, який був використаний для проведення дослідження ефективності моделей класифікації ДДЗ, наведений у додатку А.

Статистичну обробку результатів, які були отримані в ході проведення експериментів, та побудову діаграм виконали у середовищі R.

2.6 Методика порівняння ефективності різних методів керованої класифікації даних дистанційного зондування

Ефективність різних методів класифікації порівнювали за [56]. Зокрема для порівняння різних моделей використовували аналіз матриць невідповідностей, які є дуже ефективним інструментом оцінки точності класифікації як загалом, так і для окремих класів. Крім того, використали низку оціночних метрик. Так, із загальних метрик точності послуговувалися загальною точністю та коефіцієнтом каппа Коена. З метрик, які характеризують точність класифікації на рівні окремих класів, використали точність виробника та точність користувача.

Окрім показників точності дуже важливим параметром ефективності моделі є час, який витрачається на її навчання, адже теоретично придатні моделі можуть бути зовсім непридатні для практичного використання у випадку, коли на їх навчання витрачається екстремально багато часу [70]. Тож порівняння моделей здійснювали також по часу, який витрачався на їх навчання. При цьому для фіксації витрачаного на навчання моделей часу використовували вбудовані можливості пакету caret.

РОЗДІЛ 3 РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ НЕЙРОННИХ МЕРЕЖ ДЛЯ КЛАСИФІКАЦІЇ ДАНИХ ДИСТАНЦІЙНОГО ЗОНДУВАННЯ

Як можна побачити з рис. 3.1, в результаті проведених експериментів з класифікації ДДЗ штучною нейронною мережею, оптимальним поєднанням гіперпараметрів у всіх експериментах було значення 15 для кількості вузлів у прихованому шарі (параметр `size` для методу `nnet`) та значення 0.01 для скорочення вагових коефіцієнтів (L2-регуляризація; параметр `decay` для методу `nnet`).

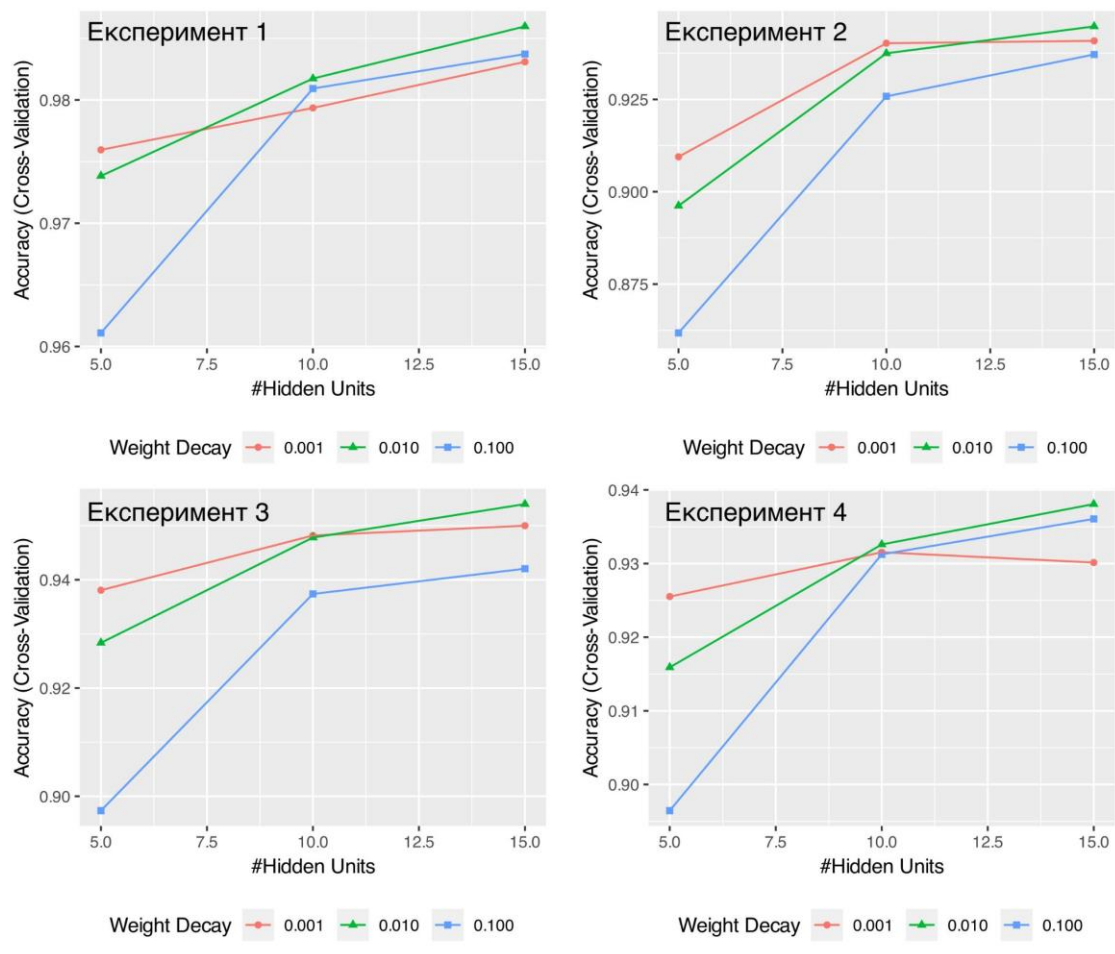




Рисунок 3.1 — Результати налаштування гіперпараметрів штучної нейронної мережі для класифікації ДДЗ в експериментах 1-4

Схематичне зображення отриманих моделей штучних нейронних мереж для класифікації ДДЗ наведено на рис. 3.2.


Експеримент 1



Експеримент 2



Експеримент 3



Експеримент 4




Рисунок 3.2 — Зображення моделей штучних нейронних мереж у експериментах 1-4

Результати налаштування гіперпараметрів моделей класифікації ДДЗ методом опорних векторів наведено на рис. 3.3. Як бачимо з цього рисунку, для всіх моделей оптимальними значеннями гіперпараметрів були наступні: тип регуляризації — L2; параметр штрафу C (параметр cost для методу svmLinear3) — 1.

