

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

Кваліфікаційна наукова
праця на правах рукопису

ШЕВЦОВА ОЛЬГА СЕРГІЇВНА

УДК 004.932.72'1: 519.688

**ДИСЕРТАЦІЯ
ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ПОПЕРЕДНЬОЇ ОБРОБКИ ТА
КЛАСИФІКАЦІЇ РІЗНОЧАСОВИХ СУПУТНИКОВИХ ЗОБРАЖЕНЬ
ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ**

122 – Комп'ютерні науки

12 – Інформаційні технології

Подається на здобуття наукового ступеня **доктора філософії**

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

 О.С. Шевцова

Науковий керівник: **ГНАТУШЕНКО Володимир Володимирович**,
доктор технічних наук, професор

Дніпро – 2024

АНОТАЦІЯ

Шевцова О.С. Інформаційна технологія попередньої обробки та класифікації різночасових супутникових зображень високої просторової розрізненості. – Рукопис

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 122 – Комп'ютерні науки. – Національний технічний університет «Дніпровська політехніка», Дніпро, 2024.

В дисертаційному дослідженні розв'язана важлива науково-прикладна задача підвищення точності, рівня автоматизації та швидкодії розпізнавання та класифікації зображень високої просторової розрізненості шляхом розробки інформаційних технологій і методів обробки з використанням машинного навчання.

Дисертація складається зі вступу, чотирьох розділів, висновків, списку використаних джерел та додатків. Повний обсяг дисертації – 165 сторінок; список використаних джерел зі 136 найменувань, 2 додатків. Робота проілюстрована 40 рисунками та містить 12 таблиць.

У вступі обґрунтовано актуальність теми, сформульовані мета і завдання досліджень, визначені методи досліджень, дана загальна характеристика роботи і структура дисертації, визначені наукова новизна, практичне значення проведених наукових досліджень та особистий внесок автора, оцінена достовірність отриманих результатів, наведені відомості про публікації та результати апробації та впровадження роботи.

У першому розділі розглянуто сучасний стан розвитку методів і технологій попередньої обробки та класифікації різночасових супутникових даних високої просторової розрізненості і відповідного існуючого математичного та програмного забезпечення, яке використовується для розробки подібних технологій. Проаналізовані методи, що базуються на штучному інтелекті, сучасні підходи глибокого навчання та останні тенденції у розвитку штучних нейронних мереж. Проведений аналіз сучасного стану

проблеми попередньої обробки та класифікації зображень дистанційного зондування Землі високого просторового розрізнення та аналіз літературних джерел виявили неефективність застосування існуючих методів, що веде до численних похибок класифікації, та визначили низку нерозв'язаних питань, зокрема відсутність автоматизованих інформаційних технологій, які дозволяють проводити класифікацію багатоспектральних різночасових супутникових зображень високої просторової розрізненості у реальному режимі часу. Існуючі рішення, як правило, є дорогі, трудомісткими та з використанням ручного дешифрування. Сформульовані висновки та постановка завдання про необхідність розробки комплексної інформаційної технології попередньої обробки, аналізу та класифікації супутникових зображень.

У другому розділі здійснено аналіз проблеми та сучасних підходів обробки великих даних дистанційного зондування Землі. Надані основні поняття й визначення, що використовуються для її розв'язання. Описано властивості організації даних, що дозволяють передбачити результат виконання певних операцій в структурі за її елементами, використовуючи їх розташування без виконання обчислювального алгоритму. Отримано висновки про вплив властивостей та математичних методів роботи зі структурою. Запропоновано та доведено ефективність методу оптимізації основних характеристик обробки великих даних на основі застосування короткої структури організації даних, який дозволяє зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних при збереженні їх відповідних значень та надійності. Запропоновано та доведено ефективність IaaS-рішення для обробки потоку даних дистанційного зондування на основі глибокого навчання та хмарних технологій Kubernetes та Apache Airflow, розміщених на платформі Google Cloud Platform. Запропонований алгоритм представлений у вигляді прямого ациклічного графа у застосунку IaaS. Згадані хмарні технології використовуються для кращого представлення робочого процесу, який

реалізує складну систему паралельного виконання обчислювально-важких завдань обробки зображень високої просторової розрізненості.

У третьому розділі запропоновано комплексний підхід до обробки зображень високої просторової розрізненості на основі застосування штучного інтелекту та класичних алгоритмів обробки зображень. Застосування підходу дозволяє автоматизувати процес семантичної сегментації та аналізу багатоканальних даних високої просторової розрізненості, підвищити якість подальшого розпізнавання і моніторингу об'єктів земної поверхні. Розроблено архітектуру згорткової мережі для задач семантичної сегментації супутникових зображень високої просторової розрізненості, запропоновано методику підготовки набору вхідних даних та поетапної реалізації каскадів шарів мережі, алгоритм її навчання, обґрунтовано вибір навчальної вибірки. Семантичні ознаки використовуються для зменшення помилок семантичного рівня контуру. Результати комп'ютерних експериментів підтвердили висновок, що запропонована технологія може ефективно покращити загальну точність сегментації зображень дистанційного зондування високої просторової розрізненості та скоротити загальний час навчання та час відповідної обробки.

Четвертий розділ роботи присвячений класифікації аерокосмічних зображень високої просторової розрізненості при вирішенні практичних завдань. Запропоновано та досліджено інформаційну технологію класифікації аерокосмічних зображень високої просторової розрізненості на основі згорткової нейронної мережі. Доведено ефективність розробленої інформаційної технології класифікації аерокосмічних зображень високої просторової розрізненості при вирішенні практичних завдань, зокрема для розпізнавання і визначення контурів об'єктів забудови на знімках з БПЛА. Тренування мережі проводилося на рівні пікселів, що дозволило підвищити точність ідентифікації об'єктів забудови та зменшити кількість неправильно класифікованих зон. Експериментальні результати показали значне

покращення точності розпізнавання будівель у загальнодоступному наборі даних. Розроблено та досліджено інформаційну технологію розпізнавання та моніторингу водних об'єктів на оптичних різночасових супутникових зображеннях високої просторової розрізненості із залученням методів машинного навчання, використання якої дозволяє отримати результати з субпіксельною точністю, забезпечуючи важливу інформацію для подальших досліджень та прийняття рішень. Інформаційна технологія класифікації зображень реалізована у вигляді окремого програмного продукту із використанням сучасних методів програмування, що дозволило полегшити виконання класифікації супутникових зображень та зменшити вимоги до кваліфікації користувача.

Впровадження розроблених в процесі дослідження інформаційних технологій, методів розпізнавання та класифікації супутникових зображень і заснованого на них програмного забезпечення при їх використанні на підприємствах дозволило значно скоротити час обробки результатів дистанційного зондування Землі, зменшити вартість процесу та підвищити точність класифікації.

Ключові слова: інформаційна технологія, обробка, машинне навчання, нейронна мережа, класифікація, сегментація, супутникові зображення, розпізнавання.

SUMMARY

Shevtsova O.S. Information technology for pre-processing and classification of multi-time satellite images of high spatial resolution. – Manuscript

Thesis for scientific degree of Doctor of Philosophy in the specialty 122 «Computer Science». – Dnipro University of Technology, Dnipro, 2024.

The dissertation research solved an important scientific and applied problem of increasing the accuracy, level of automation and speed of recognition and classification of images of high spatial fragmentation by developing information technologies and processing using machine learning.

The dissertation consists of an introduction, four chapters, a conclusion, a list of sources used and appendices. The full volume of the dissertation is 165 pages; list of used sources of 136 titles, 2 appendices. The work is illustrated with 40 drawings and contains 12 tables.

In the introduction, the relevance of the topic is substantiated, the research objectives and tasks are formulated, the research methods are defined, and a general description of the work and the structure of the dissertation are given. The scientific novelty, practical significance of the conducted research, and the author's personal contribution are determined, the reliability of the obtained results is assessed, and information about publications and the results of the approbation and implementation of the work is provided.

The first chapter examines the current state of the development of methods and technologies for the preliminary processing and classification of high spatial resolution satellite data, as well as the existing mathematical and software tools used for developing such technologies. Methods based on artificial intelligence, modern deep learning approaches, and the latest trends in the development of artificial neural networks are analyzed. An analysis of the current state of the problem of preliminary processing and classification of high spatial resolution Earth remote sensing images and a review of the literature revealed the inefficiency

of existing methods, leading to numerous classification errors, and identified several unresolved issues, particularly the lack of automated information technologies that allow real-time classification of multispectral, multitemporal high spatial resolution satellite images. Existing solutions are generally costly, labor-intensive, and involve manual decryption. Conclusions and the formulation of the task regarding the need to develop a comprehensive information technology for the preliminary processing, analysis, and classification of satellite images are presented.

In the second chapter, an analysis of the problem and modern approaches to processing extensive Earth remote sensing data is carried out. Basic concepts and definitions used for its solution are provided. The properties of the data organization are described, allowing to predict the result of performing certain operations in the structure on its elements, using their arrangement without performing a computational algorithm. Conclusions about the influence of properties and methods of working with the structure were obtained. The effectiveness of the method of optimizing the main characteristics of big data processing based on the application of a tuple structure of data organization, which allows to reduce the amount of processed information, to increase the speed of data search and processing while preserving their respective values and reliability, is proposed and proven. The effectiveness of an IaaS solution for remote sensing data flow processing based on deep learning and Kubernetes and Apache Airflow cloud technologies, hosted on the Google Cloud Platform, is proposed and proven. The proposed algorithm is presented in the form of a directed acyclic graph in an IaaS application. The mentioned cloud technologies are used for a better representation of the working process, which implements a complex system of parallel execution of computationally difficult tasks of high spatial resolution image processing.

The third chapter proposes an integrated approach to processing high spatial resolution images based on the use of artificial intelligence and classical image processing algorithms. The use of the approach allows you to automate the process of semantic segmentation and analysis of multi-channel data of high spatial

resolution, improve the quality of further recognition and monitoring of objects on the earth's surface. A convolutional network architecture has been developed for the tasks of semantic segmentation of satellite images of high spatial resolution, a methodology for preparing a set of input data and step-by-step implementation of cascades of network layers, an algorithm for its training have been proposed, and the choice of a training sample has been justified. Semantic features are used to reduce semantic contour level errors. The results of computer experiments confirmed that the proposed technology can effectively improve the overall segmentation accuracy of high spatial resolution remote sensing images and reduce the overall training time and related processing time.

The fourth chapter of the work is devoted to the classification of aerospace images of high spatial resolution in solving practical problems. An information technology for classifying aerospace images of high spatial resolution based on a convolutional neural network has been proposed and studied. The effectiveness of the developed information technology for classifying aerospace images of high spatial resolution has been proven in solving practical problems, in particular, for recognizing and determining the contours of building objects in images from UAVs. Network training was carried out at the pixel level, which made it possible to increase the accuracy of identification of building objects and reduce the number of incorrectly classified zones. Experimental results showed a significant improvement in building recognition accuracy on a public dataset. An information technology for recognizing and monitoring water bodies on optical multi-temporal satellite images of high spatial resolution using machine learning has been developed and studied, the use of which allows obtaining results with sub-pixel accuracy, providing important information for further research and decision-making. Information technology for image classification is implemented as a separate software product using modern programming methods, which makes it easier to classify satellite images and reduce the requirements for user qualifications.

The information technologies and methods for recognizing and classifying satellite images developed during the research, along with the software created based on them, when used in enterprises, significantly reduced the processing time of Earth remote sensing results, lowered the cost of the process, and improved classification accuracy.

Key words: information technology, processing, machine learning, neural network, classification, segmentation, satellite images, recognition.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Публікації у виданнях, включених до переліку наукових фахових видань

України:

1. Гнатушенко В.В., Гненний І.О., Удовик І.М., **Шевцова О.С.** Сегментація аерокосмічних зображень з використанням згорткових нейронних мереж. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 6 (137). - Дніпро, 2021. - С.24 - 33. doi: [10.34185/1562-9945-6-137-2021-03](https://doi.org/10.34185/1562-9945-6-137-2021-03) [Index Copernicus, Google Scholar]
2. Каштан В., Гнатушенко В., Удовик І., **Шевцова О.** (2023). Нейромережеве розпізнавання об'єктів забудови на аерофото знімках. Information Technology: Computer Science, Software Engineering and Cyber Security, 1, 30–39. doi: <https://doi.org/10.32782/IT/2023-1-5>. [Index Copernicus, Google Scholar]
3. Каштан В., Гнатушенко В., Удовик І., **Шевцова О.** (2023). Розпізнавання та моніторинг водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання. Information Technology: Computer Science, Software Engineering and Cyber Security, 3, 32–42, doi: [10.32782/IT/2023-3-4](https://doi.org/10.32782/IT/2023-3-4) [Index Copernicus, Google Scholar]
4. Каштан В., **Шевцова О.** (2024). Інформаційна технологія попередньої обробки супутникових знімків з використанням згорткової нейронної мережі. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 1 (150). - Дніпро, 2024. С.36–50. doi: [10.34185/1562-9945-1-150-2024-04](https://doi.org/10.34185/1562-9945-1-150-2024-04) [Index Copernicus, Google Scholar]
5. Гончаров О.Г., Гнатушенко В.В., **Шевцова О.** (2024). Нейромережевий підхід сегментації сільськогосподарських угідь на супутникових зображеннях. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 4 (153). - Дніпро, 2024. С.87–101. doi: [10.34185/1562-9945-4-153-2024-09](https://doi.org/10.34185/1562-9945-4-153-2024-09) [Index Copernicus, Google Scholar]

Публікації в іноземних наукових виданнях, включених до наукометричної бази Scopus:

6. Zhernovyi V., Hnatushenko V., **Shevtsova O.** (2023). IaaS-Application Development for Paralleled Remote Sensing Data Stream Processing. In: Babichev, S., Lytvynenko, V. (eds) Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. Lecture Notes on Data Engineering and Communications Technologies, vol 149. Springer, Cham. https://doi.org/10.1007/978-3-031-16203-9_39. [Scopus]
7. Syrotkina O., Aleksieiev M., Moroz B., Matsiuk S., **Shevtsova O.** and Kozlovskiy A. Mathematical Methods for Optimizing Big Data Processing. 10th International Conference on Advanced Computer Information Technologies (ACIT), 2020, pp. 170-176, doi: [10.1109/ACIT49673.2020.9208940](https://doi.org/10.1109/ACIT49673.2020.9208940). [Scopus]
8. Hnatushenko V., Zhernovyi V., Udovik I., **Shevtsova O.** Intelligent System for Building Separation on a Semantically Segmented Map. International Workshop on Intelligent Information Technologies & Systems of Information Security (IntelITSIS-2021), Khmelnytskyi, Ukraine. <http://ceur-ws.org/Vol-2853/keynote1.pdf>. [Scopus]

Публікації у матеріалах наукових конференцій:

9. Гнатушенко В.В., Луцик Д.М, **Шевцова О.С.** Нейромережеве розпізнавання об'єктів військової техніки на супутникових зображеннях. Проблеми використання інформаційних технологій в освіті, науці та промисловості: XVI міжн. конф. (15-17 грудня 2021 р.). НТУ «Дніпровська політехніка». – Дніпро: 2021. №6. С. 57–60. <https://ir.nmu.org.ua/handle/123456789/165809>
10. Гнатушенко В.В., Грищак Д.Д., **Шевцова О.С.** Розпізнавання зелених насаджень із застосуванням геоінформаційних технологій. Проблеми

використання інформаційних технологій в освіті, науці та промисловості:
XVII міжнар. конф. (24 листопада 2022 р., м. Дніпро): зб. наук. пр.
[Електронний ресурс] / ред. кол.: О.О. Азюковський та ін.; М-во освіти і
науки України, Нац. техн. ун-т «Дніпровська політехніка». – Електрон.
текст. дані – Дніпро: НТУ «ДП», 2023. – № 7.С. 24–26.

https://ir.nmu.org.ua/jspui/bitstream/123456789/163499/4/konfer_2022.pdf

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	16
ВСТУП	18
РОЗДІЛ 1	
ОГЛЯД СУЧАСНОГО СТАНУ ПРОБЛЕМИ ПОПЕРЕДНЬОЇ ОБРОБКИ ТА КЛАСИФІКАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ	26
1.1. Основні характеристики супутникових зображень	26
1.2. Основні етапи попередньої обробки супутникових зображень	30
1.3. Сучасні тенденції у розробці алгоритмів попередньої обробки аерокосмічних зображень.....	32
1.4. Класифікація супутникових зображень	33
1.4.1. Визначення та роль класифікації супутникових зображень	33
1.4.2. Основні методи класифікації зображень	34
1.5. Семантична сегментація супутникових зображень.....	37
1.6. Основні платформи та проекти обробки та аналізу супутникових зображень	41
1.7. Проблеми та виклики у класифікації супутникових даних високої просторової розрізненості	43
1.8. Постановка задачі та теоретичний апарат дослідження	45
1.9. Висновки до першого розділу.....	47
РОЗДІЛ 2	
ОБРОБКА РІЗНОЧАСОВИХ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ	49
2.1. Метод оптимізації обробки великих даних дистанційного зондування Землі.....	49
2.1.1. Дослідження проблеми обробки великих даних ДЗЗ.....	49
2.1.2. Визначення структури організації даних.....	53

2.1.3. Основні властивості методу	56
2.1.4. Практичні результати.....	62
2.2. Infrastructure-as-a-service для обробки потоку даних дистанційного зондування	65
2.2.1. Розробка архітектури даних	66
2.2.2. Завантаження даних	67
2.2.3. Розрахунок кластера робочого навантаження Kubernetes	67
2.2.4. Планування робочого циклу	69
2.2.5. Розрахунок обчислювальних витрат	72
2.3. Інформаційна технологія попередньої обробки супутникових зображень з використанням згорткової нейронної мережі.....	74
2.3.1. Розробка інформаційної технології	74
2.3.2. Експериментальні результати	80
2.4. Висновки до другого розділу	87
 РОЗДІЛ 3	
РОЗРОБКА НЕЙРОМЕРЕЖЕВОЇ ТЕХНОЛОГІЇ.....	89
СЕМАНТИЧНОЇ СЕГМЕНТАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ	
ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ	89
3.1. Автоматизована нейромережева технологія семантичної сегментації зображень дистанційного зондування	89
3.1.1. Переваги машинного навчання для семантичної сегментації супутникових зображень	89
3.1.2. Підготовка набору даних	90
3.1.3. Архітектура мережі	92
3.2. Технологія пост-обробки результатів сегментації	97
3.2.1. Поділ на окремі об'єкти.....	97
3.2.2. Вимірювання наземних об'єктів та щільності забудови	99
3.3. Експериментальна перевірка	100
3.4. Висновки до третього розділу	103

РОЗДІЛ 4

КЛАСИФІКАЦІЯ АЕРОКОСМІЧНИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ ЗДАТНОСТІ ПРИ ВИРІШЕННІ ПРАКТИЧНИХ

ЗАВДАНЬ 105

4.1. Інформаційна технологія нейромережевої класифікації аерокосмічних
зображень 106

4.2. Розпізнавання та моніторинг водних об'єктів на оптичних супутникових
зображеннях з використанням машинного навчання..... 118

4.2.1. Необхідність і передумови ефективного моніторингу водних
об'єктів 118

4.2.2. Інформаційна технологія моніторингу водних об'єктів 120

4.2.3. Тестування запропонованої технології 125

4.2.4. Оцінка отриманих результатів 125

4.3 Розробка програмного модулю класифікації зображень з використанням
нейронних мереж..... 131

4.4. Висновки до четвертого розділу..... 135

ВИСНОВКИ 138

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ 142

ДОДАТОК А

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ АВТОРА ЗА ТЕМОЮ

ДИСЕРТАЦІЇ 159

ДОДАТОК Б

ДОКУМЕНТИ ЩОДО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ

ДОСЛІДЖЕНЬ 163

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

DL	Deep Learning (глибоке навчання)
DMP	Диференційний Морфологічний Профіль
DNN	Deep Neural Network (мережа глибокого навчання)
DDNN	distributed deep neural networks (розподілена мережа глибокого навчання)
GIFOV	instantaneous Field of View (миттєве поле зору)
CIR	Color infrared
GPS	Global Positioning System (глобальні позиційні системи)
GRC	General Rectangularity Coefficient
GRN	green – зелений канал багатоспектрального зображення
GSI	Ground Sampling Interval (наземний інтервал дискретизації)
HIS	Hue, Saturation, Intensity – адитивна кольорова модель (тон, насиченість, світлота)
HSV	Hue, Saturation, Value – кольорова модель (тон, насиченість, значення кольору)
ISPRS	International Society for Photogrammetry and Remote Sensing (Міжнародне товариство з фотограмметрії та дистанційного зондування)
KC	Kubernetes cluster
MSS	Multispectral Scanner – мультиспектральний сканер
MSI	Morphological Shadow Index – морфологічний індекс тіні
MWIR	Midwave Infrared (Середньохвильовий інфрачервоний)
NDVI	Normalized Difference Vegetation Index – нормалізований різницевий VI
NIR	Near InfraRed – ближній інфрачервоний канал багатоспектрального зображення

RED	red – червоний канал багатоспектрального зображення
RGB	Red, Green, Blue – адитивна кольорова модель (червоний, зелений, синій)
SVM	support vector machine – метод опорних векторів
SWIR	Shortwave infrared (короткохвильовий інфрачервоний)
TIR	тепловий інфрачервоний
VNIR	Visible and Near Infrared – видимий і ближній інфрачервоний
БЗ	багатоканальне зображення
БПЛА	безпілотний літальний апарат
ГІС	геоінформаційна система
ДЗЗ	дистанційне зондування Землі
ЗС	знімальна система
КА	космічний апарат
ПЗ	панхроматичне зображення
ПЗЗ	прилад із зарядовим зв'язком

ВСТУП

Актуальність теми. Сучасні супутникові системи забезпечують отримання зображень високої просторової розрізненості, що дозволяє отримувати деталізовану інформацію про земну поверхню. Класифікація зображень дистанційного зондування полягає в ідентифікації та класифікації інформації про поверхню Землі та її оточуюче середовище. Класифікація супутникових зображень має широкий спектр застосувань, включаючи сільське господарство, геологію, моніторинг довкілля, оборонну та безпекову сфери, що робить дослідження важливим для різних галузей. Комп'ютерна класифікація зображень дистанційного зондування є специфічним застосуванням технології автоматичного розпізнавання образів у сфері дистанційного зондування.

Супутникові зображення часто піддаються різноманітним джерелам шуму, таким як атмосферні впливи, сенсорні артефакти та інші фактори. Крім того, зображення одержуються з різних джерел або у різний час, що може призводити до різних характеристик інтенсивності та кольору. Попередня обробка дозволяє нормалізувати ці характеристики та уніфікувати дані для більш точного подальшого тематичного аналізу. Крім того, з розвитком космічних технологій обсяги геопросторових даних, отриманих супутниковими системами високої просторової розрізненості, значно зростають. Із збільшенням обсягів даних виникає потреба в швидких та точних методах попередньої обробки. Розробка ефективних алгоритмів автоматизованої попередньої обробки та класифікації супутникових зображень стає критичною для швидкого аналізу та прийняття рішень.

Наукові роботи вітчизняних та закордонних дослідників, зокрема Бурштинської Х.В., Гнатушенка В.В., Корчинського В.М., Куцуль Н.М., Лялька В.І., Попова М.О., Станкевича С.А., Скакуна С.В., Путятіна Є.П., Шелестова А.Ю., Шухостанова В.К., Li H.Y., Xiao Y., Heipke C. Wei Y., Kim T., Lee D., Wang J., Huang X. та їх учнів, присвячені вирішенню проблеми

автоматизованого розпізнавання та класифікації об'єктів земної поверхні на супутникових зображеннях в основному середнього просторового розрізнення та не враховують специфіку аналізу різночасових знімків високої та надвисокої просторової розрізненості. Автоматизована класифікація різночасових супутникових знімків високої просторової розрізненості не є ефективною через високу неоднорідність їх спектральних, текстурних та просторових характеристик, наявність тіней на зображеннях та інших факторів.

Наведений короткий аналіз сучасного стану в галузі класифікації фотограмметричних різночасових зображень високої просторової розрізненості дає підстави щодо актуальності вирішення суттєвої науково-прикладної задачі підвищення ефективності автоматизованої попередньої обробки та точності класифікації супутникових зображень високої просторової розрізненості шляхом розробки відповідної інформаційної технології на основі машинного навчання.

Зв'язок роботи з науковими програмами, планами, темами.

Обраний напрямок досліджень пов'язаний із виконанням автором науково-дослідних робіт кафедри програмного забезпечення комп'ютерних систем НТУ «Дніпровська політехніка» «Методи, моделі та технології обробки даних в комп'ютерних системах загального та спеціального призначення» (державний реєстраційний номер 0121U113718), «Високопродуктивні багатопроцесорні системи: особливості конструювання, дослідження оцінок ефективності, застосування до розв'язування прикладних задач» (державний реєстраційний номер 0122U201569) та кафедри інформаційних технологій та комп'ютерної інженерії «Моделі й інформаційні технології обробки та аналізу даних в складних комп'ютерних системах і мережах» (Е-366, реєстраційний номер 0121U114523, 2021-2024 рр.).

Мета і задачі дослідження. Метою дисертаційної роботи є підвищення точності, рівня автоматизації та швидкодії класифікації різночасових

супутникових зображень високої просторової розрізненості шляхом розробки інформаційної технології їх попередньої обробки, аналізу та розпізнавання з використанням машинного навчання.

Для досягнення поставленої мети дослідження необхідно вирішити наступні задачі:

- 1) дослідити сучасний стан інформаційних технологій класифікації супутникових зображень високої просторової розрізненості, провести аналіз існуючого математичного та програмного забезпечення, яке використовується для розробки подібних технологій;
- 2) здійснити аналіз проблеми та сучасних методів обробки великих даних ДЗЗ, розробити метод оптимізації основних характеристик великих обсягів даних, який дозволить зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних при збереженні їх відповідних значень та надійності;
- 3) розробити інформаційну технологію попередньої обробки багатоканальних супутникових зображень з використанням згорткової нейронної мережі, що дозволить підвищити інформативність первинних даних;
- 4) на базі запропонованих алгоритмів та методів розробити автоматизовану інформаційну технологію класифікації різночасових супутникових зображень високої просторової розрізненості;
- 5) провести тестування розробленої інформаційної технології на різних сценах ДЗЗ, провести оцінку якості та інтерпретації отриманих результатів розпізнавання та класифікації при вирішенні практичних завдань.

Об'єкт дослідження – процес комп'ютерного розпізнавання та класифікації аерокосмічних зображень високої просторової розрізненості.

Предмет дослідження – методи та засоби інформаційної технології попередньої обробки та класифікації різночасових супутникових зображень високої просторової розрізненості з використанням нейронних мереж.

Методи дослідження. Теоретичну та методологічну основу роботи складають методи цифрової обробки зображень та комп'ютерного зору, методи машинного навчання, принципи побудови згорткових нейронних мереж, теорія алгоритмів та принципи функціонального й об'єктно-орієнтовного програмування для побудови програмного забезпечення.

Наукова новизна одержаних результатів полягає в тому, що:

Вперше:

- запропоновано метод оптимізації основних характеристик обробки великих даних на основі застосування кортежної структури організації даних, який дозволяє зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних дистанційного зондування при збереженні їх відповідних значень та надійності;

- розроблено інформаційну технологію попередньої обробки цифрових супутникових зображень високої просторової розрізненості з використанням згорткової нейронної мережі, яка здатна ефективно вилучати деталі текстури та просторові залежності. Запропонована технологія забезпечує підвищення просторової розрізненості мультиспектральних супутникових зображень, що дозволило, у порівнянні з класичними методами злиття, зменшити артефакти супутникових зображень;

- розроблено інформаційну технологію класифікації різночасових супутникових зображень високої просторової розрізненості на базі запропонованої нейромережевої архітектури. Запропонована технологія дозволяє покращити загальну точність класифікації різночасових аерокосмічних зображень високої просторової розрізненості та скоротити загальний час навчання та відповідної обробки.

Вдосконалено:

- архітектуру згорткової мережі на базі U-Net для задач семантичної сегментації супутникових зображень високої просторової розрізненості, запропоновано підхід до підготовки набору вхідних даних та поетапної реалізації каскадів шарів мережі, алгоритм її навчання, обґрунтовано вибір навчальної вибірки;

- метод автоматизованого розпізнавання об'єктів забудови на цифрових аерофотознімках на основі згорткової нейронної мережі, тренування якої проводилося на рівні пікселів, що дозволило підвищити точність ідентифікації об'єктів забудови та зменшити кількість неправильно класифікованих зон. Експериментальні результати показали значне покращення точності розпізнавання будівель у загальнодоступному наборі даних, зокрема, метрики OA, AA та K покращилися на 2.6%, 5.6% та 3.2% відповідно для навчального набору даних і на 1.2%, 1.8% та 1.5% для тестового набору даних;

- інформаційну технологію розпізнавання та моніторингу водних об'єктів на різночасових оптичних супутникових зображеннях високої просторової розрізненості на основі машинного навчання, використання якої дозволило отримати результати з субпіксельною точністю, забезпечуючи важливу інформацію для подальших досліджень та прийняття рішень. Коефіцієнт Каппа, який враховує ступінь узгодженості між реальною та передбачуваною класифікацією, підтвердив високу стабільність та достовірність підходу (0.94).

Набули подальшого розвитку:

- комплексний підхід до обробки зображень високої просторової розрізненості на основі застосування штучного інтелекту та класичних алгоритмів обробки зображень, що включає попередню обробку даних, розробку набору даних для нейронної мережі, моделювання нейронної мережі та розрахунок фізичних розмірів наземних об'єктів. Застосування підходу дозволяє автоматизувати процес семантичної сегментації та аналізу

багатоканальних даних високої просторової розрізненості, підвищити якість подальшого розпізнавання і моніторингу об'єктів земної поверхні;

- рішення у вигляді інфраструктури як сервісу IaaS для алгоритму обробки потоків даних дистанційного зондування Землі з використанням глибокого навчання і хмарних технологій Kubernetes і Apache Airflow, розміщеними на обчислювальній платформі Azure.

Практичне значення одержаних результатів визначається суттєвим підвищенням ефективності попередньої обробки та класифікації цифрових різночасових супутникових зображень, теоретичною базою якого є методи машинного навчання, злиття, семантичної сегментації та ідентифікації зображень.

Практичне значення одержаних результатів полягає у створенні інформаційної технології попередньої обробки та класифікації різночасових супутникових зображень високої просторової розрізненості, яка є інструментарієм вирішення прикладних задач моніторингу і дозволяє за рахунок розроблених методів дешифрування різночасових мультиспектральних даних проводити аналіз та розпізнавання окремих об'єктів, а також тематичну класифікацію усієї сцени з мінімальними витратами обчислюваних ресурсів та часу.

Впровадження одержаних результатів. Практичне значення результатів підтверджується впровадженнями результатів дисертаційної роботи у практику робіт «Дніпрокосмос» філії Національного центру управління та випробувань космічних засобів Державного космічного агентства України та Іноземного підприємства «ЕМЕРДЖН», а також впровадженням у освітній процес Національного технічного університету «Дніпровська політехніка».

Розроблені інформаційні технології та програмно-алгоритмічне забезпечення можуть бути використані при створенні аналогічних за цільовим призначенням програмно-апаратних комплексів розпізнавання та класифікації об'єктів земної поверхні.

Особистий внесок здобувача. Усі теоретичні та практичні результати, що складають наукову новизну дисертаційної роботи отримані особисто. Результати дисертаційної роботи опубліковані в у працях [1-10] (Додаток А).

У наукових публікаціях, створених у співавторстві, здобувачу належить: розробка алгоритму сегментації аерокосмічних зображень високої просторової розрізненості з використанням згорткових нейронних мереж [1, 8], розробка методу автоматизованого розпізнавання об'єктів забудови на цифрових аерофотознімках на основі згорткової нейронної мережі [2], запропоновано інформаційну технологію розпізнавання та моніторингу водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання [3], запропоновано інформаційну технологію попередньої обробки багатоканальних супутникових зображень з використанням згорткової нейронної мережі, що дозволило підвищити інформативність первинних даних [4], проведено порівняння трьох різних модифікацій архітектури U-Net для задачі семантичної сегментації агроугідь на основі супутникових зображень [5], запропоновано рішення у вигляді інфраструктури як сервісу IaaS для алгоритму обробки потоків даних дистанційного зондування Землі з використанням рішень глибокого навчання і хмарних технологій [6], розробка та застосування методу оптимізації основних характеристик великих даних, що передбачає зменшення обсягу обробленої інформації, а також збільшення швидкості пошуку й обробки даних та надійності [7], проведено оцінку ефективності розроблених методів розпізнавання різночасових супутникових зображень високої просторової розрізненості [9, 10].

Апробація результатів дисертації. Результати дисертаційної роботи доповідались і обговорювались на наукових семінарах кафедри програмного забезпечення комп'ютерних систем Національного технічного університету «Дніпровська політехніка»; International Scientific Conference "Intelligent Systems of Decision-Making and Problems of Computational Intelligence (ISDMCI 2022); 10th International Conference on Advanced Computer

Information Technologies (ACIT), 2020 (Deggendorf, Germany); 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security (IntelITSIS-2021) (Khmelnyskyi, Ukraine); XVI Міжнародній науково-практичній конференції «Проблеми використання інформаційних технологій в освіті, науці та промисловості», 2021 (Дніпро, Україна); XVII Міжнародній науково-практичній конференції «Проблеми використання інформаційних технологій в освіті, науці та промисловості», 2022 (Дніпро, Україна).

Публікації. Основні результати дисертаційної роботи опубліковано у 10 наукових працях. П'ять статей опубліковано у наукових виданнях, включених до переліку фахових видань України (всі індексуються у НМБД Index Copernicus), три статті в іноземних виданнях (індексуються у НМБД Scopus), одна з яких – розділ колективної монографії, дві наукових праці опубліковано у збірниках наукових праць та матеріалах міжнародних конференцій.

Структура і обсяг роботи. Дисертаційна робота складається зі вступу, чотирьох розділів, висновків, списку використаних джерел та додатків. Загальний обсяг дисертації становить 165 сторінок, містить 141 сторінку основної частини, включає 42 рисунка, 13 таблиць, 136 літературних джерел.

РОЗДІЛ 1

ОГЛЯД СУЧАСНОГО СТАНУ ПРОБЛЕМИ ПОПЕРЕДНЬОЇ ОБРОБКИ ТА КЛАСИФІКАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ

1.1. Основні характеристики супутникових зображень

Дистанційне зондування Землі (ДЗЗ) – це спостереження за поверхнею Землі за допомогою наземних, авіаційних і космічних засобів, оснащених різними видами знімальної апаратури. Методи зондування можуть бути пасивними, тобто використовувати природне відбите або вторинне теплове випромінювання об'єктів на поверхні Землі, зумовлене сонячною активністю, і активними – використовувати вимушене випромінювання об'єктів, ініційоване штучним джерелом спрямованої дії. Дані ДЗЗ, отримані з космічного апарата (КА), значною мірою залежать від прозорості атмосфери. Тому на КА використовується багатоканальне обладнання пасивного та активного типів, що реєструє електромагнітне випромінювання в різних діапазонах (VNIR, TIR, SWIR) [41-43, 124, 136].

Існує три типи розрізнення (або розрізненості) аерокосмічних зображень:

- просторове;
- спектральне;
- радіометричне;

Просторова розрізненість (у літературі часто використовують синоніми «розрізнення», «роздільна здатність») супутникових зображень є одним з основних параметрів, які визначають якість та детальність отриманих даних у дистанційному зондуванні Землі. Просторова розрізненість характеризує здатність супутника розрізняти деталі на поверхні Землі та залежить від розміру найменшого об'єкта, який можна виявити і чітко розпізнати на зображенні. Висока просторова розрізненість дозволяє отримувати

зображення з великою деталізацією, що є критично важливим для багатьох застосувань, таких як картографування, міське планування, моніторинг інфраструктури, дослідження екосистем та багато іншого.

