

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук
(повна назва)

Кафедра _____ програмної інженерії
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Дослідження методів класифікації аномалій на супутникових знімках за
допомогою комп'ютерного зору
(тема)

Виконав:
здобувач 2 року навчання
групи ІПЗМ-23-3

Олександр ВАСИЛЕЦЬ
(власне ім'я, прізвище)

Спеціальність 121 – Інженерія програмного
забезпечення
(код і повна назва спеціальності)

Тип програми освітньо-наукова

Освітня програма Інженерія програмного забезпечення
(повна назва освітньої програми)

Керівник проф. Анатолій РУТКАС
(посада, прізвище, ініціали)

Допускається до захисту
Зав. кафедри

(підпис)

Кирило СМЕЛЯКОВ
(власне ім'я, прізвище)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
 Кафедра _____ програмної інженерії _____
 Рівень вищої освіти _____ другий (магістерський) _____
 Спеціальність _____ 121 – Інженерія програмного забезпечення _____
 Тип програми _____ освітньо-наукова програма _____
 Освітня програма _____ Інженерія програмного забезпечення _____

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

«___» _____ 20__ р.

ЗАВДАННЯ НА КВАЛІФАКАЦІЙНУ РОБОТУ

здобувачеві _____ Васильцю Олександрю Олексійовичу _____

1. Тема роботи «Дослідження методів класифікації аномалій на супутникових знімках за допомогою комп'ютерного зору»

затверджена наказом університету від 15 квітня 2025 р. № 290Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії 12 червня 2025р.

3. Вихідні дані до роботи дослідження процесів обробки та класифікації супутникових знімків для виявлення аномальних об'єктів або подій; розробка та експериментальна перевірка ефективних методів класифікації аномалій на супутникових знімках із застосуванням технологій комп'ютерного зору, що поєднують методи машинного (Support Vector Machine) та глибокого навчання (CNN, GAN, LSTM, RNN, трансформери); поетапна обробка зображень (нормалізація, масштабування, фільтрація шумів), екстракція NDVI та додаткових текстурних і спектральних ознак, побудова навчальних вибірок; статистичний аналіз результатів та оцінка якості класифікації (precision, recall, F1-score), візуалізація та валідація на реальних супутникових даних; програмна реалізація пайплайну в середовищі Python із використанням бібліотек NumPy, OpenCV, scikit-learn, matplotlib, seaborn та TensorFlow; інтерактивний формат обробки та візуалізації даних; у результаті – створено

адаптивну, масштабовану систему для стабільного виявлення NDVI-аномалій у різні фази повені, підтверджено практичну значущість для екологічного моніторингу, аграрної аналітики та кризового реагування й доведено придатність до інтеграції у сучасні геоінформаційні системи.

4. Перелік питань, що потрібно опрацювати у роботі вступ, огляд літератури та аналіз проблеми, методи та технології для класифікації аномалій на супутникових знімках, опис та обґрунтування обраних методів класифікації аномалій, порівняльна оцінка методів класифікації аномалій, розробка та експериментальна реалізація методів класифікації аномалій, підготовка супутникових даних для експериментів, розробка алгоритму для класифікації аномалій на знімках, експериментальний аналіз результатів класифікації аномалій, аналіз результатів і можливості впровадження, оцінка точності та надійності методу класифікації аномалій, практична значущість отриманих результатів, перспективи використання результатів у науковій і практичній діяльності, висновки.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Огляд літератури, аналіз проблеми та постановка задачі дослідження	15.04.2025	<i>виконано</i>
2	Дослідження існуючих методів класифікації аномалій: опис, обґрунтування й порівняльна оцінка	20.04.2025	<i>виконано</i>
3	Експериментальна реалізація: підготовка даних, розробка алгоритму та аналіз результатів	26.04.2025	<i>виконано</i>
4	Оцінка точності, надійності та практичної значущості методу	27.04.2025	<i>виконано</i>
5	Підготовка пояснювальної записки	01.05.2025	<i>виконано</i>
6	Перевірка на плагіат та нормоконтроль	22.05.2025	<i>виконано</i>
7	Підготовка презентації та доповіді	29.05.2025	<i>виконано</i>
8	Рецензування	03.06.2025	<i>виконано</i>
9	Попередній захист	06.06.2025	<i>виконано</i>
10	Занесення диплома в електронний архів	07.06.2025	<i>виконано</i>
11	Допуск до захисту у зав. кафедри	12.06.2025	<i>виконано</i>

Дата видачі завдання 15.04.2025 р.

Здобувач А. Васф
(підпис)

Керівник роботи _____
(підпис)

проф. Анатолій РУТКАС
(посада, власне ім'я, прізвище)

РЕФЕРАТ / ABSTRACT

Робота містить: 107 с., 13 рис., 8 табл., 17 джер.

АНАЛІЗ ЗОБРАЖЕНЬ, АНОМАЛІЇ, КЛАСИФІКАЦІЯ, КОМП'ЮТЕРНИЙ ЗІР, МАШИННЕ НАВЧАННЯ, ОБРОБКА ЗОБРАЖЕНЬ, СУПУТНИКОВІ ЗНІМКИ, CNN, GAN, LSTM, NDVI, RNN, SVM, TRANSFORMERS.

Об'єктом дослідження є процеси обробки та класифікації супутникових знімків для виявлення аномальних об'єктів або подій.

Метою роботи є розробка та експериментальна перевірка ефективних методів класифікації аномалій на супутникових знімках за допомогою технологій комп'ютерного зору, що поєднують машинне та глибоке навчання з метою підвищення точності, швидкості та адаптивності систем екологічного моніторингу.

Методи розробки та проектування базуються на поетапній обробці супутникових зображень: попередній обробці (нормалізація, масштабування, фільтрація шумів), екстракції NDVI та додаткових ознак, побудові навчальних вибірок і подальшому використанні алгоритмів машинного навчання, зокрема Support Vector Machine, а також елементів глибокого навчання. До розробки також залучено методи статистичного аналізу, оцінки ефективності (precision, recall, F1-score), візуалізації результатів та валідації на реальних супутникових даних. Розробка програмного модуля здійснювалася з використанням мови програмування Python та таких бібліотек: NumPy, OpenCV, scikit-learn, matplotlib, seaborn, а також TensorFlow (для попередніх експериментів із глибоким навчанням). Зчитування супутникових знімків, обробка NDVI та візуалізація результатів реалізовані в інтерактивному форматі, що забезпечує гнучкість і прозорість під час експериментів.

В результаті роботи було досліджено низку методів класифікації аномалій на супутникових знімках, включаючи SVM, CNN, GAN, LSTM, RNN та трансформери, також на основі оптимального методу було реалізовано

повноцінний програмний пайплайн для класифікації аномалій на супутникових знімках, який забезпечує стабільне виявлення NDVI-аномалій. Проведено експериментальне порівняння ефективності методу SVM, оцінено його стабільність у часовій динаміці, доведено практичну значущість результатів для екологічного моніторингу, аграрної аналітики та оперативного реагування в кризових ситуаціях. Розроблена система є адаптивною, масштабованою, придатною до інтеграції у реальні геоінформаційні системи.

ANOMALIES, CLASSIFICATION, CNN, COMPUTER VISION, GAN, IMAGE ANALYSIS, IMAGE PROCESSING, LSTM, MACHINE LEARNING, NDVI, RNN, SATELLITE IMAGERY, SVM, TRANSFORMERS.

The object of research is the processes of processing and classifying satellite images for the detection of anomalous objects or events.

The aim of the work is to develop and experimentally evaluate effective methods for anomaly classification in satellite imagery using computer vision technologies that combine machine learning and deep learning approaches in order to improve the accuracy, speed, and adaptability of environmental monitoring systems.

Development and design methods are based on a step-by-step pipeline for processing satellite imagery, including preprocessing (normalization, scaling, noise filtering), extraction of NDVI and additional features, construction of training datasets, and the application of machine learning algorithms, particularly Support Vector Machine, as well as elements of deep learning. The research also involved statistical analysis methods, evaluation of classification performance (precision, recall, F1-score), result visualization, and validation on real satellite data.

The software module was developed using the Python programming language and the following libraries: NumPy, OpenCV, scikit-learn, matplotlib, seaborn, and TensorFlow (for initial deep learning experiments). The satellite image reading, NDVI computation, and result visualization were implemented in an interactive format to ensure flexibility and transparency during the experimentation process.

As a result of the work, a number of methods for anomaly classification in

satellite images were investigated, including SVM, CNN, GAN, LSTM, RNN, and transformers. Based on the optimal method, a full-featured software pipeline for anomaly classification in satellite images was implemented, enabling stable detection of NDVI anomalies. An experimental comparison of the effectiveness of the SVM method was conducted, and its stability over time was assessed. The practical significance of the results was confirmed in the context of environmental monitoring, agricultural analytics, and emergency response. The developed system is adaptive, scalable, and suitable for integration into real-world geographic information systems (GIS).

ЗМІСТ

Перелік скорочень	11
Вступ	12
1 Огляд літератури та аналіз проблеми.....	15
1.1 Сучасний стан досліджень у сфері класифікації аномалій.....	15
1.2 Комп’ютерний зір у задачах обробки супутникових знімків	17
1.3 Огляд методів класифікації аномалій на супутникових знімках	21
1.4 Класифікація аномалій: огляд алгоритмів і методів.....	24
1.5 Аналіз наукових підходів та ідентифікація проблемних аспектів.....	26
1.6 Постановка задачі.....	29
2 Методи та технології для класифікації аномалій на супутникових знімках	31
2.1 Опис та обґрунтування обраних методів класифікації аномалій.....	31
2.1.1 SVM	31
2.1.2 CNN	35
2.1.3 GAN	39
2.1.4 LSTM	43
2.1.5 RNN	46
2.1.6 Трансформери.....	49
2.2 Порівняльна оцінка методів класифікації аномалій.....	53
3 Розробка та експериментальна реалізація методів класифікації аномалій	58
3.1 Підготовка супутникових даних для експериментів.....	58
3.1.1 Джерела супутникових знімків.....	58
3.1.2 Вибір області дослідження.....	58
3.1.3 Попередня обробка знімків	59
3.1.4 Супутникові знімки	62
3.2 Розробка алгоритму для класифікації аномалій на знімках	64
3.3 Експериментальний аналіз результатів класифікації аномалій	68
4 Аналіз результатів і можливості впровадження	75
4.1 Оцінка точності та надійності методу класифікації аномалій	75
4.1.1 Метрики оцінки точності класифікації.....	75

	10
4.1.2 Інтерпретація конфузійної матриці	76
4.1.3 Порівняння якості класифікації між класами	79
4.1.4 Аналіз стабільності класифікації у динаміці (за фазами повені)	81
4.2 Практична значущість отриманих результатів	83
4.3 Перспективи використання результатів у науковій і практичній діяльності	85
Висновки	88
Перелік джерел посилань.....	90
Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	92
Додаток А Звіт результатів перевірки кваліфікаційної роботи на унікальність тексту	93
Додаток Б Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимогам ДСТУ 3008:2015	96
Додаток В Апробація результатів роботи.....	97
Додаток Г Слайди презентації	102

ПЕРЕЛІК СКОРОЧЕНЬ

CNN – Convolutional Neural Network;

F1-score – гармонічне середнє між Precision та Recall;

GAN – Generative Adversarial Network;

LSTM – Long Short-Term Memory;

NDVI – Normalized Difference Vegetation Index;

Precision – точність (метрика класифікації);

Recall – повнота (метрика класифікації);

RNN – Recurrent Neural Network;

SVM – Support Vector Machine;

Transformers – трансформери (архітектура нейронних мереж).

ВСТУП

Аналіз аномалій на супутникових знімках є важливим напрямом досліджень у галузі комп'ютерного зору, що має велике значення для різноманітних наукових і практичних застосувань, таких як моніторинг екологічних змін, виявлення катастрофічних подій, дослідження сільськогосподарських угідь, а також управління природними ресурсами [1]. У сучасному світі супутникові знімки стали основним джерелом інформації для автоматизованих систем, що використовують передові методи аналізу даних для вирішення складних задач. Виявлення аномалій на цих зображеннях є важливою складовою таких систем, оскільки дозволяє ефективно виявляти відхилення від нормальних станів, що може свідчити про наявність незвичних явищ або подій.

Зі збільшенням обсягів супутникових даних і розвитком технологій комп'ютерного зору виникає необхідність створення нових, більш ефективних методів класифікації аномалій, що дозволяють швидко і точно обробляти великі обсяги зображень. Використання супутникових знімків для класифікації аномалій має величезний потенціал у багатьох сферах: від екологічного моніторингу та запобігання природним катастрофам до аналізу військових конфліктів та ситуацій, що потребують термінової реакції [2]. Більш точне та швидке виявлення аномалій сприятиме зниженню витрат часу та ресурсів на реагування, підвищенню точності прогностичних моделей і ефективності ухвалення рішень.