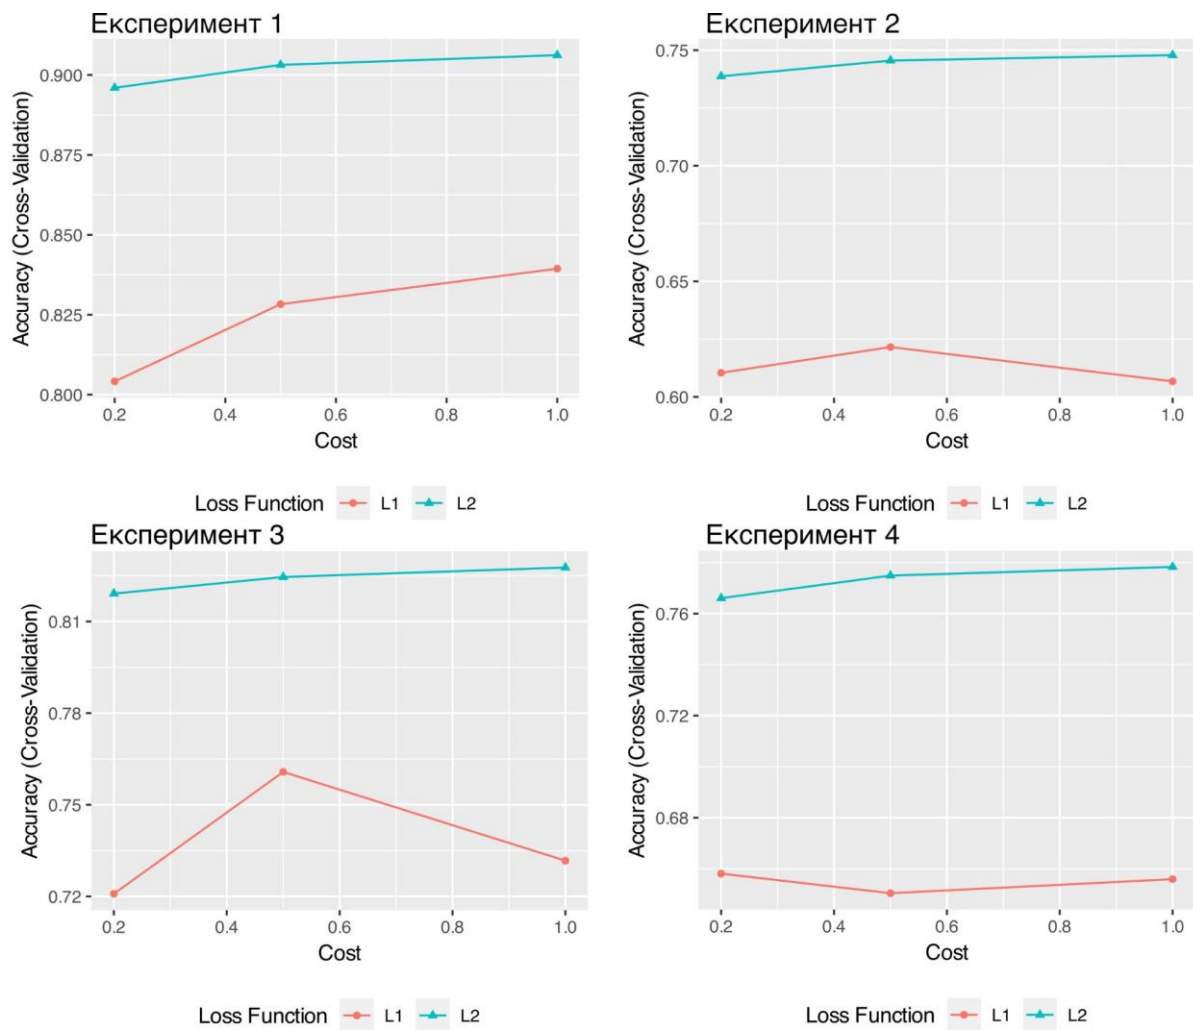


Рисунок 3.3 — Результати налаштування гіперпараметрів моделей класифікації ДДЗ методом опорних векторів в експериментах 1-4

Нарешті, для моделей, які були створені за методом випадкового лісу, оптимальним значенням кількості ознак, які випадково обираються на кожному розгалуженні, було 2 (див. рис. 3.4).

Матриці невідповідності для всіх експериментів наведені у додатку Б (таблиці Б1-Б3 — для експерименту 1; таблиці Б4-Б6 — для експерименту 2; таблиці Б7-Б9 — для експерименту 3; таблиці Б10-Б12 — для експерименту 4).

В результаті проведених досліджень встановлено, що у всіх експериментах найкращі результати за показниками точності показала класифікація штучною нейронною мережею (рис. 3.5А). Значення загальної точності для класифікації ДДЗ цим методом у всіх експериментах було дуже

високим — в середньому не нижчим 0.94. Результати класифікації методом випадкового лісу лише незначно поступилися штучній нейронній мережі. Загальна точність класифікації за цим методом у всіх експериментах була в діапазоні 0.92–0.98. Помітно гірші результати виявилися у експериментах з класифікації ДДЗ методом опорних векторів. Значення загальної точності для цього методу у всіх експериментах знаходилося у проміжку 0.75–0.91. Порівнюючи рисунки 3.5А та 3.5Б, можна дійти висновку, що аналогічні закономірності спостерігаються і для значень коефіцієнта каппа Коена.

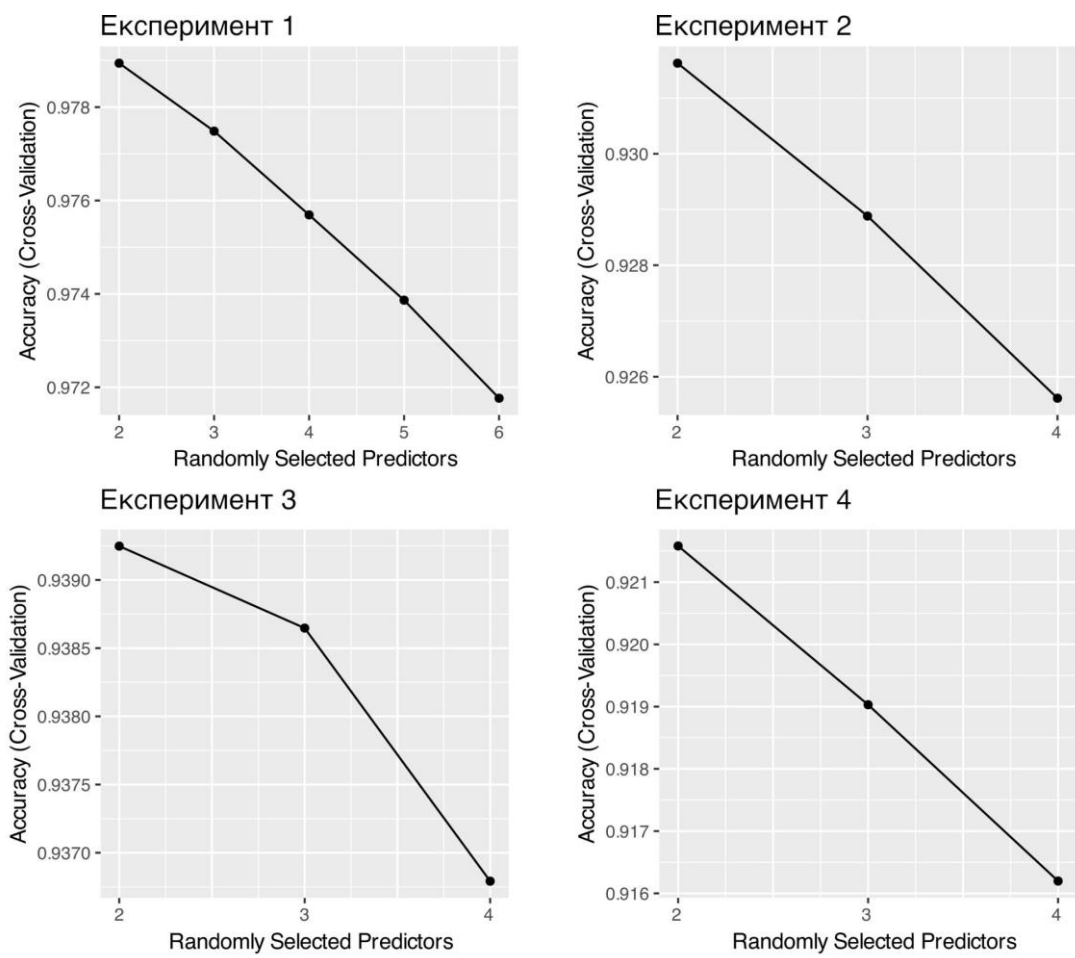


Рисунок 3.4. — Результати налаштування гіперпараметрів моделей класифікації ДДЗ методом випадкового лісу в експериментах 1-4

Якщо детально проаналізувати рис. 3.5, можна помітити цікаву закономірність. Для всіх досліджених методів найвищі показники точності

класифікації спостерігалися у експерименті 1. На другому місці за цими показниками був експеримент 3. Нарешті, для експериментів 2 і 4 були характерні найнижчі показники загальної точності та коефіцієнта каппа Коена. При цьому для штучної нейронної мережі та методу випадкового лісу зниження показників точності у експерименті 3, у порівнянні з експериментом 1, та експериментами 2 і 4, у порівнянні з експериментом 3, були незначними, чого не можна сказати про метод опорних векторів.