Просторова розрізненість зазвичай вимірюється в метрах і визначає, яку площу на поверхні Землі представляє один піксель зображення. Наприклад, якщо просторове розрізнення становить 1 метр, це означає, що один піксель супутникового зображення відповідає площі 1 квадратний метр на поверхні Землі. Чим менше є значення просторової розрізненості, тим більше деталей можна побачити на зображенні. WorldView-3 має просторову роздільну здатність панхромного каналу 30 см. Це означає, що об'єкт розміром 30×30 см відобразиться на зображенні як один піксель. Отже, на зображенні будуть помітні такі предмети, як автомобілі, і можна визначити, наприклад, їх колір (якщо знімок кольоровий), але менші деталі (реєстраційний номер, конструктивні особливості, що допомагають визначити марку та модель) не можуть бути визначені [83].

На даний час класифікація космічних апаратів ДЗЗ за просторовою розрізненістю нормативно не визначена. В роботі під зображеннями високої просторової розрізненості будемо розуміти зображення, у яких розмір проекції елементарного каналу зображення менший за 1 м.

Супутники з високою просторовою розрізненістю, такі як WorldView-3 або GeoEye-1, можуть мати розрізнення до 30 сантиметрів. Це дозволяє виявляти дуже дрібні деталі, наприклад, окремі будівлі, дороги, транспортні засоби та навіть окремі дерева. Такі зображення часто використовуються в міському плануванні, моніторингу будівельних робіт, дослідженнях ландшафтів та інших сферах, де важлива точність і деталізація [30, 31].

З іншого боку, супутники з нижчою просторовою розрізненістю, такі як MODIS або Landsat, зазвичай мають розрізнення від десятків до сотень метрів. Ці супутники здатні покривати великі території за один знімок і використовуються для моніторингу глобальних та регіональних процесів,

таких як зміни клімату, динаміка рослинного покриву, вивчення океанів та атмосфери [22, 38, 53, 83].

Вибір даних супутника з відповідною просторовою розрізненістю залежить від конкретних завдань і цілей дослідження. Для детального аналізу малих територій або об'єктів необхідні супутники з високою просторовою розрізненістю. Для широкомасштабних екологічних та кліматичних досліджень підходять супутники з нижчою розрізненістю, які забезпечують огляд великої території за короткий час. Таким чином, просторова розрізненість є критично важливим параметром у дистанційному зондуванні Землі, що визначає здатність супутника розрізняти та ідентифікувати об'єкти на поверхні планети. Від цього параметра залежить якість отриманих зображень і можливості їх використання у різних наукових, інженерних та практичних сферах.

Спектральною розрізненістю називають здатність супутника отримувати електромагнітне випромінювання з визначеного частотного діапазону. Це означає, що супутник може сприймати різні частини спектру електромагнітного випромінювання, від ультрафіолетового до інфрачервоного та мікрохвильового діапазонів. Спектральна розрізненість є важливою характеристикою, оскільки різні об'єкти та матеріали на поверхні Землі мають унікальні спектральні ознаки, які дозволяють їх ідентифікувати та аналізувати.

Електромагнітний діапазон ділиться на інтервали, в яких супутник здатен отримувати інформацію ДЗЗ. Ці інтервали називають спектральними каналами, і кожен канал відповідає певному діапазону довжин хвиль. Кількість і ширина цих каналів визначають спектральні можливості супутника. Чим більше каналів має супутник, тим більш детальною і точною може бути інформація, яку він збирає. Це дозволяє проводити детальні аналізи, наприклад, визначати типи рослинності, виявляти забруднення водних ресурсів, або моніторити стан урбанізованих територій [62].

Наприклад, супутники з високою спектральною розрізненістю можуть мати до сотні вузьких спектральних каналів, що дозволяє отримувати детальну інформацію про властивості об'єктів на Землі. Це, в свою чергу, сприяє більш точному картуванню, моніторингу екосистем і оцінці природних ресурсів. Такі дані є критично важливими для прийняття обґрунтованих рішень в галузі екології, сільського господарства, управління водними ресурсами та інших сфер.

Важливим аспектом дистанційного зондування Землі, що дозволяє відстежувати зміни на поверхні планети з плином часу, є обробка різночасових супутникових зображень високої просторової розрізненості. Різночасові зображення — це серії знімків однієї і тієї ж ділянки земної поверхні, отримані в різний час. Вони надають можливість аналізувати динаміку природних і антропогенних процесів, таких як зміни ландшафту, розвиток міст, сезонні зміни рослинного покриву, наслідки стихійних лих тощо [5, 63, 99, 110, 115-117].

Однак, обробка різночасових зображень високої просторової розрізненості є досить складною задачею з кількох причин [86]. Зображення, зроблені в різний час, як правило мають різні геометричні спотворення через зміни в орбіті супутника, кути зйомки та інші фактори. Для точного порівняння необхідно провести геометричну корекцію, вирівнюючи зображення до єдиної географічної системи координат. Крім того, між моментами зйомок змінюються атмосферні умови, що впливає на якість зображень [2, 11]. Для порівняння різночасових зображень необхідно забезпечити їхню радіометричну сумісність. Зміни в зображеннях можуть бути спричинені також сезонними змінами або погодними умовами, які необхідно враховувати при аналізі. Для цього може знадобитися додаткова інформація про кліматичні умови під час зйомки.

Таким чином, обробка різночасових супутникових зображень високої просторової розрізненості є складним та багатоступеневим процесом, який вимагає використання сучасних технологій та методів аналізу даних. Це

дозволяє отримувати цінну інформацію про зміни на поверхні Землі та приймати обґрунтовані рішення у різних галузях, від екології та сільського господарства до міського планування та управління надзвичайними ситуаціями.

1.2. Основні етапи попередньої обробки супутникових зображень

Сучасні тенденції змін навколишнього середовища вимагають негайного вирішення проблем, пов'язаних з сільським господарством, кліматом, урбанізацією та іншими аспектами. Для ефективного вирішення цих завдань надзвичайно важливо використовувати методи, засновані на дистанційному зондуванні Землі (ДЗЗ), та надавати точну класифікацію зображень, яка відображає типи земної поверхні на основі проведених спостережень [136].

Класифікація зображень земної поверхні є ключовим етапом у розвитку автоматизованих систем спостереження за територією. Вона дозволяє системам моніторингу точно ідентифікувати різноманітні елементи ландшафту, такі як ліси, водні джерела, сільськогосподарські угіддя та міські території. Точна класифікація земного покриву сприяє автоматизації процесу спостереження за динамікою природних та антропогенних об'єктів, що дозволяє ефективно прогнозувати врожайність, виявляти відхилення в екосистемах та вчасно реагувати на зміни у середовищі [12, 13, 15, 23, 32-34].

Використання методів на основі ДЗЗ в поєднанні з точною класифікацією зображень земної поверхні відкриває широкі можливості для здійснення комплексного аналізу та моніторингу природних та антропогенних процесів на Землі. Це дозволяє забезпечити науково обґрунтовані рішення у сфері ресурсного використання, природоохоронної діяльності та територіального планування, що сприяє сталому розвитку суспільства.

Попередня обробка супутникових зображень є важливим етапом, який передусь їх подальшому тематичному аналізу [83]. Цей процес включає в себе ряд технік та методів, спрямованих на вдосконалення якості, точності та коректності отриманих супутникових зображень перед їхнім подальшим використанням [45-47, 85]. Попередня обробка визначається параметрами супутникового знімання та особливостями задачі, яку необхідно вирішити. Основними етапами попередньої обробки супутникових даних є:

- Калібрування: цей етап включає в себе виправлення систематичних помилок, таких як радіометричні та геометричні спотворення. Калібрування є важливим для забезпечення однаковості та точності зображень.
- Фільтрація та видалення шуму: на цьому етапі застосовуються методи фільтрації для видалення шумових компонентів та артефактів, що можуть виникнути внаслідок різних джерел, таких як атмосферні умови або технічні характеристики супутникової апаратури [83].
- Геометрична корекція: нормалізація геометричних спотворень, які можуть виникнути під час зйомки та передачі даних супутникових систем. Цей процес має на меті забезпечення точності та стабільності геометричних параметрів зображень, щоб зробити їхнє подальше використання в додатках геоінформаційних систем та інших наукових дослідженнях більш ефективним.
- Підвищення просторової розрізненості супутникових зображень – це важливий аспект в обробці супутникової інформації, оскільки воно дозволяє отримувати більш деталізовані та високоякісні зображення. Для цього використовуються методи паншарпенінгу та/або злиття, які спрямовані на об'єднання різних типів супутникових зображень з метою покращення їхньої роздільної здатності [1, 3, 26, 35, 36, 46, 47, 52, 57, 128, 133]. Методи паншарпенінгу передбачають поєднання чорно-білих зображень високої просторової здатності (зазвичай отриманих від панхроматичних сенсорів) із кольоровими

зображеннями з низькою роздільною здатністю. Цей процес дозволяє створити супутникове зображення з покращеною роздільною здатністю та колірними характеристиками. Злиття використовує різні види супутникових даних, такі як оптичні, радарні, теплові зображення та інші, для створення одного синтетичного зображення. Цей метод спрямований на отримання максимальної інформації з кожного джерела та підвищення інформативності та роздільної здатності супутникових зображень.

1.3. Сучасні тенденції у розробці алгоритмів попередньої обробки аерокосмічних зображень

Сучасні тенденції у розробці алгоритмів попередньої обробки супутникових зображень свідчать про постійний розвиток та впровадження новаторських підходів з метою поліпшення якості та ефективності обробки цих даних. Динамічний розвиток технологій у галузі обчислювальної обробки та штучного інтелекту відіграє значущу роль у змінах, що відбуваються в сучасних алгоритмах попередньої обробки. Нижче наведено ключові напрямки цих тенденцій:

- Глибоке навчання та нейронні мережі:

Сучасні алгоритми попередньої обробки використовують глибокі нейронні мережі для автоматичної обробки та вдосконалення супутникових зображень. Використання конволюційних нейронних мереж дозволяє автоматизувати процес виявлення особливостей та корекції зображень, що призводить до покращеної точності та швидкості обробки [36, 118-120, 123, 130].

- Інтеграція геоінформаційних систем (ГІС):

Сучасні алгоритми спрямовані на покращення інтеграції з об'єктами ГІС, щоб забезпечити зручний та ефективний доступ до оброблених супутникових даних. Це важливо для використання зображень у

геопросторовому аналізу, місцевому плануванні та рішенні ряду географічних завдань [126].

- Мультиспектральна та гіперспектральна обробка:

Розширення обробки супутникових зображень на багатоспектральні та гіперспектральні дані дозволяє отримувати додаткову інформацію про об'єкти та явища на поверхні Землі [136]. Алгоритми попередньої обробки стають більш адаптивними до великого обсягу спектральної інформації [120, 124, 130].

- Розширення можливостей апаратної обробки:

Сучасні технології використовують потужні комп'ютерні ресурси та високоефективні графічні процесори для реалізації складних алгоритмів обробки в реальному часі. Це дозволяє забезпечити оперативну та швидку обробку великих обсягів супутникових даних [6, 27].

- Автоматизація та самонавчання:

Сучасні алгоритми все більше орієнтовані на автоматизацію процесів попередньої обробки та навчання на основі даних [90, 108, 109, 114, 132]. Впровадження технік самонавчання дозволяє адаптувати алгоритми до різних умов та завдань без необхідності ручного налаштування параметрів.

1.4. Класифікація супутникових зображень

1.4.1. Визначення та роль класифікації супутникових зображень

Визначення та значення класифікації супутникових зображень є ключовим аспектом в обробці та аналізі геопросторової інформації. Класифікація в контексті супутникових зображень означає процес призначення певного класу або категорії пікселям на зображенні відповідно до їхніх характеристик та властивостей. Цей процес може бути використаний для ідентифікації та розпізнавання об'єктів на земній поверхні, які мають різні природні чи штучні характеристики.

Класифікація супутникових зображень дозволяє розділити геопросторові дані на різні категорії, такі як ліси, водойми, міські зони, сільськогосподарські угіддя та інші. Це важливо для різних сфер застосування, включаючи картографію, моніторинг змін на земній поверхні, природоохоронні заходи, аграрний та міський розвиток. Однією з ключових переваг класифікації супутникових зображень є можливість автоматизованого аналізу великих обсягів даних, що дозволяє збільшити швидкість та ефективність обробки. Крім того, класифікація може служити основою для створення карт, що репрезентують різні категорії на земній поверхні, що є важливим інструментом для планування та управління територіальними ресурсами [55, 59, 61].

Значення класифікації супутникових зображень постійно зростає в контексті сучасних технологій, таких як штучний інтелект та машинне навчання [71-73]. Використання цих технологій дозволяє автоматизувати та поліпшити точність класифікаційних процесів, що робить їх більш точними та адаптивними до різних умов та потреб користувачів. Класифікація супутникових зображень відіграє ключову роль у вивченні та моніторингу земної поверхні, надаючи цінну інформацію для прийняття рішень у різних галузях.

1.4.2. Основні методи класифікації зображень

Методи та алгоритми класифікації супутникових зображень розробляються з урахуванням різних властивостей спектральних сигналів, текстур, форм та інших характеристик, які визначають класифікацію певного пікселя чи області на супутниковому зображенні. Основні методи та алгоритми класифікації включають:

Методи традиційного навчання:

Традиційні методи машинного навчання були глибоко вивчені та застосовані до різних сценаріїв, пов'язаних з обробкою зображень дистанційного зондування. У традиційних методах машинного навчання

більшість застосовуваних характеристик мають бути визначені експертами предметної області, щоб зменшити складність даних і зробити шаблон більш ефективним для алгоритму навчання.

Класифікація за допомогою методів піксельних даних [72, 107]: використовується для класифікації кожного пікселя на зображенні на основі його спектральних характеристик. Тут застосовуються методи, такі як максимальної правдоподібності, метод опорних векторів (SVM) [55], або класифікація з використанням глибокого навчання [15, 23, 40, 48, 50, 59, 120].

Класифікація на основі областей: В цьому підході зображення розділяється на регіони, а потім класифікується весь регіон, використовуючи інформацію не тільки про спектральні властивості, але і про текстурні та просторові характеристики.

Методи глибокого навчання:

Конволюційні нейронні мережі (CNN): Глибокі нейронні мережі, зокрема CNN, показують високий рівень ефективності у класифікації супутникових зображень. Вони використовуються для автоматичного розпізнавання об'єктів і функцій на поверхні Землі, що робить їх незамінним інструментом для геопросторового аналізу та моніторингу. Завдяки здатності ефективно виявляти патерни у великих обсягах даних, CNN дозволяють не лише точно ідентифікувати об'єкти, але й виявляти зміни в навколишньому середовищі з часом [15, 20, 31-33, 40, 49-51, 54, 58, 59, 61, 75-77, 87, 113, 120, 123].

Ансамблеві методи:

Випадковий ліс (Random Forest): Ансамблевий метод, який використовує кілька дерев рішень для класифікації. Він ефективний у вирішенні проблем перенавчання та надає важливі функції важливості для кожного атрибута.

Градiєнтний бустінг: Цей метод заснований на побудові послідовності слабких класифікаторів, кожен з яких компенсує недоліки попереднього. Градiєнтний бустінг зазвичай показує високу точність та ефективність.

Семантична сегментація [7, 17, 28-30, 33, 56, 64, 71, 79, 82, 100, 125]:

Семантична сегментація – це завдання пошуку груп пікселів зображення, кожна з яких характеризує один смисловий об’єкт [7, 33, 56]. При семантичній сегментації потрібно не тільки виявити об’єкти, а й визначити їх межі. Результатом такої семантичної сегментації буде колірна карта, де досить наочно і можна визначити окремі об’єкти. Це особливо зручно при роботі з великими зображеннями, що містять безліч дрібних об’єктів, як супутникові знімки поверхні Землі. Для вирішення задач семантичної сегментації застосовуються такі основні підходи:

- граничні алгоритми;
- порогові алгоритми;
- алгоритми нарощування областей;
- алгоритми сегментації на основі кластеризації;
- нейронні мережі.

Більш докладно аналіз існуючих методів семантичної сегментації розглянуто в п.1.5.

Методи, засновані на текстурах та геоморфометрії:

Використання індексів текстур [36, 114]: Застосування статистичних індексів текстур для класифікації, що допомагає врахувати важливі текстурні характеристики на зображенні.

Аналіз геоморфометричних параметрів: Врахування геоморфометричних характеристик, таких як нахил, аспект та кривизна, щоб покращити класифікацію об’єктів земної поверхні.

Ці методи та алгоритми є такими, що постійно розвиваються, адаптуючись до нових технологій та завдань у сфері обробки супутникових зображень. Комбінування різних підходів часто використовується для досягнення найкращих результатів у конкретних завданнях класифікації.

У наш час відзначається значний приріст кількості досліджень, в яких використовуються згорткові нейронні мережі (ЗНМ) для вирішення завдань

класифікації та сегментації об'єктів на зображеннях. Результати, що представлені у науковій літературі, свідчать про перевагу ЗНМ у багатьох завданнях над традиційними методами обробки зображень, такими як метод головних компонент, метод найближчого сусіда, лінійний дискримінантний аналіз, OVIA та інші. Однак основним недоліком згорткових нейронних мереж є велика кількість параметрів, які потребують налаштування від дослідника. Часто неясно, які оптимальні значення параметрів слід обирати для конкретної задачі, особливо враховуючи обмежену доступну обчислювальну потужність. Серед цих параметрів є кількість шарів, розмір ядра згортки для кожного з шарів, кількість ядер для кожного з шарів, крок зсуву ядра при обробці шару, необхідність та кількість шарів піддискретизації, ступінь зменшення розмірності, функція для зменшення розмірності (наприклад, вибір максимуму, середнього значення та інші), функція активації нейронів та наявність та параметри повнозв'язаної нейронної мережі на виході згорткової. Усі ці параметри мають значний вплив на результат, але дослідники зазвичай обирають їх емпірично. Існують кілька добре налаштованих та ефективно працюючих конфігурацій мереж, проте загалом відсутні рекомендації щодо того, як слід будувати мережу для нової задачі.

1.5. Семантична сегментація супутникових зображень

Останнім часом семантична сегментація наземних об'єктів стає надзвичайно популярною у програмах та системах дистанційного зондування. Такі сегментовані карти мають багато застосувань у різних сферах, таких як містобудування [32], сільськогосподарські програми [28], оцінка руху та моніторинг як на суші, так і на воді [33] тощо. Зазвичай розглядаються дві категорії підходів при вирішенні проблем семантичної сегментації: чіткі алгоритми, засновані на визначених вручну характеристиках, такі як описані в [33, 123], або стохастичні підходи, зокрема

ті, що базуються на глибокому навчанні, які в значній мірі покладаються на властивості глибоких нейронних мереж згортки [58, 66, 119].

Розвитком нейронних мереж глибокого вивчення прямого поширення стало чергування згорткових та шарів максимального пулінгу [14], вдосконалених декількома повнозв'язними або слабозв'язними шарами, і, відповідно, наступним остаточною шаром класифікації. Навчання «state-of-the-art» глибоких мереж зазвичай проводиться без будь-якої спонтанної попередньої підготовки на попередньо готових наборах даних загального побутового призначення, такі як Cifar100 або MS COCO. Підходи, засновані на експлуатації GPU, виграли багато конкурсів на розпізнавання зображень, включаючи конкурс розпізнавання дорожніх знаків IJCNN 2011, конкурс з сегментації нейронних структур у стеку електронної мікроскопії ISBI 2012 [14], ImageNet [50] та інші. Такі керовані методи глибокого навчання також стали першими штучними розпізнавачами зображень, які досягли в деяких завданнях ефективності, порівнянної з людською [2]. Застосування підходів глибокого навчання для обробки зображень дистанційного зондування є більш ускладненим у порівнянні з побутовими наборами даних. Зображення дистанційного зондування, як правило, мають більш складні і різноманітні образи у порівнянні зі звичайними зображення, до яких можна віднести ті, що зроблені за допомогою звичайних камер побутового призначення. Завдяки здатності глибокого навчання у представленні ознак, глибоке навчання було впроваджено в дистанційне зондування довкілля та застосовується у багатьох аспектах, включаючи картографування земельного покриття, пошук параметрів навколишнього середовища, злиття та зменшення масштабу даних, а також прогнозування інформації. Більш детальні застосування глибокого навчання в дистанційному зондуванні навколишнього середовища наведені в [118].

Більшість рішень для глибокого навчання використовують нейромережеві структури, засновані на згорткових нейронних мережах. Однією з проблем, яка існує навіть сьогодні для обробки зображень

дистанційного зондування, є те, що її часто потрібно обробляти по частинах або тайлами, оскільки більшість нейромереж обробляють триканальні зображення набагато меншої роздільної здатності, коли більшість зображень дистанційного зондування можуть досягти роздільної здатності близько кілька сот мільйонів пікселів. Повнозгорткова нейронна мережа (Fully convolutional network) була винайдена для вирішення згаданої проблеми [23, 59]. Використовуючи цей тип нейронної мережі, можна сформувану сегментовану карту будь-якого розміру. Іншим популярним підходом для семантичної сегментації є архітектура кодувальника-декодувальника, в результаті якої формується семантична карта тієї ж роздільної здатності та розмірів, що і вихідне зображення. Пізніше були розроблені більш складні рішення для вдосконалення генерації семантичних карт, а саме SegNet [98], DCNN + CRF [71], SS-CNN [120] та інші. Вичерпний огляд нейромережевих додатків для даних дистанційного зондування наведено в [77].

Однією з головних причин вибрати конкретну архітектуру нейронної мережі перед іншими для семантичної сегментації є використання спектральної та просторової інформації, яка часто надається для найбільш часто використовуваних супутникових зображень. У більшості випадків результати рішень для глибокого навчання для дистанційного зондування успішно застосовуються лише до певного типу зображень, з якими він був впроваджений і протестований. Однак існують винятки, коли належне поєднання архітектур нейронних мереж та параметрів вирішило проблему семантичної сегментації для подібних зображень з різних супутникових апаратів. Ці проблеми та рішення детально описані в [79].

Зрозуміло, що вибір ефективного методу сегментації значною мірою залежить від типу (характеристик) зображення. Встановлення порогових значень використовується для вилучення переднього плану із фону на основі інтенсивності або кольору пікселів. Дослідники також використовують текстуру та додають інші фактори для кращого розділення в регіонах. Більш складна версія може варіюватися від заснованої на кольорі для використання

більш складних доменів для сортування регіонів. Значного поширення отримали предметно-орієнтовані методи класифікації, засновані на попередній сегментації зображень з наступним аналізом параметрів виділених зон. Однак їх застосування до реальних аерокосмічних даних утруднено, оскільки для природних ландшафтів зображення високої роздільної здатності зазвичай містять інформацію про текстуру і характеризуються плавними переходами. Це негативно позначається на якості сегментації: на межах сегментів, сформованих за таких умов, виникають зони невизначеності. Інша проблема об'єктно-орієнтованих методів полягає у складності застосування контекстного аналізу до результатів сегментації.

Результати аналізу досліджень показують, що базові алгоритми сегментації в поточному вигляді не досягають ефективних результатів, тому рекомендується їх модифікація для поліпшення продуктивності обчислень. Для напівтонових і кольорових зображень відповідні методи сегментації через контури і кластерність є доцільними. Для порогових методів рекомендується застосовувати сегментацію окремих сегментів, використовуючи метод Otsu для обчислення порогового значення. При використанні методу сегментації на основі теорії кластеризації рекомендується попередньо оцінювати вхідне зображення для визначення оптимальної кількості кластерів. Для методу сегментації через виділення контурів важливо оцінювати ступінь пошкодження ділянок та проводити їх відновлення.

Таким чином, сучасні методи обробки зображень, засновані на глибокому навчанні, пропонують надзвичайно гнучкі інструменти для різних потреб, включаючи семантичну сегментацію. Використовуючи глибоке навчання, можна отримати унікальні знання з даних та адаптувати моделі й алгоритми для конкретних завдань, щоб досягти найкращих результатів.

1.6. Основні платформи та проєкти обробки та аналізу супутникових зображень

Огляд відомих робіт, проєктів та новітніх досягнень в області попередньої обробки та класифікації супутникових зображень свідчить про постійний розвиток технологій та методів, що використовуються для аналізу супутникових даних. В цьому контексті розглядаються роботи та проєкти, які визначають ключові тенденції та внесок у розвиток галузі [24, 88,96].

Google Earth Engine:

Google Earth Engine є одним із найбільших та найважливіших проєктів у галузі обробки та аналізу супутникових зображень. Ця платформа надає доступ до обширної колекції супутникових даних та використовує потужності хмарних обчислень для високоефективного виконання різноманітних аналітичних завдань.

Sentinel Hub:

Sentinel Hub – це платформа, що надає зручний доступ до даних від супутникових місій Copernicus, зокрема Sentinel-1, 2. Ця платформа пропонує широкий спектр інструментів для обробки та аналізу супутникових даних, включаючи можливості для класифікації та візуалізації.

NASA Earth Observing System Data and Information System (EOSDIS):

EOSDIS – це система NASA, яка забезпечує доступ до величезного обсягу супутникових даних, включаючи дані від таких місій, як Landsat, MODIS, та інших. EOSDIS надає різноманітні інструменти для обробки та аналізу даних для наукових досліджень та додатків в галузі екології, клімату та інших наук.

EOS Data Analytics:

EOS Data Analytics (EOSDA) – глобальний постачальник супутникової аналітики для сільського та лісового господарства, що розробляє рішення для 22 основних галузей під запит. Компанія є частиною космічної групи «Ноосфера», створеної Максом Поляковим, та працює з 2015 року,

взаємодіючи з урядовими, комерційними та науковими організаціями. Це платформа для аналізу геопросторових даних. За допомогою призначених для користувача алгоритмів, система швидко і просто доставляє рішення для задач розвитку бізнесу й збереження планети. Продукт компанії EOSDA LandViewer – це інструмент для роботи зі супутниковими даними. Він дозволяє оперативно шукати, обробляти та добувати цінну інформацію із супутникових знімків для вирішення реальних бізнес-задач. Це моніторинг земної поверхні з можливістю обробки даних на льоту, інтуїтивний інтерфейс і безліч корисних функцій. Крім того, EOS Data Analytics – глобальний провайдер аналітики супутникових даних [19].

Проекти Deep Learning:

Ряд досліджень та робіт в області глибокого навчання виявляється ключовим у напрямку класифікації супутникових зображень [15, 20, 31-33, 40, 49-51, 54, 58, 59, 61, 75-77, 87, 113, 120, 123]. Використання конволюційних нейронних мереж (CNN) та глибоких архітектур дозволяє автоматизувати процес класифікації та отримувати високу точність. На відміну від традиційного машинного навчання, де робочий процес розбивається на окремі компоненти, методи глибокого навчання, як правило, розв'язують проблеми системно. Це важливо, оскільки це значно спрощує необхідність вивчення предметної області та складний вибір функцій. Крім того, час, потрібний для обґрунтування алгоритмів глибокого навчання, набагато менший порівняно з традиційними методами машинного навчання. Крім того, без необхідності розуміти внутрішність функцій, алгоритми глибокого навчання приносять величезні переваги з точки зору точності та часу тестування, особливо в порівнянні з традиційним машинним навчанням. Проте, нарікання на алгоритми глибокого навчання включають вимогу до великих обсягів даних і відсутність можливості інтерпретації. Ці обставини також стали приводом для вивчення успішного застосування глибокого навчання для розв'язання завдань класифікації зображень дистанційного зондування.

1.7. Проблеми та виклики у класифікації супутникових даних високої просторової розрізненості

Протягом останнього десятиліття швидка еволюція системи спостереження Землі призвела до значного розширення значення, різноманітності та обсягу зображень дистанційного зондування. Сучасний супутник може щодня збирати терабайти даних та легко накопичувати петабайти даних протягом свого звичайного терміну служби. Окрім значного збільшення кількості зображень ДЗЗ, використання вдосконалених датчиків спостереження Землі може підняти якість супутникових зображень на непередбачений рівень. Оскільки просторова роздільна здатність зростає від низької до високої, змінюється і співвідношення між пікселями та об'єктами зображення. Зокрема, на початкових етапах використання методів аналізу на рівні пікселів (тобто, піксельний та субпіксельний аналіз) було широко розповсюджене в супутникових знімках з низькою роздільною здатністю, де об'єкти зображення значно менші за пікселі або залишалися на тому ж самому рівні. Однак ці методи не ефективні при дослідженні супутникових зображень високої роздільної здатності, зокрема, вони потребують регіоналізації пікселів на групи пікселів, щоб захопити контекстуальну інформацію на рівні об'єкта.

Тому класифікація супутникових даних високої просторової розрізненості вносить свої виклики та проблеми, які важливо розглядати для забезпечення точності та надійності отриманих результатів. Нижче розглянуто деякі з основних проблем та викликів у цьому контексті:

- Обробка великих обсягів даних:

Зображення високої роздільності можуть мати величезний обсяг даних, що ускладнює їх обробку та аналіз. Це вимагає високопродуктивних обчислювальних ресурсів та оптимізованих алгоритмів для ефективної обробки великих масивів даних.

- Неоднорідність та велика різноманітність природних об'єктів:

Зображення високої роздільності можуть містити велику різноманітність природних об'єктів та їхніх характеристик. Це ускладнює завдання класифікації через неоднорідність та варіабельність об'єктів на поверхні.

- Заплутані області та об'єкти:

Деякі зони можуть містити багато заплутаних областей або об'єктів, що робить їх важкими для чіткої ідентифікації та класифікації. Наприклад, міські ландшафти з великою кількістю будівель можуть представляти виклик у розрізненні різних класів.

- Проблеми затінених областей:

Тінь від будівель, гір та інших об'єктів може призводити до змін текстур та колірних характеристик на зображеннях, ускладнюючи завдання класифікації.

- Виклики у визначенні границь об'єктів:

У випадку об'єктів з високим рівнем деталізації, таких як будівлі чи ліси, визначення їхніх границь може бути складним завданням, особливо при наявності схованих або частково видимих елементів.

- Нестабільність природних умов:

Метеорологічні умови та сезонні зміни можуть впливати на зовнішній вигляд об'єктів та природних покривів, що робить адаптацію алгоритмів класифікації більш складною.

- Невідомі аномалії та зміни в часі:

Часові зміни в об'єктах або виникнення аномалій можуть ускладнювати тривалість та стійкість алгоритмів класифікації.

Для подолання цих викликів використовуються різні підходи, включаючи використання адаптивних алгоритмів, використання додаткових джерел інформації, а також розширення наборів даних для навчання більш стійких моделей. Постійний розвиток методів та технологій в цій області сприяє подоланню проблем та підвищенню точності класифікації супутникових даних високої роздільності.

1.8. Постановка задачі та теоретичний апарат дослідження

Незважаючи на значний прогрес у розвитку сучасної комп'ютерної техніки, деякі практичні завдання залишаються викликом для розв'язання. Одним з таких завдань є класифікація зображень, що виникає зі складнощів у формалізації процесу сприйняття видимих образів. Навіть при тому, що людина легко впорається з цим завданням, ще не існує «універсального» математичного або технологічного підходу, що дозволяв би конструктивно розробляти методи, алгоритми та автоматичні пристрої для ефективної класифікації.

Під час аналізу сучасних підходів до обробки та класифікації різночасових мультиспектральних супутникових зображень, виявлено, що більшість досліджень розв'язують обмежені завдання для визначеної території або типу земного покриття, такі як класифікація дерев, лісів, сільськогосподарських угідь. Величини вхідних наборів даних часто є невеликими та/або застарілими, не розглядаються мультиспектральні різночасові зображення високої просторової розрізненості, а деякі методи потребують ручного аналізу від висококваліфікованих фахівців, тому не можуть бути використані для реального вирішення завдань у реальному часі. Проведений аналіз наукових робіт виявив перевагу методів глибокого навчання над традиційними підходами класифікації. Методи, що базуються на згорткових нейронних мережах, демонструють високу ефективність для класифікації аерокосмічних зображень. Тому необхідно вдосконалити методи класифікації різночасових зображень земної поверхні на основі згорткових нейронних мереж.

Виходячи з цього, метою дисертаційної роботи є підвищення точності, рівня автоматизації та швидкодії класифікації різночасових супутникових зображень високої просторової розрізненості шляхом розробки інформаційної технології їх попередньої обробки, аналізу та розпізнавання з використанням машинного навчання.

Для досягнення визначених цілей передбачаються такі основні завдання:

- Здійснити аналіз проблеми та сучасних методів обробки великих даних ДЗЗ, розробити метод оптимізації основних характеристик великих обсягів даних, який дозволить зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних при збереженні їх відповідних значень та надійності.
- Розробити інформаційну технологію попередньої обробки багатоканальних супутникових зображень з використанням згорткової нейронної мережі, що дозволить підвищити інформативність первинних даних.
- Запропонувати рішення у вигляді інфраструктури як сервісу (IaaS) для алгоритму обробки потоків даних дистанційного зондування Землі з використанням рішень глибокого навчання і хмарних технологій, оптимізованих для роботи із запропонованим алгоритмом.
- На базі запропонованих алгоритмів та методів розробити автоматизовану інформаційну технологію класифікації різночасових супутникових зображень на основі запропонованої архітектури згорткової нейронної мережі.
- Провести тестування розробленої інформаційної технології на різних сценах ДЗЗ, провести оцінку якості та інтерпретації отриманих результатів розпізнавання та класифікації при вирішенні практичних завдань.
- Впровадити практичне застосування запропонованих методів обробки та класифікації різночасових мультиспектральних супутникових зображень та надати практичні рекомендації з їх використання.

1.9. Висновки до першого розділу

1. Були проаналізовані можливості класичних методів класифікації, таких як баєсівський підхід, метод k-найближчих сусідів, метод опорних векторів та дерева рішень, для аналізу різночасових супутникових зображень. Також були проаналізовані методи, що базуються на штучному інтелекті, сучасні підходи глибокого навчання та останні тенденції у розвитку штучних нейронних мереж.

2. Проведений аналіз сучасного стану проблеми попередньої обробки та класифікації різночасових зображень дистанційного зондування Землі високої просторової розрізненості та аналіз літературних джерел виявили неефективність застосування існуючих методів, що веде до численних помилок класифікації, та визначили низку нерозв'язаних питань, зокрема відсутність автоматизованих інформаційних технологій, які дозволяють проводити класифікацію багатоспектральних різночасових супутникових зображень високої просторової розрізненості у реальному режимі часу. Саме розробка комплексної інформаційної технології попередньої обробки, аналізу та класифікації різночасових супутникових зображень і визначає основні напрямки даного дисертаційного дослідження.

3. Завдяки використанню сучасних програмних продуктів обробки даних ДЗЗ (ERDAS, ENVI, ArcGIS, MATLAB, OpenCV) вирішується низка питань з уніфікації процедур попередньої обробки та класифікації супутникових зображень, однак практика роботи з ними показала низький ступінь автоматизації цього процесу та відсутність зручних інструментів, що враховують особливості формування різночасових супутникових зображень високої просторової розрізненості, зокрема різні умови зйомки (сезонність, освітлення, ракурс та ін.). Крім того, зазначені продукти вимагають відповідних навичок та підготовки висококваліфікованих спеціалістів.

4. В результаті проведеного аналізу літературних джерел сформульовані мета і постановка завдань щодо розробки комплексної інформаційної технології попередньої обробки, аналізу та класифікації супутникових зображень високої просторової розрізненості.

РОЗДІЛ 2

ОБРОБКА РІЗНОЧАСОВИХ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ

2.1. Метод оптимізації обробки великих даних дистанційного зондування Землі

2.1.1. Дослідження проблеми обробки великих даних ДЗЗ

В даний час спостерігається стрімке зростання техноємких галузей, невід'ємною частиною яких є інформаційні технології. Існують суворі вимоги до інформаційних і технологічних рішень, пов'язаних із завданнями обробки, зберігання, аналізу та керування великими даними, коли застосовуються часові, обчислювальні та інформаційні обмеження. Тому важливим проблемним аспектом у цій сфері є забезпечення викладених вище вимог щодо розробки та застосування математичних методів, прийомів та інструментів при роботі з великими даними.

Зйомка Землі з космосу широко використовується в різних галузях господарства та сферах бізнесу, у тому числі для управління територіями, моніторингу надзвичайних ситуацій, для вивчення та екологічних досліджень нашої планети [66-68, 106, 126]. Терабайти даних супутникових зображень надвисокої роздільної здатності щохвилини надсилаються на наземні станції, але для вирішення різноманітних задач використовується лише 5% цих даних. Це підкреслює важливість автоматизації як методу прискорення процесів обробки зображень.