Метою даного дослідження є розробка та аналіз методів класифікації аномалій на супутникових знімках за допомогою технологій комп'ютерного зору, зокрема методів машинного навчання та глибокого навчання, для підвищення точності і швидкості обробки зображень. Актуальність дослідження обумовлена необхідністю вирішення проблеми автоматизованого виявлення аномальних подій, таких як природні катастрофи, екологічні зміни чи військові конфлікти, що можуть бути виявлені на супутникових знімках. Зважаючи на великий обсяг супутникових даних та потребу в їх швидкому та точному аналізі, існуючі методи часто не забезпечують необхідної ефективності. Тому розробка нових методів класифікації аномалій є важливою для оперативного моніторингу та прийняття

рішень у багатьох сферах. Завданнями роботи є:

- огляд існуючих методів до класифікації аномалій на супутникових знімках, з аналізом їх переваг та недоліків;
- розробка методів для виявлення аномалій на супутникових знімках з використанням комп'ютерного зору, включаючи попередню обробку зображень та виділення характеристик;
- проведення експериментів з різними алгоритмами класифікації для підвищення точності та ефективності класифікації;
- оцінка ефективності запропонованих методів на реальних супутникових знімках;
- надання рекомендацій щодо вдосконалення існуючих підходів до класифікації аномалій та пропозиції щодо їх практичного застосування в системах моніторингу та прийняття рішень на основі супутникових знімках.

Об'єктом дослідження є процеси обробки та класифікації супутникових знімків для виявлення аномальних об'єктів або подій.

Предметом дослідження є методи комп'ютерного зору, що використовуються для виявлення та класифікації аномалій на супутникових знімках, а також їх застосування до реальних зображень з різних супутникових систем.

Для досягнення поставленої мети у роботі будуть використані такі методи:

- аналіз наукової літератури та дослідження існуючих підходів класифікації аномалій на супутникових знімках, який дозволяє виявити недоліки і переваги різних підходів та сформулювати наукову задачу;
- методи машинного навчання, який дозволяє оцінити ефективність традиційних підходів до класифікації: використання класичних методів машинного навчання для побудови базових моделей класифікації аномалій;
- глибоке навчання: застосування нейронних мереж для аналізу та класифікації аномалій на супутникових знімках. Цей метод дозволяє

автоматично виділяти корисні ознаки з зображень і підвищити точність класифікації в порівнянні з класичними методами;

- обробка зображень: попередня обробка супутникових знімків, включаючи нормалізацію, фільтрацію шумів, контрастування і виділення важливих ознак, що допомагає покращити якість вхідних даних і підвищити точність подальшого аналізу;
- оцінка ефективності моделей: використання стандартних метрик для оцінки ефективності класифікації. Це дозволяє визначити найкращі підходи для вирішення поставленої задачі;
- експериментальний метод: проведення серії експериментів з різними алгоритмами та їх параметрами для вибору оптимальних налаштувань, що дозволяє на основі практичних досліджень вибрати найбільш ефективні підходи для класифікації аномалій на супутникових знімках;
- статистичний аналіз результатів: обробка та аналіз результатів експериментів для порівняння ефективності різних методів допомагає оцінити значущість отриманих результатів і робити висновки щодо найбільш підходящих технік класифікації.

Наукова новизна дослідження полягає в удосконаленні методів класифікації аномалій на супутникових знімках, зокрема в розробці комбінованих підходів, що поєднують традиційні алгоритми машинного навчання з методами глибокого навчання. Запропоновані методи дозволяють досягати вищої точності в порівнянні з існуючими підходами, а також зменшити час обробки великих обсягів даних.

Практичне значення отриманих результатів полягає в підвищенні ефективності систем моніторингу на основі супутникових знімків. Розроблені методи можуть бути застосовані для автоматизації процесів виявлення аномальних подій, таких як пожежі, затоплення, зміни в екологічному стані територій, а також для покращення аналізу супутникових даних в реальному часі. Це дозволить значно зменшити час на прийняття рішень і збільшити точність прогнозів.

1 ОГЛЯД ЛІТЕРАТУРИ ТА АНАЛІЗ ПРОБЛЕМИ

1.1 Сучасний стан досліджень у сфері класифікації аномалій

Класифікація аномалій на супутникових знімках є важливою проблемою в сучасній науці та індустрії, оскільки супутникові дані відіграють ключову роль у моніторингу та управлінні екологічними, економічними та безпековими питаннями. З розвитком технологій дистанційного зондування Землі і обробки зображень, зросли обсяги та складність супутникових даних, що вимагає автоматизації процесу аналізу за допомогою комп'ютерного зору та методів штучного інтелекту [3]. У зв'язку з цим, в сучасних дослідженнях особливу увагу приділяють розробці алгоритмів, здатних ефективно класифікувати аномалії з високою точністю і швидкістю.

Існує кілька основних підходів до класифікації аномалій на супутникових знімках, серед яких:

- методи машинного навчання (ML), такі як методи опорних векторів (SVM), дерева рішень, k-ближчих сусідів (k-NN) та інші класичні алгоритми, що використовуються для ідентифікації певних аномальних ознак на супутникових знімках. Ці методи потребують вибору і налаштування особливостей зображення, що може бути обмеженням для точності класифікації;
- глибоке навчання (Deep Learning), зокрема згорткові нейронні мережі (CNN), які демонструють високу ефективність у виділенні складних закономірностей без необхідності ручної обробки ознак. CNN є найпоширенішим методом для обробки великих обсягів даних з високою точністю, що робить їх перспективними для класифікації аномалій;
- методи обробки зображень для попередньої підготовки даних, включаючи методи фільтрації шумів, нормалізації, підвищення контрастності та виділення об'єктів, що сприяє покращенню якості зображень перед класифікацією.

У сучасних дослідженнях велика увага приділяється автоматизації процесів

обробки супутникових знімків. Зростаюча складність даних змушує науковців і розробників застосовувати більш ефективні підходи, такі як:

- згорткові нейронні мережі (CNN): CNN дозволяють автоматично навчати моделі виявляти аномалії за допомогою великих обсягів супутникових зображень, що підвищує точність і зменшує кількість помилкових класифікацій;
- рекурентні нейронні мережі (RNN) та їх модифікації, зокрема LSTM (Long Short-Term Memory), які допомагають аналізувати послідовності зображень, що дозволяє краще виявляти змінні аномалії, такі як зміни в рослинному покриві, водних ресурсах чи льодовиках;
- поєднання методів комп'ютерного зору з геопросторовим аналізом: Це включає обробку зображень у поєднанні з геопросторовими даними, що допомагає враховувати особливості території, кліматичні зміни і сезонні коливання для більш точного аналізу аномалій.

Незважаючи на значні успіхи, класифікація аномалій на супутникових знімках досі стикається з низкою проблем:

- недостатність анотованих даних: для точного навчання моделей глибокого навчання необхідна велика кількість анотованих супутникових знімків з аномаліями, однак такий набір даних часто важко отримати через специфіку супутникових зображень;
- шум та низька роздільна здатність зображень: супутникові знімки можуть містити шуми або бути низької роздільної здатності, що ускладнює класифікацію. Це призводить до необхідності застосування методів обробки зображень для покращення їх якості перед аналізом;
- наявність різних типів аномалій: аномалії можуть бути викликані різними факторами, як природними, так і антропогенними, що створює труднощі в уніфікації моделей для різних видів аномалій.

Методи глибокого навчання, зокрема згорткові нейронні мережі, стали одним з провідних інструментів для аналізу супутникових знімків [4]. Використання CNN дозволяє отримувати високу точність завдяки можливості

виділяти складні особливості зображень без необхідності ручного налаштування. Крім того, поєднання CNN з такими методами, як автоенкодера, генеративно-змагальні мережі (GAN), дозволяє ефективніше працювати з великими обсягами зображень та розпізнавати складні структури аномалій.

На сьогодні існує низка значних наукових праць, присвячених питанням класифікації аномалій на супутникових знімках. Деякі дослідження фокусуються на моніторингу екологічних змін, наприклад, виявленні змін у рослинності або зменшення льодовиків, тоді як інші дослідження зосереджені на виявленні антропогенних змін, таких як розширення міських територій або лісові пожежі. Окрім цього, активно розвиваються підходи до виявлення аномалій у контексті моніторингу стихійних лих, зокрема землетрусів, ураганів та повеней.

Сучасні дослідники часто поєднують різні методи для досягнення кращих результатів у класифікації аномалій. Поєднання традиційних методів машинного навчання з глибокими нейронними мережами, а також включення додаткових даних, таких як погодні умови або висотні моделі місцевості, дозволяє підвищити точність класифікації і зменшити кількість помилкових класифікацій [5].

Отже, сучасний стан досліджень у сфері класифікації аномалій на супутникових знімках демонструє значний прогрес завдяки розвитку комп'ютерного зору та методів штучного інтелекту. Попри існуючі виклики, такі як обмеження в доступності даних та специфічність обробки супутникових знімків, перспективи розвитку технологій глибокого навчання дозволяють очікувати подальшого вдосконалення методів і розширення їх застосування в різних галузях.

1.2 Комп'ютерний зір у задачах обробки супутникових знімків

Сучасні методи комп'ютерного зору займають одне з провідних місць у задачах аналізу супутникових знімків, які використовуються для моніторингу природних ресурсів, прогнозування природних лих, відстеження змін у навколишньому середовищі, картографування, оцінки земельних ресурсів та в багатьох інших важливих сферах. Комп'ютерний зір дозволяє автоматизувати

процеси аналізу великих обсягів супутникових зображень, що знижує потребу у ручному аналізі та значно підвищує точність і швидкість обробки даних.

Комп'ютерний зір – це галузь штучного інтелекту, яка розробляє алгоритми і методи, здатні «бачити» та інтерпретувати візуальні дані, подібно до того, як це робить людський мозок [6]. У контексті супутникових знімків це означає здатність автоматично розпізнавати, класифікувати та аналізувати об'єкти та явища на великих просторових масштабах і з високою деталізацією.

Основні задачі, які вирішуються за допомогою комп'ютерного зору на супутникових знімках, включають:

- класифікація об'єктів: виявлення і розпізнавання різних типів об'єктів, таких як будівлі, дороги, річки, рослинні покриви, що важливо для картографування та моніторингу забудови;
- виявлення змін: визначення змін у ландшафті або інфраструктурі, наприклад, в результаті природних катастроф або антропогенних впливів;
- аномальна детекція: пошук аномалій або відхилень, таких як пожежі, затоплення, дефіцит рослинності, що є особливо важливим для екологічного моніторингу та прогнозування стихійних лих.

Серед сучасних методів комп'ютерного зору значну увагу привертають алгоритми глибокого навчання, зокрема згорткові нейронні мережі (Convolutional Neural Networks, CNN). CNN дозволяють автоматично навчати моделі розпізнавання об'єктів без ручного визначення особливостей, що є значною перевагою при обробці складних супутникових знімків з високою роздільною здатністю.

CNN стали стандартом у задачах комп'ютерного зору завдяки своїй здатності витягувати та аналізувати особливості зображень через численні згорткові шари, що дозволяє їм ефективно виявляти як прості, так і складні патерни [7]. Це особливо корисно для аналізу супутникових знімків, де аномалії або певні об'єкти можуть бути слабо вираженими або відрізнятися від інших на рівні деталей. CNN широко застосовуються для:

- класифікації зображень: віднесення кожного зображення або його фрагментів до певного класу (наприклад, водна поверхня, ліс, місто тощо);
- сегментації зображень: поділ зображення на різні сегменти відповідно до типу поверхні або об'єктів, що дозволяє локалізувати і детальніше розглядати аномалії;
- виявлення об'єктів: виділення специфічних об'єктів на знімках, таких як будівлі, дороги чи окремі природні утворення.

На додачу до CNN, застосовуються також рекурентні нейронні мережі (RNN), довгі короткочасні пам'яті (LSTM) та глибокі автоенкодери, які добре підходять для роботи з послідовностями зображень. Це корисно для задач, де необхідно аналізувати динамічні зміни об'єктів у часі, наприклад, для прогнозування розвитку певних екологічних або природних процесів на основі історичних даних.

Перед застосуванням комп'ютерного зору, супутникові знімки потребують попередньої обробки для підвищення якості та зменшення шумів, що сприяє точнішій класифікації. До таких методів належать:

- фільтрація шумів: використання фільтрів, таких як Гауссові, для зменшення перешкод і шумів, які можуть виникати через атмосферні явища або обмеження обладнання;
- нормалізація і стандартизація кольорових каналів: для забезпечення сталості кольорів і контрастів на знімках з різних дат або з різних супутників;
- аугментація даних: метод збільшення різноманітності тренувального набору зображень шляхом обертання, масштабування, відображення тощо, що дозволяє нейронним мережам бути більш стійкими до варіацій даних.