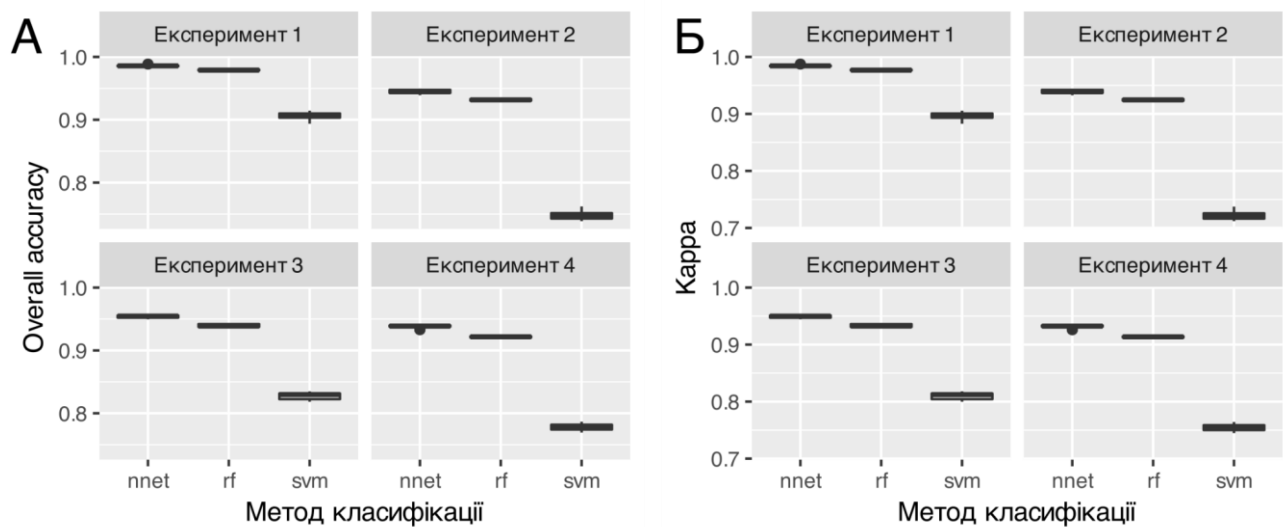


Рисунок 3.5 — Варіація загальної точності (А) та коефіцієнта каппа Коена (Б) у окремих експериментах з класифікації ДДЗ

Така синхронність напряму змін показників точності у всіх досліджуваних методах класифікації наводить на думку, що причина цього у характері ДДЗ, які класифікували в проведених експериментах. І справді, шість головних компонент, які відповідно до схеми експериментального дослідження класифікували у експерименті 1, були отримані в ході аналізу головних компонент часової серії ДДЗ, яка включала весняний, літній та осінній супутникові знімки. Відповідно, на вхід класифікатору у експерименті 1 були подані ознаки, які містили максимум інформації про просторову мінливість земельного покриття, що і зумовило найкращі показники точності класифікації ДДЗ. Навпаки, у експериментах 2 та 4 на вхід класифікатору були подані

похідні ознаки з окремих сцен ДДЗ, які були отримані або на початку вегетаційного періоду (сцена за 4 травня 2021 р.), або вже по завершенню вегетаційного періоду (сцена за 26 жовтня 2021 р.). Тобто вони містили меншу кількість спектральної інформації про мінливість земельного покриву, що і зумовило найнижчі показники точності. Проміжний результат по точності, який отримали у експерименті 3, пояснюється тим, що в цьому експерименті класифікували сцену ДДЗ, яка була отримана у розпал вегетаційного сезону. Відповідно, завдяки розвинутій зеленій рослинності навіть одна сцена містила досить багато інформації для якісного розрізнення окремих класів в ході класифікації.

Все сказане наводить на попередній висновок, що ефективність штучної нейронної мережі і методу випадкових лісів для класифікації ДДЗ вища ніж методу опорних векторів. Ба більше, штучна нейронна мережа і метод випадкового лісу показують високу ефективність навіть у випадку, коли якість ДДЗ (у сенсі багатства спектральної інформації) є обмеженою. Втім, щоб підтвердити такий висновок варто дослідити ефективність класифікації ДДЗ досліджуваними методами на рівні окремих класів. Для цього детально проаналізуємо наведені у додатку Б матриці невідповідності, а також значення точності виробника і користувача та їх варіацію (рис. 3.6-3.8).

Як можна побачити з рис. 3.6-3.8, є три класи — «Водойми», «Оголені піски» та «Штучні поверхні», які надійно виділялися в ході класифікації безвідносно до методу, яким вона проводилася, чи схеми експерименту. Це пояснюється тим, що спектральні класи, що відповідають названим тематичним класам, є досить віддалені у просторі ознак як один від одного, так і від інших класів. Здебільшого непогано також розпізнавався клас «Розріджений піщаний степ». Точність виробника для нього при класифікації штучною нейронною мережею чи методом випадкового лісу в різних експериментах коливалася в межах 0.97-0.99. Дещо гірше цей клас розпізнавався методом опорних векторів: точність виробника становила в різних експериментах 0.77–0.94. Подібна

картина для цього класу спостерігалася і по точності користувача, яка у випадку класифікації штучною нейронною мережею чи методом випадкового лісу коливалася в межах 0.97-0.99, а у випадку класифікації методом опорних векторів — в межах 0.83–0.88.




Рисунок 3.6 — Точність виробника для різних методів класифікації ДДЗ в окремих експериментах




Рисунок 3.7 — Точність користувача для різних методів класифікації ДДЗ в окремих експериментах




Рисунок 3.8 — Варіація значень точності виробника (А) та користувача (Б) (без диференціації по схемам експерименту та методам класифікації)

Здебільшого всіма методами і у всіх експериментах досить надійно ідентифікувався клас «Соснові ліси». Винятком був лише експеримент 2, в якому в результаті класифікації методом опорних векторів точність виробника

та точність користувача для цього класу була досить низькою (0.59 та 0.63 відповідно). Як можна бачити з таблиці Б5, в цьому експерименті методом опорних векторів значна частка пікселів класу «Соснові ліси» була неправильно класифікована як «Вільхові ліси». Також досить багато пікселів, що належали до класів «Вільхові ліси» та «Очерейні зарості», були неправильно класифіковані як «Соснові ліси». Ймовірно це пов'язано зі спектральною подібністю вільшняків та очеретяних заростей із сосновими лісами на початку сезону вегетації.

Для решти шести класів, при класифікації ДДЗ штучними нейронними мережами, у всіх експериментах значення точності виробника і точності користувача, за незначним винятком, було в межах 0.90–1. За показником точності виробника таких винятків у експерименті 1 не було взагалі, а в решті експериментів вони були наступними: у експерименті 2 — клас «Вільхові ліси» (0.84); у експерименті 3 — клас «Ліси робінії» (0.89), у експерименті 4 — класи «Сільськогосподарські угіддя» (0.87), «Щільний піщаний степ» (0.89) та «Піщаний степ середньої щільності» (0.87). За показником точності користувача такі винятки були лише у експерименті 4 — класи «Щільний піщаний степ» (0.87) та «Піщаний степ середньої щільності» (0.82).

Як бачимо, штучні нейронні мережі показали відмінну здатність до правильної ідентифікації більшості класів. Особливо це стосується випадку, коли цим методом здійснюється класифікація даних, які є похідними від часових серій ДДЗ і які, відповідно, відрізняються багатством спектральної інформації стосовно земельного покриття. Втім, навіть на певною мірою обмежених у якості даних (у сенсі багатства спектральної інформації) штучні нейронні мережі показують відмінний результат для більшості класів і задовільний — для решти класів.

Як і при класифікації ДДЗ штучними нейронними мережами, при класифікації методом випадкового лісу для шести класів, що розглядаються, у всіх експериментах значення точності виробника і точності користувача теж, за

незначним винятком, було в межах 0.90–1. За показником точності виробника таких винятків у експериментах 1 і 4 не було взагалі, а в решті експериментів вони були наступними: у експерименті 2 — клас «Вільхові ліси» (0.86); у експерименті 3 — клас «Ліси робінії» (0.88). За показником точності користувача такі винятки були у експерименті 3 — клас «Вільхові ліси» (0.89) та у експерименті 4 — класи «Щільний піщаний степ» (0.88) та «Піщаний степ середньої щільності» (0.85).

Таким чином, отримані результати показали, що, як і штучні нейронні мережі, метод випадкового лісу показав відмінну здатність до правильної ідентифікації всіх класів у випадку, коли цим методом здійснюється класифікація даних, які є похідними від часових серій ДДЗ. Аналогічно нейронним мережам, на певною мірою обмежених у якості даних (у сенсі багатства спектральної інформації) метод випадкового лісу теж демонструє відмінний результат для більшості класів і задовільний — для решти класів.