Дані дистанційного зондування Землі є одним із найпоширеніших джерел отримання Big Data, що дозволяють провести просторовий аналіз. Дані ДЗЗ характеризуються суттєвим збільшенням обсягу інформації і нарощуванням швидкості її надходження. Супутникові зображення мають непередбачувану об'ємність та різноманітність, що ускладнює їх аналіз та використання. Виникає потреба в розробці та вдосконаленні ефективних

методів обробки великих даних, враховуючи специфіку супутникових зображень. Це відкриває широкий простір для використання передових технологій штучного інтелекту, машинного навчання та аналізу великих даних у сфері обробки супутникових зображень, сприяючи подальшому розвитку наукових досліджень та технологічного прогресу.

В даному підрозділі розглядається створення та застосування методу оптимізації основних характеристик великих даних. Це передбачає зменшення обсягу інформації, що обробляється, а також збільшення швидкості пошуку та обробки даних, зберігаючи їх відповідні значення та надійність. Вищезазначене може бути досягнуто шляхом застосування запропонованої структури організації даних під назвою «м-кортежі на основі впорядкованих наборів довільної потужності». Ця впорядкована структура описує логічний шаблон загалом. Логічний шаблон — це впорядкований набір, що складається з усіх підмножин упорядкованого базового набору довільної потужності та будь-якого типу даних.

Щоб вирішити цю проблему, використано методи зменшення простору аналізованих станів. Іншими словами, простір розбивається на достатньо незалежні підпростори. У цій галузі розроблено декілька методів, включаючи використання симетрії для перевірки еквівалентності станів, абстракції на основі досліджень залежностей, абстракції предикатів, накладення обмежень на простір пошуку, спрямований пошук та евристичні методи [6, 84, 95, 111].

У роботі [25] автор провів аналіз на основі визнаних критеріїв щодо методів штучного інтелекту, що містять «комбінаторний вибух». Також було оцінено різні алгоритми пошуку, щоб визначити найкраще рішення проблеми «комбінаторного вибуху». У роботі [111] автори провели дослідження методів редукції великих даних. Ними зроблено висновок, що на даний момент не існує методів вирішення проблеми складності великих даних за обсягом і різноманітністю. У роботі [27] автори розглянули проблему обробки великих даних. Вони дослідили найефективнішу техніку роботи з

величезними та складними обсягами інформації, що швидко зростає, під назвою Hadoop MapReduce. У цій статті також розглянуто актуальні нереляційні моделі даних і доступні на даний момент методи моделювання. Було зроблено висновок, що на даний момент не існує техніки, яка б могла допомогти в управлінні великими даними. У роботі [94] автори надали огляд методів вибору функцій для значного зменшення складності Big Data. До них належать наступні методи: фільтри, гібридні, ансамблеві та інтегративні методи. Було зроблено висновок, що необхідно звернути увагу на обробку складних обсягів великих даних. У роботі [84] автори окреслили основні риси, характерні для Big Data. Вони запропонували формальну модель великих даних та описали її елементи. Дослідження також вивчало найсучасніші методи аналізу великих обсягів структурованих і неструктурованих даних. Водночас автори дійшли висновку, що аналіз та обробка Big Data потребує подальших досліджень. Робота [90] зосереджена на концепціях і техніках, присвячених обробці великих даних. Автори розглянули кілька категорій великих даних, таких як дані, створені людиною або комп'ютером, структуровані дані, неструктуровані дані та напівструктуровані дані. Вони також розглянули технології Big Data. Однією з концепцій Big Data, на якій вони зосередилися, є Apache Hadoop. Фреймворк Hadoop складається з двох основних компонентів. Це розподілена файлова система Hadoop і MapReduce. У роботі [37] автори запропонували трансформацію робочого процесу для обробки великих даних у реальному часі. Це було засновано на гетерогенних системах для мінімізації витрат і визначено різні шаблони як правила для алгоритму перетворення робочого процесу. Дослідницькі експерименти дійшли висновку, що запропонований метод трансформації робочого процесу може ефективно зменшити витрати на зв'язок і обчислення. У роботі [6] автори запропонували підхід до візуалізації Big Data на основі техніки кластеризації. Вони також розглянули підхід до вирішення проблеми кластеризації, коли тільки одне рішення може бути показано, що збігається до локального мінімуму. Тому авторами

запропоновано метод оптимізації алгоритму К-середніх, який сам по собі має кілька випадкових початкових точок. Це допомагає оптимізувати локальні мінімуми та візуалізувати різні рішення проблеми. Робота [95] представляє потужний метод для візуалізації, вилучення кластерів та аналізу даних. Цей метод називається самоорганізуючою картою Кохонена (SOM). SOM успішно використовується для великих даних, де традиційних методів часто недостатньо. Автори запропонували підхід, за якого топологію даних можна інтегрувати у візуалізацію SOM. Цього можна досягти шляхом введення зваженої матриці зв'язності та накладання її на SOM. Пропонується додатковий підхід для використання топології даних, що дозволяє використовувати графову модель у просторі даних.

Зроблений аналіз дозволяє визначити наступні цілі дослідження в рамках розробки методу оптимізації обробки великих даних дистанційного зондування Землі:

- Визначення способів мінімізації часу та обчислювальних ресурсів, залучених до обробки великих даних. Цього можна досягти шляхом аналізу властивостей структури організації даних під назвою «*m*-кортежі на основі впорядкованих наборів довільної потужності (OSAC)».

- Розробка методу скорочення простору аналізованих станів на основі нових функціональних залежностей між структурними елементами даних відповідно до їх розташування в упорядкованій структурі.

Вибір на користь «*m*-кортежі на основі OSAC» було зроблено через те, що ця впорядкована структура описує логічний шаблон у загальному вигляді. Це впорядкований набір усіх підмножин у межах упорядкованого базового набору довільної потужності для будь-якого типу даних. При представленні класу шаблону, який описує задану структуру даних, можна створити довільний алгоритм упорядкування даних базового набору для певного типу даних і для конкретного завдання роботи з цими даними. Математичні методи роботи з цією структурою даних пропонуються для використання при

розв'язуванні задач, пов'язаних з виконанням операцій над різними комбінаціями параметрів заданого базису.

Прикладом застосування певної структури даних може бути автоматизація аналізу та обробки багатьох потоків інформації. Як правило, такі потоки в розподілених багатозадачних багатокористувацьких автоматизованих системах можуть містити тисячі повідомлень в секунду.

2.1.2. Визначення структури організації даних

Структура організації даних під назвою «*m*-кортежі на основі OSAC» включає такі основні параметри та методи: **X** – упорядкована базисна множина за зростанням; **I** – упорядкована за зростанням базисна множина індексів елементів для множини *X*; x_i – *i*-й елемент множини *X*; *i* – елемент множини *I* та є індексом елемента множини *X*; *n* – потужність множин *X* і *I* [93].

$$\left\{ \begin{array}{l} I = \{1, 2, \dots, n\} = \{i \mid 1 \leq i \leq n\}, \\ X = \{x_1, \dots, x_i, x_{i+1}, \dots, x_n\} = \\ = \{x_i \mid 1 \leq i \leq n, \forall i \in [1, n) \rightarrow x_i < x_{i+1}\}, \\ n = |X| = |I| \end{array} \right. \quad (2.1)$$

2^X є логічним значенням набору *X*; 2^I є логічним значенням набору *I*.

$$\left\{ \begin{array}{l} 2^X = \{\emptyset, Y_1^n, \dots, Y_m^n, \dots, Y_n^n\} = \\ = \{Y_m^n \mid 1 \leq m \leq n\}, \\ 2^I = \{\emptyset, I_1^n, \dots, I_m^n, \dots, I_n^n\} = \\ = \{I_m^n \mid 1 \leq m \leq n\} \end{array} \right. \quad (2.2)$$

де Y_m^n є підмножиною 2^X . Його елементами є *m*-кортежі $y_{m,j}^n$. Вони складаються з елементів множини *X*. Ці елементи розташовані в порядку зростання за допомогою правобічної нумерації індексів i_η . Вони впорядковані від нижньої межі можливої зміни значення індексу $\alpha_{m,\eta}^n$ для кожного елемента кортежу x_{i_η} до верхньої межі $\beta_{m,\eta}^n$ [93]:

$$\left\{ \begin{array}{l} Y_m^n = \{y_{m,j}^n \mid y_{m,j}^n = (x_{i_1}, \dots, x_{i_\eta}, \dots, x_{i_m})\}, \\ 1 \leq \eta \leq m, \\ \alpha_{m,\eta}^n \leq i_\eta \leq \beta_{m,\eta}^n, \\ \alpha_{m,\eta}^n = \eta, \\ \beta_{m,\eta}^n = n - m + \eta, \\ \forall \eta \in [1, m) \rightarrow x_{i_\eta} < x_{i_{\eta+1}} \end{array} \right. \quad (2.3)$$

де $y_{m,j}^n$ – m -кортеж, який є j -м елементом множини Y_m^n , що складається з елементів базисної множини X потужності n ; m – довжина кортежу $y_{m,j}^n$; j – індекс кортежу $y_{m,j}^n$ в упорядкованому наборі Y_m^n . I_m^n є підмножиною 2^I . Її елементами є m -кортежі $i_{m,j}^n$, що відповідають кортежам $y_{m,j}^n$; $\alpha_{m,j}^n$ – нижня межа зміни значення індексу i_η у m -кортежі $y_{m,j}^n$; $\beta_{m,j}^n$ – верхня межа зміни значення індексу i_η в m -кортежі $y_{m,j}^n$; k_m^n є потужністю множин Y_m^n і I_m^n [93]:

$$\left\{ \begin{array}{l} I_m^n = \{i_{m,1}^n, i_{m,2}^n, \dots, i_{m,k_m^n}^n\} = \\ = \{i_{m,j}^n \mid i_{m,j}^n = (i_1, \dots, i_\eta, \dots, i_m), 1 \leq j \leq k_m^n\}, \\ i_\eta \in I, \\ 1 \leq \eta \leq m, \\ \eta \leq i_\eta \leq n - m + \eta, \\ \forall \eta \in [1, m) \rightarrow i_{\eta+1} - i_\eta \geq 1 \end{array} \right. , \quad (2.4)$$

де η – номер індексу елемента в кортежі $y_{m,j}^n$; i_η – індекс η -го елемента кортежу $y_{m,j}^n$ в базисному наборі X ; $i_{m,j}^n$ – це m -набір індексів елементів базису, що відповідає $y_{m,j}^n$ [93]:

$$k_m^n = |Y_m^n| = |I_m^n| = \binom{n}{m} = \frac{n!}{(n-m)! \cdot m!} \quad (2.5)$$

K^n є множиною з потужностями k_m^n підмножин Y_m^n і I_m^n для двох логічних значень 2^X і 2^I :

$$K^n = \{k_1^n = n, k_2^n = \frac{(n-1) \cdot n}{2}, \dots, k_m^n, \dots, k_{n-1}^n = n, k_n^n = 1\} = \{k_m^n | k_m^n = \binom{n}{m}, 1 \leq m \leq n\}. \quad (2.6)$$

J_m^n є впорядкованою множиною індексів j для елементів множини Y_m^n і I_m^n :

$$J_m^n = \{1, 2, \dots, k_m^n\} = \{j | 1 \leq j \leq k_m^n\} \quad (2.7)$$

Більш детальний опис основних термінів і визначень, а також математичних методів роботи зі структурою даних під назвою « m -кортежі на основі OSAC» наведено в роботах [91-93]. Таким чином маємо дану структуру даних під назвою « m -кортежі на основі OSAC», для якої необхідно розробити математичний метод розв'язання системи (2.8) для будь-якої комбінації значень параметрів: n, m_1, m_2, j_1, j_2 :

$$\begin{cases} y_{m,j}^n = (y_{m_1,j_1}^n \text{ оп } y_{m_2,j_2}^n) \neq \emptyset, \\ \text{оп} \in \{\subset, \cap, \cup\}, \\ 1 \leq m_1 \leq m_2 \leq n, \\ 1 \leq j_1 \leq \binom{n}{m_1}, \\ 1 \leq j_2 \leq \binom{n}{m_2} \end{cases} \quad (2.8)$$

Вище у системі (2.8) прийнято такі позначення:

$y_{m,j}^n$ є m -кортежем і булевим елементом 2^X ; n – потужність упорядкованого базису X ; m_1, m_2 – довжини кортежу операндів; j_1, j_2 – індекси (порядкові номери) m -кортежів операндів у впорядкованих наборах $Y_{m_1}^n$ і $Y_{m_2}^n$; m, j – індекси кортежу для результату операції *оп*.

Вищезазначене повинно бути досягнуто за мінімальний час і з використанням мінімальних обчислювальних ресурсів для обробки та аналізу даних [93].

Основна ідея цього методу полягає в розв'язуванні системи (2.8) шляхом виведення набору функціональних залежностей [93]:

$$F = \{f_\gamma(n, m_1, m_2, j_1, \eta)\}.$$

Він заснований на аналізі властивостей структури даних за різних початкових умов, тобто для будь-яких можливих допустимих комбінацій значень аргументів f_γ .

$$\begin{cases} j_2 = f_\gamma(n, m_1, m_2, j_1, \eta), \\ (j_2 \in J2_{m_2}^n(y_{m_1, j_1}^n)) \rightarrow \\ (J2_{m_2}^n(y_{m_1, j_1}^n) = \{f_\gamma(n, m_1, m_2, j_1, \eta)\}), \\ J2^n(y_{m_1, j_1}^n) = \{J2_{m_2}^n(y_{m_1, j_1}^n)\}, \\ m_1 < m_2 \leq n \end{cases} \quad (2.9)$$

У системі (2.9) прийнято такі позначення [93]:

η – це розташування елемента y_{m_1, j_1}^n в кортежі y_{m_2, j_2}^n ;

$J2_{m_2}^n(y_{m_1, j_1}^n)$ – набір індексів j_2 , що визначають елементи y_{m_2, j_2}^n з однієї з підмножин $Y_{m_2}^n$ булевих 2^X , які відповідають умові $m_1 < m_2 \leq n$, для якої система (2.8) має рішення; $J2^n(y_{m_1, j_1}^n)$ – набір індексів j_2 , що визначають елементи y_{m_2, j_2}^n для всіх підмножин 2^X і для якої система (2.8) має рішення.

2.1.3. Основні властивості методу

Можливість визначати нові властивості впорядкованої структури даних і виводити на їх основі нові функціональні залежності між елементами впливає з правил формування структури даних і аналізу розташування елементів та визначається парою індексів (j, m) .

2^X представлено графічно в загальному вигляді на рис. 2.1 і рис. 2.2.

Кожна точка на графіках, показаних на рис. 2.1 і рис. 2.2, відповідає унікальному m -кортежу $y_{m, j}^n$. Вони утворюються з елементів упорядкованої базисної множини X із потужністю n і можуть бути однозначно визначені

парою індексів (j, m) . Замкнуті полілінії, показані на графіках, окреслюють усі елементи 2^X .

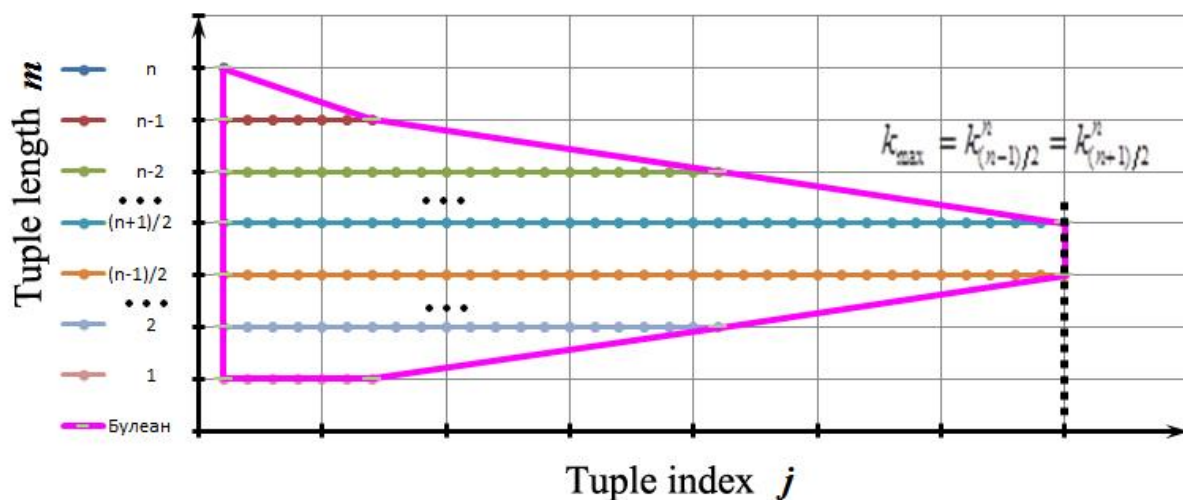


Рис. 2.1. Графічне представлення 2^X з непарною потужністю значення базового набору




Рис. 2.2. Графічне представлення 2^X з парною потужністю базового набору

У результаті проведених досліджень щодо властивостей та функціональних зв'язків між елементами структури даних « m -кортежів на основі OSAC» доведено та описано наступні певні властивості даної структури даних [93].

Властивість 1. Для двох сусідніх елементів $i_{m,j}^n$ і $i_{m,j+1}^n$ набору I_m^n , впорядкованого правобічним перерахуванням елементів базисної множини I з потужністю n , виконується наступна умова:

$$\begin{aligned} & (\exists i_{\eta'}^j \in i_{m,j}^n) \ \& \ (\exists i_{\eta'}^{j+1} \in i_{m,j+1}^n) \rightarrow \\ & \rightarrow \begin{cases} i_{\eta'}^{j+1} - i_{\eta'}^j = 1, \\ (\eta' > 1) \ ? \ (1 \leq \eta_2 = \eta_1 < \eta', \quad i_{\eta_2}^{j+1} = i_{\eta_1}^j) \end{cases} \end{aligned}$$

Властивість 2. Елементи i_{m,j_1}^n і i_{m,j_2}^n набору I_m^n , впорядковані правостороннім пошуком елементів з базисного набору I з потужністю n , є суміжними $|j_2 - j_1| = 1$, якщо виконується така умова:

$$\begin{aligned} & \left(\eta \in [1, m], \quad i_{\eta}^{j_1} \in i_{m,j_1}^n, \quad i_{\eta}^{j_2} \in i_{m,j_2}^n, \quad \Delta i_{\eta} := |i_{\eta}^{j_1} - i_{\eta}^{j_2}| \right) \rightarrow \\ & \rightarrow \left((\Delta i_1 = 1) \vee \left(\bigwedge_{\eta=1}^{\eta^*} (\Delta i_{\eta} = 0) \ \& \ (\Delta i_{\eta^*+1} = 1) \right), \quad 1 \leq \eta^* < m \right) \end{aligned}$$

При цьому порядок елементів у наборі I_m^n визначається таким чином:

$$\left((\Delta i_{\eta^*+1} = i_{\eta^*+1}^{j_1} - i_{\eta^*+1}^{j_2}) > 0 \right) \ ? \ (j_1 > j_2) : (j_2 > j_1).$$

Властивість 3. Доповнення до базового набору X до елемента $y_{m,j}^n \in Y_m^n$ це елемент, який належить множині Y_{n-m}^n .

$$\overline{y_{m,j}^n} \in Y_{n-m}^n.$$

Властивість 4. Доповнення до базової множини I до елемента $i_{m,j}^n \in I_m^n$ це елемент, який належить множині I_{n-m}^n .

$$\overline{i_{m,j}^n} \in I_{n-m}^n.$$

Властивість 5. Доповнення до базового набору X до елемента $y_{m,j}^n \in Y_m^n$ це елемент, який можна визначити наступним чином:

$$\overline{y_{m,j}^n} = y_{n-m, k_m^n - (j-1)}^n.$$

Сформулюємо деякі властивості перетинів і об'єднань для елементів структури даних. Ми маємо:

$$\begin{cases} y_{m,j}^n = (y_{m_1,j_1}^n \text{ оп } y_{m_2,j_2}^n), \\ i_{m,j}^n = (i_{m_1,j_1}^n \text{ оп } i_{m_2,j_2}^n), \\ \text{оп} \in \{\cap, \cup\} \end{cases} \quad (2.10)$$

Для виразів у системі (2.10) застосовні такі властивості [93]:

Властивість 6. (Властивість анулювання для операції перетину). Якщо один із операндів перетину є підмножиною іншого операнда, результатом операції перетину буде перший операнд.

$$\begin{aligned} (y_{m_1,j_1}^n \subset y_{m_2,j_2}^n) \text{ ? } (y_{m,j}^n := y_{m_1,j_1}^n) \text{ :} \\ ((y_{m_1,j_1}^n \supset y_{m_2,j_2}^n) \text{ ? } (y_{m,j}^n := y_{m_2,j_2}^n) \text{ : } \text{NOP}), \end{aligned}$$

де *NOP* – без операції.

Наслідок із властивості 6. Якщо принаймні один із операндів перетину булевих елементів уздовж базису з потужністю $n \in n$ -кортежем, то їх перетин буде другим операндом.

$$\begin{aligned} ((m_1 = n) \wedge (m_2 \neq n)) \text{ ? } (m := m_2, j := j_2) \text{ :} \\ (((m_1 \neq n) \wedge (m_2 = n)) \text{ ? } (m := m_1, j := j_1) \text{ : } \text{NOP}). \end{aligned}$$

Властивість 7. (Властивість анулювання для дії союзу). Якщо один із операндів об'єднання є підмножиною іншого операнда, результатом операції об'єднання буде другий операнд.

$$\begin{aligned} (y_{m_1,j_1}^n \subset y_{m_2,j_2}^n) \text{ ? } (y_{m,j}^n := y_{m_2,j_2}^n) \text{ :} \\ ((y_{m_1,j_1}^n \supset y_{m_2,j_2}^n) \text{ ? } (y_{m,j}^n := y_{m_1,j_1}^n) \text{ : } \text{NOP}). \end{aligned}$$

Наслідок 1 із властивості 7. Якщо принаймні один з операндів об'єднання булевих елементів уздовж базису набору з потужністю $n \in n$ -кортежем, то їх об'єднання буде також n -кортежем.

$$((m_1 = n) \vee (m_2 = n)) \quad ? \quad (m := n, \quad j := 1)$$

Наслідок 2 із властивості 7. Якщо операндами об'єднання є перші два або відповідно два останні елементи в підмножинах $Y_{m_1}^n$ і $Y_{m_2}^n$ з різною довжиною кортежу, то елемент з меншою довжиною кортежу є підмножиною елемента з більшою довжиною кортежу [93].

$$((m_1 \neq m_2) \wedge ((j_1 = j_2 = 1) \vee ((j_1 = k_{m_1}^n) \wedge (j_2 = k_{m_2}^n)))) \quad ?$$

$$((m_1 < m_2) \quad ? \quad (y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) \quad : \quad (y_{m_1, j_1}^n \supset y_{m_2, j_2}^n))$$

Властивість 8. Перетин/об'єднання логічного елемента з самим собою вздовж базису є тим самим m -кортежем.

$$((m_1 = m_2) \wedge (j_1 = j_2)) \quad ? \quad (m := m_1, \quad j := j_1)$$

Властивість 9. Перетин двох різних $(n - 1)$ -кортежів уздовж базисної множини з потужністю $n \in (n - 2)$ -кортежем.

$$((m_1 = m_2 = n - 1) \wedge (j_1 \neq j_2)) \quad ? \quad (m := n - 2)$$

Властивість 10. Об'єднання двох різних $(n - 1)$ -кортежів уздовж базисного набору з потужністю $n \in n$ -кортежем.

$$((m_1 = m_2 = n - 1) \wedge (j_1 \neq j_2)) \quad ? \quad (m := n, \quad j := 1)$$

Властивість 11. (Властивість доповнення для перетинів). Якщо один із операндів перетину булевих елементів уздовж базису з потужністю $n \in$ доповненням до іншого операнда до базису, то результатом операції буде \emptyset .

$$((m_2 = n - m_1) \wedge (j_2 = k_{m_1}^n - j_1 + 1)) \quad ? \quad (\emptyset)$$

Властивість 12. Якщо один із операндів об'єднання булевих елементів уздовж базису з потужністю n є доповненням до іншого операнда до базису, то результатом операції буде n -кортеж [93].

$$((m_2 = n - m_1) \wedge (j_2 = k_{m_1}^n - j_1 + 1)) \quad ? \quad (m := n, j := 1)$$

Властивість 13. Допустимий діапазон зміни довжини результуючого m -кортежу після операції об'єднання таких:

$$\max(m_1, m_2) \leq m \leq \min(m_1 + m_2, n).$$

Розглянемо далі певні властивості включення елементів структури даних. Маємо:

$$\begin{cases} y_{m,j}^n = (y_{m_1,j_1}^n \subset y_{m_2,j_2}^n), \\ i_{m,j}^n = (i_{m_1,j_1}^n \subset i_{m_2,j_2}^n), \\ 1 \leq m_1 < m_2 \leq n \end{cases} \quad (2.11)$$

Для виразів у системі (2.11) застосовні всі наведені нижче властивості [93]:

Властивість 14. Вираз (2.11) справедливий для $\binom{n - m_1}{m_2 - m_1}$ елементів множини $Y_{m_2}^n$.

Наслідок із властивості 14. Якщо $j_1 = 1$, то вираз (2.11) справедливий для перших $\binom{n - m_1}{m_2 - m_1}$ елементів множини $Y_{m_2}^n$.

Властивість 15. Вираз (2.11) справедливий для

$$N_{m_1} = \sum_{m_2=m_1+1}^n \binom{n - m_1}{m_2 - m_1} \text{ елементів } 2^X.$$

2.1.4. Практичні результати

Для булевих елементів 2^X із потужністю 2^n і довжиною кортежу $[m_1; m_2]$, які застосовуються як операнди $y_{m_1, j_1}^n \subset y_{m_2, j_2}^n$, ми можемо визначити частку комбінацій операндів, для яких виконується умова:

$$(y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) = \text{true}$$

Визначимо загальну кількість комбінацій операндів операції $y_{m_1, j_1}^n \subset y_{m_2, j_2}^n$, де $m_2 = m_1$ [93]:

$$N_{m_2=m_1}^n = N_{m_1}^n = k_{m_1}^n + \binom{k_{m_1}^n}{2}$$

Визначимо кількість комбінацій операндів для умови $(y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) = \text{true}$, де $m_2 = m_1$:

$$Nt_{m_2=m_1}^n = Nt_{m_1}^n = k_{m_1}^n$$

Частка комбінацій операндів, представлених логічними елементами з довжиною кортежу $[m_1; m_2 = m_1]$ для умови $(y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) = \text{true}$ по відношенню до загальної кількості комбінацій операндів із довжиною кортежу $[m_1; m_2 = m_1]$ розраховується наступним чином [93]:

$$\Delta_{m_2=m_1}^n = \Delta_{m_1}^n = \frac{Nt_{m_1}^n}{N_{m_1}^n} 100\% = \frac{k_{m_1}^n}{k_{m_1}^n + \binom{k_{m_1}^n}{2}} 100\%$$

Визначимо загальну кількість комбінацій операндів для умови $(y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) = \text{true}$, де $m_2 > m_1$:

$$Nt_{m_2>m_1}^n = Nt_{m_1, m_2}^n = k_{m_1}^n \binom{n - m_1}{m_2 - m_1}.$$

Частка комбінацій операндів, представлених логічними елементами з довжинами кортежів $[m_1; m_2 > m_1]$, які відповідають умові $(y_{m_1, j_1}^n \subset y_{m_2, j_2}^n) = true$ по відношенню до загальної кількості комбінацій операндів із довжиною кортежу $[m_1; m_2 > m_1]$ розраховується наступним чином:

$$\Delta_{m_2 > m_1}^n = \Delta_{m_1, m_2}^n = \frac{Nt_{m_1, m_2}^n}{N_{m_1, m_2}^n} 100\% = \frac{k_{m_1}^n \binom{n-m_1}{m_2-m_1}}{k_{m_1}^n k_{m_2}^n} 100\% \quad (2.12)$$

У таблиці 2.1 наведено результати розрахунків для Δ_{m_1, m_2}^5 .

Таблиця 2.1. Результати для Δ_{m_1, m_2}^5

m_1	m_2	N	Nt	$\Delta, \%$
1	2	3	4	5
1	1	15	5	33
	2	50	20	40
	3	50	30	60
	4	25	20	80
	5	5	5	100
2	2	55	10	18
	3	100	30	30
	4	50	30	60
	5	10	10	100
3	3	55	10	18
	4	50	20	40
	5	10	10	100
4	4	15	5	33
	5	5	5	100
5	5	1	1	100

Графік $\Delta^5 = f_5(m_1, m_2)$ показано на рис. 2.3. Щоб порівняти, як Δ_{m_1, m_2}^n змінюється при збільшенні n , на рис. 2.4 показано графік $\Delta^{15} = f_{15}(m_1, m_2)$.

З цих графіків видно, що зі збільшенням n для операндів з однаковою довжиною кортежу m_1 і m_2 частка комбінацій операндів зменшується. При цьому одна з них є підмножиною іншої. Значення частки аналізованих комбінацій операндів починає зростати при останніх значеннях масштабу m_2 .

Тому частка комбінацій операндів, де одна з них є підмножиною іншої, зростає зі збільшенням різниці $m_2 - m_1$.




Рис. 2.3. Графічне подання Δ_{m_1, m_2}^n для операндів, представлених m -кортежами при $n = 5$




Рис. 2.4. Графічне подання Δ_{m_1, m_2}^n для операндів, представлених m -кортежами при $n = 15$

Запропонований метод дозволяє оптимізувати роботу з елементами структури даних без виконання складних обчислювальних алгоритмів. Оцінки часу для отримання результату змінюються від кубічного $O(n^3)$ до лінійного $O(n)$. Цей підхід дозволяє мінімізувати час і обчислювальні ресурси, задіяні в обробці, до масштабу реального часу [93].

2.2. Infrastructure-as-a-service для обробки потоку даних дистанційного зондування

Протягом останнього десятиліття відбулися величезні досягнення в сфері дистанційного зондування, що вплинули на швидкість та якість збирання даних, їх обробку та картографування. Цей стрімкий прогрес став можливим завдяки змінам у розробці програмного забезпечення, що включає в себе хмарні технології, а також успіху глибоких нейронних мереж (DNN) у обробці величезної кількості даних. Рішення Deep Learning (DL) повинні бути належним чином навчені за допомогою потужного апаратного забезпечення вартістю тисяч доларів, що часто є неоптимальним для використання на власних серверах.

Одним із багатообіцяючих підходів до навчання та налаштування DNN є розподілені глибокі нейронні мережі (DDNN), які розроблені для роботи в структурах оркестровки докерів, таких як Kubernetes або Docker Swarm.

У цьому розділі запропоновано рішення infrastructure-as-a-service (IaaS) для обробки потоку даних дистанційного зондування за допомогою рішень глибокого навчання та хмарних технологій Kubernetes та Apache Airflow, розміщених на платформі Google Computing Platform (GCP). Запропонований алгоритм представлений у вигляді напрямного ациклічного графа (DAG) у застосунку IaaS. Згадані хмарні технології використовуються для кращого представлення робочого процесу, який реалізує складну систему паралельного виконання обчислювально-важких завдань обробки зображень

високої просторової розрізненості, зокрема для надання результатів класифікації швидко та ефективно.

Теоретичним підґрунтям цього підрозділу є отримані автором результати у п.2.1.

2.2.1. Розробка архітектури даних

Алгоритм повинен охоплювати більшість аспектів навчання та налаштування моделей, використовуючи всі наявні обчислювальні ресурси та мати можливість відповідним чином масштабувати навчальне/настроювальне середовище:

- він повинен бути готовий приступити до навчання щоразу, коли з'являться нові дані;
- виділяти достатні ресурси для виконання завдання;
- він повинен запланувати відповідний обсяг робіт і переконатися, що всі виділені ресурси використовуються більшу частину часу.

Для того щоб реалізувати ці вимоги, в поточній роботі використовуються Apache Airflow і Azure Kubernetes Service [121].

Airflow – це керований спільнотою набір інструментів, який дозволяє реалізувати різні робочі процеси та будь-яке планування для нього. Airflow реалізує чергу повідомлень з метою організації певних завдань. Робочий процес в цих рамках реалізується у вигляді DAG. На додаток до цього, Airflow дозволяє параметризувати DAG і може бути розширений плагінами для впровадження підтримки будь-якого виду інших послуг. У поточній роботі Airflow використовується спільно з Kubernetes, реалізованим в рамках AZURE.

Сам Kubernetes являє собою систему автоматизованого управління і масштабування контейнерних додатків. На практиці це дозволяє користувачам організувати певні апаратні ресурси в кластер. Сам кластер не оперує жодними ресурсами і керує лише метаданими про доступні ресурси. Кластер завжди складається з одного або декількох пулів вузлів, які

представляють певну кількість апаратних ресурсів. Ці пули вузлів можуть бути масштабовані за правилами, встановленими в межах цього конкретного пулу вузлів. Для поточних досліджень ця властивість пулів вузлів використовується з урахуванням особливих потреб у навчанні та налаштуванні DDNN.

2.2.2. Завантаження даних

Для цілей цього алгоритму дані зберігаються в межах сховища і можуть бути доступні для обробки зображень ДЗЗ, коли це необхідно. Цим сховищем керує оператор, який позначає дані з відповідним статусом:

- *pending* – стан за замовчуванням для будь-яких нових даних;
- *processing* – дані заплановані до роботи;
- *done* – дані використовуються в навчальних цілях.

Сховище сканується з певним тайм-аутом. Весь процес управління даними можна визначити як вираз предиката:

$$\forall x \forall t \exists s \in S, P(x, t, s) \quad (2.13)$$

де x – об'єкт даних зображення, t – проміжок часу і s – один зі статусів з дискретного домену статусів $S = \{pending, processing, done\}$.

2.2.3. Розрахунок кластера робочого навантаження Kubernetes

У більшості випадків кластер Kubernetes (КС) створюється і підтримується для забезпечення стабільної і масштабованої платформи для потреб різних веб-сервісів. Однак для завдань глибокого навчання такий робочий процес не є оптимальним через характер навчання та налаштування DL, які вимагають швидкого стрибка використання ресурсів час від часу.

Запропонований алгоритм реалізує робочий процес, який не вимагає, щоб КС постійно працював. Наш підхід базується на зберіганні даних.

Визначений оператор відстежує сховище і створює кластер за цими вимогами.

КС призначений для створення з числом пулів навчальних і тюнінгових (ТТ) вузлів, що дорівнює кількості використовуваних в експерименті архітектур нейронних мереж. Це рішення базується на різних потребах у апаратних ресурсах кожної конкретної мережі здебільшого через розмір мережі, а не архітектуру. КС сам по собі не вносить нічого конкретного для алгоритму, конфігурація пулів вузлів є єдиною частиною, яка має значення для роботи алгоритму.

Пули вузлів налаштовані певним чином для підтримки концепції розподіленого навчання з DDNN, а також захищені віртуальною приватною мережею (VPN), щоб запобігти непотрібному впливу Інтернету. Kubernetes надає параметри пулу вузлів для автоматичного масштабування, які спеціально налаштовані під потреби алгоритму. Рішення про масштабування приймаються наступним рівнянням:

$$R_{i+1} = [R_i (C_m)/(D_m)], i \in N, m = \{cpu, gpu, mem\} \quad (2.14)$$

де R_i і R_{i+1} є поточною і бажаною реплікою певних ресурсів в межах i -го пулу вузлів, (C_m) і (D_m) – поточне і бажане метричне значення, яке визначається кортежем m .

Варто згадати, що всередині кожного пулу вузлів можуть бути створені тільки вузли одного певного типу – це один з основних ресурсів, за якими створюються окремі вузлові пули для різних типів DNN. Однак з метою поточної роботи модель автомасштабування коригується так, щоб переконатися, що більшу частину часу використовуються всі доступні ресурси, особливо графічний процесор:

- всі запитувані ресурси виділяються негайно;
- мінімальна кількість вузлів 0 замість 1;
- введено вертикальне масштабування.

При навчанні моделі очікується, що всі запитувані ресурси будуть доступні відразу з урахуванням конкретної специфікації вузла в пулі вузлів:

$$N_{m,i} = \lfloor D_m / S_{m,i} \rfloor, i \in N, m = \{cpu, gpu, mem\} \quad (2.15)$$

де N_i – кількість вузлів для виділення в i -му пулі вузлів, D_m – кількість запитуваного m -го ресурсу, а $S_{m,i}$ – апаратна специфікація вузла m -го ресурсу в межах i -го вузлового пулу.