Попри значний прогрес, існує низка проблем, пов'язаних із застосуванням комп'ютерного зору до супутникових знімків:

- великі обсяги даних: супутникові знімки мають високу роздільну

здатність, що призводить до великих обсягів даних, які важко обробити. Це вимагає оптимізації алгоритмів і збільшення обчислювальних ресурсів;

- різноманітність аномалій: аномалії на знімках можуть бути викликані як природними, так і техногенними причинами, що ускладнює розробку універсальних методів для їх виявлення та класифікації;
- змінні атмосферні умови: погодні умови, такі як хмари, туман, дим, можуть суттєво погіршувати якість зображень, що вимагає розробки методів обробки, які дозволяють компенсувати такі фактори.

Гібридні підходи, які поєднують методи комп'ютерного зору з іншими технологіями, такими як геопросторовий аналіз або математичне моделювання, демонструють високу ефективність у вирішенні задач обробки супутникових знімків. Наприклад, поєднання CNN з кластеризацією дозволяє сегментувати супутникові знімки на основі географічних координат і виявляти певні геопросторові закономірності, що важливо для дослідження великих територій.

Використання комп'ютерного зору для виявлення аномалій на супутникових знімках є одним з найбільш перспективних напрямків. Цей підхід застосовується для моніторингу екологічних змін, відстеження розширення урбанізації, виявлення зон забруднення, пожеж, змін у рослинності та водних ресурсах. Сучасні системи моніторингу використовують алгоритми комп'ютерного зору для:

- виявлення стихійних лих: відслідковування наслідків землетрусів, повеней, пожеж або ураганів шляхом аналізу до та після катастрофічних зображень;
- моніторинг сільськогосподарських площ: виявлення змін у стані рослинності, що є важливим для управління врожайністю та оцінки продуктивності земельних угідь;
- оцінка екологічного стану територій: виявлення зон забруднення, вирубок лісів або змін водних ресурсів.

Отже, завдяки використанню методів глибокого навчання та інноваційних

підходів до обробки великих масивів супутникових знімків, комп'ютерний зір відкриває нові можливості для ефективного моніторингу та дослідження нашої планети. Виклики, пов'язані з розмаїттям аномалій і змінами умов зйомки, стимулюють наукову спільноту розробляти нові методи та гібридні підходи для підвищення точності класифікації. Технології комп'ютерного зору стають невід'ємною частиною сучасної системи аналізу супутникових знімків, роблячи великий внесок у науку, екологію, сільське господарство і безпеку.

1.3 Огляд методів класифікації аномалій на супутникових знімках

Класифікація аномалій на супутникових знімках є ключовим завданням у сучасній обробці даних дистанційного зондування. Вона знаходить застосування у широкому спектрі практичних задач, таких як моніторинг природних ресурсів, прогнозування природних катастроф, екологічний контроль, сільськогосподарські дослідження та управління інфраструктурою. Ефективність класифікації значною мірою залежить від застосованих методів, які повинні забезпечувати високу точність, стійкість до шумів і здатність працювати з великими обсягами даних.

Традиційні методи класифікації аномалій включають статистичні методи, методи аналізу спектральних ознак і алгоритми машинного навчання. Ці методи історично домінували до широкого впровадження глибокого навчання.

Основою статистичних методів є аналіз статистичних характеристик пікселів або регіонів зображення. Наприклад, методи класифікації на основі порогових значень використовують середні, медіанні або граничні значення для визначення аномалій. Хоча вони є простими у реалізації, їх ефективність обмежується низькою здатністю до роботи з багатовимірними і складними даними.

Супутникові знімки зазвичай містять інформацію в різних спектральних діапазонах, таких як видимий світ, ближній інфрачервоний або термальний інфрачервоний спектр. Методи аналізу спектральних індексів, наприклад NDVI (Normalized Difference Vegetation Index), використовуються для виявлення аномалій у рослинному покриві або водних ресурсах. Ці підходи є ефективними

для вузькоспеціалізованих задач, але вони часто не враховують просторових взаємозв'язків.

До традиційних методів машинного навчання відносять алгоритми, такі як:

- методи опорних векторів (SVM): забезпечують високу точність класифікації, але вимагають ретельного вибору гіперпараметрів і мають обмежену здатність до обробки великих обсягів даних;
- дерева рішень та випадкові ліси (Random Forest): широко використовуються завдяки стійкості до шумів і здатності працювати з різними типами даних. Однак їх ефективність падає при роботі з дуже великими наборами даних.

Сучасні підходи до класифікації аномалій на супутникових знімках базуються на методах глибокого навчання, які дозволяють автоматично витягувати та аналізувати складні просторові і спектральні особливості. Основними серед них є згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN) та їх комбінації.

CNN є основою для обробки зображень завдяки своїй здатності автоматично виявляти просторові особливості різного рівня складності. Вони використовуються для задач:

- класифікації зображень: моделі CNN, такі як ResNet, VGG або EfficientNet, успішно застосовуються для класифікації пікселів або регіонів супутникових знімків;
- сегментації зображень: такі архітектури, як U-Net або DeepLab, забезпечують поділ знімків на класи на рівні пікселів, що є особливо важливим для детекції аномалій у великих регіонах.

RNN використовуються для аналізу часового ряду зображень, що дозволяє виявляти динамічні аномалії, наприклад, зміни рослинного покриву або поступовий розвиток посухи. Моделі LSTM (Long Short-Term Memory) і GRU (Gated Recurrent Unit) показали високу ефективність у цьому контексті.

Генеративно-змагальні мережі (GAN) використовуються для виявлення аномалій шляхом порівняння реальних зображень із синтезованими. Якщо

реальний знімок значно відрізняється від згенерованого, це може свідчити про наявність аномалії.

Технологія трансформерів, яка стала популярною завдяки досягненням у природній мові (наприклад, GPT), також знайшла застосування в обробці супутникових знімків. Вони ефективні для аналізу великих контекстів і розпізнавання складних структур на зображеннях.

Супутникові знімки містять як просторову, так і спектральну інформацію. Сучасні підходи інтегрують ці два типи даних за допомогою моделей, що обробляють спектральні особливості (наприклад, через багатопланові перцептрони) і просторові залежності (через згорткові мережі). Такий підхід дозволяє враховувати як локальні, так і глобальні закономірності в даних.

Гібридні підходи поєднують переваги різних методів. Наприклад, об'єднання методів машинного навчання (наприклад, SVM) з глибоким навчанням (CNN) дозволяє досягти високої точності при збереженні швидкості обробки. Крім того, гібридні методи використовуються для побудови ансамблів моделей, які знижують ймовірність помилок і підвищують надійність класифікації.

Класифікація аномалій на супутникових знімках стикається з низкою викликів, таких як:

- великий обсяг даних: супутникові знімки мають високу роздільну здатність і охоплюють великі території, що вимагає значних обчислювальних ресурсів;
- шуми і перешкоди: атмосферні явища, такі як хмари або дим, можуть погіршувати якість даних;
- нестача анотованих даних: для тренування моделей глибокого навчання потрібні великі обсяги мічених даних, які часто важко отримати.

Для подолання цих викликів використовуються такі підходи, як самонавчання, техніки аугментації даних, перенесене навчання (transfer learning) та побудова спеціалізованих архітектур.

Отже, огляд методів класифікації аномалій на супутникових знімках

демонструє, що сучасні технології комп'ютерного зору, особливо глибоке навчання, відкривають нові можливості для високоточної обробки великих обсягів даних. Розвиток цих методів продовжує вдосконалювати здатність до аналізу супутникових знімків, роблячи їх важливим інструментом для моніторингу навколишнього середовища та прогнозування змін.

1.4 Класифікація аномалій: огляд алгоритмів і методів

Класифікація аномалій є важливою задачею в обробці супутникових знімків, яка передбачає виявлення об'єктів або явищ, що відхиляються від звичайного стану. Це можуть бути природні катастрофи, зміни ландшафту, аномальні погодні умови, незаконні вирубки лісів чи інші події, які потребують оперативного реагування. У цій сфері використовуються різні алгоритми та підходи, які постійно еволюціонують під впливом новітніх досягнень у галузі комп'ютерного зору і машинного навчання.

До появи сучасних методів машинного навчання основну роль у класифікації аномалій відігравали статистичні методи, аналітичні моделі та базові алгоритми машинного навчання.

Методи на основі статистики базуються на аналізі розподілу даних, визначенні відхилень від середніх значень або інших статистичних характеристик.

Наприклад:

- метод порогового значення: використовується для простих задач, де аномалії визначаються як значення, що перевищують заданий поріг (наприклад, температура або NDVI);
- методи базисного аналізу: передбачають вивчення середніх і стандартних відхилень для визначення аномалій. Хоча вони є ефективними для простих задач, їх застосування обмежене в умовах складних і багатовимірних даних.

Для супутникових знімків важливу роль відіграє спектральна інформація.

Наприклад:

- індекси рослинності (NDVI, EVI): використовуються для аналізу стану

рослинного покриву. Відхилення від нормальних значень можуть свідчити про посуху, хвороби рослин чи вирубку лісу;

- спектральні класифікатори: методи, які аналізують багатоспектральні або гіперспектральні зображення для виявлення аномалій.

Серед базових алгоритмів машинного навчання, які широко використовуються для класифікації аномалій, можна виділити:

- методи опорних векторів (SVM): дозволяють створювати нелінійні моделі для класифікації, використовуючи ядрові функції. Вони добре працюють із обмеженими даними, але можуть бути неефективними для дуже великих наборів даних;
- кластеризація (k-means, DBSCAN): ці методи використовуються для визначення груп нормальних даних, а все, що знаходиться за межами кластерів, вважається аномалією;
- випадкові ліси (Random Forest): забезпечують високу точність завдяки створенню ансамблю дерев рішень. Їх основною перевагою є стійкість до шумів і різноманітності даних.

З появою глибокого навчання класифікація аномалій на супутникових знімках перейшла на новий рівень. Глибокі нейронні мережі дозволяють автоматично витягувати характеристики з даних, що значно підвищує точність і універсальність алгоритмів.

CNN є основою для аналізу зображень. Вони дозволяють автоматично виявляти як низькорівневі (текстура, контури), так і високорівневі (форми, об'єкти) особливості. Найпоширеніші підходи:

- класифікація зображень: моделі CNN, такі як AlexNet, ResNet і EfficientNet, використовуються для класифікації знімків або їх фрагментів;
- сегментація зображень: U-Net та SegNet дозволяють виконувати піксельну класифікацію, що особливо важливо для виявлення аномалій, таких як виливи нафти або лісові пожежі.

RNN і їх варіації, такі як LSTM і GRU, є ефективними для аналізу даних, що

мають часову залежність. Наприклад, вони застосовуються для виявлення змін у послідовності супутникових знімків, таких як зсуви землі або поступове танення льодовиків.

GAN використовуються для створення синтетичних даних, які порівнюються з реальними. Наприклад, аномалія може бути виявлена, якщо реальний знімок значно відрізняється від згенерованого.

Трансформери, які стали популярними завдяки успіхам у обробці природної мови, також знайшли застосування в аналізі зображень. Їх використання дозволяє ефективно обробляти глобальний контекст і складні просторові залежності.

Сучасні дослідження часто використовують інтегровані методи, які поєднують різні алгоритми для досягнення найкращих результатів. Наприклад:

- комбінація CNN і RNN: дозволяє враховувати як просторові, так і часові залежності;
- ансамблі моделей: об'єднання різних моделей (наприклад, SVM і CNN) дозволяє знизити ймовірність помилок і підвищити надійність класифікації.

Перспективи розвитку включають впровадження більш ефективних алгоритмів, використання технологій самонавчання, а також розвиток хмарних платформ для обробки даних. Крім того, інтеграція супутникових знімків із іншими типами даних (наприклад, метеорологічними) може значно підвищити точність і ефективність класифікації.

Отже, огляд алгоритмів і методів класифікації аномалій демонструє, що постійний розвиток у цій галузі відкриває нові можливості для ефективного аналізу супутникових знімків і вирішення нагальних проблем моніторингу довкілля.

1.5 Аналіз наукових підходів та ідентифікація проблемних аспектів

Класифікація аномалій на супутникових знімках є однією з ключових задач сучасного аналізу просторових даних, що знаходить застосування в екологічному моніторингу, міському плануванні, сільському господарстві та управлінні

надзвичайними ситуаціями. Розвиток цієї галузі напряму пов'язаний із впровадженням технологій комп'ютерного зору, машинного та глибокого навчання, які значно підвищили можливості автоматизації та точності обробки супутникових даних. Проте, як і будь-яка інша наукова сфера, ця область стикається із суттєвими викликами та невирішеними проблемами, що потребують додаткових досліджень.

На основі аналізу існуючих наукових і практичних методів можна виокремити кілька ключових напрямів, які визначають розвиток технологій класифікації аномалій.

Традиційні методи класифікації базуються на використанні статистичних підходів і базових алгоритмів машинного навчання. Наприклад, пороговий аналіз або розрахунок статистичних характеристик спектральних індексів дозволяють виявляти базові відхилення, такі як зміна рослинного покриву чи викиди тепла. Методи опорних векторів (SVM), кластеризація (k-means, DBSCAN) та випадкові ліси стали основою для перших автоматизованих систем обробки супутникових знімків. Однак їх застосування обмежене складністю багатовимірних даних, значними часовими витратами та необхідністю вручну підбирати ознаки для класифікації.