На відміну від штучних нейронних мереж та методу випадкового лісу, при класифікації ДДЗ методом опорних векторів точність розпізнавання шести класів, що розглядаються, варіювала істотно сильніше. При цьому швидше винятком було відмінне розпізнавання цих класів. Так точність виробника в межах 0.90–1 спостерігали у експерименті 1 у класів «Вільхові ліси» (0.95), «Очеретяні зарості» (0.96), «Ліси робінії» (0.95) та «Щільний піщаний степ» (0.91), у експерименті 3 у класу «Очеретяні зарості» (0.90), а також у експерименті 4 у класу «Вільхові ліси» (0.90). Точність користувача в межах 0.90–1 спостерігали у експерименті 1 у класів «Сільськогосподарські угіддя» (0.99), «Вільхові ліси» (0.97) та «Ліси робінії» (0.93), у експерименті 2 у класу «Очеретяні зарості» (0.90), а також у експерименті 4 у класу «Вільхові ліси» (0.95).

Слід наголосити, що здебільшого винятком було і задовільне розпізнавання цих класів. Так точність виробника в межах 0.80–0.89 спостерігали у експерименті 2 у класу «Ліси робінії» (0,87), у експерименті 3 у

класів «Вільхові ліси» (0.83) та «Щільний піщаний степ» (0.89), у експерименті 4 у класу «Сільськогосподарські угіддя» (0.84). В решті випадків, при класифікації ДДЗ методом опорних векторів розпізнавання тих шести класів, що розглядаються, у проведених експериментах виявилось незадовільним.

Таким чином, дослідження показало, метод опорних векторів вельми чутливий до багатства спектральної інформації про земельний покрив. Відповідно, більш-менш якісний результат класифікації цим методом можна отримати, якщо застосовувати його до часових серій ДДЗ.

Ще одним аспектом ефективності методу класифікації є час, який витрачається на тренування моделі. Як видно з табл. 3.1, найменшого часу для тренування моделі у нашому дослідженні потребувала класифікація ДДЗ методом опорних векторів — всього лише 3–3.3 с. Приблизно на порядок більше потребувало часу тренування моделі при класифікації ДДЗ методом випадкового лісу. Нарешті, метод класифікації ДДЗ штучною нейронною мережею потребував найбільше часу — приблизно у 2.4–3.1 рази більше, ніж методом випадкового лісу.

Таблиця 3.1 — Час, що витрачався на навчання моделі при класифікації ДДЗ, с

Метод класифікації	Експеримент			
	1	2	3	4
Штучна нейронна мережа	93.5	73.4	76.3	68.5
Метод випадкового лісу	30.2	28.2	26.0	28.5
Метод опорних векторів	3.3	3.0	3.1	3.0

ВИСНОВКИ

1. В ході аналізу літератури та власного експериментального дослідження було встановлено, що штучні нейронні мережі є сучасним ефективним методом класифікації ДДЗ.

2. Порівняння ефективності штучних нейронних мереж в ході експериментального дослідження показало, що за показниками точності цей метод класифікації ДДЗ є близьким до методу випадкового лісу і істотно перевищує метод опорних векторів.

3. Штучні нейронні мережі, як і метод випадкового лісу, показують відмінні результати при класифікації даних заснованих на часових серіях ДДЗ. Втім цілком задовільні результати вони демонструють і при класифікації окремих сцен ДДЗ, навіть якщо ті отримані не у розпал вегетаційного сезону.

4. Штучні нейронні мережі дещо поступаються методу випадкового лісу у сенсі витрат часу на навчання моделі.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Kamusoko C. Remote Sensing Image Classification in R / C. Kamusoko. — 2019. — ISBN 9789811380129.
2. Bruzzone L. A Review of Modern Approaches to Classification of Remote Sensing Data / L. Bruzzone, B. Demir // Land Use and Land Cover Mapping in Europe: Practices & Trends / Manakos I., Braun M. — Dordrecht : Springer Netherlands, 2014. — С. 127–143.
3. Computer processing of remotely-sensed images: an introduction / P. M. Mather, M. Koch. — Chichester, West Sussex, UK ; Hoboken, NJ : Wiley-Blackwell, 2011. — 434 с. — ISBN 978-0-470-74239-6.
4. Camps-Valls G. Remote Sensing Image Processing. / G. Camps-Valls, D. Tuia, L. Gómez-Chova, S. Jiménez. — Morgan & Claypool Publisher, 2012. — ISBN 978-1-60845-820-2.
5. Lu D. A survey of image classification methods and techniques for improving classification performance / D. Lu, Q. Weng // International Journal of Remote Sensing. — 2007. — Вып. 28, № 5. — С. 823–870.
6. R Core Team R: A Language and Environment for Statistical Computing / R Core Team. — Vienna, Austria : R Foundation for Statistical Computing, 2021.
7. Kuhn M. caret: Classification and Regression Training / M. Kuhn. — 2021. URL : <https://CRAN.R-project.org/package=caret>.
8. Venables W. N. Modern Applied Statistics with S / W. N. Venables, B. D. Ripley. — New York : Springer, 2002.
9. Liaw A. Classification and Regression by randomForest / A. Liaw, M. Wiener // R News. — 2002. — Вып. 2, № 3. — С. 18–22.
10. Corporation M. doParallel: Foreach Parallel Adaptor for the “parallel” Package / M. Corporation, S. Weston. — 2020.
11. Шовенгердт Р. А. Дистанционное зондирование. Модели и методы

- обработки изображений / Р. А. Шовенгердт. — Москва : Техносфера, 2010. — 560 с.
12. Свідзінська Д. В. Методи геоєкологічних досліджень: геоінформаційний практикум на основі відкритої ГІС SAGA: навчальний посібник / Д. В. Свідзінська. — Київ : Логос, 2014. — 402 с.
 13. Remote sensing and image interpretation / Т. М. Lillesand, R. W. Kiefer, J. W. Chipman. — Hoboken, N.J : John Wiley & Sons, Inc, 2015. — 720 с. — ISBN 978-1-118-34328-9.
 14. Canada N. R. Passive vs. Active Sensing / N. R. Canada. — 2014. URL : <https://www.nrcan.gc.ca/maps-tools-publications/satellite-imagery-air-photos/remote-sensing-tutorials/introduction/passive-vs-active-sensing/14639> (access date: 03/30/2022).
 15. Landsat 7 Data Users Handbook | U.S. Geological Survey / . URL : <https://www.usgs.gov/landsat-missions/landsat-7-data-users-handbook> (access date: 03/31/2022).
 16. Landsat 8 Data Users Handbook | U.S. Geological Survey / . URL : <https://www.usgs.gov/landsat-missions/landsat-8-data-users-handbook> (access date: 03/31/2022).
 17. Drusch M. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services / M. Drusch, U. Del Bello, S. Carlier, та ін. // Remote Sensing of Environment. — 2012. — Вип. 120. — С. 25–36.
 18. European Space Agency Sentinel-2 User Handbook, ESA Standard Document / European Space Agency. — Paris, France : 2015. — 64 с.
 19. Types Of Remote Sensing: Devices And Their Applications / 2020. URL : <https://eos.com/blog/types-of-remote-sensing/> (access date: 03/30/2022).
 20. Torres R. GMES Sentinel-1 mission / R. Torres, P. Snoeij, D. Geudtner, та ін. // Remote Sensing of Environment. — 2012. — Вип. 120. — С. 9–24.
 21. Encyclopedia of remote sensing / ed. E. G. Njoku. — New York, NY : Springer, 2014. — 939 с. — ISBN 978-0-387-36700-2.