Коли кількість необхідних ресурсів дорівнює 0, всі вузли будуть зайняті, вводячи близько 0 вартості використання певного пулу вузлів, коли немає доступних завдань навчання або налаштування (всі статуси завдань у сховищі даних *виконані*). Вертикальне масштабування вводиться для того, щоб уникнути простою ресурсів. Коли певна підмережа DDNN закінчує свої завдання, вивільнені ресурси розподіляються між іншими запущеними процесами.

2.2.4. Планування робочого циклу

Для того, щоб потік даних і автоматичне масштабування кластера працювали, необхідно визначити робочий процес. Кращий спосіб опису алгоритму – динамічний спрямований ациклічний граф (DAG). Для оновлення стану даних циклічна залежність не потрібна, оскільки вихідні дані лише зчитуються і жодним чином не змінюються, а стани даних управляються окремо, враховуючи будь-які відсутні значення в результаті як *очікувані*. Дані переглядаються кожен раз при запуску тренувального процесу. Існує кілька причин, чому DAG є динамічним: деякі його вершини представляють процес створення пулу вузлів, а кількість моделей DNN та їх специфікації можуть відрізнятись. Інші вершини представляють розподілений навчальний процес, коли кожна DNN розбивається на певну кількість підмереж (рис. 2.5). Отже, кінцевий DAG розраховується з урахуванням кількості специфікацій нейронної мережі та кількості підмереж

для кожної мережі. Для кожної підмережі створюється Pod, що представляє певний навчальний процес підмережі. Pod, зокрема, визначає кількість ресурсів, необхідних для будь-якого завдання.

Для демонстрації гнучкості запропонованого підходу вводяться додаткові вершини, які доповнюють процес навчання DL. Коли всі pod припинені (що означає, що всі завдання виконані), вводиться 5-кратна перехресна валідація (на рисунку позначено CV) з подальшою оцінкою найкращої навченої моделі кожного типу.

Кінцевою вершиною DAG є кластерне вибуття. Коли всі процеси завершені, результати навчання зберігаються на постійне зберігання за межами кластера, тому кластер більше не потрібен.

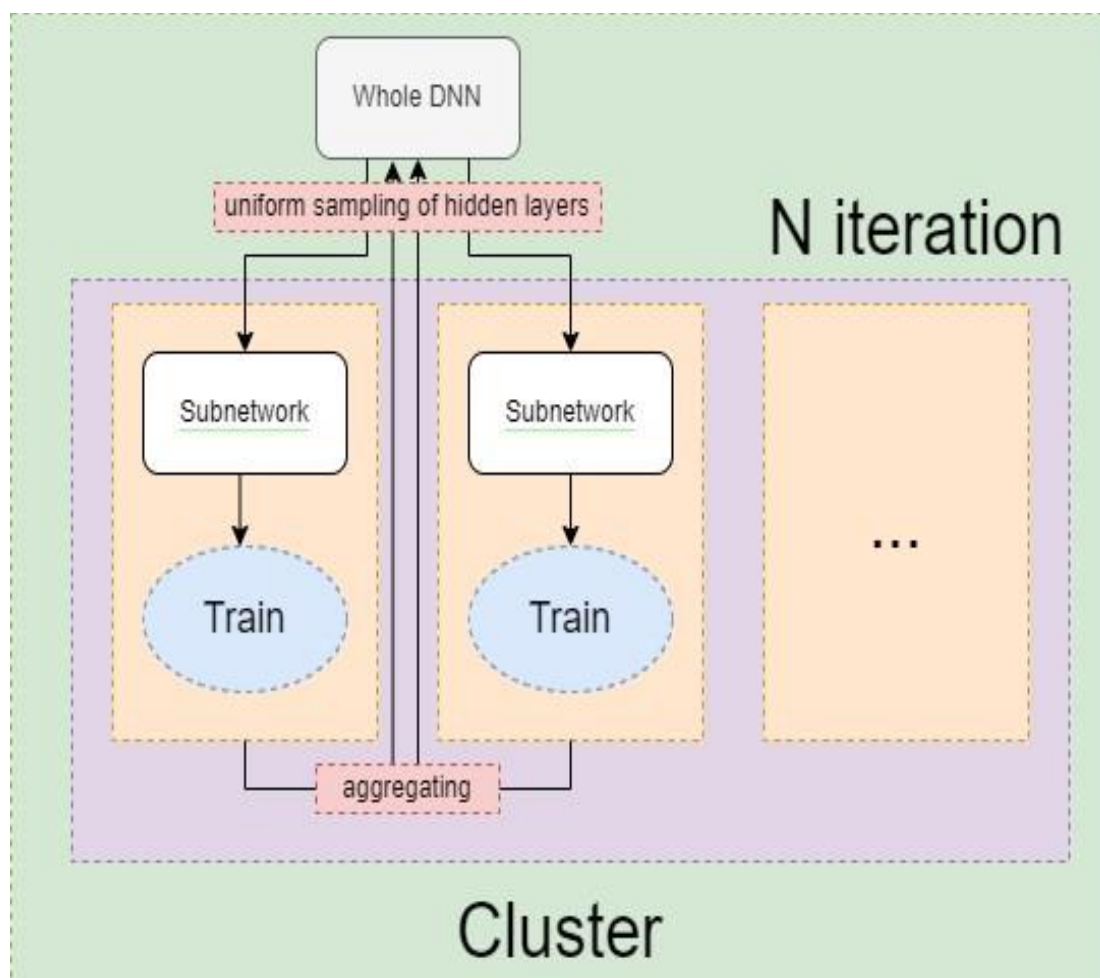


Рис.2.5. Розподіл моделі DNN між наявними ресурсами в межах обчислювального кластера

Вся динамічна схема DAG знаходиться на рисунку 2.6.

Для цього експерименту використовуються кілька інструментів, головним з яких є Apache Airflow. Це фреймворк, що працює на основі відкритого коду та розвивається спільнотою, призначений для планування та моніторингу робочих процесів, причому DAG розглядається як основа цього інструмента для визначення будь-яких робочих процесів, що логічно відповідає запропонованому алгоритму. Кожен елемент DAG у Airflow визначається операторами. Ці оператори реалізовані для представлення частини функціоналу багатьох різних платформ, включаючи Kubernetes. Існують оператори Kubernetes для управління кластером та потоками, які є достатніми для втілення алгоритму.

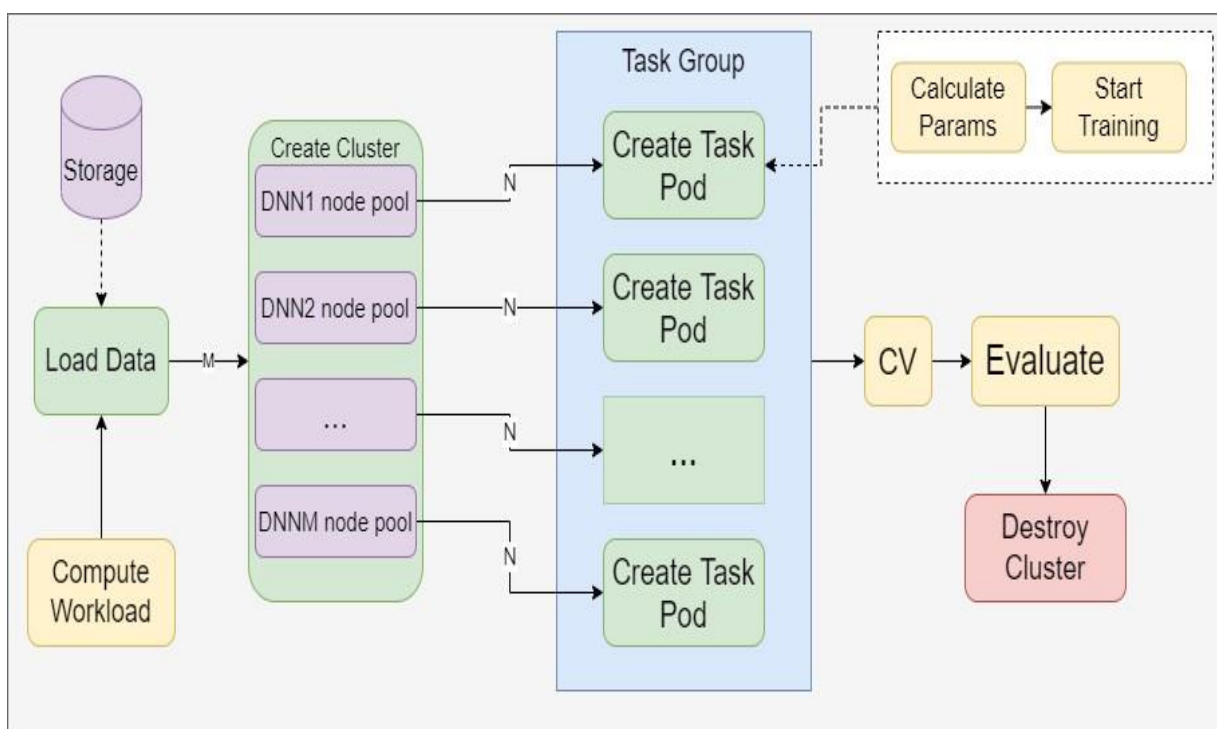


Рис.2.6. Алгоритм навчання DAG

У зв'язку з недостатнім обсягом маркованих даних, доступних у поточній роботі, використовується набір даних, що був розроблений у роботі [31]. Набір даних базується на зображеннях високої просторової розрізненості супутника WorldView-3. Для досягнення кращої

продуктивності моделі DNN, використовувалися додаткові методи аугментації, використовуючи унікальні властивості супутникових зображень, такі як канали близької інфрачервоної зони (NIR). Техніка паншарпенінгу використовувалася для об'єднання монохромного зображення з багатоспектральним зображенням (більш докладно розглянуто у п.2.3).

2.2.5. Розрахунок обчислювальних витрат

Показник, який використовується для вимірювання продуктивності моделей, – це загальна точність (OA):

$$OA = N_c/N_t, \quad (2.16)$$

де N_c – це кількість правильно класифікованих вибірок, а N_t – кількість вибірок для тестування.

Використано співвідношення навчання/тестування 90/10, де 90% даних використовуються в 5-кратній перехресній перевірці (5-fold CV).

При розрахунку витрат на обчислення час розглядається як адекватна метрика, оскільки алгоритм розроблено так, щоб бути нечутливим до апаратного забезпечення і може бути налаштований щодо апаратного забезпечення для задоволення конкретних потреб. Таким чином, вартість хмарних апаратних ресурсів представлена значенням X . Крім того, реалізована автоматична схема масштабування обґрунтовує твердження, що певна кількість ресурсів з вартістю X на годину використовується на 100% усього часу.

Рентабельність витрат розраховується як співвідношення обчислювальних витрат:

$$CE = \frac{C_{alg}}{C_{std} * N_{gpu}} * 100\%, \quad (2.17)$$

де C_{alg} і C_{std} – витрати, розраховані за допомогою запропонованого алгоритму і стандартного підходу, згаданого вище, а N_{gpu} – це ряд графічних

процесорів, що використовуються в алгоритмі завдяки розподіленому навчанню.

У таблиці 2.2 продемонстровані результати моделювання із застосуванням запропонованого алгоритму.

Як зазначалося, глибокі нейронні мережі стають складнішими та точнішими, але все ще потребують великих витрат на навчання та налаштування. Проблема швидко загострюється, коли йдеться про навчання кількох моделей з метою визначення кращої, тут витрати на обчислення зростають дуже швидко.

Таблиця 2.2. Моделювання результатів ефективності навчання

Назва моделі	Функція втрат	ОА	Кількість GPU	Обчислювальна вартість (X-годин)	СЕ (%)
ARCNet	Категорична	87.5%	4	7.144610277	122
ARCNet	Вассерштейн	91.02%	4	51.39644785900009	121
MCNN	Категорична	79.54%	2	125.00879671299981	126
MCNN	Вассерштейн	81.44%	2	7.1446102779998455	125
SF-CNN	Категорична	85.5%	3	51.39644785900009	131
SF-CNN	Вассерштейн	89.9%	3	125.00879671299981	141
GBN	Категорична	83.7%	2	7.1446102779998455	111
GBN	Вассерштейн	87.2%	2	51.39644785900009	112

Запропонований алгоритм є складним end-to-end рішенням, яке готове до використання з усіма інструментами, які є доступними та відкритими для використання. Коли алгоритм детально складний, описаний симуляційний підхід демонструє, що його дуже легко налаштувати та запустити завдяки прямолінійному опису алгоритму у вигляді DAG в інфраструктурі Apache Airflow з усіма налаштуваннями Kubernetes, які керуються прозоро.

Симуляційний експеримент показав, що можливо налаштувати будь-яку конфігурацію щодо моделей та ресурсів, які доступні, і є чітке підтвердження кращого управління витратами згідно з метрикою SE, яка адекватно відображає ефективність алгоритму. Згідно проведеного дослідження, можна зробити висновок, що за допомогою цього алгоритму можливо досягти принаймні 10% покращення витрат, а для більшості моделей SE досягає понад 20% покращення.

2.3. Інформаційна технологія попередньої обробки супутникових зображень з використанням згорткової нейронної мережі

2.3.1. Розробка інформаційної технології

Останніми роками зростає потреба у супутникових зображеннях високої просторової розрізненості через їхню важливість у практичних застосуваннях, таких як землевпорядкування, навігація, екологічний моніторинг та розробка інфраструктурних проєктів. Одним із ключових етапів попередньої обробки супутникових геопросторових даних є їхнє злиття, або паншарпенінг, що включає в себе поєднання панхроматичних зображень (ПЗ) та багатоканальних зображень (БЗ), які хоч і мають нижчу просторову розрізненість, ніж панхроматичні, проте містять спектральну інформацію, що є невід'ємною частиною аналізу земної поверхні [45-47, 62]. Методи паншарпенінгу не лише підвищують просторову роздільну здатність отриманих зображень, але і зберігають спектральну інформацію. Це дозволяє отримати повніші та більш інформативні дані для подальшого тематичного аналізу даних (виявлення, розпізнавання об'єктів, класифікацію земного покриття, тощо). Хоча існує значна кількість запропонованих алгоритмів паншарпенінгу, але жоден з них не може бути універсальним для всіх типів датчиків та демонструє різні результати. Ці дослідження можна розділити на дві групи: традиційні методи оптимізації та методи, що базуються на глибокому навчанні. Метод інтенсивність-відтінок-насиченість (HSV) [46,

74], аналіз головних компонент (PCA) [18] та перетворення Грама-Шмідта (Gram-Schmidt) [3], метод Бровей (Brovey), тощо – традиційні методи. Ці методи дозволяють досягти високої просторової роздільної здатності, але призводять до значних спектральних спотворень. З іншого боку, методи, що базуються на аналізі множинної роздільної здатності, такі як вейвлет-перетворення [46], фільтри високих частот та узагальнена піраміда Лапласа [1], можуть зберігати спектральну інформацію, але мають просторові спотворення. Поширеним є методи паншарпенінгу на основі стискання (CS) [26]. Недоліком методу є те, що він потребує великої кількості навчальних зображень високої просторової розрізненості, які можуть бути недоступними. Для вирішення цієї проблеми, було запропоновано використання комбінованих методів, таких як Revisited AWLP, керованого фільтра, тощо. Ці методи призначені для збільшення просторової здатності зображень при збереженні спектральної інформації. Але, експериментально доведено, що ці методи все одно призводять до певних спектральних і просторових спотворень.

Останнім часом велика увага приділяється методам паншарпенінгу на основі глибокого навчання. Автори [35] запропонували методіку самокодування з низьким рівнем шуму для отримання співвідношення між зображеннями з високою та низькою роздільною здатністю за допомогою глибоких нейронних мереж. В роботі [36] застосували згорткові нейронні мережі (CNNs) до області паншарпенінгу, що значно покращило продуктивність алгоритму порівняно з традиційними методами. Автори [103] вирішили проблему втрати інформації під час вилучення ознак на основі нейронних мереж. В роботі [112] запропоновано модель PanNet для спектрального збереження та просторового покращення первинних даних.

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

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

Метою дослідження є розробка інформаційної технології попередньої обробки цифрових супутникових зображень з використанням згорткової нейронної мережі, яка здатна ефективно вилучати деталі текстури та просторові залежності, а також локальну та нелокальну інформацію. Це дозволить покращити точність та деталізацію (інформативність) отриманих зображень після такої попередньої обробки.

Загальна структура запропонованої інформаційної технології представлена на рисунку 2.7 та включає такі етапи: завантаження первинних цифрових супутникових зображень; застосування геометричної, радіометричної, атмосферної корекцій; а також блоку нейронної мережі, який складається з вивчення глобальної інформації про текстуру та отримання просторової інформації з кожної смуги зображення по каналах.

Спочатку завантажуюмо багатоканальне в композиції RGB (Канали 5-3-2) та панхроматичне зображення, наприклад з космічного апарату WorldView-3. Потім виконуємо ряд корекцій, спрямованих на усунення різноманітних спотворень, що можуть виникати під час зйомки та передачі зображень з космосу. Геометрична корекція цифрових супутникових зображень є важливим етапом попередньої обробки для усунення спотворень, що виникають у зображеннях через геометричні особливості процесу зйомки. Математично перерахунок значень пікселів для різноканальних зображень, отриманих на одному витку (по суті одночасно), можна виразити за допомогою формули [52, 133]:

$$\begin{aligned} X_{corr} &= X_{inp} \times \frac{S_x}{S_y} + \Delta x, \\ Y_{corr} &= Y_{inp} \times \frac{S_x}{S_y} + \Delta y, \end{aligned} \quad (2.18)$$

де X_{inp} , Y_{inp} – координати пікселя первинного супутникового зображення, X_{corr} , Y_{corr} – координати пікселя після геометричної корекції, S_x , S_y – коефіцієнти по осях X та Y, Δx , Δy – зсув по відповідним осям.

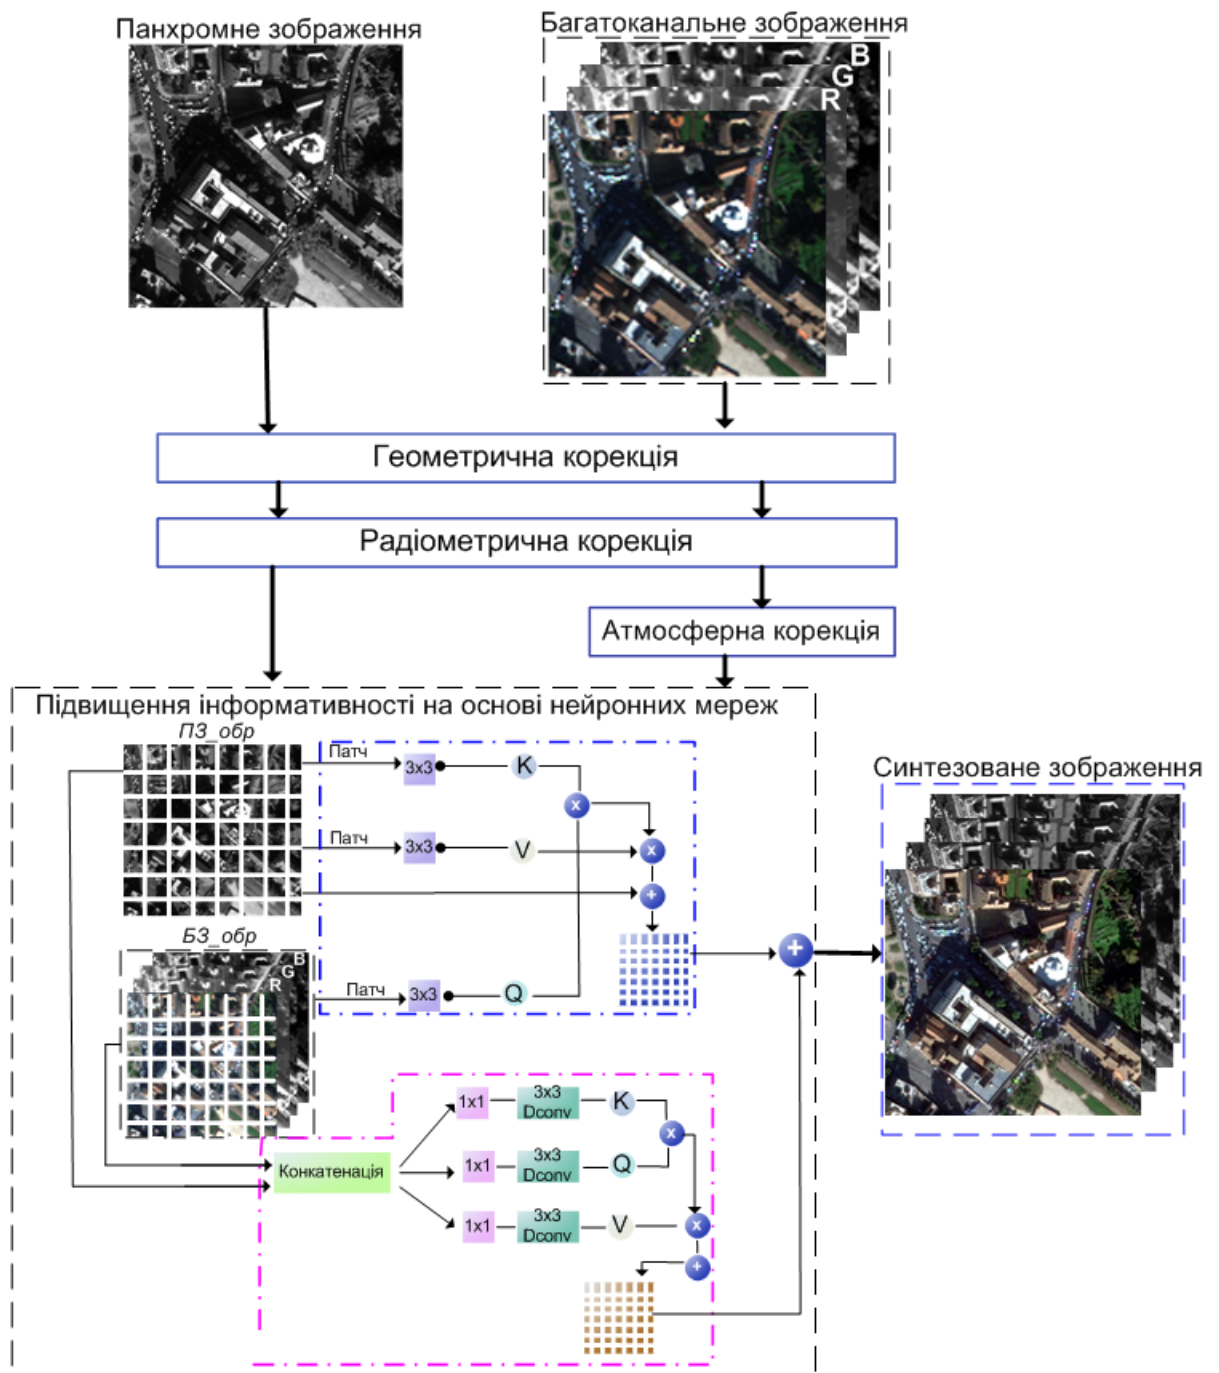


Рис.2.7. Схема запропонованої інформаційної технології попередньої обробки супутникових зображень

Наступний етап включає процес передискретизації, який полягає у масштабуванні БЗ до розмірів ПЗ [46]:

$$P'(x', y') = a \cdot P(x, y) + b \cdot P(x+1, y) + c \cdot P(x, y+1) + d \cdot P(x+1, y+1) \quad (2.19)$$

Радіометрична корекція, спрямована на виправлення впливу атмосферних умов на оптичних зображеннях. Однією з поширених проблем в оптичному дистанційному зондуванні є хмарний покрив, який може заважати спостереженню земної поверхні. Перш за все, важливо виконати відносне радіометричне калібрування для мінімізації впливу цих артефактів [52]:

$$q = \frac{p - A}{B}, \quad (2.20)$$

де q – радіометрично виправлені дані датчика, p – необроблені дані датчика, A – зсув темряви для конкретного супутникового зображення, а B – відносний коефіцієнт підсилення датчика.

Атмосферна корекція БЗ полягає в перетворенні радіометрично скоригованих пікселів зображення на спектральну яскравість верхнього шару атмосфери з мінімальним значенням. Для цього використовується загальне рівняння, яке враховує параметри телескопа на висоті 770 км супутника WorldView-2 [52]:

$$B(\lambda) = \frac{L(\lambda)}{\tau(\lambda)} + L_{atm}(\lambda) \left(1 - \frac{1}{\tau(\lambda)}\right) + L_p(\lambda) \quad (2.21)$$

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

Після того, як виконано геометричну, радіометричну та атмосферну корекції, отримуємо нові багатоканальні (БЗ_обр) та панхроматичні (ПЗ_обр) зображення. Далі використовуємо ці зображення для підвищення їхньої

інформативності за допомогою нейронної мережі. Спочатку зображення ПЗ_обр і БЗ_обр розбиваються на ділянки однакового розміру, що не перетинаються. Потім кодується їхнє положення для створення послідовності ділянок з обох зображень. Ці патчи зображень використовуються як вхідні ознаки текстури. Далі, ознаки виділяються за допомогою згортки 3×3 , і проєктуються на три компоненти, які необхідні для відповідного трансформатора: Q (запит), K (ключ) і V (значення) [114]:

$$\begin{aligned} Q &= X \cdot W_q, \\ K &= X \cdot W_k, \\ V &= X \cdot W_v, \end{aligned} \tag{2.22}$$

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

Використовуючи Q та K для оцінки схожості між ознаками, формуємо матрицю асоціацій. Потім множимо цю матрицю асоціацій на матрицю асоціацій PAN-зображення (ознака V). Це дозволяє отримати остаточну зважену карту ознак карти. Додатково вводиться перехідний зв'язок, щоб уникнути втрати інформації. Нарешті, всі згенеровані карти особливостей патчів знову зшиваються разом за допомогою кодування позиції, щоб отримати остаточну карту особливостей текстури.

Наступна гілка нейронної мережі дозволяє отримати відповідну просторову інформацію кожного каналу зображення. Спочатку застосовуємо точкову згортку 1×1 для отримання контекстної інформації між різними каналами на рівні пікселів, а потім використовуємо глибинну згортку 3×3 для отримання просторового контексту вздовж напрямку каналу. Після цього отриману інформацію згортки розділяємо на глибину для подальшого використання у Q , K і V :

$$X = \text{Concat}(\text{ПЗ_нов}, \text{БЗ_нов}), \tag{2.23}$$

де X – результуюче зображення після злиття ПЗ та БЗ.

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

2.3.2. Експериментальні результати

В роботі використано 16-розрядні стандартні мультипослідовності рівня 2 зі супутника WorldView-2. Ці дані містять односмугові панхроматичні та 8-смугові багатоканальні зображення. Розмір кожного зображення складає 599×576 пікселів.

На рисунку 2.8 наведено первинні супутникові зображення та після запропонованої в роботі технології.

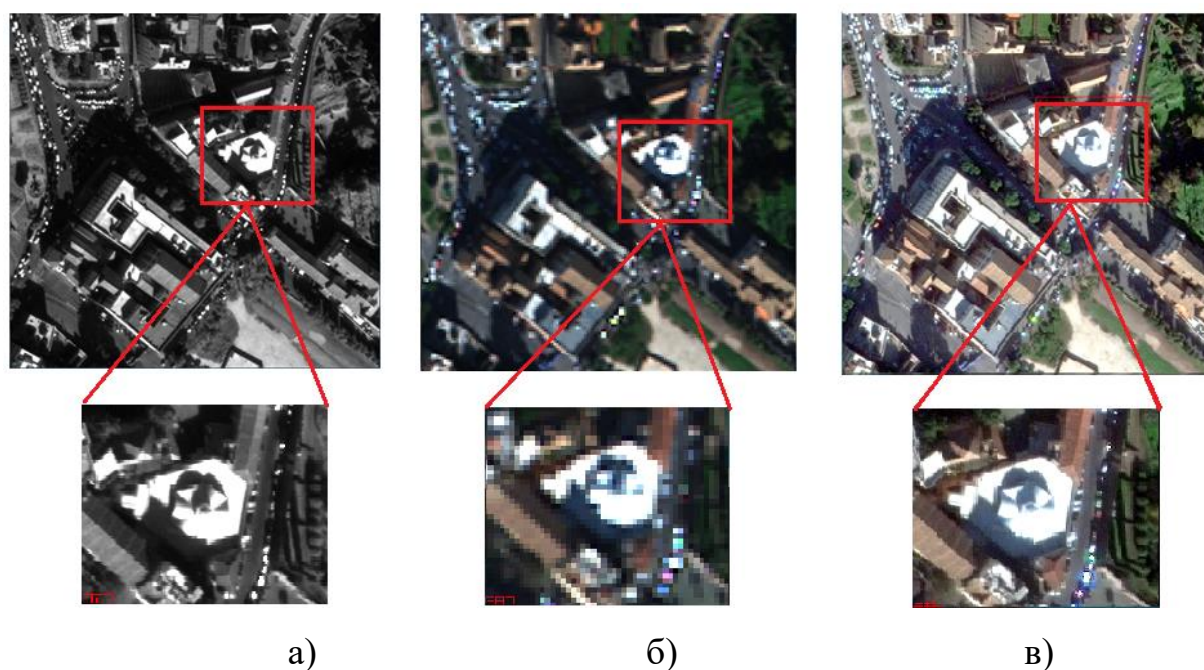


Рис.2.8. Супутникові зображення космічного апарату WorldView-2:

а) панхроматичне; б) багатоканальне (Канали 5-3-2);

в) після обробки запропонованою технологією

Синтезовані зображення характеризуються збільшеною роздільною здатністю, при цьому локальні збільшені частини не демонструють явного розмиття контурів, що свідчить про високу якість паншарпенінгу. Для оцінки ефективності запропонованої інформаційної технології з існуючими, обрано сім методів для порівняння: HSV (Hue, Saturation, Value), Adaptive Tonal Weighting Transformation (ATWT), Adaptive Weighted Linear Prediction (AWLP), Brightness-Difference-Based Saturation-Difference (BDSB), Brovey Transform, High Pass Filtering (HPF), та комбінацію вейвлет із методом HSV (Wavelet + HSV).

Використано критерій максимальної інформативності для оцінки якості зображень. Ентропія, поняття в теорії інформації, є одним з інструментів для вимірювання кількості інформації в зображеннях. Вона визначається на основі ймовірності виникнення різних значень пікселів у зображенні і характеризує імовірнісну поведінку джерела інформації [45, 47, 128]. На рисунку 2.9 наведено значення ентропії для традиційних методів обробки зображень та запропонованої технології.




Рис.2.9. Графічне представлення значень ентропії

За результатами значень рис.2.9 можна зробити висновок, що запропонована технологія має найвище значення ентропії, що свідчить про більшу різноманітність та складність інформації в отриманому зображенні порівняно з іншими методами обробки.

Коефіцієнт кореляції (CORR) є важливим інструментом для кількісної оцінки ступеня відповідності між двома наборами даних, у нашому випадку - між синтезованим та оригінальними зображеннями. Цей показник дозволяє визначити, наскільки злиге зображення відтворює оригінальні дані. Високий коефіцієнт кореляції свідчить про те, що злиге зображення добре відтворює оригінальні дані, тобто воно має високу схожість з оригіналом [46]. У таблиці 2.3 наведено значення коефіцієнту CORR.

Таблиця 2.3. Значення коефіцієнту CORR

Методи	Канали		
	R	G	B
HSV	0.87	0.84	0.85
ATWT	0.59	0.61	0.63
AWLP	0.64	0.65	0.66
BDSB	0.60	0.61	0.64
Brovey	0.53	0.50	0.54
HPF	0.55	0.56	0.58
Wavelet+ HSV	0.90	0.86	0.86
Запропонована технологія	0.97	0.96	0.96

Аналізуючи дані з табл.2.3, можемо пересвідчитись, що метод HSV демонструє високий рівень кореляції для всіх трьох каналів (R, G, B), що свідчить про добре збережену спектральну інформацію після злиття зображень. Методи ATWT, AWLP, BDSB, Brovey та HPF мають нижчі значення кореляції порівняно з методом HSV. Це вказує на меншу ефективність цих методів у збереженні спектральної інформації під час

злиття зображень. Метод Wavelet+HSV має високий рівень кореляції, що свідчить про добре збереження спектральної інформації. Запропонована технологія демонструє найвищий рівень кореляції для всіх трьох каналів, що свідчить про її високу ефективність у збереженні спектральної інформації та збереження деталізації зображення.

Коефіцієнти структурної схожості зображень (SSIM) та PSNR (Peak Signal-to-Noise Ratio) є важливими метриками для оцінки якості зображень [47, 128]. SSIM аналізує структурну подібність між оригінальним та обробленим зображеннями, визначаючи ефективність методів обробки, тоді як PSNR (максимум відношення сигнал/шум) вимірює якість відтворення зображення після компресії або обробки. Ідея знаходження SSIM полягає у наступному [128]. Нехай є два сигнали однієї розмірності $\mathbf{x} = (x_1, \dots, x_n)$ та $\mathbf{y} = (y_1, \dots, y_n)$. Тоді SSIM-індекс визначається за виразом [128]:

$$SSIM = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\bar{x}^2 + \bar{y}^2)(\sigma_x^2 + \sigma_y^2)}, \quad (2.24)$$

або інакше

$$SSIM = \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \cdot \frac{2\sigma_x\sigma_y}{\sigma_x^2 + \sigma_y^2} \cdot \frac{\sigma_{xy}}{\sigma_x\sigma_y}, \quad (2.25)$$

де дисперсія та коваріація дорівнюють, відповідно

$$\sigma_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}),$$

$$\sigma_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2, \quad \sigma_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2,$$

\bar{x} , \bar{y} — середні значення інтенсивностей x , y відповідно [128].

Чим вище подібність геометричних структур первинного та обробленого зображень, тим більше SSIM-індекс між ними, можливі

значення якого належать інтервалу $[0, 1]$ (значення 1 – повна структурна подібність, 0 – абсолютна відмінність) [128].

Значення цих метрик наведено в таблиці 2.4.

Таблиця 2.4. Значення коефіцієнтів SSIM та PSNR

Методи	SSIM			PSNR		
	Канали			Канали	Канали	Канали
	R	G	B	R	G	B
HSV	0.49	0.46	0.45	17.85	16.75	17.35
ATWT	0.48	0.50	0.51	13.92	14.45	14.93
AWLP	14.32	14.77	15.22	0.46	0.48	0.48
BDSB	0.50	0.51	0.51	13.85	14.38	14.88
Brovey	0.40	0.40	0.41	13.14	13.16	14.07
HPF	0.44	0.46	0.47	13.30	13.82	14.29
Wavelet+ HSV	0.56	0.54	0.52	23.12	22.96	22.95
Запропонована технологія	0.71	0.65	0.67	37.60	38.38	38.93

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

Для оцінки точності обробки та відтворення зображень використовуються метрики ERGAS (Relative Dimensionless Global Error in Synthesis) і RMSE (Root Mean Square Error) [128]:

$$\text{ERGAS} = 100 \frac{h}{l} \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\frac{\text{RMSE}(k)}{\mu(k)} \right)^2}, \quad (2.26)$$

де h/l — відношення між піксельними розмірами панхроматичного та багатоспектрального зображень (наприклад, $\frac{1}{4}$ для більшості сучасних супутників); $\mu(k)$ — середнє k -каналу; K — кількість спектральних каналів (смуг).

Значення ERGAS вище ніж 3 відповідає одержаному зображенню дуже низької якості. Чим менше значення ERGAS – тим краще.

На рис.2.10 наведено кількісні показники метрик ERGAS та RMSE.

Аналізуючи отримані результати з рис.2.10, бачимо, що значення ERGAS та RMSE для запропонованої технології та методу Wav+HSV є найменшими порівняно з іншими методами. Це свідчить про високу точність синтезу та відтворення зображень за допомогою цих методів. З іншого боку, значення ERGAS та RMSE для методів HSV, ATWT, AWLP, BDSD, Brovey і HPF свідчать про меншу точність злиття зображень.