Успіхи CNN у розв'язанні задач комп'ютерного зору, таких як класифікація об'єктів та сегментація зображень, знайшли широке застосування у сфері аналізу супутникових знімків. CNN дозволяють автоматично виділяти важливі ознаки зображень і адаптуватися до різноманітних типів аномалій. Мережі, такі як ResNet, EfficientNet та U-Net, активно використовуються для виявлення лісових пожеж, повеней, змін ґрунтового покриву та інших явищ.

Для аналізу змін у часових рядах супутникових знімків використовуються RNN, зокрема їх варіанти LSTM і GRU. Це дозволяє відстежувати динамічні процеси, такі як ерозія, зміна рівня води у річках або поступове танення льодовиків. Проте складність навчання таких моделей та необхідність обробки великих обсягів часових даних залишається значною проблемою.

GAN використовуються для виявлення аномалій через порівняння реальних

і згенерованих даних. Цей підхід особливо корисний у випадках, коли аномалії рідкісні або важко визначаються, наприклад, для виявлення незаконних забудов або аномалій у хмарному покриві.

Сучасні дослідження орієнтовані на поєднання кількох підходів для покращення результатів класифікації. Наприклад, об'єднання CNN та RNN дозволяє враховувати як просторові, так і часові аспекти даних, що є важливим для комплексного аналізу супутникових знімків.

Хоча сучасні методи значно підвищили ефективність класифікації аномалій, існує ряд викликів, які потребують подальшого дослідження:

- велика кількість даних і обмежені обчислювальні ресурси: супутникові знімки, особливо гіперспектральні, створюють величезні обсяги даних, що потребують значних ресурсів для обробки. Використання хмарних технологій і оптимізація моделей є одним із напрямків подолання цієї проблеми;
- нестача анотованих даних: моделі глибокого навчання вимагають великої кількості анотованих даних для навчання. Однак створення таких наборів даних є трудомістким і дорогим процесом. Використання методів самонавчання, трансферного навчання та синтетичних даних може допомогти у вирішенні цієї проблеми;
- вплив шумів і атмосферних явищ: хмари, дим та інші атмосферні явища ускладнюють аналіз супутникових знімків. Розробка моделей, стійких до шумів, та вдосконалення методів попередньої обробки зображень є актуальним завданням;
- генералізація моделей: більшість моделей добре працюють на певних наборах даних, але їх ефективність може знижуватися на нових знімках або в інших регіонах. Це потребує створення універсальних алгоритмів або адаптивних моделей, здатних до самонавчання;
- інтеграція даних з різних джерел: використання лише супутникових знімків може бути недостатнім для повного аналізу аномалій. Інтеграція даних з наземних сенсорів, метеорологічних станцій чи дронів відкриває

нові можливості для підвищення точності класифікації.

Отже, вирішення описаних проблемних аспектів дозволить створити метод, систему для моніторингу навколишнього середовища на супутникових знімках та управління ризиками більш ефективнішими, точнішими та доступнішими, що, у свою чергу, сприятиме прийняттю більш обґрунтованих рішень на глобальному та локальному рівнях.

1.6 Постановка задачі

Основною метою дослідження є розробка та вдосконалення методів класифікації аномалій на супутникових знімках із використанням технологій комп'ютерного зору, зокрема методів машинного та глибокого навчання. Рішення цієї задачі дозволить значно підвищити точність і швидкість обробки супутникових зображень для виявлення аномалій, що є важливим кроком у різноманітних галузях, таких як моніторинг довкілля, управління ресурсами, прогнозування катастроф та інші.

Ключові задачі, які потребують вирішення в межах даного дослідження, включають:

- огляд і аналіз існуючих підходів: у першу чергу, необхідно провести огляд літератури і існуючих наукових підходів у галузі класифікації аномалій на супутникових знімках. Це дозволить зрозуміти рівень розвитку даної проблеми, виявити актуальні методи та технології, а також визначити ключові обмеження і можливості для вдосконалення підходів;
- ідентифікація проблемних аспектів: потрібно виявити основні проблеми, з якими стикаються сучасні методи класифікації аномалій на супутникових знімках. Це можуть бути, наприклад, обмеження в точності результатів через складність або нестабільність зображень, значний обсяг даних, шум у знімках, а також потреба в значних обчислювальних потужностях для обробки великих обсягів даних;
- розробка і вдосконалення методів класифікації: визначити та розробити

нові або вдосконалені методи класифікації аномалій, що дозволяють забезпечити високу точність та ефективність у реальних умовах. Це включає вибір оптимальних алгоритмів машинного навчання та глибокого навчання, які здатні обробляти різноманітні типи супутникових зображень, враховуючи різні види аномалій;

- порівняння методів: необхідно провести порівняльний аналіз різних методів класифікації, таких як SVM, CNN, GAN, LSTM, RNN та трансформери. Це дозволить виявити найефективніші підходи для конкретних задач;
- експериментальна перевірка: провести серію експериментів для тестування розроблених методів на реальних супутникових знімках. Результати експериментів повинні продемонструвати ефективність методів у порівнянні з існуючими підходами за такими параметрами, як точність, час обробки, стійкість до шумів і зміни умов зйомки;
- практичне застосування: оцінити практичну значущість результатів дослідження, зокрема можливості їх впровадження у реальні системи моніторингу та управління, що можуть використовувати супутникові дані для вирішення різноманітних завдань, від екологічного моніторингу до управління надзвичайними ситуаціями.

Отже, задачі дослідження полягають у розробці та експериментальній перевірці методів класифікації аномалій, що дозволяють підвищити точність та ефективність обробки супутникових зображень, а також виявити та проаналізувати основні проблеми та обмеження, з якими стикаються існуючі методи.

2 МЕТОДИ ТА ТЕХНОЛОГІЇ ДЛЯ КЛАСИФІКАЦІЇ АНОМАЛІЙ НА СУПУТНИКОВИХ ЗНІМКАХ

2.1 Опис та обґрунтування обраних методів класифікації аномалій

Класифікація аномалій на супутникових знімках є складною задачею, що вимагає застосування високоточних та ефективних методів для виявлення нетипових чи несподіваних подій, таких як природні катастрофи, зміни в екосистемах або незаконні забудови. Оскільки супутникові зображення мають велику роздільну здатність і містять величезні обсяги інформації, традиційні методи аналізу часто не забезпечують достатньої ефективності в обробці таких даних. У зв'язку з цим, сучасні підходи до класифікації аномалій включають використання передових алгоритмів машинного навчання та глибокого навчання, серед яких особливу роль відіграють SVM, CNN, GAN, LSTM, RNN та трансформери.

Ці методи мають різні підходи до обробки даних і вирішення задач класифікації, що робить їх підходящими для вирішення конкретних проблем у виявленні аномалій.

2.1.1 SVM

Метод опорних векторів (SVM) є одним із найбільш популярних і ефективних алгоритмів машинного навчання, який знайшов широке застосування у вирішенні завдань класифікації, регресії та виявлення аномалій (див. рис. 2.1). Він базується на математично строгій концепції, яка полягає у визначенні оптимальної гіперплощини, що розділяє класи даних з максимальним відступом між ними [8]. Це забезпечує високу точність і стійкість алгоритму до шуму та інших можливих похибок у даних. Завдяки своїй універсальності та ефективності метод SVM активно використовується у задачах комп'ютерного зору, включно з класифікацією аномалій на супутникових знімках.

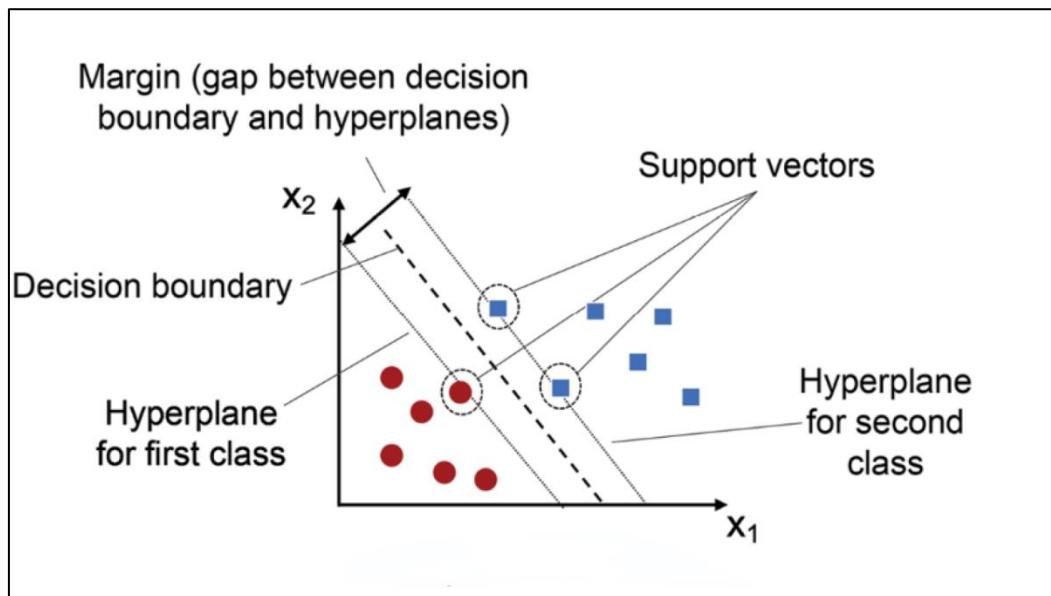


Рисунок 2.1 – SVM (рисунок створено самостійно)

Принцип роботи методу SVM:

- пошук оптимальної гіперплощини: гіперплощина в контексті SVM є умовним розділовим бар'єром, який проходить через багатовимірний простір ознак і розділяє точки, що належать до різних класів. Основна задача алгоритму – знайти таку гіперплощину, яка забезпечить максимальний відступ (margin) між найближчими точками обох класів. Цей підхід мінімізує ризик помилок під час класифікації нових даних;
- опорні вектори: опорні вектори – це точки даних, які розташовані найближче до гіперплощини і безпосередньо визначають її положення. Інші точки, що знаходяться далі від гіперплощини, не впливають на її побудову, що робить метод стійким до шуму у даних;
- нелінійна класифікація: для задач, де дані неможливо розділити за допомогою лінійної гіперплощини, метод SVM використовує спеціальні математичні функції, відомі як ядрові функції. Вони дозволяють перенести дані у простір більшої розмірності, де стає можливим їх лінійне розділення.

Для обробки нелінійних даних метод SVM пропонує використання ядрових функцій, які забезпечують ефективну трансформацію вхідних даних у новий

простір ознак. Найпоширеніші ядрові функції:

- лінійне ядро: застосовується, коли дані легко розділяються прямою лінією або площиною. Це найпростіше ядро, яке підходить для задач із чітким поділом класів;
- поліноміальне ядро: корисне для задач, де залежність між ознаками є нелінійною, але може бути описана поліномом певного ступеня;
- радіально-базисне ядро (RBF): один із найпопулярніших варіантів, який дозволяє ефективно моделювати складні та нелінійні залежності між ознаками. Це ядро особливо корисне для задач з великим обсягом супутникових даних, де зв'язок між ознаками часто не є очевидним;
- сигмоїдальне ядро: використовується у випадках, коли задача класифікації схожа на роботу нейронних мереж. Це ядро забезпечує гнучкість у моделюванні складних залежностей.

Окрім стандартного застосування для класифікації, SVM також використовується для задач виявлення аномалій. Для цього розроблено модифікацію алгоритму – One-Class SVM, яка фокусується на моделюванні нормального стану даних. Алгоритм навчається лише на нормальних зразках, визначаючи гіперплощину, що відокремлює нормальні дані від аномальних. Це робить One-Class SVM ефективним інструментом для задач, де кількість аномальних зразків є обмеженою або вони зовсім відсутні під час навчання.

Переваги методу SVM:

- висока точність і узагальнювальна здатність: метод SVM забезпечує точне розділення навіть у випадках складних і багатовимірних даних, що робить його ідеальним для класифікації супутникових знімків;
- гнучкість у роботі з нелінійними даними: завдяки використанню ядрових функцій алгоритм може успішно працювати з даними, які не піддаються лінійному розділенню;
- стійкість до перенавчання: максимізація відступу між класами зменшує ризик перенавчання моделі, навіть при роботі з великими наборами даних;

- можливість виявлення аномалій: використання One-Class SVM дозволяє ефективно ідентифікувати рідкісні події або патерни, які можуть сигналізувати про аномалії.

Недоліки методу SVM:

- обчислювальна складність: метод може бути ресурсомістким при роботі з великими наборами даних, особливо якщо використовується складне ядро;
- висока залежність від вибору параметрів: налаштування таких параметрів, як тип ядра або його параметри, вимагає ретельного підбору для забезпечення оптимальної продуктивності;
- складність у багатокласовій класифікації: для задач із більше ніж двома класами доводиться застосовувати додаткові стратегії, що збільшує складність моделі.