22. Шихов А. Н. Тематическое дешифрирование и интерпретация космических снимков среднего и высокого пространственного разрешения / А. Н. Шихов, А. П. Герасимов, А. И. Пономарчук, Е. С. Перминова. — Пермь : Пермский государственный национальный исследовательский университет, 2020. — 191 с.
23. Remote Sensing Techniques and GIS - CE6003 Anna University - Important Questions Answers, Question Paper, Lecture Notes, Study Material / . URL : https://www.brainkart.com/subject/Remote-Sensing-Techniques-and-GIS_44/ (access date: 04/13/2022).
24. Дейвис Ш. М. Дистанционное зондирование: количественный подход / Ш. М. Дейвис, Д. А. Ландгребе, Т. Л. Филлипс, та ін. — Москва : Недра, 1983. — 415 с.
25. Remote sensing digital image analysis: an introduction / J. A. Richards. — Berlin : Springer, 2013. — 494 с. — ISBN 978-3-642-30061-5.
26. Гарбук С. В. Космические системы дистанционного зондирования Земли / С. В. Гарбук, В. Е. Гершензон. — Москва : Изд-во А и Б, 1997. — 296 с.
27. Earth observation of global change: the role of satellite remote sensing in monitoring global environment / ed. E. Chuvieco. — New York : Springer, 2008. — 223 с. — ISBN 978-1-4020-6357-2.
28. Thenkabail P. S. Hyperspectral remote sensing of vegetation. Volume IV, Volume IV, / P. S. Thenkabail, J. G. Lyon, A. Huete. — 2019. — ISBN 978-0-429-77515-4.
29. Remote sensing of drought: innovative monitoring approaches / ed. B. D. Wardlow, ed. M. C. Anderson, ed. J. P. Verdin. — Boca Raton, FL : CRC Press, 2012. — 422 с. — ISBN 978-1-4398-3557-9.
30. Remote sensing and climate modeling: synergies and limitations / ed. M. Beniston, ed. M. M. Verstraete. — Dordrecht ; Boston : Kluwer Academic Publishers, 2001. — 343 с. — ISBN 978-0-7923-6801-4.
31. Meissner B. Remote Sensing Cartography: Following the Basic Rules of

- Cartography Guaranties the Optimum Use of Remote Sensing Data for Topographic and Thematic Maps / B. Meissner // *GeoJournal*. — 1994. — Вип. 32, № 1. — С. 71–79.
32. Remote sensing in archaeology / ed. J. Wiseman, ed. F. El-Baz. — New York : Springer, 2007. — 553 с. — ISBN 978-0-387-44453-6.
33. Chandra A. M. Remote sensing and geographical information system / A. M. Chandra, S. K. Ghosh. — Oxford : Alpha Science Intern, 2007. — 298 с. — ISBN 978-1-84265-278-7.
34. Aranha T. R. B. T. Remote Analysis of the Chlorophyll-a Concentration Using Sentinel-2 MSI Images in a Semiarid Environment in Northeastern Brazil / T. R. B. T. Aranha, J.-M. Martinez, E. P. Souza, та ін. // *Water*. — 2022. — Вип. 14, № 3. — С. 451.
35. Senf C. Remote sensing of forest insect disturbances: Current state and future directions / C. Senf, R. Seidl, P. Hostert // *International Journal of Applied Earth Observation and Geoinformation*. — 2017. — Вип. 60. — С. 49–60.
36. Classification methods for remotely sensed data / B. Tso, P. M. Mather. — Boca Raton : CRC Press, 2009. — 356 с. — ISBN 978-1-4200-9072-7.
37. Image processing and GIS for remote sensing: techniques and applications / J.-G. Liu, P. J. Mason. — Chichester, UK ; Hoboken, NJ : Wiley/Blackwell, 2016. — 1 с. — ISBN 978-1-118-72417-0.
38. QGIS Development Team QGIS Geographic Information System / QGIS Development Team. — Open Source Geospatial Foundation, 2021.
39. Conrad O. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4 / O. Conrad, B. Bechtel, M. Bock, та ін. // *Geoscientific Model Development*. — 2015. — Вип. 8, № 7. — С. 1991–2007.
40. GRASS Development Team Geographic Resources Analysis Support System (GRASS) Software, Version 7.8.2 / GRASS Development Team. — 2019. URL : <http://grass.osgeo.org>.
41. Bahari N. I. S. Application of support vector machine for classification of

- multispectral data / N. I. S. Bahari, A. Ahmad, B. M. Aboobaider // IOP Conference Series: Earth and Environmental Science. — 2014. — Вип. 20. — С. 012038.
42. Pal M. Support vector machines for classification in remote sensing / M. Pal, P. M. Mather // International Journal of Remote Sensing. — 2005. — Вип. 26, № 5. — С. 1007–1011.
43. Belgiu M. Random forest in remote sensing: A review of applications and future directions / M. Belgiu, L. Drăguț // ISPRS Journal of Photogrammetry and Remote Sensing. — 2016. — Вип. 114. — С. 24–31.
44. Лижник Г. Л. Аналіз сучасної структури землекористування території на основі дешифрування даних ДЗЗ (на прикладі Мурованокуриловецького району Вінницької області) / Г. Л. Лижник, Д. В. Свідзінська // Часопис картографії. — 2014. — Вип. 10. — С. 90–97.
45. Бондаренко Е. Методичні особливості дешифрування даних дистанційного зондування землі для геоінформаційного картографування земельних ресурсів Чернівецької області / Е. Бондаренко, Я. Смірнов // Вісник Київського національного університету імені Тараса Шевченка. Географія. — 2014. — № 1. — С. 53–59.
46. Зелик Я. І. Аналітичний огляд європейських проектів LUCAS і CORINE для моніторингу та валідації земного покриття і землекористування на основі супутникових та наземних спостережень та досвід картографування земного покриття в Україні / Я. І. Зелик, Н. М. Куссуль, А. Ю. Шелестов, Б. Я. Яйлимов // Український журнал дистанційного зондування Землі. — 2017. — № 12. — С. 10–36.
47. Büttner G. CORINE Land Cover and Land Cover Change Products / G. Büttner // Land Use and Land Cover Mapping in Europe: Practices & Trends / Manakos I., Braun M. — Dordrecht : Springer Netherlands, 2014. — С. 55–74.
48. Stehman S. V. Design and Analysis for Thematic Map Accuracy Assessment:

- Fundamental Principles / S. V. Stehman, R. L. Czaplewski // Remote Sensing of Environment. — 1998. — Вып. 64, № 3. — С. 331–344.
49. Muchoney D. M. Pixel- and site-based calibration and validation methods for evaluating supervised classification of remotely sensed data / D. M. Muchoney, A. H. Strahler // Remote Sensing of Environment. — 2002. — Вып. 81, № 2. — С. 290–299.
50. A. Ramezan C. Evaluation of Sampling and Cross-Validation Tuning Strategies for Regional-Scale Machine Learning Classification / C. A. Ramezan, T. A. Warner, A. E. Maxwell // Remote Sensing. — 2019. — Вып. 11, № 2. — С. 185.
51. Stehman S. V. Sampling designs for accuracy assessment of land cover / S. V. Stehman // null. — 2009. — Вып. 30, № 20. — С. 5243–5272.
52. Dormann C. F. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance / C. F. Dormann, J. Elith, S. Bacher, та ін. // Ecography. — 2013. — Вып. 36, № 1. — С. 27–46.
53. Ur Rehman A. Combining Landsat-8 spectral bands with ancillary variables for land cover classification in mountainous terrains of northern Pakistan / A. Ur Rehman, S. Ullah, M. Shafique, та ін. // J. Mt. Sci. — 2021. — Вып. 18, № 9. — С. 2388–2401.
54. Glanz H. A parametric model for classifying land cover and evaluating training data based on multi-temporal remote sensing data / H. Glanz, L. Carvalho, D. Sulla-Menashe, M. A. Friedl // ISPRS Journal of Photogrammetry and Remote Sensing. — 2014. — Вып. 97. — С. 219–228.
55. Henrich V. IDB — www.indexdatabase.de, Entwicklung einer Datenbank für Fernerkundungsindizes. AK Fernerkundung, Bochum, 4.-5. 10. 2012. / V. Henrich, G. Krauss, C. Götze, C. Sandow // AK Fernerkundung. — 2012. — Вып. 4–5, № 10.
56. Assessing the accuracy of remotely sensed data: principles and practices / R. G. Congalton, K. Green. — Boca Raton : CRC Press/Taylor & Francis, 2009.