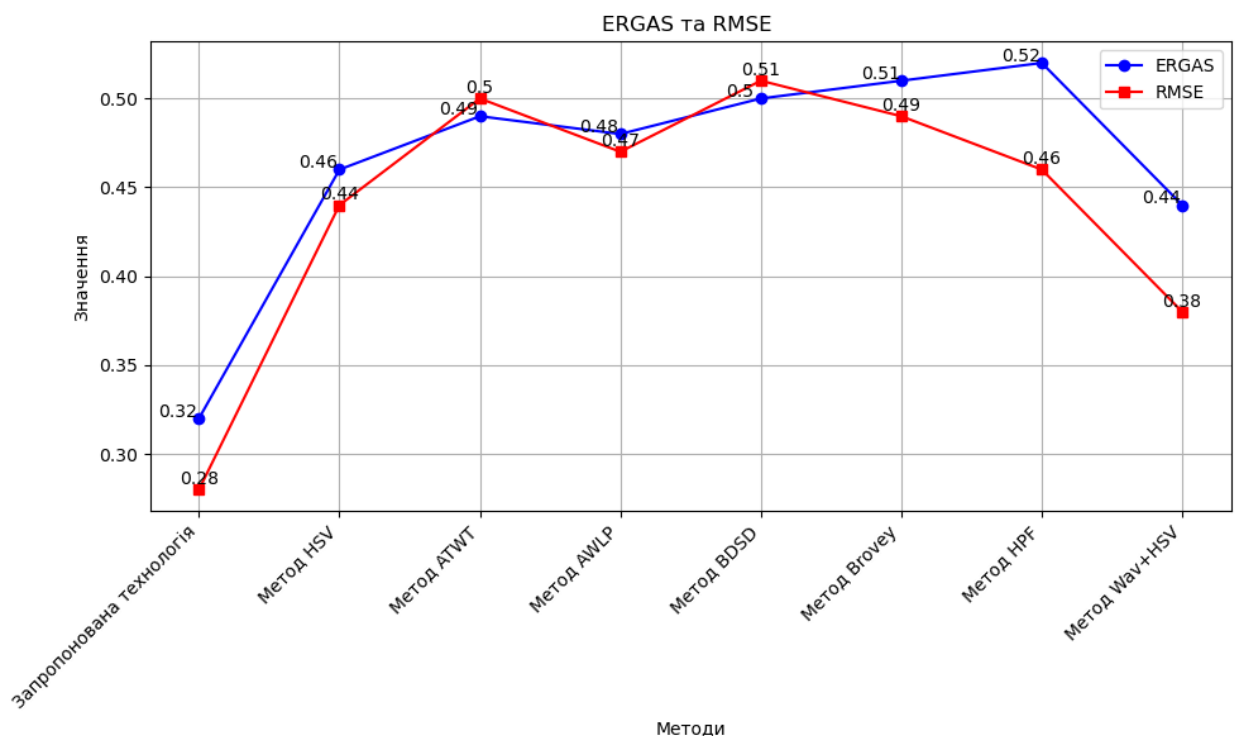


Рис.2.10. Графічне представлення метрик ERGAS та RMSE

У порівняльному аналізі різних методів злиття WorldView-2 зображень (рис.2.11), можна помітити відмінності у якості синтезованих зображень.




Рис.2.11. Порівняння різних методів злиття:

а) Gram-Shmidt; б) HSV; в) Wav+ HSV; г) ATWT; д) AWLP; е) BDSL;
є) Brovey; ж) HPF; з) запропонована технологія

Методи ATWT, AWLP, BDSL та HPF демонструють значні просторові спотворення, і загальне зображення виглядає розмитим. Brovey і HSV – розмиття кольорів, а спотворення первинних кольорів трави на

зображення стають очевидними. Ці артефакти знижують інформативність зображення та роблять його менш придатним для подальшого використання в додатках, де важлива точність кольору та деталізація. Gram-Shmidt та Wav+HSV, хоча ближчі за просторовою структурою та спектральним збереженням, але все ще демонструють просторове розмиття. Синтезоване зображення після запропонованої технології демонструє високу інформативність, чіткість та деталізацію без помітного розмиття кольорів або просторових спотворень.

Таким чином, запропоновано інформаційну технологію попередньої обробки цифрових супутникових зображень з використанням згорткової нейронної мережі, яка здатна ефективно вилучати деталі текстури та просторові залежності, а також локальну та нелокальну інформацію. Результати тестування, проведеного на восьмиканальних зображеннях, отриманих супутником WorldView-2, підтверджують, що запропонована технологія (ERGAS=0.32, RMSE=0.28, SSIM=0.71, PSNR=37.60) дозволяє досягти високої спектральної та просторової якості багатоканальних зображень та перевершує існуючі методи. Це дозволило, у порівнянні з класичними методами злиття, зменшити артефакти та автоматизувати процес обробки супутникових зображень.

2.4. Висновки до другого розділу

1. Здійснено аналіз проблеми та сучасних методологій обробки великих даних ДЗЗ. Надані основні поняття й визначення, що використовуються для її розв'язання. Описано властивості організації даних, що дозволяють передбачити результат виконання певних операцій в структурі за її елементами, використовуючи їх розташування без виконання обчислювального алгоритму. Отримано висновки про вплив властивостей та математичних методів роботи зі структурою.

2. Запропоновано та доведено ефективність методу оптимізації основних характеристик обробки великих даних на основі застосування кортежної структури організації даних, який дозволяє зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних при збереженні їх відповідних значень та надійності.

3. Запропоновано та доведено ефективність IaaS-рішення для обробки потоку даних дистанційного зондування на основі глибокого навчання та хмарних технологій Kubernetes та Apache Airflow, розміщених на платформі Google Cloud Platform. Запропонований алгоритм представлений у вигляді прямого ациклічного графа у застосунку IaaS. Згадані хмарні технології використовуються для кращого представлення робочого процесу, який реалізує складну систему паралельного виконання обчислювально-важких завдань обробки супутникових зображень високої просторової розрізненості.

4. Розроблено та досліджено інформаційну технологію попередньої обробки цифрових супутникових зображень з використанням згорткової нейронної мережі, яка здатна ефективно підвищити інформативність первинних даних, вилучати деталі текстури та просторові залежності, а також локальну та нелокальну інформацію. Результати тестування підтвердили, що запропонована технологія дозволяє досягти підвищення просторової розрізненості багатоканальних зображень та, у порівнянні з класичними методами злиття, зменшити артефакти супутникових знімків.

Основні результати даного розділу опубліковані в роботах автора [93, 132].

РОЗДІЛ 3

РОЗРОБКА НЕЙРОМЕРЕЖЕВОЇ ТЕХНОЛОГІЇ СЕМАНТИЧНОЇ СЕГМЕНТАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ РОЗРІЗНЕНОСТІ

Для аналізу аерокосмічних зображень зазвичай використовують різні традиційні методи сегментації та класифікації, які мають певні обмеження та недоліки. Виконаний у першому розділі аналіз літературних джерел дозволив зробити висновок про перспективність застосування нейронних мереж для семантичної сегментації супутникових зображень високої просторової розрізненості.

Сегментація зображення – це метод, у якому цифрове зображення розбивається на різні підгрупи, звані сегментами зображення, що допомагає зменшити складність зображення і спростити подальшу обробку чи аналіз зображення [7, 17, 20, 29, 33, 56]. Всі елементи зображення або пікселі, що належать до однієї і тієї ж категорії, мають спільну призначену мітку. Семантична сегментація аерокосмічних сцен в даній роботі розглядається як попередній етап обробки перед подальшою класифікацією зображень.

3.1. Автоматизована нейромережева технологія семантичної сегментації зображень дистанційного зондування

3.1.1. Переваги машинного навчання для семантичної сегментації супутникових зображень

Інформаційна технологія, що розроблена в цьому підрозділі, застосовує переваги глибокого навчання для семантичної сегментації в комбінації з класичними методами обробки зображень та лінійної алгебри. Система оптимізована з точки зору швидкодії шляхом підбору параметрів і налаштування нейронної мережі як найбільш ресурсоємкої частини рішення. Застосування додаткових засобів та інструментів, окрім нейронної мережі,

зумовлено необхідністю чіткого розділення наземних об'єктів на окремі одиниці для підвищення точності апроксимації фізичних розмірів. На додаток до алгоритму вимірювань, таких основних фізичних параметрів наземних об'єктів, як периметри, площі, розроблено комплексний показник – щільність забудови, що комбіновано використовує результати семантичної сегментації та інформацію про характеристики просторової роздільної здатності зображень дистанційного зондування надвисокої роздільної здатності, що використовуються в поточній роботі як джерело даних для навчального набору даних. Запропонована технологія може бути застосована до таких областей, як планування забудови, аналіз забудови, управління дорожнім рухом і т.і. Рішення є гнучким і може бути додатково оптимізоване для різних потреб.

Запропоновано модифіковану Unet-подібну архітектуру сімейства автокодувальників для обробки зображень високої просторової розрізненості, зокрема зі супутника WorldView-3. Зображення WorldView-3 використовуються для розробки набору даних для навчання пропонованої архітектури нейронної мережі. Додаткові шари розроблені і додані на виході архітектури нейронної мережі, щоб відокремити екземпляри виявлених наземних об'єктів та виконати алгоритм вимірювання фізичних параметрів щільності наземних об'єктів.

3.1.2. Підготовка набору даних

Зображення WorldView-3 використовуються як джерело для навчального та тестового набору даних. WorldView-3 – супутниковий апарат із датчиками для реєстрації знімків Землі надвисокої роздільної здатності, що працює на висоті 617 км. Супутник WorldView-3 забезпечує панхроматичну роздільну здатність 31 см, мультиспектральну роздільну здатність 1,24 м, інфрачервону роздільну здатність коротких хвиль (SWIR) 3,7 м та роздільну здатність CAVIS 30 м. Супутник має середній час перегляду менше 1 доби і здатний збирати до 680 000 кв. км на день [81].

Для підвищення якості набору даних застосовувались додаткові методи покращення зображення, описані в дослідженні [45]. З тою ж самою ціллю була зроблена додаткова спроба застосування алгоритму виявлення тіней [85] до набору даних, але вона не продемонструвала суттєвого поліпшення роботи алгоритму пост-обробки.

WorldView-3 надає широкий спектр можливостей щодо спектральної роздільної здатності, включаючи панхроматичні та мультиспектральні зображення. Для WorldView-3 це значення є 16-бітним, що означає, що значення спектральної освітленості для цих зображень варіюється від 0 до 65535. Для використання з нейронною мережею ці значення нормуються від 0 до 1 використовуючи 16-бітовий тип даних (FP16). Серед найкращих практик для навчання нейронної мережі є нормалізація даних для отримання середнього значення, близького до 0. Нормалізація даних, як правило, прискорює навчання та призводить до швидшого сходження функції втрат [89]. Спектральні і просторові характеристики WorldView-3 представлені в таблиці 3.1.

Таблиця 3.1. Просторові характеристики зображення WorldView-3

Тип	Хвильові смуги	Роздільна здатність пікселів, м	Кількість каналів	Розмір
напівтонові	панхроматичні	0,31	1	16924×17020
8-смуговий	мультиспектральні із застосуванням паншарпенінгу	0,31	8	16924×17020
16-смуговий	мультиспектральні	1,24	8	4255×4231
	короткохвильові інфрачервоні	7,5	8	670×688

3.1.3. Архітектура мережі

Протягом останніх років архітектура U-net є популярним вибором у багатьох областях досліджень, де потрібна семантична сегментація. Спочатку U-net було розроблено для біомедичної сегментації зображень [76]. Однак сьогодні U-net успішно застосовується в інших галузях знань, включаючи дистанційне зондування [39, 40, 67, 86].

На сьогоднішній день не існує чітко регламентованих правил реалізації структури нейронної мережі: кількість та організація шарів, кількість та розмір карт ознак, розмір матриць згортки, вибір алгоритму навчання. При розробці структури CNN слід розуміти, що невелика кількість параметрів мережі може знизити точність сегментації. Однак велика кількість параметрів збільшує обчислювальну складність мережі та не завжди забезпечує покращення класифікувальних здібностей мережі. Таким чином, розробка оптимальної структури нейронної мережі є емпіричним процесом, який включає велику кількість експериментальних досліджень.

У роботі запропоновано додаткове налаштування нейронної мережі, щоб оптимізувати алгоритм розділення цілої маски на окремі екземпляри та вимірювань фізичних параметрів наземних об'єктів.

Пропонована нейронна мережа складається з (рис.3.1):

- Вхідний шар розміром $512 \times 512 \times 3$;
- 5 блоків кодера;
- 1 стандартний блок згортки;
- 1 додатковий блок згортки;
- 5 блоків декодера;
- Вихідний шар розміром $512 \times 512 \times 3$ із сигмоїдною функцією активації.

Навчання проводиться на 4255 навчальних та 759 зразках тестування. Випадковий відтінок, горизонтальне перевертання та зміщення по ширині по висоті застосовуються як доповнення для набору навчальних даних. Вибрано

значення дельти відтинку 0,1. Таке збільшення не застосовується до набору даних тестування.

Існують метрики, спеціально розроблені для адекватного вимірювання ефективності рішень на базі глибокого навчання. Спеціальні метрики та функції втрат були розроблені в поточній роботі для кращого представлення ефективності нейронної мережі та ефективності алгоритму пост-обробки.

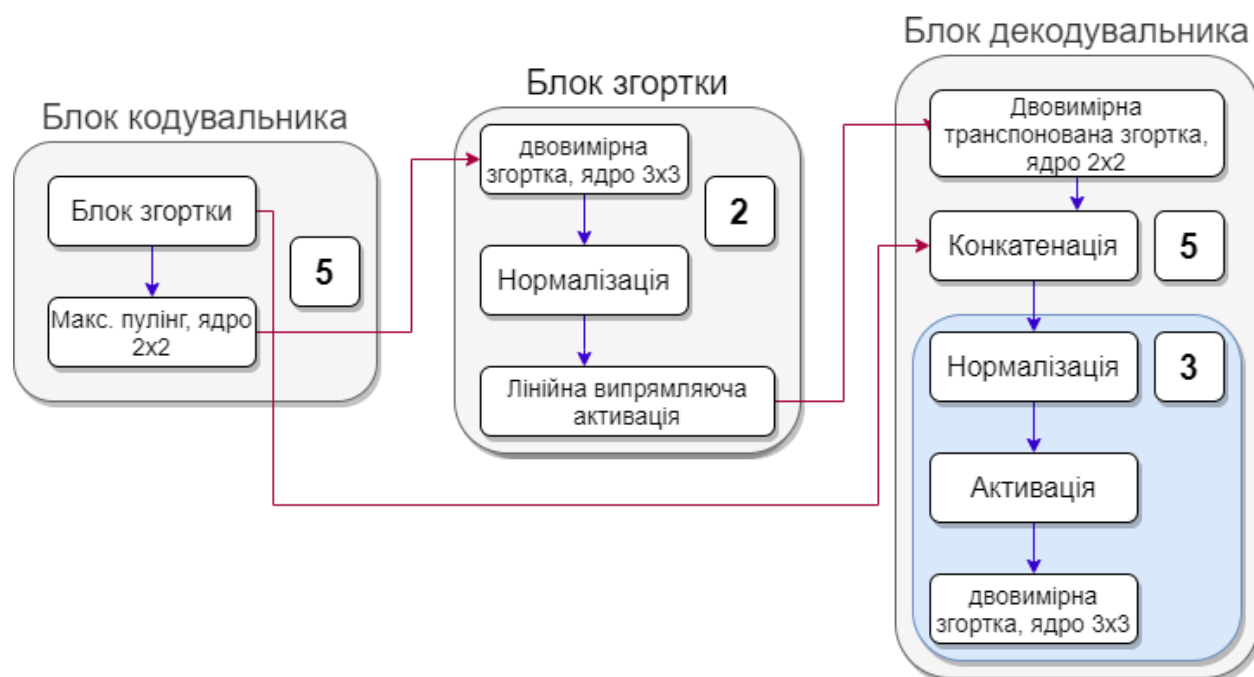


Рис. 3.1. Магістральні блоки нейронної мережі

Оскільки однією з цілей роботи було досягнення задовільних результатів сегментації екземплярів, було вирішено застосувати модифікований коефіцієнт Дайса (міра F1) [30]:

$$Dice = \frac{1}{N} \sum_{i=0}^n \frac{2 \cdot p(y_i) \cdot y_i + 1}{p(y_i) + y_i + 1}, \quad (3.1)$$

де $p(y_i)$ – прогнозована маска, а y_i – анована істинна маска, доступна з навчальних даних.

Оригінальний коефіцієнт Дайса модифікується додаванням одиниці для частин перетину та об'єднання в рівнянні, щоб запобігти діленню на нуль. Крім того, для тренування використовується функція втрати [30]:

$$loss_{dice} = 1 - Dice, \quad (3.2)$$

де $Dice$ визначено в (3.1).

Функція втрат Дайса – це метрика для вимірювання перекриття істинних значень пікселів та сегментованих пікселів (масок). Метрика втрат Дайса дуже гнучка і може бути додатково оптимізована, що може покращити результати [20, 67], але в поточній роботі така оптимізація не досліджується.

На жаль, використання архітектури нейронної мережі з (3.2) призвело до повного сходження функції втрат. Для подолання цієї проблеми було впроваджено вдосконалення функції втрат. Рішення полягає у визначенні більш комплексної функції втрат [30]:

$$loss = loss_{dice} + loss_{bce}, \quad (3.3)$$

де $loss_{bce}$ – функція двійкової перехресної ентропії або логарифмічної функції втрат, яка визначається як

$$loss_{bce} = -\frac{1}{N} \sum_{i=0}^n y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)), \quad (3.4)$$

де $p(y_i)$ – сегментована маска і y_i – анована істинна маска, доступна з навчальних даних.

Техніку змішаної точності було застосовано для того, щоб покращити швидкість тренування відносно великої моделі (10 мільйонів параметрів) в обмеженому навчальному середовищі (Google Collaboratory). Техніка змішаної точності докладно описана в [65].

Тут і далі в роботі використано:

– матрицю помилок (confusion matrix), що дозволяє для кожного класу розрахувати кількість істинно позитивних передбачень (True Positive, TP), істинно негативних (True Negative, TN), хибно позитивних (False Positive, FP) і хибно негативних передбачень (False Negative, FN) [63]. Схематично матриця помилок представлена на рисунку 3.2;

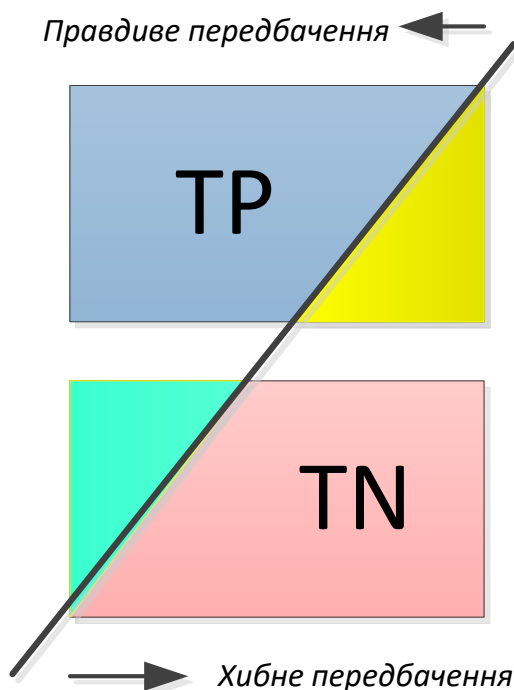


Рис. 3.2. Графічне представлення матриці помилок [30]

– метрику intersection over union (IoU) або коефіцієнт Жаккара [75]:

$$IoU = \frac{TP_c}{TP_c + FP_c + FN_c}, \quad (3.5)$$

де TP_c , FP_c і FN_c – кількість істинно позитивних, хибно позитивних та хибно негативних рішень для класу c ;

– загальну точність (OA), що вимірює відсоток загальної кількості правильно класифікованих пікселів класу об'єктів забудови, на загальну кількість пікселів N [48]:

$$OA = \frac{\sum D_{ij}}{N} \quad (3.6)$$

де D_{ij} — загальна кількість правильно класифікованих пікселів у рядку i та стовпці j ;

– середню точність (AA) [48, 63]:

$$AA = \frac{1}{m} \sum_{m=1}^m PA_m; \quad (3.7)$$

– точність для кожного класу (PA) [116]:

$$PA = \frac{\sum D_{ij}}{\sum R_i} \quad (3.8)$$

де R_i – загальна кількість пікселів у рядку;

– індекс Каппа (K) – є кількісним показником рівня узгодженості або точності в правильно класифікованих пікселях [63]. Значення $K=1$ вказує на повну згоду, тоді як $K=0$ вказує на випадкову згоду, еквівалентну ймовірності класифікації пікселів [133, 134]:

$$K = \frac{N \sum_{i,j=1}^m D_{ij} - \sum_{i,j=1}^m R_i \cdot C_j}{N^2 - \sum_{i,j=1}^m R_i \cdot C_j} \quad (3.9)$$

де m – кількість класів, D_{ij} – кількість правильно класифікованих пікселів у рядку i та стовпці j , R_i – загальна кількість пікселів у рядку i , C_j – загальна кількість пікселів у стовпці j , N – загальна кількість пікселів.

Частина правильних відповідей є метрикою, що показує, покращення навчальних ітерацій продуктивності моделі [63, 113]:

$$Accuracy = \frac{\sum_{i=1}^m C_{ii}}{\sum_{i=1}^m \sum_{j=1}^m C_{ij}} \quad (3.10)$$

де C_{ii} – правильна класифікація по діагоналі, m – кількість класів, C_{ij} – кількість разів, коли предмети класу i класифікувалися як клас j (неправильна класифікація) та $\sum_{i=1}^m \sum_{j=1}^m C_{ij}$ – загальна кількість зразків, які були оцінені.

Окремі результати навчання наведені в таблиці 3.2.

Таблиця 3.2. Результати тренування запропонованої нейромережі

Метрика	Значення
Точність (Accuracy)	0.9884
Точність (Precision)	0.9217
Повнота (Recall)	0.7641
Міра F1	0.8355

Дослідження показало, що більша кількість тренувань та очищення наборів даних є основним фактором кращого запам'ятовування.

3.2. Технологія пост-обробки результатів сегментації

Головною метою цього підрозділу є пост-обробка результатів сегментації, яка реалізована як верхні шари для U-net-подібної магістральної архітектури. Ця подальша обробка може виконувати кілька послідовних кроків:

- поділ на окремі об'єкти цільної маски;
- семантичне маркування;
- об'єднання масок за комплексною розрахованою ознакою близькості граничних пікселів;
- вилучення наддрібних пікселів на кількісною ознакою;
- розрахунок фізичних розмірів із використанням утворених окремих масок і спектральних характеристик пікселя;
- розрахунок щільності забудови.

3.2.1. Поділ на окремі об'єкти

Вихідні дані U-net – це піксельні значення відтінків сірого в діапазоні 0..1, які представляють ступінь належності пікселя до певного класу. Для того, щоб правильно відрізнити виявлені маски від фону, необхідно застосувати певне порогове значення, щоб кожен піксель можна було розділити за цим значенням.

Більшість досліджень використовують середнє значення 0.5. Однак для запропонованого підходу інше значення дало кращі результати. Це значення отримується шляхом застосування методу Otsu [69] до результатів сегментації для розрахунку порогового значення, що використовується для класифікації всіх пікселів на два класи: передній план та фон. У результаті отримуємо бінарзоване зображення (рис. 3.3). Згідно з методом Otsu, оптимальний поріг для бінарзації досягає мінімізації зваженої суми дисперсій у кожному кластері або, з іншого боку, максимальної суми дисперсій між класами [30].




Рис. 3.3. Результати застосування алгоритму порогового вимірювання Otsu:
а) вхідне зображення, б) сегментоване зображення,
в) пост-оброблене зображення

Інший алгоритм реалізований для відокремлення примірників від усієї маски. Ця методика включає аналіз на основі функції, яка розрізняє масиви пікселів за допомогою центросиметричної структури фільтра. Такий підхід допомагає зберегти разом пікселі, які належать до однієї території, але складаються з множини об'єктів пошуку (рис. 3.4).

Додатковий семантичний пошук виконується після розділення для отримання координат та розмірів усіх знайдених об'єктів. Ці координати та розміри використовуються для розрахунків фізичних параметрів та щільності.

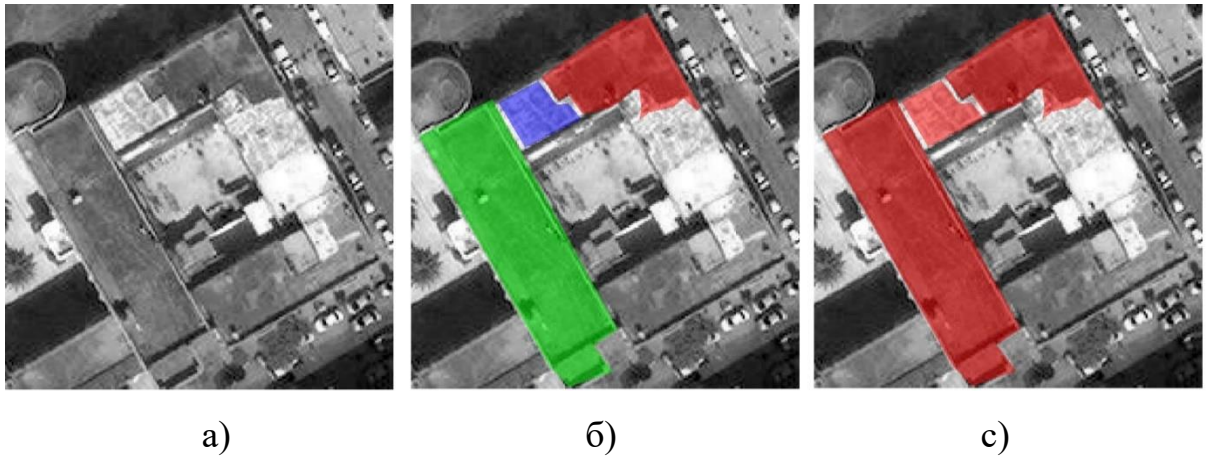


Рис. 3.4. Алгоритм пост-обробки

а) вхідне зображення, б) сегментоване на три області, с) класифіковане як один об'єкт

3.2.2. Вимірювання наземних об'єктів та щільності забудови

Ця частина пост-обробки базується на знанні структури супутникових знімків. Відомі довжина і ширина одного пікселя, наприклад для панхроматичного зображення супутника WorldView-3 становлять 31 см, що дає можливість розрахувати фізичні параметри виявлених об'єктів.

Для одного об'єкта обчислюється прямокутник мінімальної площі, що повністю описує полігональну маску об'єкта. Цей прямокутник побудований із знайденими найбільшими вертикальним та горизонтальним «діаметрами» (рис. 3.5).

З використанням розрахункового діаметра наземних об'єктів приймаються фізичні параметри: умовно названі як «периметр» (3.11) і «площа» (3.12).

$$Perimeter = 2 * (vmax + hmax), \quad (3.11)$$

де $hmax$ – максимальний горизонтальний «діаметр», отриманий з мінімального «дотичного» (прилеглого) прямокутника, $vmax$ – вертикальний.




Рис. 3.4. Максимальний вертикальний і горизонтальний «діаметр» на основі мінімального розміру охоплюючого прямокутника

$$SqArea = v_{max} * h_{max}. \quad (3.12)$$

Щільність забудови обчислюється за допомогою (3.7) як відсоток усіх пікселів, визначених як наземні об'єкти, до загальної кількості пікселів зображення:

$$BD = \frac{precision}{recall} * \frac{\sum_{i=0}^m p(y_i)}{\sum_{j=0}^n x_j}, \quad (3.13)$$

де m – кількість сегментованих пікселів, n – загальна кількість пікселів зображення, $p(y_i)$ – прогнозований піксель та x_j – піксель зображення. *Precision* та *Recall* – це відповідні метрики нейронної мережі, отримані під час перевірки етапу навчання.

3.3. Експериментальна перевірка

Експерименти проводились кількома різними способами – модульним та інтеграційним: для нейронної мережі, алгоритмів апроксимації та для всієї

системи. Необхідність таких умов обґрунтовується модульністю та порівнянністю кожної частини з подібними підходами для попередньої обробки, обробки нейронною мережею та пост-обробки.

Для вимірювання ефективності нейронної мережі обчислено точність, відкриття та оцінку F1 та порівняно із іншими сучасними Unet-подібними рішеннями нейронної мережі для семантичної сегментації зображень дистанційного зондування надвисокої просторової розрізненості. Для порівняння обирались тільки Unet-подібні архітектури. Суть такого порівняння полягає в тому, щоб продемонструвати, що запропонована нейромережа не гірша за існуючі подібні моделі та враховує щільність забудови. Запропонована архітектура (SA) порівнюється з оригінальною Unet, HSFA-Unet [67], Refined Unet [39], Stacked Un ets.

Усі згадані нейронні мережі працюють на наборі даних, який використовується для розробки та тестування в поточній роботі [31]. Результат тестування нейронних мереж наведено в таблиці 3.3.

Оригінальна Unet дещо краща з точки зору загальної ефективності, але запропонована Unet-подібна архітектура є кращою з огляду на застосування процедури постобробки через значно більшу точність, ніж у оригінальної Unet архітектури.

Коли була визначена архітектура нейронної мережі, був проведений інший експеримент для перевірки основної частини дослідження – методу для вимірювання наземних об'єктів. Таким чином, розрахунки для будівлі на рисунках 3.3–3.5 наведено в таблиці 3.4.

Подальші експерименти показали, що час розрахунку щільності забудови для всієї сцени замість окремих об'єктів зменшується приблизно на 10%.

Таблиця 3.3. Порівняння ефективності нейронних мереж із запропонованою

Нейронна мережа	Accuracy	Precision	Recall	F1-score
SA	0.9834	0.9217	0.7641	0.8355
Unet	0.8911	0.9316	0.7923	0.8563
HSFA-Unet	0.9831	0.8832	0.7373	0.8036
Refined Unet	0.7712	0.6909	0.7601	0.7238
Stacked Unets	0.8989	0.8877	0.7878	0.8347

Таблиця 3.4. Результати розрахунку щільності забудови

Метрика	Значення
Максимальний горизонтальний діаметр, м	154.4
Максимальний вертикальний діаметр, м	121.8
Периметр, м	552.4
Площа, м ²	18805.92
Щільність, %	34

Отримані в цьому розділі результати пропонують підхід до розробки набору даних для вирішення проблем дистанційного зондування, що включає додаткові методи збільшення набору даних для підвищення ефективності подальшої нейромережевої сегментації супутникових зображень та алгоритму апроксимації фізичних розмірів наземних об'єктів. Рішення підкреслює актуальність Unet для задач дистанційного зондування, пропонуючи інший підхід до налаштування цієї архітектури для вирішення багатьох різноманітних проблем та викликів, включаючи сегментацію окремих екземплярів та вимірювання наземних об'єктів, зокрема забудови, для яких вона спочатку не призначена. Розроблені спеціальні метрики та

функції втрат, які доповнюють подальшу обробку результатів семантичної сегментації та можуть бути застосовані при вирішенні завдань вимірювання наземних об'єктів, зокрема в таких галузях як містобудування тощо. Пропоноване рішення повністю автоматизовано та демонструє підвищення якості (точності) автоматизованої обробки супутникових зображень. Незважаючи на те, що ефективність запропонованої технології продемонстровано для обробки зображень супутника WorldView-3, вона може бути використана для іншого супутникового апарату, такого як Landsat або Sentinel. Важливим аспектом роботи є те, що вона демонструє застосування інструментів глибокого навчання на менш «популярних» зображеннях дистанційного зондування, що є у відкритому доступі (таких як Landsat 8, GeoEye-1 або Sentinel-2), а комерційних даних, зокрема зі супутника WorldView-3, що на сьогодні надають краще просторове розрізнення, та найменш охоплені науковими дослідженнями.

3.4. Висновки до третього розділу

1. Запропоновано та доведено ефективність комплексного підходу до обробки зображень високої просторової розрізненості на основі застосування штучного інтелекту та класичних алгоритмів обробки зображень, що включає попередню обробку даних, розробку набору даних для нейромережі, моделювання нейронної мережі та розрахунок фізичних розмірів наземних об'єктів. Застосування підходу дозволяє автоматизувати процес семантичної сегментації та аналізу багатоканальних даних високої просторової розрізненості, підвищити якість подальшого розпізнавання і моніторингу об'єктів земної поверхні.

2. Розроблено архітектуру згорткової мережі на базі U-Net для задач семантичної сегментації супутникових зображень високої просторової розрізненості, запропоновано методику підготовки набору вхідних даних та поетапної реалізації каскадів шарів мережі, алгоритм її навчання,

обґрунтовано вибір навчальної вибірки. Семантичні ознаки використовуються для зменшення помилок семантичного рівня контуру. Розроблені спеціальні метрики та функції втрат, які доповнюють подальшу обробку результатів семантичної сегментації та можуть бути застосовані при вирішенні завдань вимірювання наземних об'єктів, зокрема забудови.

3. На додаток до алгоритму вимірювань, таких основних фізичних параметрів наземних об'єктів, як периметри, площі, розроблено комплексний показник – щільність забудови, що комбіновано використовує результати семантичної сегментації та інформацію про характеристики зображень дистанційного зондування високої просторової розрізненості, що використовуються в поточній роботі як джерело даних для навчального набору даних. Результати комп'ютерних експериментів підтвердили висновок, що запропонована технологія може ефективно покращити загальну точність класифікації зображень дистанційного зондування високої просторової розрізненості та скоротити загальний час навчання та час відповідної обробки.

Результати досліджень даного розділу опубліковано в роботах автора [121, 125, 130].

РОЗДІЛ 4

КЛАСИФІКАЦІЯ АЕРОКОСМІЧНИХ ЗОБРАЖЕНЬ ВИСОКОЇ ПРОСТОРОВОЇ ЗДАТНОСТІ ПРИ ВИРІШЕННІ ПРАКТИЧНИХ ЗАВДАНЬ

Результати попередніх розділів дисертаційної роботи є теоретичним підґрунтям при розробці інформаційної технології класифікації різночасових аерокосмічних зображень високої просторової розрізненості.

Слід зазначити, самі класифіковані дані є лише початковою точкою для подальшого вирішення конкретних завдань, які мають суттєве значення для кінцевих користувачів. Результати класифікації аерокосмічних зображень високої просторової розрізненості надають важливу основу для вирішення широкого спектру практичних задач, наприклад для автоматизованого аналізу змін в земельному використанні, що є критичним для оцінки екологічного стану регіонів. Якісна класифікація різночасових супутникових зображень сприяє удосконаленню процесів моніторингу лісів, пожеж та природних катастроф, що дозволяє оперативно реагувати на надзвичайні ситуації та зменшити ризики для населення. Також вона може бути використана у військових цілях для забезпечення безпеки, розвідки та стратегічного планування. В області моніторингу водних ресурсів відповідна інформаційна технологія класифікації дозволить не лише визначати розподіл водних об'єктів, але й передбачати зміни в гідрологічному режимі, що критично для водокористувачів та органів водного господарства. Для сфери urban detection важливим є вміння точно визначати розміри та типи забудови, що допомагає у плануванні міського розвитку та інфраструктурних проєктах. Відстеження змін у забудові дозволяє ефективніше використовувати міську інфраструктуру та ресурси, покращуючи якість життя мешканців. Тому опис процесів розробки та тестування зазначеної інформаційної технології класифікації зображень нижче буде здійснено через вирішення конкретних

практичних завдань, зокрема для розпізнавання об'єктів забудови на знімках з БПЛА.

4.1. Інформаційна технологія нейромережевої класифікації аерокосмічних зображень

Метою даного підрозділу є розробка та тестування інформаційної технології класифікації зображень високої просторової розрізненості для розпізнавання об'єктів забудови на знімках з БПЛА [130].

У останні роки безпілотні літальні апарати (БПЛА) стали популярними в сфері аерофотозйомки для збору даних у важкодоступних віддалених районах. Ці апарати, також відомі як дистанційно пілотовані літальні апарати (RPA) або дрони різних типів (багатомоторні, з фіксованими крилами, гібридні), здатні надавати зображення високої та надвисокої просторової розрізненості. Ці дані використовуються для створення географічних інформаційних систем, автоматизованого прийняття рішень, сільськогосподарського картографування, міського планування, управління землекористуванням, моніторингу та оцінки стану навколишнього середовища, включаючи цивільні і військові застосування [41-43]. Високе просторове розрізнення отриманих з БПЛА зображень (розмір пікселя від см до дм) дозволило створювати великі та детальні набори даних, які потрібно оброблювати. При обробці даних важливо враховувати кілька факторів, таких як нестабільна поведінка літального апарату в повітрі та використання дешевого бортового обладнання. Наприклад, на багатьох безпілотних літальних апаратах встановлюють лише GPS-приймачі без інерційних систем і не застосовують диференціальну корекцію [130].