Метод SVM широко використовується в задачах обробки супутникових даних через його здатність працювати з великими обсягами складної інформації.

Приклади практичного застосування включають:

- моніторинг екологічних змін: виявлення змін у ландшафті, таких як вирубка лісів, зміна берегової лінії або розливи нафти;
- аналіз наслідків природних катастроф: ідентифікація постраждалих регіонів після землетрусів, повеней чи пожеж для оперативного реагування;
- контроль використання земель: виявлення незаконних будівель або змін у сільськогосподарських угіддях;
- військовий та безпековий аналіз: виявлення потенційно небезпечних аномалій, таких як рух транспорту, будівництво об'єктів або незвичайні активності.

Метод опорних векторів обраний для класифікації аномалій на супутникових знімках завдяки його високій точності, стійкості до шуму та здатності працювати з нелінійними даними. Його використання дозволяє створити надійну систему, яка може ефективно обробляти великі обсяги супутникової

інформації, сприяючи точнішому моніторингу та швидшому прийняттю рішень у критичних ситуаціях.

2.1.2 CNN

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) є одним із найбільш ефективних і популярних підходів у галузі комп'ютерного зору, особливо в задачах аналізу зображень (див. рисю 2.2). Завдяки своїй здатності автоматично витягувати ключові ознаки з вхідних даних і працювати з великими обсягами інформації, CNN стали основним вибором для вирішення задач класифікації, сегментації та виявлення аномалій на зображеннях, включаючи супутникові знімки [9].

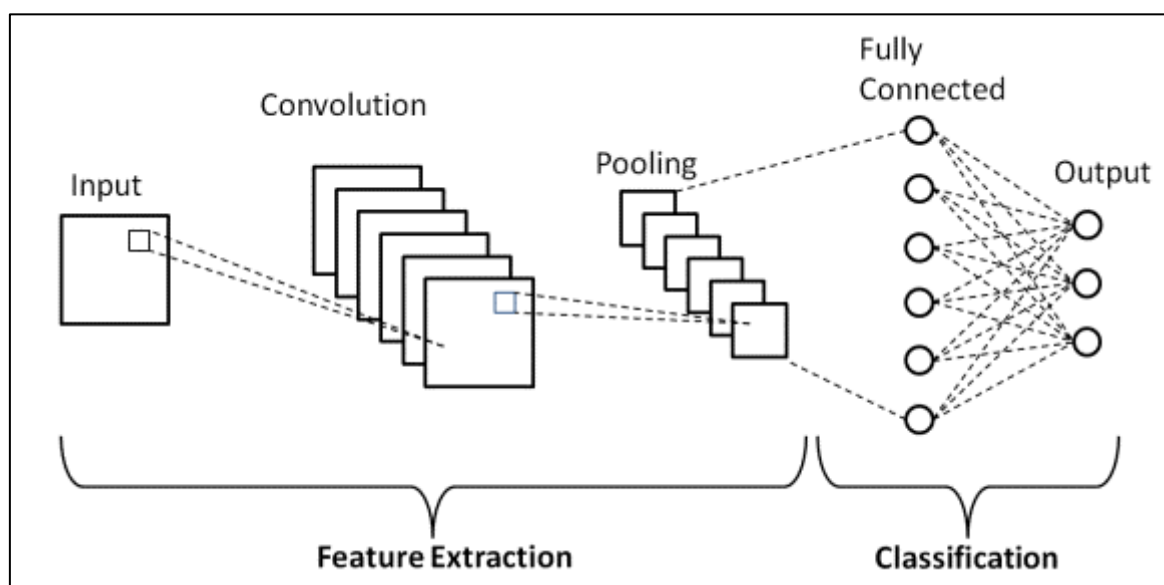


Рисунок 2.2 – CNN (рисунок створено самостійно)

CNN базуються на принципах згортки, яка є ключовою операцією для виявлення патернів у даних. Мережа складається з кількох шарів, кожен з яких виконує специфічну функцію, забезпечуючи ієрархічний аналіз вхідних зображень:

- згортковий шар (Convolutional Layer): у цьому шарі відбувається основна операція згортки, під час якої застосовуються фільтри (ядра) до вхідного зображення. Кожен фільтр відповідає за виявлення специфічних особливостей, таких як краї, текстури, кути чи складніші патерни.

Результати згортки формують карту ознак (feature map), яка зберігає інформацію про виявлені патерни;

- шар активації (Activation Layer): для забезпечення нелінійності аналізу використовуються функції активації, такі як ReLU (Rectified Linear Unit), яка залишає лише позитивні значення, усуваючи негативні. Це дозволяє мережі моделювати складні залежності в даних;
- шар підвибірки (Pooling Layer): для зменшення розмірності карти ознак і збереження ключових інформаційних елементів використовується операція підвибірки (пулінг), наприклад, максимальний або середній пулінг. Це допомагає зменшити кількість параметрів і підвищити стійкість моделі до зсувів або деформацій зображення;
- повнозв'язний шар (Fully Connected Layer): цей шар відповідає за фінальну класифікацію. Вхідні дані з попередніх шарів перетворюються у вектор і передаються через нейрони для прийняття рішення щодо належності об'єкта до певного класу;
- вихідний шар (Output Layer): на цьому етапі використовується функція активації, наприклад Softmax, для визначення ймовірностей належності зображення до конкретного класу.

Особливості застосування CNN у задачах класифікації аномалій:

- автоматичне витягування ознак: CNN автоматично виявляють ключові ознаки у зображеннях без необхідності попереднього ручного вибору ознак. Це особливо важливо для супутникових знімків, де структура даних може бути складною і багатовимірною;
- обробка великих зображень: супутникові знімки мають високу роздільну здатність, що створює значні виклики для традиційних методів аналізу. CNN завдяки своїй ієрархічній структурі ефективно обробляють такі зображення;
- висока точність: CNN забезпечують точність класифікації, порівнянну або вищу за інші алгоритми машинного навчання, особливо в задачах з великою кількістю класів або складними патернами даних;

- можливість виявлення аномалій: CNN можуть бути адаптовані для задач виявлення аномалій шляхом навчання на нормальних зразках і визначення відхилень від стандартних патернів.

Популярні архітектури CNN:

- LeNet: Одна з перших CNN, розроблена для розпізнавання рукописних цифр. Хоча LeNet є базовою моделлю, її принципи були розвинені в сучасних архітектурах;
- AlexNet: Революційна модель, яка значно покращила точність класифікації завдяки використанню глибших шарів та GPU-обчислень. AlexNet вперше довела ефективність CNN у великих наборах даних;
- VGGNet: Характеризується простотою архітектури, яка базується на невеликих 3×3 згорткових ядрах. VGGNet є популярним вибором для задач супутникового аналізу завдяки зручності адаптації;
- ResNet: Мережа з залишковими зв'язками (residual connections), які допомагають уникнути проблеми затухання градієнта в дуже глибоких мережах. ResNet є ефективним для обробки складних супутникових знімків;
- U-Net: Ця архітектура спеціалізується на задачах сегментації зображень і може використовуватися для виявлення аномалій на супутникових знімках.

Переваги методу CNN:

- стійкість до змін у даних: CNN здатні враховувати зміни у вигляді масштабування, поворотів і деформацій об'єктів, що є критично важливим для аналізу супутникових даних, які можуть бути отримані з різних ракурсів і в різний час;
- висока продуктивність: завдяки паралельним обчисленням на GPU CNN забезпечують швидку обробку великих наборів зображень;
- масштабованість: CNN можна адаптувати для роботи з різними обсягами даних, включаючи багатоканальні супутникові знімки (наприклад, з інфрачервоним чи радіолокаційним спектрами);

- гнучкість у налаштуванні: можливість тонкого налаштування параметрів і використання попередньо навчених моделей (transfer learning) робить CNN ефективними навіть для невеликих наборів даних.

Недоліки методу CNN:

- потреба у великих наборах даних: CNN вимагають значних обсягів даних для навчання, що може бути проблемою для задач із обмеженою кількістю супутникових знімків аномалій;
- високі обчислювальні витрати: для навчання та тестування моделей CNN потрібні потужні обчислювальні ресурси, особливо при роботі з великими зображеннями;
- чутливість до шуму: незважаючи на загальну стійкість, CNN можуть бути вразливими до шумових даних або артефактів, які виникають під час збирання супутникових знімків.

Практичне застосування CNN у задачах класифікації аномалій:

- виявлення природних катастроф: використання CNN для аналізу супутникових знімків дозволяє виявляти наслідки землетрусів, повеней, пожеж та інших катастроф;
- моніторинг довкілля: CNN використовуються для виявлення змін у лісових масивах, сільськогосподарських угіддях або водоймах;
- аналіз міських територій: класифікація аномалій у міській інфраструктурі, таких як незаконне будівництво чи дорожні пошкодження;
- сільське господарство: виявлення проблемних зон у посівах, спричинених шкідниками або кліматичними умовами.

Згорткові нейронні мережі є потужним інструментом для аналізу супутникових знімків завдяки їхній здатності автоматично витягувати складні патерни, враховуючи контекст зображень. Використання CNN дозволяє досягати високої точності та ефективності у задачах класифікації аномалій, що є важливим для своєчасного виявлення проблем та прийняття рішень у різних галузях.

2.1.3 GAN

Генеративно-змагальні мережі (Generative Adversarial Networks, GAN) є одним із сучасних підходів у галузі глибокого навчання, які використовуються для генерації нових даних, виявлення аномалій, відновлення зображень та інших задач (див. рис. 2.3). GAN складаються з двох нейронних мереж – генератора (Generator) та дискримінатора (Discriminator), які працюють у режимі змагання, створюючи потужну архітектуру для моделювання складних розподілів даних [10]. У контексті класифікації аномалій на супутникових знімках GAN мають значний потенціал, оскільки дозволяють виявляти незвичайні патерни шляхом моделювання нормальної поведінки даних.

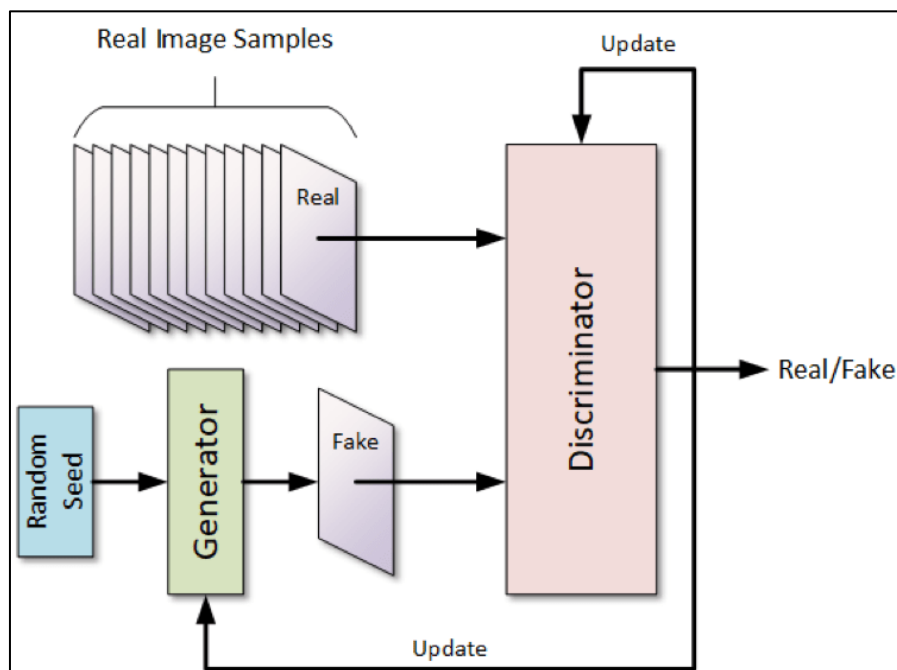


Рисунок 2.3 – GAN (рисунок створено самостійно)

Основні принципи роботи GAN:

- генератор (Generator): генератор створює нові дані, які мають виглядати схожими на реальні. У задачах аномалій це можуть бути супутникові знімки, що відповідають нормальним умовам. Генератор отримує на вхід випадковий шум і перетворює його в дані, що відповідають цільовому розподілу;
- дискримінатор (Discriminator): дискримінатор оцінює, чи є дані

справжніми (з реального розподілу) або штучно створеними генератором. Його завдання – відрізнити справжні дані від підроблених, забезпечуючи зворотній зв'язок генератору;

- процес змагання: генератор і дискримінатор навчаються у процесі гри з нульовою сумою. Генератор намагається створити настільки реалістичні дані, щоб дискримінатор не міг їх відрізнити від справжніх. У свою чергу, дискримінатор постійно покращується, щоб ефективніше виявляти підробки;
- фінальна мета: ідеальний баланс досягається, коли генератор створює дані, які дискримінатор визначає як справжні із ймовірністю 50%. У цьому випадку генератор вважається успішним у моделюванні реального розподілу даних.