- 183 с. — ISBN 978-1-4200-5512-2.
57. Banko G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data and of Methods Including Remote Sensing Data in Forest Inventory / G. Banko // Remote Sensing of Environment. — 1998. — Вып. 37, № 2. — С. 270–9.
58. Principles of artificial neural networks / D. Graupe. — New Jersey : World Scientific, 2013. — 363 с. — ISBN 978-981-4522-73-1.
59. Russell S. J. Artificial intelligence: a modern approach / S. J. Russell, P. Norvig, E. Davis, D. Edwards. — Boston Columbus Indianapolis New York San Francisco Upper Saddle River Amsterdam Cape Town Dubai London Madrid Milan Munich Paris Montreal Toronto Delhi Mexico City Sao Paulo Sydney Hong Kong Seoul Singapore Taipei Tokyo : Pearson, 2016. — 1132 с. — ISBN 978-1-292-15396-4.
60. Heaton J. Deep learning and neural networks / J. Heaton, J. Heaton. — St. Louis, MO : Heaton Research, Inc, 2013. — 323 с. — ISBN 978-1-5057-1434-0.
61. Salem F. M. Recurrent neural networks: from simple to gated architectures. / F. M. Salem. — S.l. : SPRINGER, 2022. — ISBN 978-3-030-89928-8.
62. Friedman M. Introduction to pattern recognition: statistical, structural, neural, and fuzzy logic approaches / M. Friedman, A. Kandel. — London : River Edge, NJ : Imperial College Press ; Distributed by World Scientific Pub, 1999. — ISBN 978-981-02-3312-9.
63. Aggarwal C. C. Neural networks and deep learning: a textbook / C. C. Aggarwal. — Cham, Switzerland : Springer, 2018. — 497 с. — ISBN 978-3-319-94463-0.
64. Mas J. F. The application of artificial neural networks to the analysis of remotely sensed data / J. F. Mas, J. J. Flores // International Journal of Remote Sensing. — 2008. — Вып. 29, № 3. — С. 617–663.
65. Cheng G. Remote Sensing Image Scene Classification Meets Deep Learning:

- Challenges, Methods, Benchmarks, and Opportunities / G. Cheng, X. Xie, J. Han, та ін. // *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*. — 2020. — Вип. 13. — С. 3735–3756.
66. Sefrin O. Deep Learning for Land Cover Change Detection / O. Sefrin, F. M. Riese, S. Keller // *Remote Sensing*. — 2021. — Вип. 13, № 1. — С. 78.
67. Природа Херсонської області. Фізико-географічний нарис / ed. М. Ф. Бойко. — Київ : Фітосоціоцентр, 1998. — 120 с.
68. The Copernicus Open Access Hub / . URL : <https://scihub.copernicus.eu/> (access date: 02/15/2022).
69. Deep learning with R / F. Chollet, J. J. Allaire. — Shelter Island, NY : Manning Publications Co, 2018. — 335 с. — ISBN 978-1-61729-554-6.
70. Wang S. Comparing hundreds of machine learning classifiers and discrete choice models in predicting travel behavior: an empirical benchmark / S. Wang, B. Mo, S. Hess, J. Zhao. — arXiv, 2021. URL : <https://arxiv.org/abs/2102.01130>.
71. Василенко Є. Класифікація ландшафтного покриття за допомогою алгоритму Random Forest / Є. Василенко. URL : https://rpubs.com/geka/Gazon_noDegLawn_20170901 (access date: 02/14/2022).
72. Stefan V. R — using Random Forests, Support Vector Machines and Neural Networks for a pixel based supervised classification of Sentinel-2 multispectral images / V. Stefan. URL : <https://valentinitnelav.github.io/satellite-image-classification-r/> (access date: 02/14/2022).

ДОДАТКИ

ДОДАТОК А ЛІСТИНГ КОДУ З КЛАСИФІКАЦІЇ ДДЗ НА МОВІ R

Код на мові R для проведення експериментів з класифікації ДДЗ розроблений на основі майстеркласів Євгена Василенка [71] та Валентина Стефана [72]. З метою економії місця у лістингу наведений код лише для першого експерименту. Код для решти експериментів аналогічний цьому і відрізняється лише у кількості імпортованих растрових шарів.

```
# Завантаження необхідних пакетів
library(raster)
library(plyr)
library(dplyr)
library(caret)
library(randomForest)
library(nnet)
library(NeuralNetTools)
library(parallel)
library(doParallel)
library(ggplot2)

# Встановлення директорії для кешування растрів
rasterOptions(tmpdir = "./temp")

# Завантаження растрів
PC1 = raster("PC1.tif")
PC2 = raster("PC2.tif")
PC3 = raster("PC3.tif")
PC4 = raster("PC4.tif")
PC5 = raster("PC5.tif")
PC6 = raster("PC6.tif")

# Нормалізація растрових шарів
PC1s <- scale(PC1)
PC2s <- scale(PC2)
PC3s <- scale(PC3)
PC4s <- scale(PC4)
PC5s <- scale(PC5)
PC6s <- scale(PC6)

# Об'єднання растрів у стек
ImageStack <- stack(PC1s, PC2s, PC3s, PC4s, PC5s, PC6s)

#Перейменування растрів у стеку
```

```

names(ImageStack) <- c("PC1", "PC2", "PC3", "PC4", "PC5", "PC6")

# Видалення зайвих об'єктів
rm(PC1, PC2, PC3, PC4, PC5, PC6, PC1s, PC2s, PC3s, PC4s, PC5s,
    PC6s)

# Завантаження шейп-файлу з полігонами еталонних класів
trainData <- shapfile("TrainTestSamplePreparing.shp")

# Створюємо поле цілих чисел з номерами класів
trainData@data$ClassInt <-
    as.integer(factor(trainData@data$C_name))

# Кількість наявних навчальних полігонів за класами
summary(factor(trainData@data$C_name))

# Екстракція значень пікселів, які знаходяться в межах полігонів
# еталонної вибірки, у таблицю
dfAll <- data.frame(matrix(vector(), nrow = 0, ncol =
    length(names(ImageStack)) + 1))
for (i in 1:length(unique(trainData[["ClassInt"]]))){
    category <- unique(trainData[["ClassInt"]][i])
    categorymap <- trainData[trainData[["ClassInt"]] == category,]
    dataSet <- extract(ImageStack, categorymap)
    dataSet <- dataSet[!unlist(lapply(dataSet, is.null))]
    dataSet <- lapply(dataSet, function(x){cbind(x, ClassInt =
        as.numeric(rep(category, nrow(x))))})
    df <- do.call("rbind", dataSet)
    dfAll <- rbind(dfAll, df)
}

# Повернення символічних найменувань класів в отриману на
# попередньому кроці таблицю
ClassDF <- data.frame(Class =
    levels(factor(trainData@data$C_name)), ClassInt = seq(1:11))
dfAll <- left_join(dfAll, ClassDF)

# Підготовка таблиці з еталонними даними
LearnDF <- select(dfAll, -ClassInt)

# Виведення кількості пікселів кожного класу в отриманій таблиці
summary(factor(LearnDF$Class))

# Розділення таблиці з еталонними даними на навчальну (70%) і
# тестову (30%) вибірки
set.seed(456)
idx_train <- createDataPartition(LearnDF$Class, p = 0.7, list =
    FALSE)
dt_train <- LearnDF[idx_train,]
dt_test <- LearnDF[-idx_train,]