Останнім часом було запропоновано багато методів та технологій на основі комп'ютерного зору для автоматичної класифікації зображень дистанційного зондування, зокрема для розпізнавання об'єктів забудови. Ці методи використовують емпіричні знання про будівлі і дозволяють виділяти

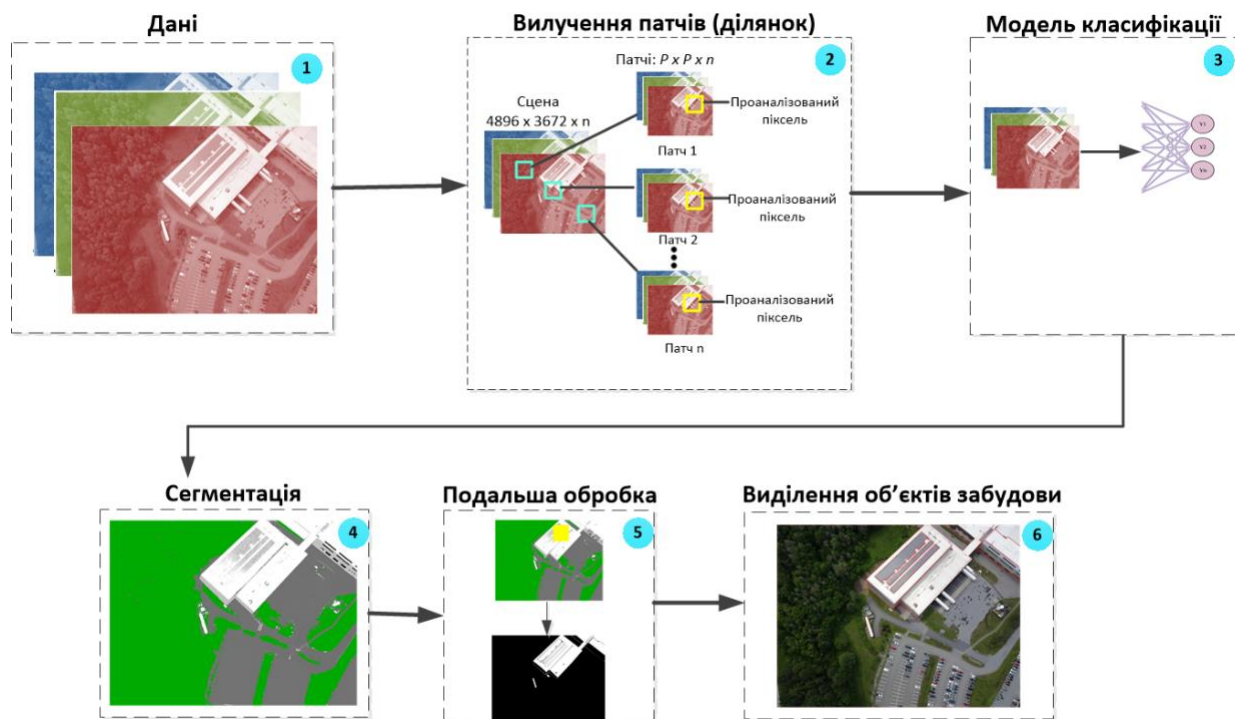
такі характеристики, як кольори, текстури, краї, форми, тіні та інші. Крім того, існують комплексні методи, які використовують зіставлення шаблонів, моделі активного контуру, математичну морфологію та інші алгоритми. Однак різноманітність типів будівель і складність фону роблять автоматичне розпізнавання об'єктів забудови на зображеннях дуже складним завданням з високим рівнем складності [130].

В основі розробленої технології лежить метод класифікації зображень, алгоритм якого представлений на рис. 4.1. Він складається з наступних шести етапів.

Першим етапом є завантаження зображень високого просторової розрізненості з безпілотних літальних апаратів (рис.4.2). Збір даних проводився за допомогою БПЛА, що летів на висоті 353 м, за допомогою Canon PowerShot SX230 HS (5 мм). RGB-зображення складаються з трьох каналів (червоний, зелений, блакитний) з просторовим розрізненням приблизно 9.95 см/піксель, 4000×3000 пікселів [130]. Первинні зображення слід розділити на невеликі фрагменти для детального аналізу локальних особливостей. Класифікацію пікселів рекомендується виконувати за допомогою глибокої навчальної моделі, що дозволить нейронній мережі отримати більше інформації про границі зображення високої просторової розрізненості. Оскільки багато деталей можуть бути втрачені в процесі зменшення частоти дискретизації, пропонується виконати пост-обробку для уточнення даних після кожного шару згорток з метою зменшення кількості неправильно класифікованих пікселів [130].

Етап вилучення патчів має на меті створення навчального набору даних для класифікації центральних пікселів. Спочатку формуються два набори даних для кожної послідовності. Для кожного пікселя зображення створюються патчі розміром $32 \times 32 \times n$ для використання у згорткових нейронних мережах (CNN) і $8 \times 8 \times n$ для рекурентних нейронних мереж (RNN). Ці патчі включають центральний піксель і його сусідів, що дозволяє аналізувати контекст пікселя.

Далі кожен патч класифікується для визначення, чи належить центральний піксель до класу інтересу. Для цього обчислюється частота пікселів в патчі зі значеннями класу, схожими на піксель інтересу. Якщо розмір патча перевищує 512 пікселів, він не обробляється [130].



Легенда:

n – кількість смуг зображення; P – розмір фрагмента.

Рис. 4.1. Алгоритм запропонованого методу




Рис. 4.2. Тестовий знімок з БПЛА

Після цього з кожного класу випадковим чином вибирається 1К патчів, що дозволяє збалансувати розподіл класів і зменшити розмір навчального набору. Результатом цього етапу є два навчальних набори даних, які містять 10К патчів для послідовності 1 та 9К патчів для послідовності 2, відповідно. Ці набори даних можуть бути використані для тренування моделі класифікації центральних пікселів [130]. Потім, запропоновано використати геометричне перетворення [48]:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & T_x \\ 0 & 1 & T_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (4.1)$$

де x' і y' – перетворені координати, а x і y – початкові координати пікселів; T_x і T_y – значення переходу по горизонталі та вертикалі.

Третім етапом є класифікація зображень за допомогою згорткової нейронної мережі. Глибина архітектури впливає як на точність, так і на кількість навчальних параметрів, які необхідно оптимізувати. Це безпосередньо залежить від технічних можливостей обчислювальної техніки. Чим глибше архітектура, тим більше зразків потрібно для навчання надійних моделей і для запобігання перевантаженню мережі. Для розв'язання цієї проблеми рекомендується використовувати CNN-архітектуру нейронної мережі. Ця архітектура включає послідовність згорткових і пулінгових шарів, які оптимально підходять для навчання на основі даних від БПЛА [113]. Такий вид архітектури часто завершується повністю пов'язаними рівнями для прогнозування однієї мітки класу або набору ймовірностей класу [75]. Згорткові шари застосовують фільтри до всіх пікселів вхідного зображення, щоб отримати набір абстрактних особливостей високого рівня; шари об'єднання зменшують кількість функцій – контроль надміру; і повністю підключені шари змінюють вихід у вектор із розміром, що дорівнює кількості класів [75]. Для класифікації CNN зазвичай застосовує дві функції активації: softmax для вихідного шару та випрямлений лінійний блок (ReLU) для решти

шарів. Softmax спрямований на масштабування виходів між нулем і одиницею. Це дозволить визначити приналежність об'єкту до певного класу. ReLu – це лінійна функція, яка безпосередньо виводить вхідні дані, якщо вони позитивні. В іншому випадку він виведе нуль. Розмір фільтра (f_s) був обраний як $f_s = [2 \times 2, 4 \times 4, 8 \times 8]$, що є першим значенням, яке дозволило досягти найвищої продуктивності. На рисунку 4.3 зображено графічне пояснення CNN-архітектури [130].

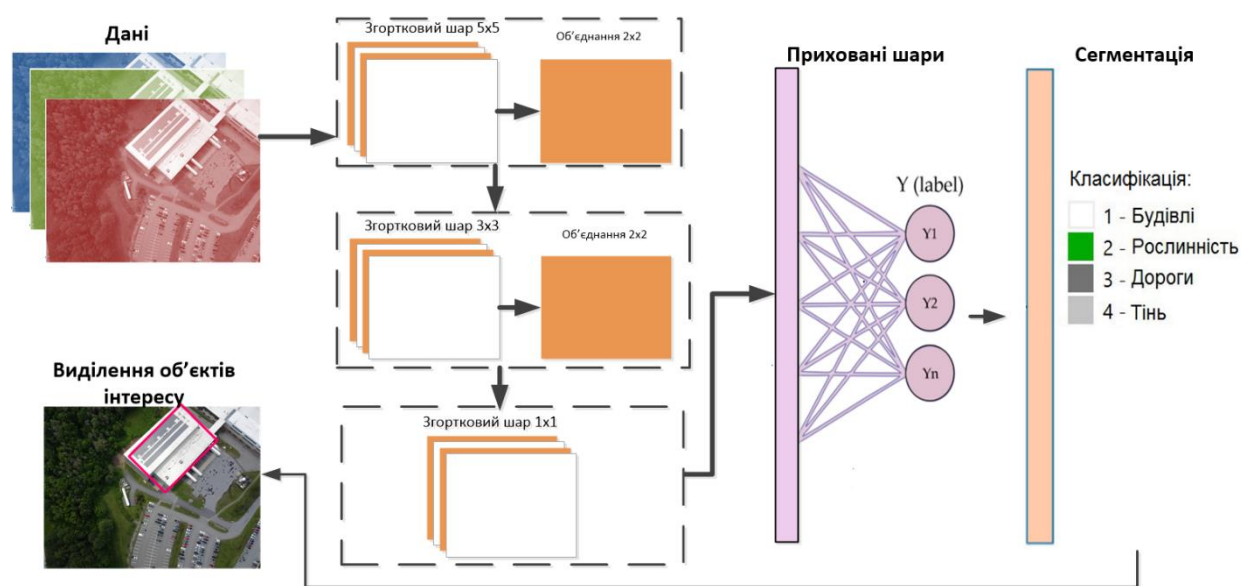


Рис. 4.3. Архітектура нейронної мережі

Рівень об'єднання CNN (рис.4.3). Операція об'єднання має на меті ідентифікацію подібних характеристик (значень, які статистично сильно корельовані) шляхом обрання максимального значення в кожному патчі [63]. Ця операція зменшення дискретизації дозволяє зменшити просторовий розмір виходу і контролює перенавчання моделі. Після цього кроку налаштовується наступний параметр для контролю надмірного навчання, що сприяє поліпшенню процесу навчання [130].

Згортковий шар CNN. Класифікатор Softmax (функція активації) використовується для прогнозування ексклюзивних класів, а характеристики коду CNN були об'єднані в повністю щільний шар, щоб класифікувати кожен піксель зображення за найімовірнішою міткою. Класифікатор Softmax зважає

відстані між даними перевірки та навчальними наборами даних із цього класу для ідентифікації категорії кожного пікселя [130, 134].

На четвертому етапі запропонованого методу проводилась сегментація даних та класифікація. Після навчання моделей глибокого навчання (DL) вони використовуються для класифікації кожного пікселя на зображеннях, отриманих від безпілотних літальних апаратів. Для кожного зображення використовується ковзне вікно розміру 3×3 для поля сприйняття (FOV) вхідних даних. Процес класифікації завершується, коли всі пікселі отримали класифікаційні мітки [134]. Якщо клас має більше шести пікселів у вікні і відрізняється від класу центрального пікселя, він приймає мітку домінуючого класу; в іншому випадку залишається значення мітки центрального пікселя. Цей алгоритм сприяє підвищенню точності ідентифікації об'єктів забудови та зменшенню неправильно класифікованих зон. Результати класифікації можна побачити на рисунку 4.4.

На п'ятому етапі створюємо бінарну маску розпізнавання об'єктів забудови на основі функції втрат перехресної ентропії. Багатоступенева маскова втрата L_M формулюється наступним чином [116]:

$$L_M = - \sum_{i,j} [y_{i,j} \log(\hat{y}_{i,j}) + (1 - y_{i,j}) \log(1 - \hat{y}_{i,j})] \quad (4.2)$$



Рис. 4.4. Результат класифікації зображення

При побудові граничного прогнозу негативні приклади становлять більшість усіх зразків. У нашому експерименті ми вибираємо втрату Dice як функцію втрат для граничного прогнозування, що дозволяє зменшити ступінь навчання на простих негативних прикладах та підвищити значення F1-балу. Контурні втрати L_c визначаються наступним чином [48, 130]:

$$L_c = \frac{2 \sum_{i,j} y_{i,j} \cdot \hat{y}_{i,j}}{\sum_{i,j} y_{i,j}^2 + \sum_{i,j} \hat{y}_{i,j}^2} \quad (4.3)$$




Рис. 4.5. Результат бінарної маски виділення об'єктів забудови на зображенні ДЗЗ

Запропонований метод розпізнавання об'єктів забудови на основі загорткових мереж покращує точність класифікації БПЛА-зображень (рис. 4.6).

Нами проведено дослідження ефективності цього методу та порівняння з існуючими підходами для оцінки розпізнавання об'єктів забудови [130].



Рисунок 4.6. Результат нейромережевого виділення об'єктів забудови на зображенні ДЗЗ

Процес класифікації передбачає узагальнення, існує певний рівень втрати інформації, що призводить до втрати повноти кінцевого результату [13]. Тому, пропонуємо розрахувати функцію втрат як [130]:

$$\text{втрати} = 1 - \text{Точність} \quad (4.4)$$

Для вимірювання якості виділення границь об'єктів забудови пропонуємо використати IoU:

$$\text{Границі IoU} = \frac{|(G_d \cap G) \cap (P_d \cap P)|}{|(G_d \cap G) \cup (P_d \cap P)|}, \quad (4.5)$$

де G позначає двійкову маску зображення, P позначає прогнозовану двійкову маску, d позначає ширину пікселів граничної області, а G_d і P_d відносяться до наборів пікселів маски базової правди та прогнозованих пікселів маски відповідно, які знаходяться в межах задану відстань від кожного контуру [130].

Запропонований в роботі метод нейромережевої класифікації зображень високої просторової розрізненості реалізовано на основі структури глибокого навчання PyTorch на одному графічному процесорі


Nvidia RTX 3090, на системі Intel Core-i3 8th Gen (2.90 ГГц) з 8 ГБ оперативною пам'яттю. Нейронна модель навчена за допомогою оптимізатора середньоквадратичного розповсюдження (RMSprop), і швидкість навчання ініціалізована на 0.0001 з розпадом ваги 1×10^{-8} . Загальна кількість епох встановлена на 150 з розміром 16 [130].

Під час процесу навчання на кожній ітерації використовується набір перевірки для обчислення індукованої похибки після завершення навчання моделі. Для запобігання перенавчанню використовується стратегія ранньої зупинки: навчання автоматично зупиняється, якщо значення IoU (індекс схожості Жаккара) моделі на наборі перевірки не покращується протягом 12 ітерацій. Також використовується стратегія ReduceLRonPlateau для динамічного зменшення швидкості навчання: якщо продуктивність моделі на верифікаційному наборі даних не покращується протягом певної кількості епох, швидкість навчання зменшується. На етапі тестування модель оцінюється за допомогою тестового набору даних, що дозволяє отримати бінарну маску зі значеннями 0 і 1, що відповідають класифікації об'єктів на зображенні [130].

На рисунку 4.7 зображено відсоток пікселів наборів даних для кожного класу земельного покриття для тестового зображення БПЛА та після запропонованого методу в роботі. Так, кількість пікселів для класів доріг з твердим покриттям в обох наборах даних становила приблизно 0.3%, тоді як відсотки для класу забудови були близькими до 0.8%, що було майже в 2.6 рази більше вибірки класу доріг з твердим покриттям [130].

В таблиці 4.1 наведено результат методів класифікації CNN з цифровою та без цифровою моделями. Загальна точність (OA) має кращі результати на основі запропонованого методу в роботі (з 0.968 до 0.980), середня точність (AA) – з 0.952 до 0.970. І навпаки, найвище значення індексу Каппа (K) було виміряно (0.988) у даних навчання на основі реалізації загорткових нейронних мереж. Дослідження показали, що нейронна мережа

без урахування цифрової моделі має нижчу продуктивність, ніж об'єднані набори даних з цифровою моделлю [130].



Легенда:

■ % – первинне зображення

■ % – після застосування інформаційної технології

Рис. 4.7. Відсоток пікселів наборів даних для кожного класу земельного покриття для тестового зображення та після запропонованого методу

Таблиця 4.1. Ефективність методів класифікації

Тип	Модель	<i>OA</i>	<i>AA</i>	<i>K</i>
Навчання	CNN з цифровою моделлю	0.982	0.978	0.984
	CNN без цифрової моделі	0.956	0.936	0.949
Тестування	CNN з цифровою моделлю	0.979	0.963	0.978
	CNN без цифрової моделі	0.961	0.953	0.967

В таблиці 4.2 наведено результати точності для кожного розглянутого класу: зелень (рослинність), дороги, тіні, будівлі. Ці результати свідчать про

те, що модель на основі запропонованого в роботі методу змогла класифікувати майже всі класи з відносно високою точністю. Максимальна точність становила для класу дороги та будівлі, тоді як мінімальна точність належала класу тіні (0.981) [130].

Таблиця 4.2. Точність (РА) для кожного класу

Клас	CNN	Запропонований метод
Рослинність	0.971	0.982
Дороги	0.987	0.994
Тіні	0.879	0.981
Будівлі	0.953	0.992

Для дослідження розпізнавання границь об'єктів забудови проаналізовано метрику IoU. Результати наведено на рисунку 4.8. Порівняно з методом Baseline (базова лінія), запропонований метод забезпечує точне виділення контурів об'єктів забудови.

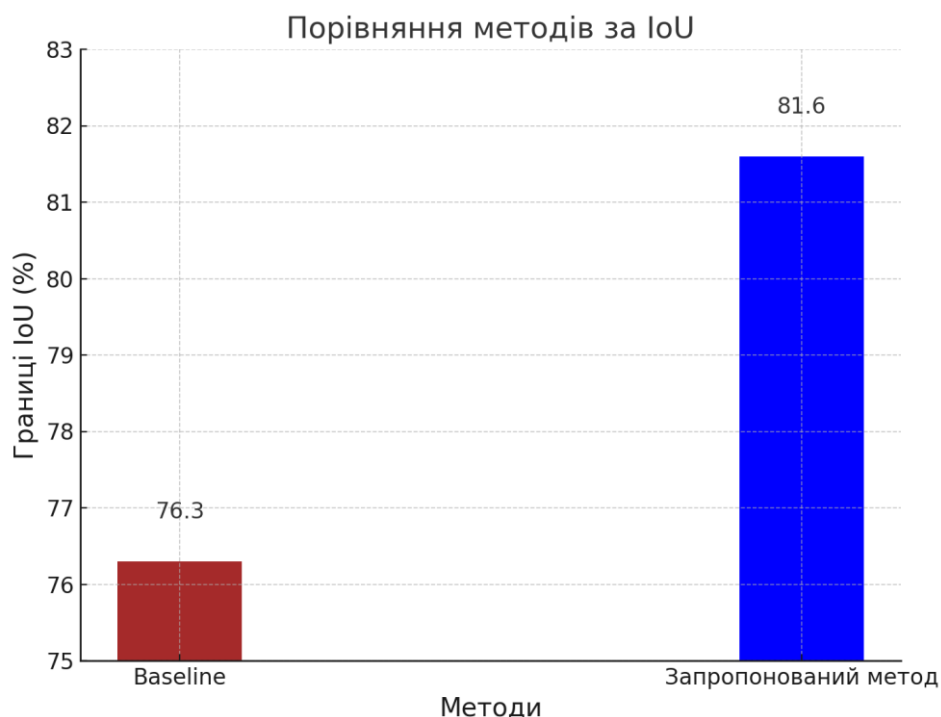


Рис. 4.8. Результат метрики IoU

В таблиці 4.3 наведено результати дослідження для тестового набору даних. Значення IoU збільшується на 5.3%, вказуючи на те, що допоміжна інформація про контур може зробити границі більш регулярними та підвищити точність моделі. Результати, наведені в табл. 4.3, підтверджують кращу ефективність запропонованого методу порівняно з іншими методами оцінки розпізнавання об'єктів за будови.

Таблиця 4.3. Результати дослідження метрики IoU

Метод	IoU (%)
Baseline	76.3
Запропонований метод	81.6

Нижче подано результати класифікації ще одного фрагменту супутникового зображення (рис.4.9).



Рис.4.9. Результати нейромережевої класифікації

Оціночні індекси (метрики) результатів класифікації наведено в таблиці 4.4 [130].

Таблиця 4.4. Оцінки результатів класифікації

Оцінка	Ліс	Лука	Тіні	Ґрунт	Будівлі	Дороги
Precision	89	82	86	84	83	88
Recall	86	87	88	89	91	90
IoT	82	74	73	75	74	78

Як можна побачити, запропонована технологія нейромережевої класифікації дозволяє точніше визначати класи завдяки використанню функції втрати багатозадачності, що допомагає отримати додаткову інформацію про межі об'єктів. Порівняльні експерименти показали значне покращення точності класифікації на загальнодоступному наборі даних. Зокрема, метрики OA (загальна точність), AA (середня точність) і K (коефіцієнт Каппа) зросли на 2.6%, 5.6% і 3.2% відповідно для навчального набору даних і на 1.2%, 1.8% і 1.5% для тестового набору даних. Використання запропонованого підходу разом з цифровою моделлю успішно покращило PA (точність класифікації) як для тестових, так і для навчальних наборів даних. [130].

4.2. Розпізнавання та моніторинг водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання

4.2.1. Необхідність і передумови ефективного моніторингу водних об'єктів

Річки, озера та відкриті водойми важливі для «здоров'я» навколишнього середовища, особливо в міських районах. Детальні карти цих водних об'єктів на основі супутникових даних є необхідним інструментом для ефективного моніторингу міських екосистем, управління впливом міських теплових островів та адаптації до зміни клімату.

Вода є багатогранним природним ресурсом, що впливає на ключові аспекти міських екосистем. Надмірна експлуатація, зміни у

землекористуванні, ґрунтовому покриві та зміна клімату мають негативний вплив на гідрологічний цикл, що призводить до змін поверхневих і підземних вод на Землі [106]. Дані, отримані від космічних супутників таких як Landsat, Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) і Satellite Pour l'Observation de la Terre (SPOT), Sentinel-1, 2, дозволяють проводити моніторинг повеней, оцінку водних ресурсів [109], визначати якість води [16] та контроль за береговою лінією [70]. Особливу увагу слід звертати на дослідження прибережних екотонних зон – унікальних областей, де суша зустрічається з водою і часто має водну рослинність. Ці екотони впливають на точність розпізнавання та класифікації водних об'єктів на супутникових зображеннях. Крім того, на оптичних супутникових знімках можуть бути хмари, їхні тіні, що ускладнює обробку таких даних та розпізнавання водних об'єктів. Таким чином, оптичні супутникові зображення мають потенціал надавати важливу інформацію для моніторингу водних об'єктів. З іншого боку, враховуючи вищенаведені труднощі, пов'язані з тінями від хмар і об'єктами із низьким альбедо [11], важливим є постійне вдосконалення методів розпізнавання водних об'єктів на супутникових зображеннях [131].

Наразі розроблені методи для розпізнавання, картографування та моніторингу водних об'єктів на супутникових зображеннях. Ці методи поділяються на три категорії: аналіз статистичного розпізнавання образів на основі пікселів, що включає контрольовані [60] і неконтрольовані [68] підходи до класифікації; аналіз зображень з урахуванням параметрів, таких як спектральні характеристики, текстура та складність форми [53]; а також субпіксельний аналіз [108]. Для моніторингу водних об'єктів широко застосовуються спектральні індекси води. Автори [122] порівняли продуктивність різних індексів води в Landsat 7 ETM+, Landsat 8 OLI та Sentinel-2 MSI. У роботі [22] був запропонований новий індекс води для супутників Landsat TM/ETM+/OLI, заснований на коефіцієнті відбиття поверхні з використанням порогового значення. Цей метод оптимізований

для обробки великого обсягу даних та надає простий, але ефективний підхід для автоматизованої класифікації великих водойм. Хоча існуючі методи, засновані на спектральних індексах води, можуть досягати високої точності у виділенні площ поверхневих вод, вони не є ефективними при аналізі багатоспектральних супутникових зображень [131].

Методи класифікації, засновані на виділенні ознак і машинному навчанні, є передовою технікою для моніторингу поверхневих водних об'єктів, наприклад «випадковий ліс» (random forest) [102], метод опорних векторів [55], XGBoost [10]. З іншого боку, неконтрольовані методи класифікації не вимагають ніяких навчальних зразків і більше підходять для розробки автоматизованих алгоритмів. Згорткові нейронні мережі є популярним методом глибокого навчання і широко використовуються для семантичної сегментації, виявлення хмар, вилучення водойм, тощо. Розроблено різноманітні нові моделі глибокого навчання для вилучення поверхневих водних об'єктів на основі космічних супутникових даних [38], для яких важливою є багатомасштабна семантична інформація.

Метою даного підрозділу є підвищення ефективності розпізнавання та подальшого моніторингу водних об'єктів на цифрових оптичних супутникових зображеннях з використанням машинного навчання.

4.2.2. Інформаційна технологія моніторингу водних об'єктів

Запропонована в роботі технологія моніторингу водних об'єктів складається з восьми етапів, представлених на рисунку 4.10 [131].

Перший етап складається із завантаження знімків, для конкретики в даній роботі обрано дані з 2016 по 2023 роки з оптичного супутника Sentinel-2 у літній період (рис. 4.11). Завантажуємо топографічні карти, які містять важливу інформацію про територію дослідження.

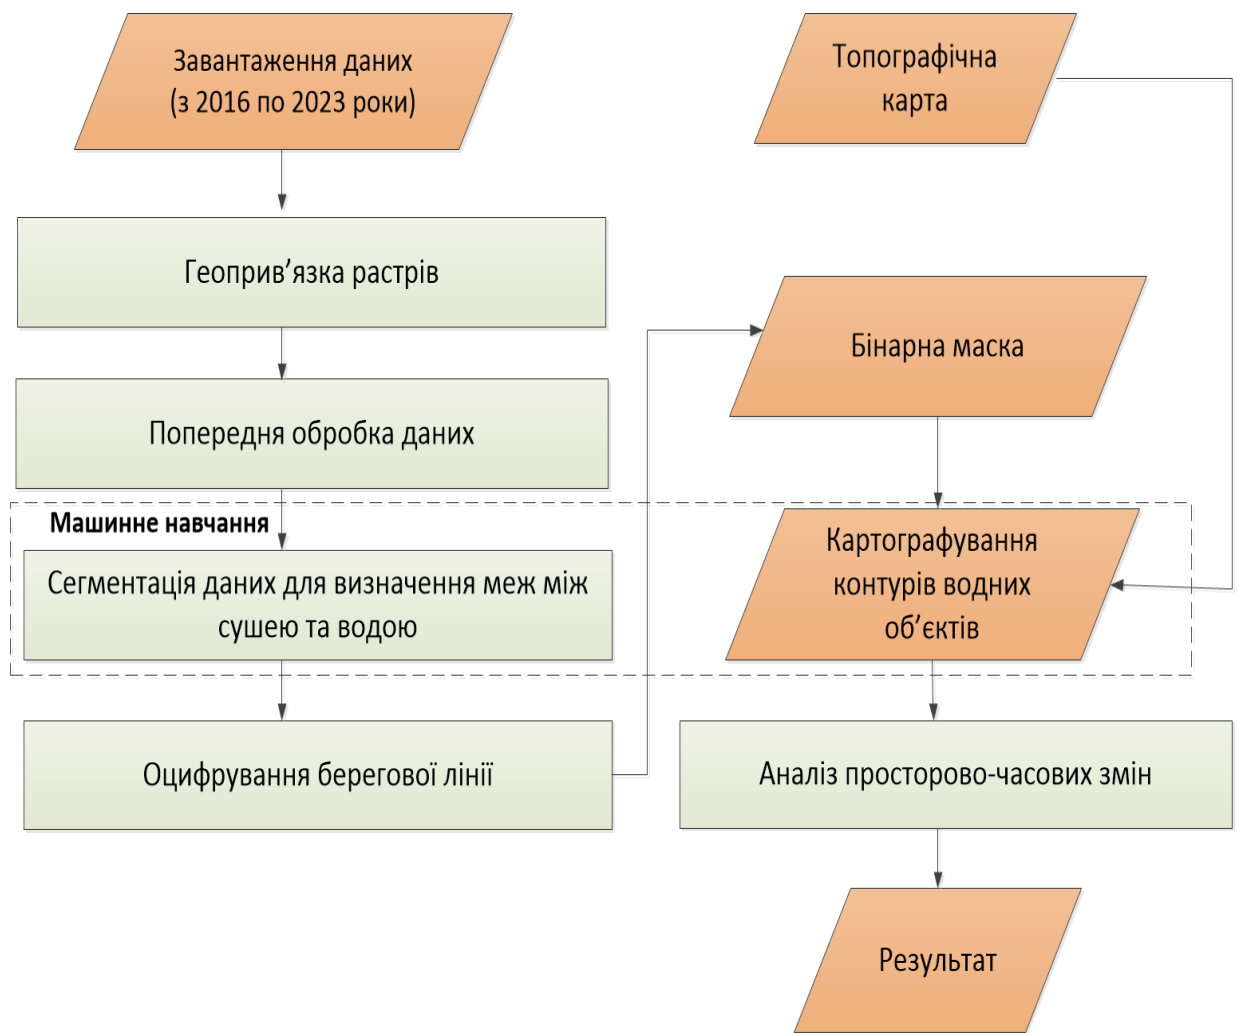




Рис. 4.10. Алгоритм запропонованої технології



а)



б)

Рис. 4.11. Супутниковий знімок Тузлівських лиманів у літній період:

а) 2016 рік; б) 2023 рік

Для картографування контурів водних об'єктів на топографічні карти використовується геопросторовий аналіз, де визначаються координати берегової лінії на карті.

Третім етапом є попередня обробка даних, яка включає в себе калібрування супутникових знімків, видалення атмосферного шуму і покращення контрастності. Завдання радіометричного калібрування полягає в перерахунку значень яскравості (Digital Number) у значення спектральної енергетичної яскравості на верхній межі атмосфери [70]:

$$L_{\lambda} = M_L \cdot Q_C + A_L, \quad (4.6)$$

де L_{λ} – енергетична яскравість для спектральної зони; M_L – калібрувальний коефіцієнт масштабування; Q_C – каліброване значення; A_L – калібрувальна константа, яка відповідає мінімальній величині реєстрованої яскравості.


Для атмосферної корекції враховано пропускання електромагнітного випромінювання і власне світіння атмосфери. На цьому ж етапі було здійснено переведення значень пікселів з енергетичної яскравості в коефіцієнти відбивної здатності від 0 до 1 [131]:

$$p_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot D^2}{E_{sun\lambda} \cdot \cos\theta}, \quad (4.7)$$

де L_{λ} – енергетична яскравість для спектральної зони [Вт/(ср \geq м²-нм)]; D – відстань від Землі до Сонця в астрономічних одиницях для конкретного періоду; $E_{sun\lambda}$ – середня сонячна позаатмосферна освітленість [Вт/(м² нм)]; θ – кут піднесення сонця.


Сегментація даних є четвертим етапом і використовується для розпізнавання водних об'єктів на знімках, включаючи берегову лінію (рис.4.12). Для цього використовувалась класифікація пікселів супутникових знімків на дві категорії: суша і водні об'єкти. На цьому етапі було використано метод кластеризації в поєднанні з Orfeo ToolBox (OTB) в QGIS

для групування пікселів за їхніми спектральними характеристиками у різних каналах (червоний, зелений, синій та ін.) [131].



Легенда:
■ - Водні об'єкти
■ - Суша

а)



Легенда:
■ - Водні об'єкти
■ - Суша

б)

Рис. 4.12. Сегментація супутникового знімка за літній період:

а) 2016 рік; б) 2023 рік

П'ятий етап відповідає за картографування берегової лінії та базується на морфологічних операціях та функціях.

Шостим етапом є отримання бінарної маски з контурами водних об'єктів за 2016 та 2023 роки (рис.4.13). На цьому етапі використано метод порогового значення Otsu [69] для визначення оптимального порогового значення сегментації водних об'єктів і суші [131].




Рис. 4.13. Бінарна маска супутникового знімка за: а) 2016 рік; б) 2023 р.

Сьомим етапом є картографування контурів водних об'єктів на цифрових супутникових зображеннях. Вибір порогового значення є ключовим кроком у використанні підходів, заснованих на правилах, для картографування водойм. З цією метою було використано постійний параметр оптимізації SVM, який базується на статистичній теорії навчання та спрямований на визначення меж прийняття рішень шляхом максимізації розриву між класами [97]. У випадку двох лінійно роздільних класів SVM вибирає серед нескінченної кількості лінійних границь рішення оптимальну роздільну гіперплощину, яка мінімізує помилку узагальнення. Коли дані не є лінійно роздільними, SVM розширюється шляхом введення змінних slack і застосування функції ядра для вирішення проблеми оптимізації. Ядро радіальної базисної функції зазвичай тренується набагато швидше. Параметр c у c -SVM допомагає оптимізувати SVM, оскільки його значення налаштовуються на основі вхідних даних [131].

Останнім етапом є проведення аналізу просторово-часових змін берегової лінії.

4.2.3. Тестування запропонованої технології

Тестування запропонованої в роботі інформаційної технології проводилось на прикладі берегової лінії Одеської області, а саме Національного природного парку «Тузлівські лимани», розташованого у Татарбунарському районі. Цей парк включає в себе систему лиманів, таких як Шагани, Алібей та Бурнас, а також групу солоних лиманів лагунного типу. Від узбережжя Чорного моря ці лимани відокремлені піщаною косою завдовжки 29 кілометрів і шириною від 60 до 400 метрів. Національний природний парк був заснований у 2010 році з метою захисту унікальної і вразливої природи Причорномор'я (рис.4.14) [131].



Рис. 4.14. Область дослідження

4.2.4. Оцінка отриманих результатів

Для аналізу зміни площі водного дзеркала Тузлівських лиманів, використано коефіцієнт Пірсона r :


$$r = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}}, \quad (4.8)$$

де \bar{x} , \bar{y} є середніми значеннями двох змінних x і y відповідно.


Для оцінки ефективності технології моніторингу водних об'єктів було проведено обчислення загальної точності (Overall Accuracy, OA) та коефіцієнт Каппа (Карра). Ці метрики надають об'єктивну оцінку та




порівнюють ефективність розробленого методу з водними індексами та методом K-means [115].

Отримані контури водних об'єктів були детально проаналізовані з використанням геоінформаційних технологій та інструментів, зокрема QGIS і мови програмування Python (рис.4.15). Аналіз контурів водних об'єктів надав змогу визначити характер змін, їхню інтенсивність та розподіл вздовж берегової зони Тузлівських лиманів.



а)



Легенда:  - суша;  - водні об'єкти;  - границі водних об'єктів

б)

Рис. 4.15. Виділення водних об'єктів після сегментації: а) 2016 рік; б) 2023 р.

Для оцінки змін водних об'єктів та берегової лінії використано коефіцієнт кореляції Пірсона, який може мати значення в діапазоні від -1 до 1. Значення близьке до 1 вказує на сильний позитивний зв'язок між масками, значення близьке до -1 вказує на сильний негативний зв'язок, а значення близьке до 0 вказує на відсутність зв'язку. Результати значень коефіцієнта Пірсона, наведено у вигляді графіка на рис.4.16 [131].