Використання GAN для класифікації аномалій:

- моделювання нормального розподілу: GAN можна використовувати для навчання на наборах нормальних супутникових знімків, створюючи модель, яка генерує нові зображення, що відповідають цим даним. Аномалії визначаються як зразки, які значно відхиляються від цього розподілу;
- виявлення аномалій: після навчання генератора на нормальних даних будь-яке зображення, яке дискримінатор класифікує як підроблене, можна вважати аномальним. Це дає можливість автоматично виявляти відхилення, такі як природні катастрофи, зміни в міському середовищі чи інші незвичайні явища;
- покращення візуалізації: GAN також використовуються для відновлення зображень із пошкоджених даних або для покращення їхньої якості, що є важливим для аналізу супутникових знімків із низькою роздільною здатністю.

Основні архітектури GAN:

- Vanilla GAN: початкова архітектура GAN, запропонована Іеном Гудфеллоу. Вона складається з простих багатошарових перцептронів для

генератора і дискримінатора. Хоча Vanilla GAN має обмеження у складних задачах, вона заклала основу для подальших удосконалень;

- DCGAN (Deep Convolutional GAN): використовує згорткові нейронні мережі для генератора і дискримінатора, що дозволяє працювати із зображеннями високої роздільної здатності. DCGAN є популярним вибором для аналізу супутникових знімків;
- WGAN (Wasserstein GAN): покращена версія GAN, яка використовує метрику Вассерштейна для оцінки відстані між розподілами, що забезпечує стабільніше навчання;
- Pix2Pix: використовується для задач перекладу зображень у різних доменах, наприклад, перетворення супутникових знімків у карти місцевості або виявлення аномалій;
- CycleGAN: може перетворювати зображення між доменами без парних даних. Це важливо для аналізу супутникових знімків, коли немає анотацій для всіх зразків.

Переваги використання GAN у задачах класифікації аномалій:

- адаптивність: GAN можуть навчатися на необмеженій кількості нормальних даних і автоматично виявляти аномалії без необхідності анотацій для кожної категорії;
- генерація даних: GAN дозволяють створювати нові синтетичні зразки, які можуть бути використані для навчання інших моделей або для оцінки ефективності існуючих алгоритмів;
- можливість роботи з багатоканальними даними: GAN здатні аналізувати не лише оптичні зображення, але й дані з різних спектральних діапазонів, таких як інфрачервоний або радіолокаційний;
- поліпшення якості даних: GAN можуть відновлювати супутникові знімки з пошкодженими ділянками або поліпшувати їхню роздільну здатність, що є важливим для подальшого аналізу.

Виклики та недоліки використання GAN:

- складність навчання: збалансування роботи генератора і дискримінатора

є складним завданням, оскільки мережі можуть "переучуватись" або досягати ситуації, коли один із компонентів домінує;

- високі обчислювальні ресурси: GAN вимагають значних ресурсів для навчання, особливо у задачах із високою роздільною здатністю супутникових знімків;
- обмеження генеративної моделі: у деяких випадках генератор може створювати дані, які виглядають реалістично, але не відповідають всім деталям реального розподілу;
- вразливість до шуму: GAN можуть бути чутливими до шуму в навчальних даних, що впливає на їхню здатність точно моделювати нормальний розподіл.

Практичне застосування GAN у класифікації аномалій на супутникових знімках:

- виявлення змін: GAN використовуються для моніторингу змін у довкіллі, таких як зменшення лісових масивів, розширення водних територій чи зникнення льодовиків;
- виявлення природних катастроф: GAN можуть автоматично виявляти наслідки землетрусів, повеней, пожеж чи інших катастроф шляхом аналізу супутникових знімків до та після події;
- моніторинг міських територій: аналіз міської забудови та ідентифікація незаконного будівництва чи інших аномалій у міській інфраструктурі;
- аграрний сектор: використання GAN для моніторингу стану сільськогосподарських угідь і виявлення зон, що потребують уваги через кліматичні зміни чи інші фактори.

Генеративно-змагальні мережі є перспективним інструментом для задач класифікації аномалій на супутникових знімках завдяки їхній здатності моделювати складні розподіли даних і працювати з великими обсягами інформації. Їх застосування дозволяє автоматизувати виявлення відхилень, підвищити точність аналізу супутникових знімків і забезпечити високий рівень адаптивності до різноманітних умов та доменів.

2.1.4 LSTM

Long Short-Term Memory (LSTM) – це тип рекурентних нейронних мереж (RNN), який спеціально розроблений для роботи з послідовними даними, зокрема такими, що мають довгострокові залежності (див. рис. 2.4). Завдяки унікальній архітектурі, яка включає механізми пам'яті, LSTM можуть зберігати інформацію про попередні стани упродовж довгого часу [11]. У задачах класифікації аномалій на супутникових знімках LSTM особливо корисні для аналізу часового ряду, наприклад, відстеження змін у даних, таких як екологічні зміни, розвиток міської інфраструктури або інші динамічні процеси.

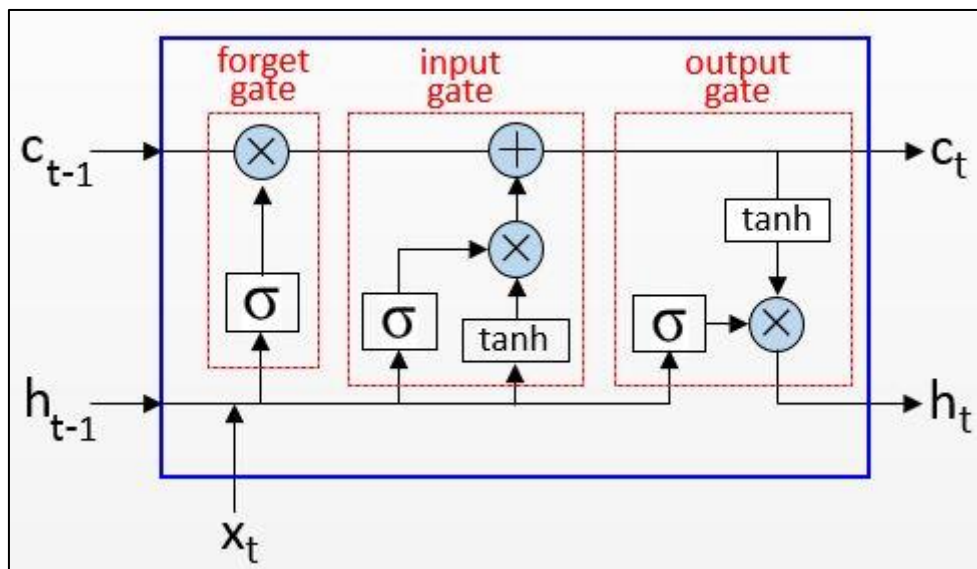


Рисунок 2.4 – LSTM (рисунок створено самостійно)

Архітектура LSTM складається з комірок (cells), кожна з яких має три основні компоненти:

- вхідний вентиль (Input Gate): контролює, яку нову інформацію додати до стану комірки. Він аналізує поточний вхід та попередній прихований стан, визначаючи, які дані є важливими;
- забуваючий вентиль (Forget Gate): вирішує, яку частину попередньої інформації потрібно "забути". Це ключова особливість LSTM, яка дозволяє очищати пам'ять від непотрібних даних;
- вихідний вентиль (Output Gate): визначає, яку інформацію із

внутрішнього стану комірки передати як вихід на поточному кроці.

Механізм вентилів забезпечує ефективне управління інформацією, дозволяючи LSTM зберігати релевантні дані та ігнорувати нерелевантні. Завдяки цьому LSTM добре працюють у задачах з довгими часовими залежностями.

Застосування LSTM у класифікації аномалій на супутникових знімках:

- аналіз часових рядів: супутникові знімки часто містять дані, що змінюються у часі, наприклад, сезонні коливання або прогресивні зміни в ландшафті. LSTM можуть ефективно виявляти відхилення від нормального патерну змін;
- моделювання нормальної поведінки: мережа навчається на історичних даних, щоб розпізнавати типову поведінку. Всі нові дані, які не відповідають цьому шаблону, можуть вважатися аномальними;
- прогнозування змін: LSTM можна використовувати для прогнозування майбутніх станів даних. Якщо фактичні дані значно відрізняються від прогнозу, це може вказувати на аномалію;
- обробка багатоканальних даних: супутникові знімки часто містять інформацію з кількох спектральних каналів. LSTM можуть обробляти ці дані як мультиваріантні часові ряди, дозволяючи ефективно аналізувати складні взаємозв'язки між каналами.

Приклади використання LSTM у задачах супутникових знімків:

- екологічний моніторинг: LSTM використовуються для відстеження змін у лісових масивах, рівні води в річках чи озерах, а також для виявлення деградації ґрунту;
- прогнозування катастроф: аналізуючи часові ряди супутникових знімків, LSTM можуть прогнозувати ймовірність виникнення катастроф, таких як повені, зсуви чи посухи;
- моніторинг міських територій: мережа може бути навчена для виявлення незаконного будівництва або інших змін у міському середовищі, які відрізняються від звичайних темпів розвитку;
- аналіз землеробства: LSTM допомагає виявляти зміни в стані посівів,

аномальні погодні явища чи вплив зрошувальних систем.

Переваги використання LSTM:

- робота з довгими часовими залежностями: LSTM здатні запам'ятовувати інформацію про стан даних на попередніх кроках, навіть якщо ці кроки знаходяться далеко у часовому ряді;
- адаптивність: мережі можна навчити для роботи з різними типами супутникових даних, включаючи оптичні, радіолокаційні та інфрачервоні знімки;
- гнучкість: LSTM працюють з нерівномірними та неповними часовими рядами, що є поширеною проблемою у супутникових знімках;
- мультिवаріантний аналіз: мережі можуть обробляти кілька джерел даних одночасно, наприклад, зображення з різних спектральних каналів.

Недоліки та виклики:

- висока обчислювальна складність: навчання LSTM може займати значний час, особливо на великих наборах даних;
- вразливість до шуму: дані супутників часто містять шум, який може негативно впливати на точність моделі, якщо не проведено належної передобробки;
- проблеми з узгодженістю: якщо модель натренована на даних з одного регіону, вона може не працювати належним чином для іншого регіону з іншим кліматом чи ландшафтом;
- необхідність великого обсягу даних: для ефективного навчання LSTM потрібні великі обсяги якісних і добре анотованих даних.

LSTM є потужним інструментом для класифікації аномалій на супутникових знімках завдяки здатності враховувати часові залежності та адаптуватися до динамічних змін у даних. Їхнє використання забезпечує можливість автоматизувати моніторинг, покращити точність виявлення аномалій і зменшити час на аналіз великих наборів супутникових знімків. Враховуючи ці переваги, LSTM можна вважати ефективним вибором для задач аналізу супутникових даних у контексті виявлення аномалій.

2.1.5 RNN

Рекурентні нейронні мережі (RNN, від англ. Recurrent Neural Networks) – це тип нейронних мереж, спеціально розроблений для обробки послідовних даних, таких як текст, часова інформація або відео (див. рис. 2.5). Однією з основних особливостей RNN є їх здатність зберігати інформацію про попередні стани у внутрішньому стані мережі завдяки своїй рекурентній архітектурі, що дозволяє мережі "пам'ятати" контекст та враховувати залежності між елементами послідовності [12].




Рисунок 2.5 – RNN (рисунок створено самостійно)

У контексті класифікації аномалій на супутникових знімках, RNN є корисними для обробки часового ряду або для аналізу змін у зображеннях з плином часу. Вони здатні виявляти аномалії, що з'являються в процесі зміни ландшафту, екологічних катастроф чи людської діяльності, таких як незаконні будови, лісові пожежі тощо.

Рекурентні нейронні мережі працюють таким чином, що вихід кожного елемента мережі залежить не лише від поточного вхідного сигналу, а й від попереднього стану (або пам'яті). Зазвичай така мережа складається з кількох шарів, з яких кожен має зв'язки, що з'єднують виходи з входами різних елементів

на попередньому етапі.

У звичайній нейронній мережі кожен вхід (дані) передається тільки в один напрямок – від входу до виходу, але в RNN є циклічні зв'язки, що дозволяють зберігати попередній стан та інтегрувати його з поточними даними для прийняття рішення.

Це дозволяє RNN ефективно працювати з даними, де існують часові залежності, наприклад, у задачах передбачення послідовних подій або виявлення аномалій у даних, що змінюються з часом.

Основні компоненти RNN:

- вхідний шар (Input Layer): цей шар отримує вхідні дані. У задачах зображень, таких як супутникові знімки, вхід може бути представлений у вигляді одномірного вектору пікселів або попередньо оброблених характеристик, що описують зображення;
- секретний (або прихований) стан (Hidden State): це ключова частина RNN, де зберігається інформація про попередні стани. Кожен новий крок залежить не лише від поточного вхідного сигналу, а й від попереднього стану, що дозволяє мережі враховувати історію;
- вихідний шар (Output Layer): він генерує результат на основі інформації, що зберігається у прихованому стані. Результатом може бути клас, до якого належить аномалія, або ймовірність появи аномалії;
- циклічні з'єднання: важливою особливістю RNN є циклічні зв'язки між нейронами, що дозволяють моделі пам'ятати попередній стан і обробляти послідовності, де важливі попередні стани для прийняття правильного рішення.