```

```

# Кількість пікселів у навчальній вибірці по класам
table(dt_train$Class)
# Кількість пікселів у тестовій вибірці по класам
table(dt_test$Class)

# Налаштування крос-валідації моделей методом k-блоків
n_folds <- 10
set.seed(456)
folds <- createFolds(1:nrow(dt_train), k = n_folds)
seeds <- vector(mode = "list", length = n_folds + 1)
for(i in 1:n_folds) seeds[[i]] <- sample.int(1000, n_folds)
seeds[n_folds + 1] <- sample.int(1000, 1)

# Створення змінної, в якій будуть зазначені низка параметрів
# машинного навчання, що будуть використовуватися у всіх
# методах класифікації
ctrl <- trainControl(summaryFunction = multiClassSummary,
                      method = "cv",
                      number = n_folds,
                      search = "grid",
                      classProbs = TRUE,
                      savePredictions = TRUE,
                      index = folds,
                      seeds = seeds)

# ++++++
# Класифікація ДДЗ методом випадкового лісу
# ++++++

# Створення кластеру для паралельних обчислень з використанням 3/4
# від кількості процесорів
cl <- makeCluster(3/4 * detectCores())
registerDoParallel(cl)
# Власне навчання моделі
model_rf <- caret::train(Class ~ . , method = "rf",
                        data = dt_train,
                        importance = TRUE,
                        allowParallel = TRUE,
                        tuneGrid = data.frame(mtry = c(2, 3, 4, 5, 6)),
                        trControl = ctrl)

# Зупинка і видалення кластеру паралельних обчислень
stopCluster(cl); remove(cl)

registerDoSEQ()

# Збереження отриманої моделі у файл
saveRDS(model_rf, file = "model_rf.rds")

```

```

# Виведення оціночних параметрів моделі
# Загальний час обчислення моделі
model_rf$times$everything

# Друк результату налаштування моделі
ggplot(model_rf)

# Розрахунок матриці невідповідностей та інших оцінок моделі на
# тестових даних
cm_rf <- confusionMatrix(data = predict(model_rf, newdata =
  dt_test),
  factor(dt_test$Class))

# Виведення матриці невідповідностей та інших оцінок моделі
cm_rf

# Друк діаграми важливості предикторів
randomForest::varImpPlot(model_rf$finalModel)

# Створення прогнозованої тематичної мапи на основі отриманої моделі
predict_rf <- raster::predict(object = ImageStack,
  model = model_rf, type = 'raw')

# Запис отриманої тематичної мапи у файл у форматі GeoTIFF
writeRaster(predict_rf, "RFPredictMap.tif")

# ++++++
# Класифікація ДДЗ методом опорних векторів
# ++++++

# Створення набору комбінацій гіперпараметрів моделі
svm_grid <- expand.grid(cost = c(0.2, 0.5, 1),
  Loss = c("L1", "L2"))

# Створення кластеру для паралельних обчислень з використанням 3/4
# від кількості процесорів
cl <- makeCluster(3/4 * detectCores())
registerDoParallel(cl)

# Власне навчання моделі
model_svm <- caret::train(Class ~ . , method = "svmLinear3", data
  = dt_train,
  allowParallel = TRUE,
  tuneGrid = svm_grid,
  trControl = ctrl)

# Зупинка і видалення кластеру паралельних обчислень
stopCluster(cl); remove(cl)

```

```

registerDoSEQ()

# Збереження отриманої моделі у файл
saveRDS(model_svm, file = "model_svm.rds")

# Виведення оціночних параметрів моделі
# Загальний час обчислення моделі
model_svm$times$everything

# Друк результату налаштування моделі
ggplot(model_svm)

# Розрахунок матриці невідповідностей та інших оцінок моделі на
# тестових даних
cm_svm <- confusionMatrix(data = predict(model_svm, newdata =
  dt_test),
  factor(dt_test$Class))

# Виведення матриці невідповідностей та інших оцінок моделі
cm_svm

# Створення прогнозованої тематичної мапи на основі отриманої моделі
predict_svm <- raster::predict(object = ImageStack,
  model = model_svm, type = 'raw')

# Запис отриманої тематичної мапи у файл у форматі GeoTIFF
writeRaster(predict_svm, "SVMPredictMap.tif")

# ++++++
# Класифікація ДДЗ за допомогою штучної нейронної мережі
# ++++++

# Створення змінної з набором комбінацій гіперпараметрів
nnet_grid <- expand.grid(size = c(5, 10, 15),
  decay = c(0.001, 0.01, 0.1))

# Створення кластеру для паралельних обчислень з використанням 3/4
# від кількості процесорів
cl <- makeCluster(3/4 * detectCores())
registerDoParallel(cl)

# Власне навчання моделі
model_nnet <- train(Class ~ ., method = 'nnet', data = dt_train,
  importance = TRUE,
  maxit = 1000,
  allowParallel = TRUE,
  tuneGrid = nnet_grid,
  trControl = ctrl)

# Зупинка і видалення кластеру паралельних обчислень
stopCluster(cl); remove(cl)

```

```
registerDoSEQ()

# Збереження отриманої моделі у файл
saveRDS(model_nnet, file = "model_nnet.rds")

# Виведення оціночних параметрів моделі
# Загальний час обчислення моделі
model_nnet$times$everything

model_nnet$finalModel

# Друк результату налаштування моделі
ggplot(model_nnet)

# Друк зображення моделі штучної нейронної мережі
plotnet(model_nnet)

# Розрахунок матриці невідповідностей та інших оцінок моделі на
# тестових даних
cm_nnet <- confusionMatrix(data = predict(model_nnet,
                                         newdata = dt_test),
                           factor(dt_test$Class))

# Виведення матриці невідповідностей та інших оцінок моделі
cm_nnet

# Створення прогнозованої тематичної мапи на основі отриманої моделі
predict_nnet <- raster::predict(object = ImageStack,
                               model = model_nnet, type = 'raw')

# Запис отриманої тематичної мапи у файл у форматі GeoTIFF
writeRaster(predict_nnet, "NnetPredictMap.tif")
```

ДОДАТОК Б МАТРИЦІ НЕВІДПОВІДНОСТІ РЕЗУЛЬТАТІВ КЛАСИФІКАЦІЇ ДЗ

Експеримент 1

Таблиця Б.1 — Матриця невідповідностей результату класифікації за методом випадкового лісу у експерименті 1

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	969	0	2	0	0	0	0	0	0	0	0	971
AL	0	1121	0	0	0	9	0	0	0	0	0	1130
BU	0	0	980	0	1	0	2	0	1	1	0	985
Ph	0	1	0	953	0	1	0	0	0	0	0	955
P	0	0	0	0	1028	0	0	0	0	0	0	1028
R	0	12	0	0	0	1073	0	0	0	0	0	1085
S	0	0	4	0	0	0	688	0	0	1	0	693
SSt	0	0	1	0	0	0	0	606	10	0	0	617
SSt1	0	0	2	0	0	0	0	19	826	12	0	859
SSt2	0	0	0	0	0	0	5	0	2	744	0	751
W	0	0	0	0	0	0	0	0	0	0	1060	1060
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.2 — Матриця невідповідностей результату класифікації за методом опорних векторів у експерименті 1

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	629	0	2	0	0	0	3	2	0	2	0	638
AL	0	1078	0	0	0	29	0	0	0	0	0	1107
BU	5	0	896	0	6	1	1	0	1	17	0	927
Ph	183	8	2	919	4	16	0	0	0	0	0	1132
P	34	0	1	5	1019	10	0	0	0	0	13	1082

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
R	4	48	0	29	0	1027	0	0	0	0	0	1108
S	0	0	2	0	0	0	690	0	0	7	0	699
SSt	12	0	1	0	0	0	0	566	111	0	0	690
SSt1	102	0	60	0	0	0	0	57	662	32	0	913
SSt2	0	0	25	0	0	0	1	0	65	700	0	791
W	0	0	0	0	0	0	0	0	0	0	1047	1047
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.3 — Матриця невідповідностей результату класифікації штучною нейронною мережею у експерименті 1

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	969	0	2	0	0	0	0	0	0	0	0	971
AL	0	1128	0	0	0	8	0	0	0	0	0	1136
BU	0	0	981	0	0	0	2	1	1	0	0	985
Ph	0	1	0	953	0	2	0	0	0	0	0	956
P	0	0	2	0	1029	0	0	0	0	0	0	1031
R	0	5	0	0	0	1073	0	0	0	0	0	1078
S	0	0	2	0	0	0	691	0	0	2	0	695
SSt	0	0	0	0	0	0	0	616	7	0	0	623
SSt1	0	0	1	0	0	0	0	8	827	8	0	844
SSt2	0	0	1	0	0	0	2	0	4	748	0	755
W	0	0	0	0	0	0	0	0	0	0	1060	1060
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Експеримент 2