Рис. 4.16. Графік значень коефіцієнта Пірсона за роками

Наступним етапом є аналіз середньорічної швидкості змін площі водних об'єктів Тузлівських лиманів в період з 2016 по 2023 рр. На цьому етапі виконано розрахунок площі водного дзеркала Тузлівських лиманів за 7 років:

$$S = L \cdot W, \quad (4.9)$$

де L – довжина берегової лінії; W – ширина берегової лінії.

$$\text{Середня річна швидкість} = \frac{\text{Сума приростів та втрат площі}}{\text{Кількість років}} \approx 4.96 \text{ км}^2/\text{рік}. \quad (4.10)$$

На рисунку 4.17 наведено графік змін площі водного дзеркала Тузлівських лиманів з 2016 по 2023 роки. З 2016 по 2018 рік спостерігалася стабільна тенденція втрати площі, а з 2019 по 2020 рік відбувся різкий спад. Найбільший приріст площі відбувся в 2020-2021 році, що вказує на позитивні зміни у водних об'єктах. Аналізуючи графік, можна визначити тенденцію зміни площі водного дзеркала, що вказує на тенденцію до втрати прибережних територій (обміління) з часом.




Рис. 4.17. Графік зміни площі водного дзеркала Тузлівських лиманів

На наступному етапі було створено векторний шар отриманих контурів водних об'єктів на супутниковому знімку Sentinel-2 за період 2016-2023 р. (рис.4.18). Візуально можна спостерігати за втратами прибережних територій (обміління) протягом семи років. Візуально проведений аналіз (рис.4.19) водних об'єктів дозволяє виявити території, де відбувається осушення лиманів. Такими областями є озеро-лиман Солоне та озеро-лиман Хаджидер.

Значення коефіцієнтів відбиття світла від поверхні води та суші у 2023 році наведено на рис.4.19. Коефіцієнт відбиття вказує на те, який відсоток світла падає на поверхню, відбивається від неї. Зміна цих коефіцієнтів

пов'язана з різницею в фізичних властивостях води та суші, таких як структура поверхні, прозорість, вологість і т.і. [131].



Легенда

- Берегова лінія 2016 року
- Берегова лінія 2023 року

Рис. 4.18. Картографування зміни площі водного дзеркала Тузлівських лиманів з 2016 рік по 2023 рік




Рис. 4.19. Коефіцієнти відбиття водної поверхні та суші

В даному дослідженні побудовано та проаналізовано графік значень коефіцієнтів відбиття прибережної зони в інфрачервоному (ІЧ) каналі за період 2016–2023 роки (рис.4.20). Зміни в значеннях коефіцієнтів відбиття в ІЧ-каналі свідчать про різниці в температурі та тепловіддачі прибережної зони. Це може бути пов'язано з такими факторами, як зміни клімату, розширення або зменшення водних об'єктів, або інші природні та антропогенні впливи [131].

У таблиці 4.4 представлено результати метрик OA та Карра для запропонованої технології та індексів NDWI, MNDWI, K-means. У 2016 році запропонована технологія виділяє водні об'єкти з точністю 97% та коефіцієнтом Каппа 0.94. Порівняно з цим, інші методи, такі як NDWI, MNDWI та K-means, мають нижчі показники ефективності. Для зображення 2023 р. запропонована технологія знову показує високу точність – 96.96%, а Каппа залишається стабільно високою на рівні 0.94. При цьому NDWI має точність 77.08% та Каппа 0.56, MNDWI демонструє точність 93.46% та Каппа 0.86, а K-means – точність 95.36% та Каппа 0.92 [131].

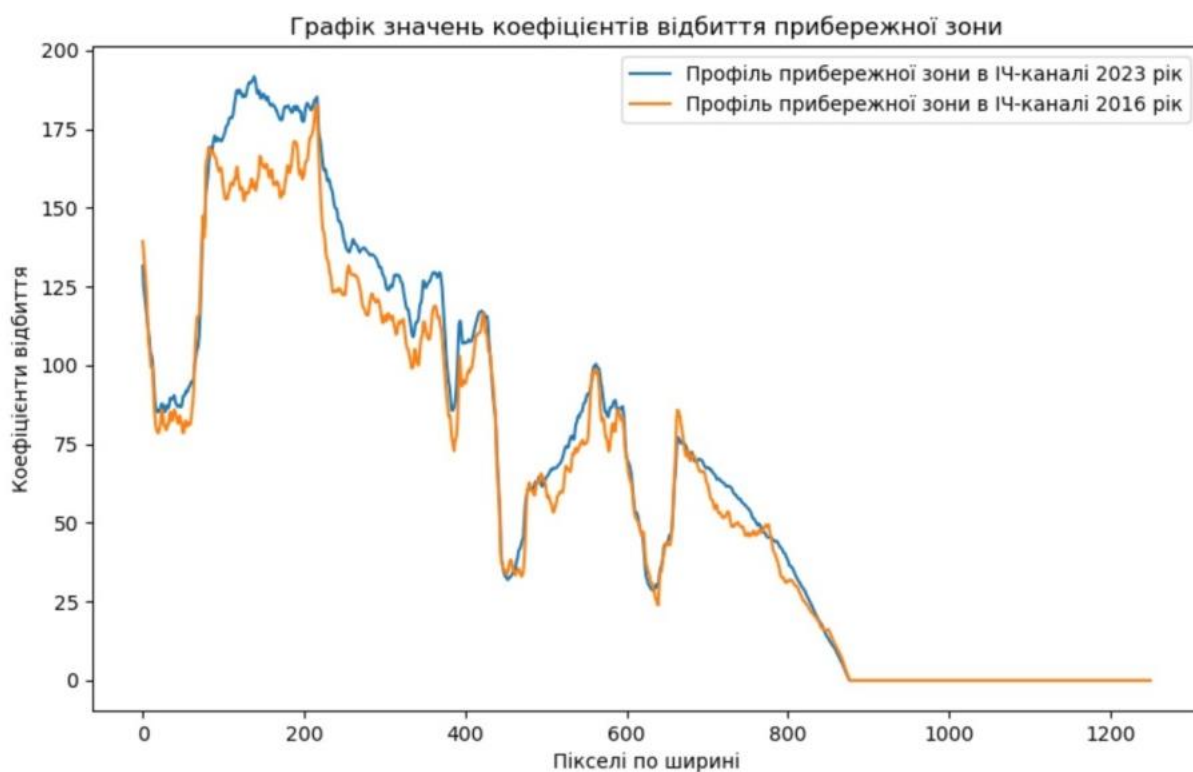


Рис. 4.20. Графік коефіцієнтів відбиття прибережної зони в ІЧ-каналі

Таблиця 4.4. Результати оцінки точності картографування водних об'єктів

Метод	2016 рік		2023 рік	
	OA	Kappa	OA	Kappa
NDWI	83%	0.67	77%	0.56
MNDWI	91%	0.82	93%	0.86
K-means	94%	0.90	95%	0.90
Запропонована технологія	97%	0.94	97%	0.94

Отримані результати свідчать про високу точність запропонованої інформаційної технології у порівнянні з існуючими методами, підкреслюючи її ефективність для розпізнавання та моніторингу водних об'єктів на основі супутникових зображень. Запропонований підхід дозволяє отримати результати з субпіксельною точністю для подальших досліджень та прийняття рішень.

Технологія моніторингу водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання може бути використана для дослідження змін на прибережних територіях, прийняття рішень в галузі управління прибережними ресурсами та земельним використанням [131].

4.3 Розробка програмного модулю класифікації зображень з використанням нейронних мереж

Інформаційна технологія реалізована у вигляді програмного додатку Image Processing, написаного мовою Python у середовищі Microsoft Visual Studio 2023. Архітектура додатку наведена на рис.4.21.

Програмний модуль призначений для класифікації зображень з використанням нейронних мереж. Він реалізує графічний інтерфейс користувача (GUI) на основі бібліотеки PyQt5, що дозволяє завантажувати зображення, проводити попередню обробку та класифікацію зображень.

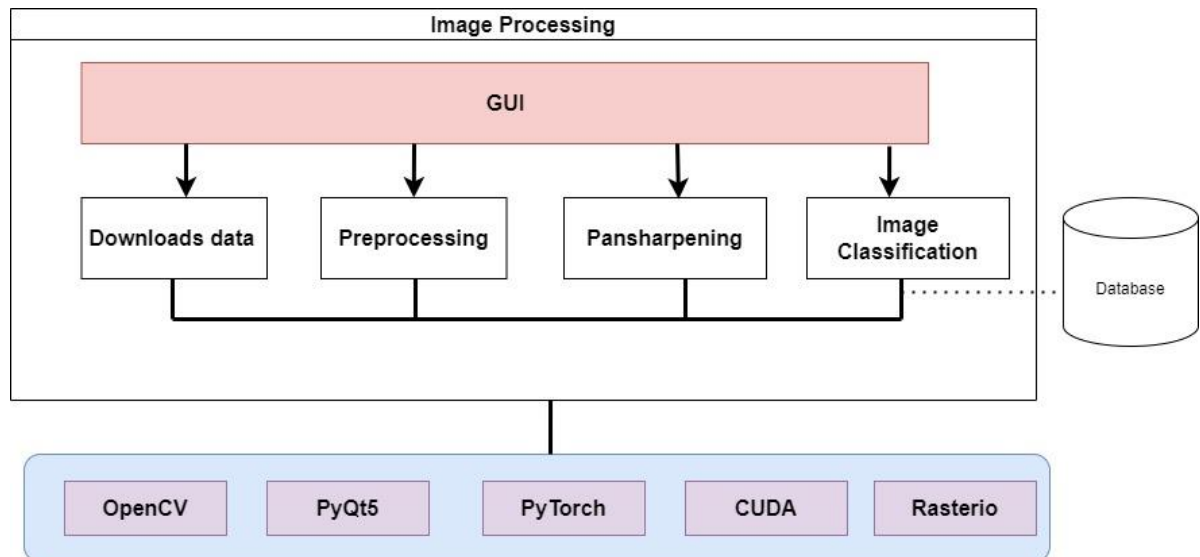


Рис. 4.21. Архітектура програмного додатку

Графічний інтерфейс користувача створений для взаємодії користувача з програмою, побудований за допомогою бібліотеки PyQt5 і складається з меню, кнопок управління та чекбоксів (рис.4.22). Меню дозволяє користувачу зберігати файли та виходити з програми. Кнопки управління забезпечують основні функції, такі як завантаження знімків (рис. 4.23), попередня обробка та класифікація знімків (4.24).

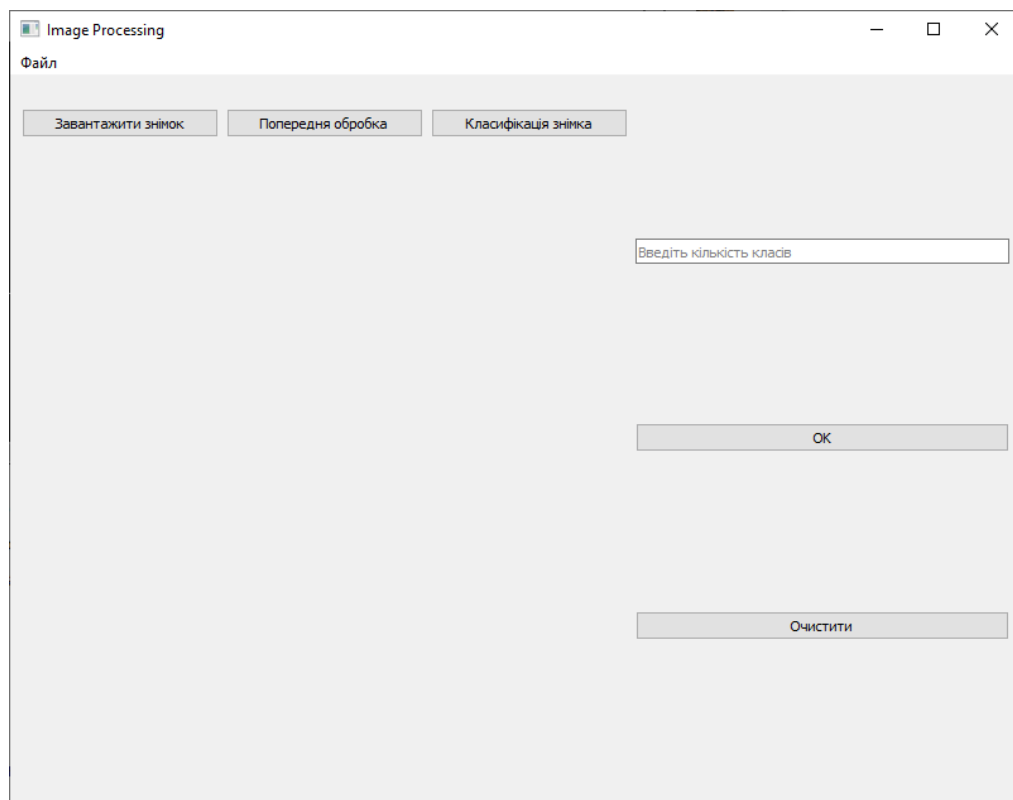


Рис.4.22. Зовнішній вигляд графічного інтерфейсу користувача

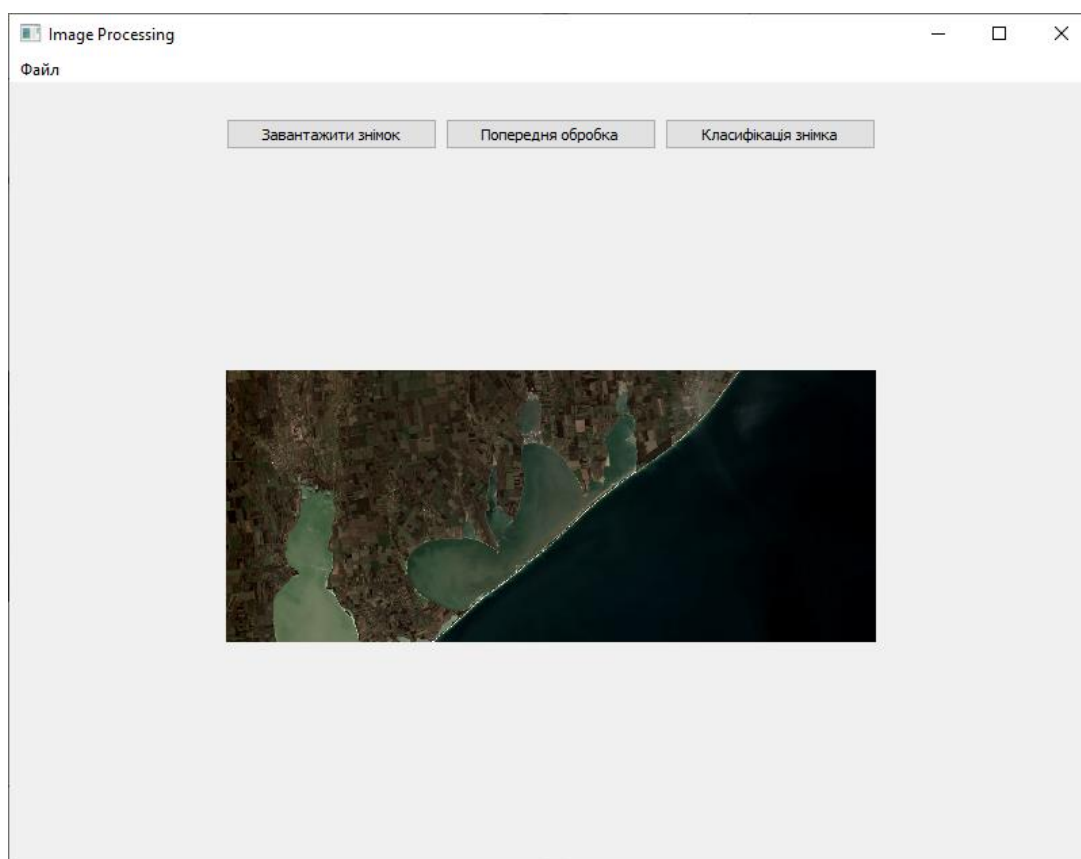


Рис.4.23. Завантаження первинного багатоспектрального зображення

Попередня обробка зображень включає операції з підготовки знімків перед класифікацією, зокрема підвищення інформативності згідно п.2.2.

Класифікація зображень здійснюється з використанням нейронної мережі, яка виконує класифікацію на основі тренуваних моделей. Чекбокси GUI дозволяють обрати кількість класів (рис. 4.24, 4.25).

Нейронна мережа, побудована за допомогою PyTorch, є основним інструментом для класифікації супутникових знімків. Модель завантажується та використовується для обробки зображень, попередньо підготовлених за допомогою бібліотеки Pillow. Результати класифікації відображаються користувачу через GUI, з можливістю збереження оброблених зображень та результатів на диск.

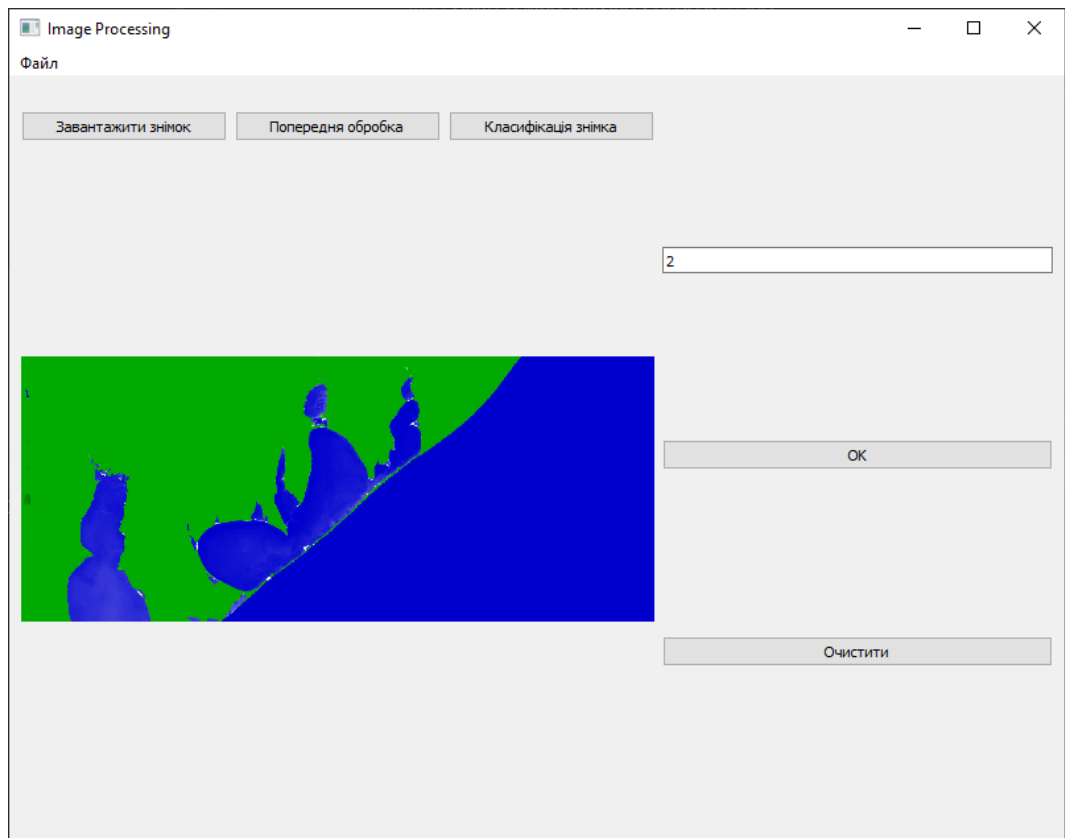


Рис.4.24. Вибір двох класів та результат класифікації зображення



Рис.4.25. Вибір шести класів та результат класифікації зображення

Модуль використовує різноманітні бібліотеки для забезпечення функціональності:

- PyQt5 використовується для створення графічного інтерфейсу користувача;
- PyTorch використовується для завантаження та використання нейронної мережі для класифікації;
- Pillow використовується для завантаження та попередньої обробки зображень;
- QFileDialog дозволяє користувачу вибирати файли для завантаження та збереження;
- QMessageBox використовується для відображення повідомлень користувачу;
- CUDA використовується для прискорення обчислень на GPU;
- OpenCV використовується для обробки зображень і комп'ютерного зору;
- Rasterio використовується для читання та запису географічних растрових даних.

Детальний опис програмної реалізації та усіх функціональних можливостей програмної реалізації розробленої інформаційної технології не є предметом даної роботи.

4.4. Висновки до четвертого розділу

1. Запропоновано та досліджено інформаційну технологію класифікації аерокосмічних зображень високої просторової розрізненості на основі згорткової нейронної мережі. Доведено ефективність розробленої інформаційної технології класифікації аерокосмічних зображень високої просторової розрізненості при вирішенні практичних завдань, зокрема для розпізнавання і визначення контурів об'єктів забудови на знімках з БПЛА. Спочатку завантажуються та обробляються знімки високої просторової розрізненості. Потім проводиться сегментація та класифікація зображення на

основі архітектури згорткової нейронної мережі з активаційною функцією softmax для вихідного шару та активаційною функцією ReLu для решти шарів. Згорткові шари застосовують фільтри до всіх пікселів вхідного зображення, щоб отримати набір абстрактних особливостей високого рівня. Далі, для класифікації кожного пікселя зображення була проведена класифікація даних, де поле сприйняття (fov) для кожного зображення вважається ковзним вікном розміру 3×3 вхідних даних. Це дозволяє визначати приналежність об'єкту до певного класу. Завершальним етапом є створення бінарної маски розпізнавання об'єктів забудови на основі функції втрат перехресної ентропії. Тренування мережі проводилося на рівні пікселів, що дозволило підвищити точність ідентифікації об'єктів забудови та зменшити кількість неправильно класифікованих зон. Комп'ютерні експерименти показали значне покращення точності розпізнавання будівель у загальнодоступному наборі даних. Зокрема, метрики OA, AA та K покращилися на 2.6%, 5.6% та 3.2% відповідно для навчального набору даних і на 1.2%, 1.8% та 1.5% для тестового набору даних.

2. Розроблено та досліджено інформаційну технологію розпізнавання та моніторингу водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання. Розроблена технологія складається з восьми етапів: завантаження первинних даних; геоприв'язка растрових зображень; попередня обробка даних; сегментація даних для визначення границь водних об'єктів та ділянки землі; оцифрування берегової лінії; створення бінарної маски; картографування контурів водних об'єктів з використанням топографічної карти та аналіз просторово-часових змін. Машинне навчання використовується для сегментації зображень, а метод опорних векторів використовується для картографування контурів водних об'єктів. Це дозволяє отримати результати з субпіксельною точністю, забезпечуючи важливу інформацію для подальших досліджень та прийняття рішень.

3. Проведено експерименти на супутникових даних Sentinel-2 для моніторингу водних об'єктів з просторовим розрізненням 10 метрів. Областю дослідження стала берегова лінія Одеської області – Національний природний парк «Тузлівські лимани». Порівняльний кількісний аналіз з існуючими методами, такими як водні індекси та K-means, підтверджує високу точність розробленої технології протягом 2016–2023 років (точність від 97%). Коефіцієнт Каппа, який враховує ступінь узгодженості між реальною та передбачуваною класифікацією, підтверджує високу стабільність та достовірність підходу (0.94).

4. Інформаційна технологія класифікації аерокосмічних зображень реалізована у вигляді програмного додатку Image Processing, написаного мовою Python у середовищі Microsoft Visual Studio 2023. Він реалізує графічний інтерфейс користувача на основі бібліотеки PyQt5, що дозволяє завантажувати багатоканальні супутникові зображення високої просторової розрізненості, проводити їх попередню обробку та класифікацію.

5. Запропоновані інформаційні технології та методи розпізнавання та класифікації супутникових зображень і розроблене на їх основі програмне забезпечення впроваджені в «Дніпрокосмос» філії Національного центру управління та випробувань космічних засобів Державного космічного агентства України, Іноземному підприємстві «ЕМЕРДЖН» та в освітній процес Національного технічного університету «Дніпровська політехніка».

Результати досліджень даного розділу опубліковано в роботах автора [30, 121, 127, 130-132].

ВИСНОВКИ

В дисертаційному дослідженні розв'язана важлива науково-прикладна задача підвищення точності, рівня автоматизації та швидкодії розпізнавання та класифікації різночасових супутникових зображень високої просторової розрізненості шляхом розробки інформаційних технологій і методів обробки із застосуванням методів машинного навчання.

Основні наукові та практичні результати роботи полягають у наступному:

1. Проаналізовано сучасний стан розвитку методів і технологій попередньої обробки та класифікації різночасових супутникових даних високої просторової розрізненості і відповідного існуючого математичного та програмного забезпечення, яке використовується для розробки подібних технологій. Також проаналізовані методи, що базуються на штучному інтелекті, сучасні підходи глибокого навчання та останні тенденції у розвитку штучних нейронних мереж. Існуючі рішення, як правило, є дорогими, трудомісткими та з використанням ручного дешифрування. За результатами проведеного аналізу обґрунтовано необхідність розробки інформаційних технологій автоматизованої нейромережевої обробки з метою скорочення часу та вартості розпізнавання і класифікації супутникових зображень.

2. Здійснено аналіз проблеми та сучасних методів обробки великих даних ДЗЗ. Надані основні поняття й визначення, що використовуються для її розв'язання. Описано властивості організації даних, що дозволяють передбачити результат виконання певних операцій в структурі за її елементами, використовуючи їх розташування без виконання обчислювального алгоритму. Отримано висновки про вплив властивостей та математичних методів роботи зі структурою.

3. Запропоновано та доведено ефективність методу оптимізації основних характеристик обробки великих даних дистанційного зондування

Землі на основі застосування кортежної структури організації даних, який дозволяє зменшити обсяг оброблюваної інформації, підвищити швидкості пошуку та обробки даних при збереженні їх відповідних значень та надійності.

4. Запропоновано та доведено ефективність IaaS-рішення для обробки потоку даних дистанційного зондування на основі глибокого навчання та хмарних технологій Kubernetes та Apache Airflow, розміщених на платформі Google Cloud Platform. Запропонований алгоритм представлений у вигляді прямого ациклічного графа у застосунку IaaS. Згадані хмарні технології використовуються для кращого представлення робочого процесу, який реалізує складну систему паралельного виконання обчислювально-важких завдань обробки зображень високої просторової розрізненості.

5. Розроблено та досліджено інформаційну технологію попередньої обробки цифрових супутникових зображень з використанням згорткової нейронної мережі, яка здатна ефективно підвищити інформативність первинних даних, вилучати деталі текстури та просторові залежності, а також локальну та нелокальну інформацію. Результати комп'ютерних експериментів підтвердили, що запропонована технологія дозволяє досягти підвищення просторової розрізненості первинних багатоканальних зображень та, у порівнянні з класичними методами злиття, зменшити артефакти супутникових знімків.

6. Запропоновано та доведено ефективність комплексного підходу до обробки зображень високої просторової розрізненості на основі застосування штучного інтелекту та класичних алгоритмів обробки зображень, що включає попередню обробку даних, розробку набору даних для нейронної мережі, моделювання нейронної мережі та розрахунок фізичних розмірів наземних об'єктів. Застосування підходу дозволило автоматизувати процес семантичної сегментації та аналізу різночасових багатоканальних даних високої просторової розрізненості, підвищити якість подальшого розпізнавання і моніторингу об'єктів земної поверхні.

7. Розроблено архітектуру згорткової мережі на базі U-Net для задач семантичної сегментації супутникових зображень високої просторової розрізненості, запропоновано методику підготовки набору вхідних даних та поетапної реалізації каскадів шарів мережі, алгоритм її навчання, обґрунтовано вибір навчальної вибірки.

8. На додаток до алгоритму вимірювань, таких основних фізичних параметрів наземних об'єктів, як периметри, площі, розроблено комплексний показник – щільність забудови, що комбіновано використовує результати семантичної сегментації та інформацію про характеристики супутникових зображень високої просторової розрізненості, що використовуються в поточній роботі як джерело даних для навчального набору даних. Результати комп'ютерних експериментів підтвердили висновок, що запропонована технологія може ефективно покращити загальну точність сегментації зображень дистанційного зондування високої просторової розрізненості та скоротити загальний час навчання та час відповідної обробки.

9. Запропоновано та досліджено інформаційну технологію класифікації аерокосмічних зображень високої просторової розрізненості на основі згорткової нейронної мережі. Доведено ефективність розробленої інформаційної технології класифікації аерокосмічних зображень високої просторової розрізненості при вирішенні практичних завдань, зокрема для розпізнавання і визначення контурів об'єктів забудови на знімках з БПЛА. Тренування мережі проводилося на рівні пікселів, що дозволило підвищити точність ідентифікації об'єктів забудови та зменшити кількість неправильно класифікованих зон. Експериментальні результати показали значне покращення точності розпізнавання будівель у загальнодоступному наборі даних. Зокрема, метрики OA, AA та K покращилися на 2.6%, 5.6% та 3.2% відповідно для навчального набору даних і на 1.2%, 1.8% та 1.5% для тестового набору даних.

10. Розроблено та досліджено інформаційну технологію розпізнавання та моніторингу водних об'єктів на різночасових оптичних

супутникових зображеннях високої просторової розрізненості з використанням машинного навчання, використання якої дозволяє отримати результати з субпіксельною точністю, забезпечуючи важливу інформацію для подальших досліджень та прийняття рішень. Порівняльний кількісний аналіз з існуючими методами, такими як водні індекси та K-means, підтверджує високу точність розробленої технології протягом 2016–2023 років (точність 97%). Коефіцієнт Каппа, який враховує ступінь узгодженості між реальною та передбачуваною класифікацією, підтверджує високу стабільність та достовірність підходу (0.94).

11. Інформаційна технологія класифікації зображень реалізована у вигляді окремого програмного продукту із використанням сучасних методів програмування, що дозволяє полегшити виконання класифікації супутникових зображень та зменшити вимоги до кваліфікації користувача.

12. Запропоновані в дисертації інформаційні технології та методи розпізнавання та класифікації супутникових зображень і розроблене на їх основі програмне забезпечення впроваджені в «Дніпрокосмос» філії Національного центру управління та випробувань космічних засобів Державного космічного агентства України, Іноземному підприємстві «ЕМЕРДЖН» та в освітній процес Національного технічного університету «Дніпровська політехніка».

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Addesso P., Restaino R., Vivone G. An Improved Version of the Generalized Laplacian Pyramid Algorithm for Pansharpening // *Remote Sensing*. - 13(17):3386, 2021. DOI:10.3390/rs13173386.
2. Agostinelli, Forest, Michael R. Anderson, and Honglak Lee. Adaptive multi-column deep neural networks with application to robust image denoising. *Advances in Neural Information Processing Systems*. 2013.
3. Alcaras E, Parente C. The Effectiveness of Pan-Sharpener Algorithms on Different Land Cover Types in GeoEye-1 Satellite Images // *Journal of Imaging*. - 9(5):93, 2023. DOI:10.3390/jimaging9050093.
4. Arai K. Image Clustering Method Based on Density Maps Derived from Self-Organizing Mapping: SOM. // *International Journal of Advanced Computer Science and Applications (IJACSA)*. – 2012. – Vol. 3. – No. 7. – P.102-107.
5. Avudaiamma R., Dayana S., Prabhu R. and Swarnalatha A. Automatic Building Extraction from VHR Satellite Image. *International Conference on Current Trends towards Converging Technologies (ICCTCT)*. 2018. P. 1-6, DOI: 10.1109/ICCTCT.2018.8551119.
6. Bifulco I., Cirillo S. Discovery multiple data structures in Big Data through global optimization and clustering Methods, *IEEE 22nd International Conference Information Visualization*, pp. 117–121, 2018.
7. Brand A.K., Manandhar, A.: Semantic segmentation of burned areas in satellite images using a U-Net-based convolutional neural network, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B3-2021, 47–53, <https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-47-2021>, 2021.
8. Carleer A.P. Assessment of very high spatial resolution satellite image segmentations / A.P.Carleer, O.Debeir, E. Wolff // *Photogrammetric Engineering & Remote Sensing*. – 2005. – Vol. 71. – No. 11. – P.1285-1294.

9. Carvana Image Masking Challenge | Kaggle. (2015). URL: Kaggle. <https://www.kaggle.com/c/carvana-image-masking-challenge/discussion/40199>
10. Chatufale, Aditya P., Priti, P. Rege, and Abhishek Bhatt. (2022). Extraction of waterbody using object-based image analysis and XGBoost. *Advanced Machine Intelligence and Signal Processing*. Singapore: Springer Nature Singapore, 341-350.
11. Chen Y., Fan R., Bilal M., Yang X., Wang J., Li W. (2018). Multilevel Cloud Detection for High-Resolution Remote Sensing Imagery Using Multiple Convolutional Neural Networks. *ISPRS Int. J. Geo-Inf.*, 7, 181.
12. Cheng G., Han J., Lu X. Remote sensing image scene classification: Benchmark and state of the art. *Proceedings of the IEEE*, 2017. Vol.105 (10). P. 1865-188.
13. Cheng H., Lian D., Gao S., Geng Y. Evaluating Capability of Deep Neural Networks for Image Classification via Information Plane. In *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018. P. 168–182.
14. Ciresan D., Giusti A., Gambardella L., Schmidhuber J. Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images. In *Advances in Neural Information Processing Systems (NIPS 2012)*, Lake Tahoe, 2012.
15. Ciresan D.C., Meier U., Masci J., Gambardella L. M., Schmidhuber J. Flexible, High Performance Convolutional Neural Networks for Image Classification. *International Joint Conference on Artificial Intelligence (IJCAI-2011, Barcelona)*, (2011).
16. Désirée, Ruppen, James, Runnalls, Raphael, M., Tshimanga, Bernhard, Wehrli, Daniel, Odermatt. (2023). Optical remote sensing of large-scale water pollution in Angola and DR Congo caused by the Catoca mine tailings spill. *International Journal of Applied Earth Observation and Geoinformation*, 118.
17. Dey V. A review on image segmentation techniques with remote sensing perspective / V.Dey, Y.Zhang, M.Zhong // *Proc. ISPRS TC VII Symposium, IAPRS. – 2010. – Vol. 38. – Part 7A. – P. 31-42.*

18. Duran J., Buades A. Restoration of pansharpened images by conditional filtering in the PCA domain // *IEEE Geosci. Remote Sens. Lett.* - 16 (3), 2019. – P. 442–446
19. EOS Data Analytics. [Электронный ресурс]. – Режим доступа: <https://eos.com/uk>
20. Fausto Milletari, Navab Nassir, Ahmadi Seyed-Ahmad. V-net: Fully convolutional neural networks for volumetric medical image segmentation. 2016 fourth international conference on 3D vision (3DV). IEEE, 2016.
21. Feng, W., Sui, H., Huang, W., Xu, C. and An, K. (2019). Water Body Extraction From Very High-Resolution Remote Sensing Imagery Using Deep U-Net and a Superpixel-Based Conditional Random Field Model. *IEEE Geoscience and Remote Sensing Letters*, 16(4), 618-622.
22. Fisher, A., Flood, N., Danaher, T. (2016). Comparing Landsat water index methods for automated water classification in eastern Australia. *Remote Sens. Environ*, 175, 167–182.
23. Gang Fu, et al. Classification for high resolution remote sensing imagery using a fully convolutional network. *Remote Sensing* 9.5 (2017): 498.
24. Garcia G.B. Learning Image Processing with OpenCV. / G.B.Garcia O. D.Suarez, J. L. E.Aranda. – Birmingham: Packt Publishing, 2015. – 319p.
25. Gaur A. Search techniques to contain combinatorial explosion in artificial intelligence,” *International Journal of Engineering Research & Technology*, vol. 1, issue 7, pp. 1–7, September 2012.
26. Ghahremani M., Ghassemian H. A Compressed-Sensing-Based Pan-Sharpener Method for Spectral Distortion Reduction // *IEEE Transactions on Geoscience and Remote Sensing.* - 54, 2016.- P. 2194 - 2206. 10.1109/TGRS.2015.2497309.
27. Hashem H., Ranc D. An integrative modeling of Big Data processing, *International Journal of Computer Science and Applications*, ©Technomathematics Research Foundation, vol. 12, pp. 1–15, January 2015.