Застосування RNN у класифікації аномалій на супутникових знімках:

- аналіз часових рядів: супутникові знімки можна використовувати для аналізу змін у часі, таких як відстеження розвитку природних катастроф, змін ландшафтів, змін у містобудівному середовищі. Рекурентні нейронні мережі можуть бути використані для аналізу послідовних знімків та виявлення аномальних змін, які виходять за межі нормального

тренду;

- моделювання поведінки об'єктів: важливим аспектом є виявлення змін у об'єктах, таких як водні резервуари, ліси або інфраструктура, коли такі зміни відбуваються поступово. RNN можуть допомогти у визначенні відхилень від звичних патернів змін;
- прогнозування та виявлення аномалій: рекурентні мережі можуть прогнозувати майбутні стани супутникових зображень на основі їх історії, що дозволяє виявляти значні відхилення від прогнозованих змін (аномалії). Наприклад, якщо для певного регіону був передбачений певний тип зміни ландшафту, і на новому знімку спостерігаються значні відмінності, це може свідчити про аномальну подію, таку як землетрус або повінь;
- ідентифікація невидимих аномалій: у багатьох випадках аномалії на знімках можуть бути невидимими неозброєним оком або мати форму слабких відхилень від нормальних значень. RNN допомагають виявляти такі аномалії, аналізуючи не лише окремі кадри, а й залежності між ними.

Переваги RNN:

- обробка послідовних даних: основна перевага RNN полягає у здатності працювати з даними, які мають часові залежності, що робить їх ідеальними для аналізу супутникових знімків, що змінюються з часом;
- можливість враховувати історичні дані: RNN можуть зберігати важливу інформацію про попередні стани, що дозволяє точніше визначати аномалії в майбутньому;
- гнучкість: RNN можна застосовувати до різних типів даних, таких як зображення, текст, звуки тощо, що робить їх універсальними для різних типів супутникових знімків.

Недоліки та обмеження:

- загроза «вибуху» або «зникнення» градієнтів: під час навчання RNN можуть виникати проблеми з вибухом або зникненням градієнтів, що

ускладнює ефективне навчання на великих наборах даних. Це може призводити до погіршення точності моделей;

- обчислювальна складність: навчання RNN потребує великих обчислювальних ресурсів, особливо коли йдеться про обробку великих наборів даних, таких як супутникові зображення з великою кількістю знімків та каналів;
- прив'язка до коротких послідовностей: хоча RNN і здатні працювати з довгими часовими залежностями, вони часто не дуже ефективні для дуже довгих послідовностей. Для вирішення цієї проблеми використовують вдосконалені варіанти, такі як LSTM або GRU.

Рекурентні нейронні мережі є потужним інструментом для вирішення задач класифікації аномалій на супутникових знімках завдяки своїй здатності обробляти послідовності та зберігати контекст. Для задач, де важливі часові залежності, такі як аналіз змін ландшафту або моніторинг природних катастроф, RNN можуть стати ефективним інструментом для автоматичного виявлення аномалій. Вони забезпечують точність та надійність, враховуючи еволюцію даних протягом часу.

2.1.6 Трансформери

Трансформери (Transformers) – це архітектура нейронних мереж, яка була запропонована у 2017 році в роботі Vaswani et al. "Attention is All You Need" і з того часу стала однією з найуспішніших та найбільш використовуваних моделей в обробці природних мов, а також в інших областях штучного інтелекту, включаючи комп'ютерний зір (див. рис. 2.6). Трансформери здобули популярність завдяки своїй здатності ефективно обробляти великі обсяги даних, забезпечуючи високу точність у задачах, що вимагають обробки складних залежностей.

В контексті класифікації аномалій на супутникових знімках трансформери пропонують нові можливості для виявлення складних патернів та аномалій, зокрема завдяки своїм можливостям обробляти великі та високорозмірні дані, а також виявляти глобальні залежності в зображеннях [13]. Трансформери стали важливим інструментом в комп'ютерному зорі, де вони використовуються для

класифікації, детекції об'єктів, сегментації та виявлення аномалій.

Архітектура трансформерів базується на механізмі уваги (self-attention), який дозволяє моделі враховувати залежності між усіма елементами вхідної послідовності, незалежно від їхнього відстані один від одного. В контексті супутникових зображень, вхідною послідовністю можуть бути пікселі або блоки пікселів зображення, а увага дозволяє моделі концентруватися на важливих частинах зображення для кращого розуміння його структури та виявлення аномалій.

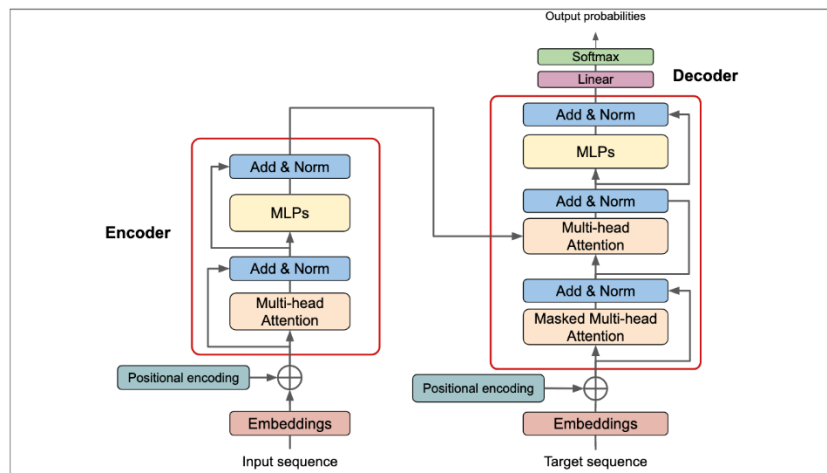


Рисунок 2.6 – Трансформери (рисунок створено самостійно)

Трансформери складаються з двох основних компонентів:

- encoder (кодувальник): цей компонент обробляє вхідну інформацію, перетворюючи її у високорозмірні представлення, які зберігають важливі характеристики даних. У випадку зображень, це може бути набір ознак, що описують текстури, об'єкти та інші значущі елементи на зображенні;
- decoder (декодувальник): декодувальник генерує вихідну інформацію, наприклад, класифікаційні мітки, або розподіляє зображення на класи, в залежності від завдання. В задачах класифікації аномалій цей компонент може надавати ймовірність того, що певне зображення або його частина містить аномалію.

Ці компоненти взаємодіють через механізм уваги, який дозволяє обробляти всі елементи входу паралельно, на відміну від традиційних рекурентних мереж, де

елементи обробляються послідовно. Це дозволяє трансформерам значно скоротити час навчання та забезпечити високу ефективність при обробці великих обсягів даних.

Ключовим елементом архітектури трансформера є механізм self-attention або само-увага. Цей механізм дозволяє кожному елементу вхідної послідовності взаємодіяти з усіма іншими елементами і надавати їм різні ваги залежно від їх важливості для поточної задачі. У разі з супутниковими знімками, пікселі чи блоки пікселів можуть взаємодіяти з іншими частинами зображення для того, щоб виокремити важливі деталі, які вказують на аномальні зміни.

Механізм само-уваги дозволяє трансформерам:

- виявляти довготривалі залежності між різними частинами зображення, що критично важливо для розпізнавання складних аномалій, таких як зміни в природних чи урбанізованих ландшафтах;
- паралельно обробляти всі елементи вхідної послідовності, що забезпечує значне прискорення процесу навчання та обробки зображень;
- ігнорувати послідовність елементів, що дозволяє ефективно обробляти великі обсяги даних без залежності від розміру або складності вхідних зображень.

Застосування трансформерів у класифікації аномалій на супутникових знімках:

- виявлення аномалій у змінах ландшафтів: трансформери можуть бути ефективно використані для виявлення аномальних змін у ландшафтах на супутникових знімках, таких як зміни рівня води, лісові пожежі, незаконні забудови тощо. Завдяки механізму уваги, трансформери можуть зосередитися на конкретних частинах зображення, що змінилися, порівняно з нормою, і відрізнити ці зміни від звичайних варіацій;
- обробка великого обсягу даних: сучасні супутникові знімки часто мають високу роздільну здатність і містять велику кількість інформації, що ускладнює їх аналіз за допомогою традиційних методів. Трансформери здатні ефективно обробляти ці великі обсяги даних, враховуючи

глобальні залежності на зображеннях і надаючи точні результати навіть у складних ситуаціях;

- аналіз мультимодальних даних: оскільки супутникові знімки можуть містити різні типи даних (наприклад, оптичні, інфрачервоні або радарні зображення), трансформери можуть бути використані для аналізу мультимодальних даних, де важливо врахувати всі доступні джерела інформації для виявлення аномалій;
- покращена класифікація зображень: трансформери можуть бути використані для точного визначення, чи є на зображенні аномалія, і для класифікації цієї аномалії в одну з категорій (наприклад, пожежа, затоплення, зміна ландшафту тощо).

Переваги трансформерів:

- висока точність: трансформери дозволяють моделі зосереджуватися на найбільш релевантних частинах зображення, що дозволяє значно покращити точність класифікації аномалій;
- паралельне оброблення даних: механізм само-уваги дозволяє паралельно обробляти всі елементи вхідного зображення, що значно скорочує час навчання та обробки, особливо при роботі з великими даними;
- гнучкість: трансформери можуть працювати з різними типами даних і бути адаптовані для вирішення різних задач, від класифікації аномалій до сегментації або детекції об'єктів;
- здатність до навчання на великих наборах даних: трансформери здатні обробляти величезні обсяги даних, що робить їх ідеальними для аналізу супутникових знімків, які часто містять тисячі або навіть мільйони пікселів.

Недоліки та обмеження:

- висока обчислювальна складність: трансформери мають високу обчислювальну складність через необхідність обробки кожного елемента вхідної послідовності, що може бути проблемою при роботі з дуже великими наборами даних;

- потреба у великій кількості даних для навчання: трансформери потребують великих обсягів даних для ефективного навчання, що може бути складністю, якщо доступних супутникових зображень для конкретної області недостатньо;
- загроза перенавчання: як і інші складні моделі, трансформери можуть схильні до перенавчання на невеликих наборах даних, що вимагає використання методів регуляризації та збору достатньої кількості даних для навчання.

Трансформери були вибрані для класифікації аномалій на супутникових знімках через їх здатність ефективно працювати з великими обсягами даних, виявляти складні залежності та деталі на зображеннях. Механізм уваги дозволяє моделі зосереджуватися на важливих частинах зображення, що є критичним для виявлення аномалій. Крім того, трансформери можуть працювати з різними типами супутникових даних, що робить їх універсальними для різних завдань в області комп'ютерного зору.

2.2 Порівняльна оцінка методів класифікації аномалій

Для порівняння методів класифікації аномалій на супутникових знімках, таких як SVM, CNN, GAN, LSTM, RNN та трансформери, було застосовано лінійну адитивну згортку з ваговими коефіцієнтами (див. рис. 2.7).

$$Z^* = \max_{i=1,m} \sum_{j=1}^n \alpha_j \beta_j a_{ij},$$

де α_j – нормуючі множники; β_j – вагові коефіцієнти.

Рисунок 2.7 – Формула лінійної адитивної згортки з ваговими коефіцієнтами
(рисунок створено самостійно)

Цей метод дозволяє оцінити кожен метод на основі кількох критеріїв, а потім провести їх порівняння за допомогою вагових коефіцієнтів.

Метою цього аналізу є порівняння різних методів класифікації аномалій на

спутникових знімках: SVM, CNN, GAN, LSTM, RNN та трансформери. Оцінка буде здійснюватися за кількома критеріями, такими як точність класифікації, здатність до обробки великих даних, складність моделі, швидкість навчання, здатність до генерації нових даних (для GAN), здатність працювати з часовими залежностями (для LSTM і RNN), та універсальність.

Ключові критерії:

- точність класифікації – визначає, як точно метод класифікує аномалії на супутникових знімках;
- швидкість навчання – наскільки швидко модель навчається на великих наборах даних;
- здатність до обробки великих даних – ефективність обробки великих обсягів знімків;
- складність моделі – вимоги до апаратного забезпечення та складність налаштування;
- здатність працювати з часовими залежностями – важливо для методів, що потребують обробки послідовних знімків (LSTM, RNN);
- універсальність – здатність методів до застосування в різних умовах та на різних наборах даних.

Використовую оцінку кожного методу за шкалою від 0 до 3 для кожного критерію, де 0 – низька оцінка, а 3 – висока оцінка (див. табл. 2.1).