Таблиця Б.4 — Матриця невідповідностей результату класифікації за методом випадкового лісу у експерименті 2

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	927	0	0	0	0	19	0	0	0	1	0	947
AL	3	976	0	1	68	16	0	0	0	0	1	1065
BU	0	0	981	0	0	0	2	0	2	1	0	986
Ph	0	7	1	938	10	0	0	1	0	0	1	958
P	0	98	0	13	949	0	0	0	0	0	2	1062
R	30	53	0	1	2	1038	0	0	0	0	0	1124
S	0	0	0	0	0	0	687	0	0	1	0	688
SSt	0	0	1	0	0	10	0	590	22	0	0	623
SSt1	0	0	5	0	0	0	0	34	810	11	2	862
SSt2	9	0	1	0	0	0	6	0	5	744	0	765
W	0	0	0	0	0	0	0	0	0	0	1054	1054
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.5 — Матриця невідповідностей результату класифікації за методом опорних векторів у експерименті 2

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	652	6	7	76	0	76	6	74	181	37	0	1115
AL	8	769	0	64	392	32	0	0	0	0	2	1267
BU	0	0	917	0	7	0	4	0	5	32	0	965
Ph	0	15	4	437	8	16	0	1	0	0	3	484
P	0	228	0	113	604	0	0	0	0	0	9	954
R	72	116	0	0	16	943	0	106	1	0	0	1254
S	0	0	0	0	0	0	685	0	0	12	0	697
SSt	117	0	0	165	2	16	0	327	25	0	0	652

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
SSt1	74	0	32	98	0	0	0	117	548	11	0	880
SSt2	46	0	5	0	0	0	0	0	79	666	7	803
W	0	0	24	0	0	0	0	0	0	0	1039	1063
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.6 — Матриця невідповідностей результату класифікації штучною нейронною мережею у експерименті 2

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	939	0	1	0	0	26	1	0	0	0	0	967
AL	0	957	0	7	64	27	0	0	0	0	0	1055
BU	0	0	978	0	0	0	2	1	3	0	0	984
Ph	0	6	1	927	8	1	0	0	0	0	3	946
P	0	119	0	13	954	0	0	0	0	0	0	1086
R	23	52	0	3	3	1022	0	1	1	0	0	1105
S	0	0	0	0	0	0	688	0	0	1	0	689
SSt	0	0	0	3	0	7	0	595	27	0	0	632
SSt1	0	0	6	0	0	0	0	28	805	7	1	847
SSt2	7	0	3	0	0	0	4	0	3	750	0	767
W	0	0	0	0	0	0	0	0	0	0	1056	1056
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Експеримент 3

Таблиця Б.7 — Матриця невідповідностей результату класифікації за методом випадкового лісу у експерименті 3

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	949	0	5	2	2	0	1	0	14	2	0	975
AL	0	1050	0	0	0	131	0	0	0	0	0	1181
BU	1	0	974	0	4	0	2	1	0	0	0	982
Ph	4	4	0	948	0	3	0	0	0	0	0	959
P	0	0	2	0	1023	0	0	0	0	0	0	1025
R	0	80	0	3	0	949	0	0	0	0	0	1032
S	0	0	2	0	0	0	689	0	0	1	0	692
SSt	1	0	0	0	0	0	0	590	36	0	0	627
SSt1	14	0	5	0	0	0	0	34	785	17	0	855
SSt2	0	0	1	0	0	0	3	0	4	738	0	746
W	0	0	0	0	0	0	0	0	0	0	1060	1060
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.8 — Матриця невідповідностей результату класифікації за методом опорних векторів у експерименті 3

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	463	0	19	0	1	0	2	5	57	22	0	569
AL	2	941	0	37	0	234	0	0	0	0	0	1214
BU	0	0	903	0	15	0	4	0	0	14	0	936
Ph	139	12	2	856	0	23	0	0	0	0	0	1032
P	3	0	3	35	1008	0	0	0	0	0	36	1085
R	2	181	0	25	0	826	0	0	0	0	0	1034
S	0	0	0	0	0	0	688	0	0	4	0	692
SSt	130	0	4	0	4	0	0	550	108	0	0	796

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
SSt1	189	0	51	0	1	0	0	70	597	7	0	915
SSt2	41	0	6	0	0	0	1	0	77	711	0	836
W	0	0	1	0	0	0	0	0	0	0	1024	1025
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.9 — Матриця невідповідностей результату класифікації штучною нейронною мережею у експерименті 3

Прогнозований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	953	0	5	1	2	0	0	0	20	1	0	982
AL	0	1047	0	0	0	118	0	0	0	0	0	1165
BU	1	0	973	0	3	0	1	1	2	0	0	981
Ph	4	1	0	950	0	2	0	0	0	0	0	957
P	2	0	5	0	1024	0	0	0	0	0	0	1031
R	0	86	0	2	0	963	0	0	0	0	0	1051
S	0	0	1	0	0	0	692	0	0	1	0	694
SSt	2	0	0	0	0	0	0	584	37	0	0	623
SSt1	7	0	5	0	0	0	0	40	772	14	0	838
SSt2	0	0	0	0	0	0	2	0	8	742	0	752
W	0	0	0	0	0	0	0	0	0	0	1060	1060
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Експеримент 4

Таблиця Б.10 — Матриця невідповідностей результату класифікації за методом випадкового лісу у експерименті 4

Прогнозований клас	Справжній клас											Разом:
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	
AG	870	0	5	4	0	5	0	8	37	3	0	932
AL	0	1088	0	0	17	22	0	0	0	0	0	1127
BU	1	0	965	0	1	0	0	0	1	2	1	971
Ph	2	6	0	908	5	37	0	0	0	0	0	958
P	0	26	0	0	993	7	0	0	0	0	0	1026
R	0	14	1	41	12	1004	0	16	0	0	0	1088
S	0	0	3	0	0	0	684	0	0	4	0	691
SSt	21	0	4	0	0	8	0	564	46	0	0	643
SSt1	72	0	8	0	0	0	0	37	751	12	0	880
SSt2	3	0	2	0	0	0	11	0	4	737	0	757
W	0	0	1	0	1	0	0	0	0	0	1059	1061
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.11 — Матриця невідповідностей результату класифікації за методом опорних векторів у експерименті 4

Прогнозований клас	Справжній клас											Разом:
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	
AG	809	0	15	0	0	2	6	164	579	110	0	1685
AL	0	1025	0	1	3	53	0	0	0	0	0	1082
BU	0	0	887	0	2	0	3	0	19	53	21	985
Ph	69	9	1	624	19	113	0	0	0	0	0	835
P	0	96	0	0	993	46	0	0	0	0	7	1142
R	2	4	0	322	12	853	0	154	7	0	0	1354
S	6	0	4	0	0	0	683	0	0	6	0	699
SSt	27	0	8	6	0	12	0	251	2	0	0	306

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
SSt1	25	0	36	0	0	4	0	56	163	3	0	287
SSt2	31	0	13	0	0	0	3	0	69	586	0	702
W	0	0	25	0	0	0	0	0	0	0	1032	1057
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134

Таблиця Б.12 — Матриця невідповідностей результату класифікації штучною нейронною мережею у експерименті 4

Прогно- зований клас	Справжній клас											
	AG	AL	BU	Ph	P	R	S	SSt	SSt1	SSt2	W	Разом:
AG	843	0	3	4	0	3	0	11	54	0	0	918
AL	0	1096	0	0	27	13	0	0	0	0	0	1136
BU	1	0	966	0	0	0	1	0	2	0	7	977
Ph	3	7	1	922	6	29	0	0	0	0	0	968
P	0	24	0	1	990	4	0	0	0	0	0	1019
R	0	7	0	26	6	1024	0	15	0	0	0	1078
S	0	0	5	0	0	0	686	0	0	6	0	697
SSt	19	0	2	0	0	10	0	556	52	0	0	639
SSt1	97	0	6	0	0	0	0	43	726	13	0	885
SSt2	6	0	4	0	0	0	8	0	5	739	0	762
W	0	0	2	0	0	0	0	0	0	0	1053	1055
Разом:	969	1134	989	953	1029	1083	695	625	839	758	1060	10134