28. Hnatushenko V., Kogut P., Uvarov M. On Satellite Image Segmentation via Piecewise Constant Approximation of Selective Smoothed Target Mapping, *Applied Mathematics and Computation*, Vol.389, 2020, Id 125615, 26p, doi.org/10.1016/j.amc.2020.125615.
29. Hnatushenko V., Zhernovyi V. (2020) Method of Improving Instance Segmentation for Very High Resolution Remote Sensing Imagery Using Deep Learning. In: Babichev S., Peleshko D., Vynokurova O. (eds) *Data Stream Mining & Processing. DSMP 2020. Communications in Computer and Information Science*, vol 1158. Springer, Cham. https://doi.org/10.1007/978-3-030-61656-4_21
30. Hnatushenko V., Zhernovyi V., Udovik I., Shevtsova O. Intelligent System for Building Separation on a Semantically Segmented Map. *International Workshop on Intelligent Information Technologies & Systems of Information Security (IntellITSIS-2021)*, Khmelnytskyi, Ukraine. <http://ceur-ws.org/Vol-2853/keynote1.pdf>.
31. Hnatushenko Volodymyr, Zhernovyi Vadym. Complex Approach of High-Resolution Multispectral Data Engineering for Deep Neural Network Processing. In: Lytvynenko V., Babichev S., Wójcik W., Vynokurova O., Vyshemyrskaya S., Radetskaya S. (eds) *Lecture Notes in Computational Intelligence and Decision Making. ISDMCI 2019. Advances in Intelligent Systems and Computing*, (2020) vol 1020. Springer, Cham. https://doi.org/10.1007/978-3-030-26474-1_46.
32. Hordiiuk D. M., Hnatushenko V. V. (2017). Neural network and local laplace filter methods applied to very high resolution remote sensing imagery in urban damage detection. 2017 IEEE International Young Scientists Forum on Applied Physics and Engineering (YSF).[doi:10.1109/ysf.2017.8126648](https://doi.org/10.1109/ysf.2017.8126648).
33. Hordiiuk D., Oliinyk I., Hnatushenko V., Maksymov K. Semantic Segmentation for Ships Detection from Satellite Imagery. 2019 IEEE 39th International Conference on Electronics and Nanotechnology (ELNANO). [doi:10.1109/elnano.2019.8783822](https://doi.org/10.1109/elnano.2019.8783822).

34. Huang J., Zhang X., Xin Q., Sun Y., Zhang P. Automatic building extraction from high-resolution aerial images and LiDAR data using gated residual refinement network. *ISPRS J. Photogramm. Remote Sens.* 2019. P. 91–105.
35. Huang W., Xiao L., Liu H., Wei Z., Tang S. A New Pan-Sharpener Method With Deep Neural Networks // *IEEE Geosci. Remote Sens. Lett.* – 12, 2015. – P. 1037–1041.
36. Imani M. Texture feed based convolutional neural network for pansharpening // *Neurocomputing.* - 398, 2020. – P. 117–130.
37. Ishizuka Y., Chen W., Paik I. Workflow transformation for real-time Big Data processing, *IEEE International Congress on Big Data*, pp.31–318, 2016.
38. Jiang, W., He, G., Long, T., Ni, Y., Liu, H., Peng, Y., Lv, K., Wang G. (2018). Multilayer Perceptron Neural Network for Surface Water Extraction in Landsat 8 OLI Satellite Images. *Remote Sens*, 10, 755.
39. Jiao L., Huo L., Hu C. and Tang P. Refined UNet: UNet-Based Refinement Network for Cloud and Shadow Precise Segmentation. *Remote Sens.* 2020, 12, 2001. <https://doi.org/10.3390/rs12122001>.
40. Kaili Cao, Zhang Xiaoli. An improved res-unet model for tree species classification using airborne high-resolution images. *Remote Sensing* 2020; 12(7): 1128. <https://doi.org/10.3390/rs12071128>.
41. Kalantar B., Halin A.A., Al-Najjar H.A.H., Mansor S., van Genderen J.L., Shafri H.Z.M., Zand, M. A Framework for Multiple Moving Objects Detection in Aerial Videos. In *Spatial Modeling in GIS and R for Earth and Environmental Sciences*. Elsevier: Amsterdam, The Netherlands. 2019. P. 573–588.
42. Kalantar B., Mansor S.B., Halin A.A., Shafri H.Z.M., Zand, M. Multiple moving object detection from UAV videos using trajectories of matched regional adjacency graphs. *IEEE Trans. Geosci. Remote Sens.* 2017. Vol. 55. P.5198–5213.
43. Kalantar B., Mansor S.B., Sameen M.I., Pradhan B., Shafri H.Z.M. Drone-based land-cover mapping using a fuzzy unordered rule induction algorithm

- integrated into object-based image analysis. *Int. J. Remote Sens.* 2017. Vol.38. P. 2535–2556.
44. Kamagata N. A new method of vegetation mapping by object-based classification using high resolution satellite data / N.Kamagata, K.Hara, M.Mori, Y.Akamatsu, Y.Li, Y.Hoshino. // *Proc. 1st Intern. Conf. Object-Based Image Analysis.* – 2006. – V. 36-4. – C.42.
 45. Kashtan V.J., Hnatushenko V. V. and Shedlovska Y. I. Processing technology of multispectral remote sensing images," 2017 IEEE International Young Scientists Forum on Applied Physics and Engineering (YSF), Lviv, 2017, pp. 355-358, doi: 10.1109/YSF.2017.8126647.
 46. Kashtan V.Yu., Hnatushenko V.V. A Wavelet and HSV Pansharpening Technology of High Resolution Satellite Images // *Intelligent Information Technologies & Systems of Information Security IntellITSIS 2020.* - Khmelnytskyi, Ukraine, June 10-12, 2020. – P. 67-766.
 47. Kashtan V.Yu., Hnatushenko V.V. Automated pansharpening information technology of satellite images // *The scientific journal «Radio Electronics, Computer Science, Control».* - №2 (57). - Zaporizhzhia, 2021. – P.123-133.
 48. Kim E.K., Lee H., Kim J.Y., Kim S. Data Augmentation Method by Applying Color Perturbation of Inverse PSNR and Geometric Transformations for Object Recognition Based on Deep Learning. *Appl. Sci.* 2020. Vol. 10. P. 3755. DOI: 10.3390/app10113755
 49. Knapheide J., Stabernack B., Kuhnke M. A High Throughput MobileNetV2 FPGA Implementation Based on a Flexible Architecture for Depthwise Separable Convolution. 30th International Conference on Field-Programmable Logic and Applications (FPL), 2020, pp. 277-283, doi: 10.1109/FPL50879.2020.00053.
 50. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks. *NIPS 2012: Neural Information Processing Systems*, Lake Tahoe, Nevada, (2012).

51. Krówczyńska M., Raczko E., Staniszevska N., Wilk, E. Asbestos—cement roofing identification using remote sensing and convolutional neural networks (CNNs). *Remote Sens.* 2020. Vol. 12, P.2-16.
52. Li H., Jing L., Tang Y. Assessment of Pansharpening Methods Applied to WorldView-2 Imagery Fusion // *Sensors.* - 17(1):89. – 2017. DOI:10.3390/s17010089.
53. Li, W, Qin, Y, Sun, Y, Huang H, Ling F, Tian L, Ding Y. (2016). Estimating the relationship between dam water level and surface water area for the Danjiangkou Reservoir using Landsat remote sensing images. *Remote Sens Lett*, 7(2), 121–130.
54. Liu L., Ouyang W., Wang X., Fieguth W.P., Chen J., Liu X., Pietikinen M. Deep learning for generic object detection. A survey. *I International Journal of Computer Vision.* 2020. Vol. 128. P. 261–31.
55. Liu, Qihang, et al. (2020). Probabilistic river water mapping from Landsat-8 using the support vector machine method. *Remote Sensing*, 12(9), 1374.
56. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. In *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA. 2015. P. 3431–3440.
57. Luo Xin, Tong Xiaohua, Hu Zhongwen. Improving Satellite Image Fusion via Generative Adversarial Training // *IEEE Transactions on Geoscience and Remote Sensing.* 2020. – P. 1-14. DOI:10.1109/TGRS.2020.3025821.
58. Ma Lei, et al. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing* 152 (2019): 166-177.
59. Maggiori Emmanuel, et al. Fully convolutional neural networks for remote sensing image classification. *2016 IEEE international geoscience and remote sensing symposium (IGARSS).* IEEE, 2016.

60. Mao, Taomin, Yewen, Fan, Shuang Zhi, and Jinshan, Tang. (2022). A Morphological Feature-Oriented Algorithm for Extracting Impervious Surface Areas Obscured by Vegetation in Collaboration with OSM Road Networks in Urban Areas. *Remote Sensing*, 10(14), 2493.
61. Marushko E.E, Doudkin A.A, Zheng X. Identification of Earth's surface objects using ensembles of convolutional neural networks. *Journal of the Belarusian State University. Mathematics and Informatics*. 2021;2:114–123.
62. Mateo-Sanchis, Anna Piles, Maria Muñoz, Jordi Adsuara, Jose Pérez-Suay, Adrián Camps-Valls, Gustau. Synergistic Integration of Optical and Microwave Satellite Data for Crop Yield Estimation // *Remote Sensing of Environment*. - Volume 234, 2019
63. Mäyrä J., Keski-Saari S., Kivinen S., Tanhuanpää T., Hurskainen P., Kullberg P., Poikolainen L., Viinikka A., Tuominen S., Kumpula T., et al. Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. *Remote Sens. Environ*. 2021. Vol.256. P. 112-322.
64. Michel J. Stable mean-shift algorithm and its application to the segmentation of arbitrarily large remote sensing images / J. Michel, D. Youssefi, M. Grizonnet // *IEEE Transactions, Geoscience and Remote Sensing*. – 2015. – Vol. 53. – No. 2. – P. 952-964.
65. Micikevicius P., Narang S., Alben J., Damos G., Elsen E., Garcia D., ... & Wu H. Mixed precision training. *arXiv preprint arXiv:1710.03740*, (2017).
66. Mozgovoy D., Hnatushenko V., Vasyliiev V. Accuracy evaluation of automated object recognition using multispectral aerial images and neural network, *Proc. SPIE 10806, Tenth International Conference on Digital Image Processing (ICDIP 2018)*, 108060H (9 August 2018); <https://doi.org/10.1117/12.2502905>.
67. Nanjun He, Fang Leyuan, Plaza Antonio. Hybrid first and second order attention Unet for building segmentation in remote sensing images. *Science China Information Sciences* 63.4 (2020): 1-12.

68. Nardini, A.G.C., Salas, F., Carrasco, Z., Valenzuela, N., Rojas, R., Vargas-Baecheler, J., Yépez S. (2023). Automatic River Planform Recognition Tested on Chilean Rivers. *Water*, 15, 2359.
69. Otsu Nobuyuki. A threshold selection method from gray-level histograms". *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62-66, Jan. 1979, doi: 10.1109/TSMC.1979.4310076.
70. Palomar-Vázquez, Jesús, Josep E., Pardo-Pascual, Jaime, Almonacid-Caballer, and Carlos, Cabezas-Rabadán. (2023). Shoreline Analysis and Extraction Tool (SAET): A New Tool for the Automatic Extraction of Satellite-Derived Shorelines with Subpixel Accuracy. *Remote Sensing*, (15), 3198.
71. Papandreou George, et al. Weakly-and semi-supervised learning of a deep convolutional network for semantic image segmentation. *Proceedings of the IEEE international conference on computer vision*. 2015.
72. Qian J. Comparison of pixel-based and object-oriented classification methods for extracting built-up areas in aridzone./ J.Qian, Q.M.Zhou, Q.Hou. // *ISPRS Workshop on Updating Geo-spatial Databases with Imagery and The 5th ISPRS Workshop on DMGISs*, 2007. – P.163-171.
73. Qiangqiang Yuan, Shen H., Li T., Li Zhi-wei, Li Shuwen, Jiang Yun, Hongzhang Xu, Tan W., Yang Q., Wang Jiwen, Gao Jianhao, Zhang Liangpei. Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment* 241 (2020): 111716.
74. Rahimzadeganasl A, Alganci U, Goksel C. An Approach for the Pan Sharpening of Very High Resolution Satellite Images Using a CIELab Color Based Component Substitution Algorithm // *Applied Sciences*. - 9(23):5234, 2019. DOI: 10.3390/app9235234
75. Rahman T., Chowdhury M.E., Khandakar A., Islam K.R., Islam K.F., Mahbub Z.B., Kadir M.A., Kashem S. Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection using Chest X-ray. *Appl. Sci*. 2020. Vol. 10. P. 32-33.

76. Ronneberger Olaf, Fischer Philipp, Brox Thomas. U-net: Convolutional networks for biomedical image segmentation. International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015.
77. Saifi M. Y., Singla J., & Nikita. Deep Learning based Framework for Semantic Segmentation of Satellite Images. 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC). doi:10.1109/iccmc48092.2020.iccmc-00069
78. Sandler M., Howard A., Zhu M., Zhmoginov A. and Chen L. MobileNetV2: Inverted Residuals and Linear Bottlenecks. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018, pp. 4510-4520, doi: 10.1109/CVPR.2018.00474.
79. Saralioglu E., Gungor O. Semantic segmentation of land cover from high resolution multispectral satellite images by spectral-spatial convolutional neural network. Geocarto International, 1–21, (2020). doi:10.1080/10106049.2020.1734871
80. Sarmah S. A grid-density based technique for finding clusters in satellite image / S.Sarmah, D.K.Bhattacharyya // Pattern Recognition Letters. – 2012. – Vol. 33. – No. 5. – P.589-604.
81. Satimagingcorp. WorldView-3 Satellite Sensor | Satellite Imaging Corp. (2016). URL: <https://www.satimagingcorp.com/satellite-sensors/worldview-3/>
82. Schiewe J. Segmentation of high-resolution remotely sensed data-concepts, applications and problems. / J.Schiewe // International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences. – 2002. – Vol. 34. – No. 4. – P. 380-385.
83. Schowengerdt R. Remote sensing: models and methods for image processing, New York: Academic Press. 2007. p.560.

84. Shakhovska N., Veres O., Hirnyak M. Generalized formal model of Big Data, *Econtechmod. An International Quarterly Journal*, vol. 5, pp. 33–38, February 2016.
85. Shedlovska Y. I., Hnatushenko V. V. Shadow detection and removal using a shadow formation model," 2016 IEEE First International Conference on Data Stream Mining & Processing (DSMP), Lviv, Ukraine, 2016, pp. 187-190, doi: 10.1109/DSMP.2016.7583537.
86. Shuting Sun, et al. L-UNet: An LSTM Network for Remote Sensing Image Change Detection" *IEEE Geoscience and Remote Sensing Letters* (2020). doi: 10.1109/LGRS.2020.3041530.
87. Simonyan K., Zisserman A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *CoRR*, abs/1409.1556.
88. Spatial Resolution. [Електронний ресурс]. – Режим доступу: <http://ibis.geog.ubc.ca/courses/geob373/lectures/lecture09.html>
89. Stöttner T. (2019, May 16). Why Data should be Normalized before Training a Neural Network. *Medium*. URL: <https://towardsdatascience.com/why-data-should-be-normalized-before-training-a-neural-network-c626b7f66c7d>.
90. Suvarnamukhi B., Seshashayee M. Big Data concepts and techniques in data processing, *International Journal of Computer Sciences and Engineering*, vol. 6, Issue-10, pp. 712–714, Oct 2018.
91. Syrotkina O., Alekseyev M., Asotskyi V. and Udovyk I. Analysis of how the properties of structured data can influence the way these data are processed, *Naukovyi Visnyk NHU, Dnipro*, vol. 3 (171), 2019, pp. 119–129.
92. Syrotkina O., Alekseyev M., Meshcheriakov L. and B. Moroz, Methods of working with “big data” based on the application of “mtuple” theory. *Computer-Integrated Technologies: Education, Science, Production, Lutsk*, vol. 36, 2019, pp. 140–152.
93. Syrotkina O., Aleksieiev M., Moroz B., Matsiuk S., Shevtsova O. and Kozlovskiy A. Mathematical Methods for Optimizing Big Data Processing. 10th International Conference on Advanced Computer Information

- Technologies (ACIT), 2020, pp. 170-176, doi: 10.1109/ACIT49673.2020.9208940.
94. Tadist K., Najah S., Nikolov N., Mrabti F., Zahi A. Feature selection methods and genomic Big Data: a systematic review, *Journal of Big Data*, pp. 1–24, August 2019.
 95. Tasdemir K., Merenyi E. Exploiting data topology in visualization and clustering of self-organizing maps, *IEEE Transactions on Neural Networks*, vol. 20, pp. 549–562, April 2009.
 96. The european space agency. [Электронный ресурс]. – Режим доступа: <https://www.esa.int/>
 97. Vapnik V. Cham. (2013). *The Nature of Statistical Learning Theory*. Springer Science & Business Media.
 98. Vijay Badrinarayanan, Kendall Alex, Cipolla Roberto. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence* 39.12 (2017): 2481-2495.
 99. Waleed A., Turkey A., Basil D. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net. *Computational Intelligence and Neuroscience*, 2018. P.1687-5265. DOI: 10.1155/2022/4831223.
 100. Wang A. Segmentation of multispectral high-resolution satellite imagery based on integrated feature distributions / A. Wang, S. Wang, A. Lucieer // *International Journal of Remote Sensing*. – 2010. – Vol. 31. – No. 6. – P. 1471-1483.
 101. Wang J. Z. Unsupervised multiresolution segmentation for images with low depth of field. / J.Z.Wang, L.Jia, R.M.Gray, G.Wiederhold. // *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*. – 2001. – 23(1). – P.85-90.
 102. Wangchuk, Sonam, and Tobias, Bolch. (2020). Mapping of glacial lakes using Sentinel-1 and Sentinel-2 data and a random forest classifier: Strengths and challenges. *Science of Remote Sensing*, 2, 100008.

103. Weaver James, Centrosymmetric (Cross-Symmetric) Matrices, Their Basic Properties, Eigenvalues, and Eigenvectors". The American Mathematical Monthly, Vol. 92, No. 10, 1985, pp. 711-717.
104. Wei Y., Yuan Q., Shen H., Zhang L. Boosting the Accuracy of Multispectral Image Pansharpening by Learning a Deep Residual Network // IEEE Geosci. Remote Sens. Lett. - 14, 2017. – P. 1795–1799.
105. Weiwei Sun, Wang Ruisheng. Fully convolutional networks for semantic segmentation of very high resolution remotely sensed images combined with DSM. IEEE Geoscience and Remote Sensing Letters 15.3 (2018): 474-478.
106. Xiang, X., Li, Q., Khan, S., & Khalaf, O. I. (2021). Urban Water Resource Management for Sustainable Environment Planning Using Artificial Intelligence Techniques. Environmental Impact Assessment Review, (86), 106515.
107. Xiaoxia S. A comparison of object-oriented and pixel-based classification approaches using Quickbird imagery. / S.Xiaoxia, Z.Jixian, L.Zhengjun. // Intern. Symp. Spatio-Temporal Modelling, Spatial Reasoning, Analysis, Data Mining and Data Fusion, Beijing, China, 2005.
108. Xie, H, Luo, X, Xu, X, Pan, H, Tong, X. (2016). Automated Subpixel Surface Water Mapping from Heterogeneous Urban Environments Using Landsat 8 OLI Imagery. Remote Sensing, 87, 584.
109. Xie, H.; Luo, X.; Xu, X.; Pan, H.; Tong, X. Evaluation of Landsat 8 OLI imagery for unsupervised inland water extraction. Int. J. Remote Sens. 2016, 37, 1826–1844.
110. Xu Y., Wu L., Xie Z., Chen Z. Building extraction in very high resolution remote sensing imagery using deep learning and guided filters. Remote Sens. 2018. Vol. 10. P. 144.
111. Yadav S., Phulre A., Pradesh M. A literature review on Big Data reduction methods. International Journal of Electrical, Electronics and Computer Engineering, pp. 92–99, June 2017.

112. Yang J., Fu X., Hu Y., Huang Y., Ding X., Paisley J. PanNet: A Deep Network Architecture for Pan-Sharpener // In Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV). - Venice, Italy, 22–29 October 2017. – P. 1753–1761.
113. Yang J., Guo J., Yue H., Liu Z., Hu H., Li K. CDnet: CNN-Based Cloud Detection for Remote Sensing Imagery. *IEEE Trans. Geosci. Remote Sens.* 2019. Vol. 57. P. 6195–6211.
114. Yang, F.; Yang, H.; Fu, J.; Lu, H.; Guo, B. Learning texture transformer network for image super-resolution // In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. . - 2020. – P. 5790–5799.
115. Yang, X., Zhao, S., Qin, X., Zhao, N., Liang, L. (2017). Mapping of Urban Surface Water Bodies from Sentinel-2 MSI Imagery at 10 m Resolution via NDWI-Based Image Sharpening. *Remote Sens*, 9, 596.
116. Yılmaz I., Imamođglu M., Özbulak G., Kahraman F., Aptoula E. Large Scale Crop Classification from Multi-temporal and Multi-spectral Satellite Images. In Proceedings of the 2020 28th Signal Processing and Communications Applications Conference (SIU). 2020. P. 1–4.
117. Yuan J. Learning building extraction in aerial scenes with convolutional networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2017. P. 2793–2798.
118. Yuan, Qiangqiang, et al. Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment* 241 (2020): 111716.
119. Zhang Liangpei, Lefei Zhang, and Bo Du. Deep learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine* 4.2 (2016): 22-40.
120. Zhang Mengmeng, Wei Li, and Qian Du. Diverse region-based CNN for hyperspectral image classification." *IEEE Transactions on Image Processing* 27.6 (2018): 2623-2634.
121. Zhernovyi V., Hnatushenko V., Shevtsova O. (2023). IaaS-Application Development for Paralleled Remote Sensing Data Stream Processing. In:

- Babichev, S., Lytvynenko, V. (eds) *Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. Lecture Notes on Data Engineering and Communications Technologies*, vol 149. Springer, Cham. https://doi.org/10.1007/978-3-031-16203-9_39.
122. Zhou, Y., Dong, J., Xiao, X., Xiao, T., Yang, Z., Zhao, G., Zou, Z., Qin, Y. (2017). Open Surface Water Mapping Algorithms: A Comparison of Water-Related Spectral Indices and Sensors. *Water*, 7.
123. Zhu, Xiao Xiang, et al. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, no. 4, pp. 8-36, Dec. 2017, doi: 10.1109/MGRS.2017.2762307.
124. Бурштинська Х.В. Аерокосмічні знімальні системи: навч. посібник./ Х.В. Бурштинська, С.А.Станкевич. – Львів: Видавництво Львівської політехніки, 2010. – 292с.
125. Гнатушенко В.В., Гненний І.О., Удовик І.М., Шевцова О.С. Сегментація аерокосмічних зображень з використанням згорткових нейронних мереж. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 6 (137). - Дніпро, 2021. - С.23 - 30. doi: 10.34185/1562-9945-6-137-2021-03
126. Гнатушенко В.В., Грищак Д.Д., Шевцова О.С. Розпізнавання зелених насаджень із застосуванням геоінформаційних технологій. Проблеми використання інформаційних технологій в освіті, науці та промисловості: XVII міжн. конф.: зб. наук. пр. [Електроний ресурс] / НТУ «Дніпровська політехніка». – Дніпро: 2022.
127. Гнатушенко В.В., Луцик Д.М., Шевцова О.С. Нейромережеве розпізнавання об'єктів військової техніки на супутникових зображеннях Проблеми використання інформаційних технологій в освіті, науці та промисловості: XVI міжн. конф. (15-17 грудня 2021 р.). НТУ «Дніпровська політехніка». – Дніпро: 2021. №6. С. 57–60.

128. Гнатушенко В.В. Геометричні моделі формування та попередньої обробки цифрових фотограмметричних зображень високого просторового розрізнення : Дис... д-ра наук: 05.01.01 - КНУБА, Київ, 2009.
129. Дорожинський О.Л. Фотограмметрія: підручник. / О.Л.Дорожинський, Р.Тукай. – Львів: Вид-во НУ "Львівська політехніка", 2008. – 332с.
130. Каштан В., Гнатушенко В., Удовик І., Шевцова О. (2023). Нейромережеве розпізнавання об'єктів забудови на аерофотознімках. Information Technology: Computer Science, Software Engineering and Cyber Security, 1, 30–39. doi: <https://doi.org/10.32782/IT/2023-1-5>.
131. Каштан В., Гнатушенко В., Удовик І., Шевцова О. (2023). Розпізнавання та моніторинг водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання. Information Technology: Computer Science, Software Engineering and Cyber Security, 3, 32–42. doi: [10.32782/IT/2023-3-4](https://doi.org/10.32782/IT/2023-3-4)
132. Каштан В., Шевцова О. (2024). Інформаційна технологія попередньої обробки супутникових знімків з використанням згорткової нейронної мережі. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 1 (150). - Дніпро, 2024. С.36 - 50. doi: [10.34185/1562-9945-1-150-2024-04](https://doi.org/10.34185/1562-9945-1-150-2024-04)
133. Каштан В.Ю., Гнатушенко В.В. Дослідження ефективності методів злиття супутникових знімків високого просторового розрізнення // Прикладні питання математичного моделювання. - Том 3.- Херсон, 2020. – С.117-127.
134. Каштан В.Ю., Гнатушенко В.В. Контурна сегментація цифрових супутникових знімків з використанням особливих точок вейвлет-перетворення. Системні технології. Регіональний міжвузівський збірник наукових робіт. 2019. Випуск 1 (120). С.3 - 11.

135. Куссуль Н.М., Федоров О.П., Шелестов А.Ю.. Моніторинг досягнення цілей сталого розвитку України за супутниковими даними, К.: «Наукова думка» – 2023. – 164 с. DOI: doi:10.15407/978-966-00-1865-5
136. Лялько В.І. Багатоспектральні методи дистанційного зондування Землі. / В.І.Лялько, М.О.Попов, О.Д.Федоровський. – К.: Наукова думка, 2006. –357 с.

ДОДАТОК А
СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ АВТОРА ЗА ТЕМОЮ
ДИСЕРТАЦІЇ

*Публікації у виданнях, включених до переліку наукових фахових видань
України:*

1. Гнатушенко В.В., Гненний І.О., Удовик І.М., **Шевцова О.С.** Сегментація аерокосмічних зображень з використанням згорткових нейронних мереж. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 6 (137). - Дніпро, 2021. - С.24 - 33. doi: [10.34185/1562-9945-6-137-2021-03](https://doi.org/10.34185/1562-9945-6-137-2021-03)
(Фахове видання категорії Б, індексується в Index Copernicus. Особистий внесок: розробка алгоритму сегментації аерокосмічних зображень високого просторового розрізнення з використанням згорткових нейронних мереж)
2. Каштан В., Гнатушенко В., Удовик І., **Шевцова О.** (2023). Нейромережеве розпізнавання об'єктів забудови на аерофотознімках. Information Technology: Computer Science, Software Engineering and Cyber Security, 1, 30–39. doi: <https://doi.org/10.32782/IT/2023-1-5>.
(Фахове видання категорії Б, індексується в Index Copernicus. Особистий внесок: метод автоматизованого розпізнавання об'єктів забудови на цифрових аерофотознімках на основі згорткової нейронної мережі)
3. Каштан В., Гнатушенко В., Удовик І., **Шевцова О.** (2023). Розпізнавання та моніторинг водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання. Information Technology: Computer Science, Software Engineering and Cyber Security, 3, 32–42. doi: [10.32782/IT/2023-3-4](https://doi.org/10.32782/IT/2023-3-4)
(Фахове видання категорії Б, індексується в Index Copernicus. Особистий внесок: запропоновано інформаційну технологію розпізнавання та

моніторингу водних об'єктів на оптичних супутникових зображеннях з використанням машинного навчання)

4. Каштан В., Шевцова О. (2024). Інформаційна технологія попередньої обробки супутникових знімків з використанням згорткової нейронної мережі. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 1 (150). - Дніпро, 2024. С.36 - 50. doi: [10.34185/1562-9945-1-150-2024-04](https://doi.org/10.34185/1562-9945-1-150-2024-04) [Index Copernicus, Google Scholar]
(Фахове видання категорії Б, індексується в Index Copernicus. Особистий внесок: запропоновано інформаційну технологію попередньої обробки багатоканальних супутникових зображень з використанням згорткової нейронної мережі, що дозволило підвищити інформативність первинних даних)
5. Гончаров О.Г., Гнатушенко В.В., **Шевцова О.** (2024). Нейромережевий підхід сегментації сільськогосподарських угідь на супутникових зображеннях. Системні технології. Регіональний міжвузівський збірник наукових праць. – Випуск 4 (153). - Дніпро, 2024. С.87 - 101. doi: [10.34185/1562-9945-4-153-2024-09](https://doi.org/10.34185/1562-9945-4-153-2024-09) [Index Copernicus, Google Scholar]
(Фахове видання категорії Б, індексується в Index Copernicus. Особистий внесок: проведено порівняння трьох різних модифікацій архітектури U-Net для задачі семантичної сегментації агроугідь на основі супутникових зображень)

Публікації у наукових виданнях, включених до наукометричної бази

Scopus:

6. Zhernovyi V., Hnatushenko V., **Shevtsova O.** (2023). IaaS-Application Development for Paralleled Remote Sensing Data Stream Processing. In: Babichev, S., Lytvynenko, V. (eds) Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. Lecture Notes on Data Engineering and Communications Technologies, vol 149. Springer, Cham. https://doi.org/10.1007/978-3-031-16203-9_39.

(Індексується в Scopus. Особистий внесок: запропоновано рішення у вигляді інфраструктури як сервісу IaaS для алгоритму обробки потоків даних дистанційного зондування Землі з використанням рішень глибокого навчання і хмарних технологій)

7. Syrotkina O., Aleksieiev M., Moroz B., Matsiuk S., **Shevtsova O.** and Kozlovskiy A. Mathematical Methods for Optimizing Big Data Processing. 10th International Conference on Advanced Computer Information Technologies (ACIT), 2020, pp. 170-176, doi: [10.1109/ACIT49673.2020.9208940](https://doi.org/10.1109/ACIT49673.2020.9208940).

(Індексується в Scopus. Особистий внесок: розробка та застосування методу оптимізації основних характеристик великих даних, що передбачає зменшення обсягу обробленої інформації, а також збільшення швидкості пошуку й обробки даних та надійності)

8. Hnatushenko V., Zhernovyi V., Udovik I., **Shevtsova O.** Intelligent System for Building Separation on a Semantically Segmented Map. International Workshop on Intelligent Information Technologies & Systems of Information Security (IntelITSIS-2021), Khmelnytskyi, Ukraine. <http://ceur-ws.org/Vol-2853/keynote1.pdf>.

(Індексується в Scopus. Особистий внесок: розробка нейронної мережі семантичної сегментації багатоканальних аерокосмічних знімків високого просторового розрізнення)

Публікації у матеріалах наукових конференцій:

9. Гнатушенко В.В., Луцик Д.М, **Шевцова О.С.** Нейромережеве розпізнавання об'єктів військової техніки на супутникових зображеннях Проблеми використання інформаційних технологій в освіті, науці та промисловості: XVI міжн. конф. (15-17 грудня 2021 р.). НТУ «Дніпровська політехніка». – Дніпро: 2021. №6. С. 57–60. <https://ir.nmu.org.ua/handle/123456789/165809>

10.Гнатушенко В.В., Гришак Д.Д., **Шевцова О.С.** Розпізнавання зелених насаджень із застосуванням геоінформаційних технологій. Проблеми використання інформаційних технологій в освіті, науці та промисловості: XVII міжнар. конф. (24 листопада 2022 р., м. Дніпро): зб. наук. пр. [Електронний ресурс] / ред. кол.: О.О. Азюковський та ін.; М-во освіти і науки України, Нац. техн. ун-т «Дніпровська політехніка». – Електрон. текст. дані – Дніпро: НТУ «ДП», 2023. – № 7.С. 24–26.

https://ir.nmu.org.ua/jspui/bitstream/123456789/163499/4/konfer_2022.pdf

ДОДАТОК Б
ДОКУМЕНТИ ЩОДО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ
ДОСЛІДЖЕНЬ



Іноземне Підприємство «ЕМЕРДЖН»

49044, м. Дніпро, вул. Січових Стрільців, 3А, оф. 401,
тел/факс. 790-07-23. Код ЄДРПОУ 33718384.

ДОВІДКА

про використання результатів дисертаційної роботи

Шевцової Ольги Сергіївни

«Інформаційна технологія попередньої обробки та класифікації різночасових супутникових зображень високої просторової розрізненості»,

поданої на здобуття наукового ступеня доктора філософії

за спеціальністю 122 – Комп'ютерні науки

Результати дисертаційної роботи Шевцової О.С., поданої на здобуття наукового ступеня доктора філософії за спеціальністю 122 – Комп'ютерні науки використані в Іноземне Підприємство «ЕМЕРДЖН» при обробці неструктурованих великих даних.

Запропонований авторкою метод оптимізації основних характеристик великих даних, якими, зокрема, є набори багатоканальних аерокосмічних зображень, забезпечує зменшення обсягу інформації, що обробляється, а також збільшення швидкості пошуку та обробки цифрових даних, зберігаючи їх відповідні значення та надійність. Вищезазначене досягнуто шляхом застосування запропонованої «кортежної» структури організації даних. Це дозволяє мінімізувати обчислювальні ресурси.



М. П.

Директор

/ Дмитро Письменний /



Державне космічне агентство України
**«ДНІПРОКОСМОС» ФІЛІЯ НАЦІОНАЛЬНОГО ЦЕНТРУ
УПРАВЛІННЯ ТА ВИПРОБУВАНЬ КОСМІЧНИХ ЗАСОБІВ**

а/с 798, м. Дніпро, 49008, тел./факс: +380562340370, E-mail: dk@dtdk.dp.ua
код ЄДРПОУ 38294544

А К Т

про впровадження наукових результатів дисертаційної роботи
Шевцової Ольги Сергіївни на тему «Інформаційна технологія попередньої
обробки та класифікації різночасових супутникових зображень високої
просторової розрізненості»,
поданої на здобуття наукового ступеня доктора філософії
за спеціальністю 122 – Комп'ютерні науки

Результати досліджень, виконаних у дисертації О.С. Шевцової, використані у практиці робіт «Дніпрокосмос» філії Національного центру управління та випробувань космічних засобів при розробці методів і технологій автоматизованого оброблення та класифікації зображень дистанційного зондування Землі для вирішення тематичних задач.

Запропонований в дисертації новий метод класифікації супутникових зображень високої просторової розрізненості на основі нейромережевого підходу дозволяє отримати класифіковане зображення земної поверхні та виділити на ній різні типи об'єктів. Ольгою Шевцовою запропоновано метод семантичної сегментації зображень високої просторової розрізненості, що дозволило значно підвищити достовірність подальшого розпізнавання об'єктів. Крім того, розвинутий авторкою метод паншарпенінгу аерокосмічних знімків дозволив на етапи попередньої обробки покращити просторову розрізненість багатоканальних зображень та підвищити точність подальшого розпізнавання та класифікації об'єктів земної поверхні.

Начальник філії



Віталій КАВАЦ

ЗАТВЕРДЖУЮ



Проректор з навчальної роботи
Юрій ХОМЕНКО

«20» серпня 2023 р.

**впровадження результатів дисертаційного дослідження
Шевцової Ольги Сергіївни на тему «Інформаційна технологія попередньої
обробки та класифікації різночасових супутникових зображень високої
просторової розрізненості» в навчальний процес**

Наукові та науково-практичні результати дисертаційного дослідження на тему «Інформаційна технологія попередньої обробки та класифікації різночасових супутникових зображень високої просторової розрізненості», що виконувалися протягом 2020-2023 рр., впроваджено в 2023/2024 навчальному році у навчальному процесі на факультеті інформаційних технологій на кафедрі програмного забезпечення комп'ютерних систем при розробці дисциплін: «Обробка зображень та комп'ютерний зір» (проф. Гнатушенко В.В.) для бакалаврів спеціальності 122 Комп'ютерні науки; «Машинне навчання» (доц. Приходченко С.Д.) для магістрів спеціальності 121 Інженерія програмного забезпечення; «Сучасні методи і системи підтримки прийняття рішень» (проф. Мороз Б.І.); «Моделі та методи штучного інтелекту в комп'ютерних науках» (проф. Мещеряков Л.І.) для докторів філософії спеціальності 122 Комп'ютерні науки.

Декан факультету
інформаційних технологій
Чорна Ірина УДОВИК
«20» серпня 2023 р.

Завідувач кафедри
програмного забезпечення
комп'ютерних систем
Александр Михайло АЛЕКСЄЄВ
«20» 12 2023 р.

Науковий керівник
Гнатушенко Володимир ГНАТУШЕНКО
«20» серпня 2023 р.