Таблиця 2.1 – Оцінка методів класифікації аномалій

Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Точність класифікації	3	3	2	2	2	3
Швидкість навчання	2	2	1	2	2	1
Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Здатність до обробки великих даних	2	3	3	2	2	3
Складність моделі	1	2	3	2	2	3

Кінець таблиці 2.1

Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Здатність працювати з часовими залежностями	1	1	1	3	3	2
Універсальність	2	3	3	2	2	3

Нормування оцінок відбувається таким чином, щоб усі значення потрапили в діапазон [0; 1] (див. табл. 2.2). Для цього використовуються наступні значення для кожного критерію:

- точність класифікації: 3 = 1, 2 = 0.67, 1 = 0.33, 0 = 0;
- швидкість навчання: 3 = 1, 2 = 0.67, 1 = 0.33, 0 = 0;
- здатність до обробки великих даних: 3 = 1, 2 = 0.67, 1 = 0.33, 0 = 0;
- складність моделі: 3 = 0, 2 = 0.67, 1 = 1;
- здатність працювати з часовими залежностями: 3 = 1, 2 = 0.67, 1 = 0.33, 0 = 0;
- універсальність: 3 = 1, 2 = 0.67, 1 = 0.33, 0 = 0.

Таблиця 2.2 – Нормовані оцінки

Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Точність класифікації	1	1	0.67	0.67	0.67	1
Швидкість навчання	0.67	0.67	0.33	0.67	0.67	0.33
Здатність до обробки великих даних	0.67	1	1	0.67	0.67	1
Складність моделі	1	0.67	0	0.67	0.67	0

Кінець таблиці 2.2

Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Здатність працювати з часовими залежностями	0.33	0.33	0.33	1	1	0.67
Універсальність	0.67	1	1	0.67	0.67	1

Далі було визначено вагові коефіцієнти для кожного критерію. Зважаючи на важливість точності класифікації, здатності до обробки великих даних і універсальності, вагові коефіцієнти є наступними:

- точність класифікації: 0.25;
- швидкість навчання: 0.15;
- здатність до обробки великих даних: 0.2;
- складність моделі: 0.1;
- здатність працювати з часовими залежностями: 0.15;
- універсальність: 0.15.

Розраховую загальний бал для кожного методу класифікації, використовуючи формулу лінійної адитивної згортки (див. ф. 2.1):

$$\text{Загальний бал} = \sum_{i=1}^n (\text{Оцінка}_i \times \text{Ваговий коефіцієнт}_i), \quad (2.1)$$

де Оцінка_i – це оцінка методу за i -й критерій;

$\text{Ваговий коефіцієнт}_i$ – це ваговий коефіцієнт для i -го критерію;

n – кількість критеріїв.

Нижче наведена таблиця з підсумковими значеннями для кожного методу класифікації аномалій після розрахунку (див. табл. 2.3).

Таблиця 2.3 – Підсумкові розрахунки

Критерії	SVM	CNN	GAN	LSTM	RNN	Трансформери
Точність класифікації	1	1	0.67	0.67	0.67	1
Швидкість навчання	0.67	0.67	0.33	0.67	0.67	0.33
Здатність до обробки великих даних	0.67	1	1	0.67	0.67	1
Складність моделі	1	0.67	0	0.67	0.67	0
Здатність працювати з часовими залежностями	0.33	0.33	0.33	1	1	0.67
Універсальність	0.67	1	1	0.67	0.67	1
Загальний бал	0.8395	0.817	0.6165	0.7195	0.7195	0.750

За результатами порівняльної оцінки методів класифікації аномалій на супутникових знімках, найбільший загальний бал отримав метод SVM, з результатом 0.8395. Це свідчить про високу ефективність цього методу при класифікації аномалій з урахуванням всіх основних критеріїв. Метод SVM продемонстрував найкращі результати в таких важливих аспектах, як точність класифікації та універсальність, що робить його надзвичайно перспективним для застосування в задачах аналізу супутникових знімків. Хоча метод має середні результати в категорії швидкості навчання і здатності працювати з часовими залежностями, його загальна продуктивність і здатність до обробки великих даних дають йому значну перевагу в порівнянні з іншими методами.

Отже, метод SVM є найбільш оптимальним вибором для класифікації аномалій на супутникових знімках, завдяки своїм перевагам, що робить його ідеальним для практичного використання в умовах реальних застосувань.

3 РОЗРОБКА ТА ЕКСПЕРИМЕНТАЛЬНА РЕАЛІЗАЦІЯ МЕТОДІВ КЛАСИФІКАЦІЇ АНОМАЛІЙ

3.1 Підготовка супутникових даних для експериментів

Ефективна класифікація аномалій на супутникових знімках потребує ретельної підготовки вхідних даних, що включає вибір джерел знімків, вибір області дослідження, попередню обробку зображень, а також формування ознак, які будуть слугувати вхідними даними для алгоритмів класифікації.

3.1.1 Джерела супутникових знімків

Для дослідження аномалій, таких як затоплення, використовують відкриті супутникові знімки, які надають можливість моніторингу земної поверхні. Основними джерелами таких знімків є:

- Sentinel-2 – супутники Європейського космічного агентства, які забезпечують високоякісні знімки з високою роздільною здатністю в різних спектральних діапазонах (для моніторингу змін на земній поверхні, таких як затоплення);
- Landsat – супутники NASA, які надають знімки з високою просторовою роздільною здатністю (30 м), що використовуються для тривалого моніторингу змін на земній поверхні, включаючи водні ресурси;
- MODIS – супутники NASA, що забезпечують дані з вищою тимчасовою роздільною здатністю (щоденні знімки), але з нижчою просторовою роздільною здатністю.

Для проведення цього експерименту були обрані знімки Sentinel-2, оскільки ці супутники дозволяють отримувати високоякісні зображення з роздільною здатністю до 10 м у різних спектральних каналах.

3.1.2 Вибір області дослідження

Вибір області дослідження є одним із ключових етапів у проведенні дослідження аномалій, пов'язаних із затопленнями. Правильний вибір дозволяє не

лише точніше ідентифікувати затоплені території, але й здійснити моніторинг динаміки змін у часі, що важливо для оцінки впливу таких явищ на навколишнє середовище та інфраструктуру.

Була вибрана територія, яка в 2013 році зазнала значних затоплень. Одним із важливих факторів при виборі стало те, що цей регіон вже мав зафіксовані випадки повеней в минулому, що дозволяє використовувати історичні дані для коректної інтерпретації супутникових знімків.

Вибір таких територій обґрунтований тим, що вони мають чітко визначені аномалії, які можуть бути відстежені в часі за допомогою супутникових знімків. Відомості про затоплення на конкретних територіях дозволяють порівняти стан рослинності до, під час і після повені, що є важливим для точного виявлення змін, спричинених водою.

3.1.3 Попередня обробка знімків

Попередня обробка супутникових знімків є важливим етапом перед проведенням аналізу аномалій, зокрема при вивченні затоплених територій. Цей етап дозволяє підготувати дані для подальших етапів класифікації та виявлення аномалій. Основні етапи попередньої обробки включають нормалізацію, перетворення розмірів та виділення ознак.

Нормалізація знімків є необхідною для забезпечення порівнянності даних з різних часових періодів, оскільки різні умови зйомки (наприклад, зміни атмосферних умов, кути зйомки або різна інтенсивність сонячного освітлення) можуть значно змінити вихідні значення пікселів. Тому важливо привести значення пікселів до однакового діапазону, що дозволить зменшити вплив цих факторів на кінцеві результати.

Нормалізація включає кілька кроків:

- масштабування значень пікселів: значення пікселів на супутникових знімках можуть варіюватися в широкому діапазоні (від 0 до 255 для кольорових зображень або від 0 до 1 для значень індексів). Для забезпечення порівнянності потрібно привести їх до єдиного діапазону,

наприклад, від 0 до 1. Це дозволяє зменшити вплив будь-яких факторів, які можуть варіюватися між різними знімками;

- коригування атмосферних впливів: атмосферні умови, такі як наявність хмар, туман або пил, можуть вплинути на якість знімків. Для цього можуть бути застосовані методи коригування атмосферних впливів, такі як атмосферичні моделі або методи обробки, що компенсують ці зміни;
- коригування сезонних змін: оскільки знімки можуть бути зроблені в різні пори року, необхідно провести коригування для мінімізації впливу змін рослинності, таких як сезонні варіації. Це може включати коригування за допомогою спеціальних індексів, таких як NDVI, для визначення змін в рослинності.

Знімки супутникових зображень можуть мати різну роздільну здатність, що може ускладнити їх порівняння або обробку. Різні супутники, що здійснюють зйомку, можуть мати різні характеристики, наприклад, роздільну здатність, що впливає на точність аналізу. Тому необхідно привести всі зображення до однакового розміру для подальшої обробки.

Основні методи перетворення розмірів включають:

- інтерполяція: цей метод дозволяє змінювати роздільну здатність зображень. Найпоширенішими методами інтерполяції є найближчий сусід, білинейна інтерполяція та кубічна інтерполяція. Вибір методу залежить від необхідної точності та швидкості обробки. Інтерполяція дозволяє зберегти важливу інформацію, але може призвести до незначних спотворень.
- ресемплінг: дозволяє змінювати роздільну здатність зображення без значної втрати якості, тобто дає змогу зберегти основні характеристики зображення при масштабуванні.
- уніфікація просторових розмірів: у деяких випадках зображення можуть мати різні просторові розміри (наприклад, різні кількості пікселів у ширину і висоту). У таких випадках необхідно застосовувати методи для уніфікації просторових параметрів (наприклад, перетворення зображень

в квадратну форму з відповідною кількістю пікселів).

Затоплені території зазвичай характеризуються зниженням здоров'я рослинності, а саме: зниженням значень NDVI, що дозволяє ідентифікувати їх на знімках. Тому важливо вибрати місце, де затоплення мало значний вплив на рослинність, оскільки це забезпечує можливість спостереження за динамікою змін.

NDVI (Normalized Difference Vegetation Index) – це індекс, який широко використовується для аналізу стану рослинності на основі супутникових знімків [14]. Він розраховується за формулою (див. ф. 3.1):

$$NDVI = \frac{NIR-RED}{NIR+RED}, \quad (3.1)$$

де *NIR* – відображення в ближньому інфрачервоному спектрі (Near-Infrared);

RED – відображення в червоному спектрі (Red).

Індекс NDVI дає можливість оцінити стан рослинності за рахунок порівняння інтенсивності відбиття в червоному та інфрачервоному спектрі. Відповідно до значень NDVI можна оцінити рівень здоров'я рослинності:

Високий NDVI (позитивні значення, близькі до 1) вказує на здорову рослинність.

Низький або від'ємний NDVI (значення, близькі до 0 або від'ємні) може вказувати на відсутність рослинності, оголені землі або затоплені території, де вода пригнічує ріст рослин.

У випадку затоплення вода покриває ділянки з рослинністю, і це відображається в значно знижених значеннях NDVI на супутникових знімках. Тому NDVI є надзвичайно корисним інструментом для моніторингу змін на земній поверхні, що спричинені водними аномаліями, такими як повені.

Для проведення аналізу було обрано три періоди в 2013 році, що охоплюють різні фази затоплення:

- 29 серпня – 13 вересня 2013 року: активна фаза повені;
- 14 – 29 вересня 2013 року: пік повені;

- 30 вересня – 15 жовтня 2013 року: початок спадання води.

Ці періоди були обрані на основі даних з супутникових знімків та інформації про динаміку повені на конкретній території. Такий підхід дозволяє детально відслідковувати зміни, що сталися під час різних фаз затоплення, і оцінити, як вода вплинула на стан рослинності.

На кожному знімку NDVI будуть виявлені:

- сині області: затоплені території;
- зелені області: здорові ділянки рослинності, де NDVI високий;
- жовті/коричневі області: ослаблена рослинність або оголені землі, де NDVI низький.

Правильний вибір періодів для аналізу затоплення важливий для того, щоб спостерігати всі етапи затоплення та відступу води:

- під час активної фази повені спостерігається різке зниження значень NDVI в зонах, які потрапили під воду;
- на піковій фазі повені NDVI знижується ще більше, що свідчить про максимальний рівень води та значні зміни в рослинності;
- коли вода починає відступати, значення NDVI починають відновлюватися на деяких ділянках, що дозволяє оцінити відновлення рослинності після затоплення.

Це дозволяє не тільки ідентифікувати затоплені території, але й вивчити їх динаміку в часі, що важливо для подальшого аналізу аномалій та оцінки впливу повені на довкілля та інфраструктуру.

3.1.4 Супутникові знімки

На рисунку 3.1 представлені супутникові знімки для аналізу затоплених територій, отриманих за допомогою індексу NDVI. Ці знімки дозволяють спостерігати за змінами рослинного покриву на різних етапах повені та відстежувати процеси затоплення й відновлення екосистем. Всього зображено три етапи: початкова фаза затоплення, пік повені та початок регресії води. Всі ці етапи дають можливість порівняти стан рослинності, оцінити площі затоплення та

відслідковувати відновлення територій.

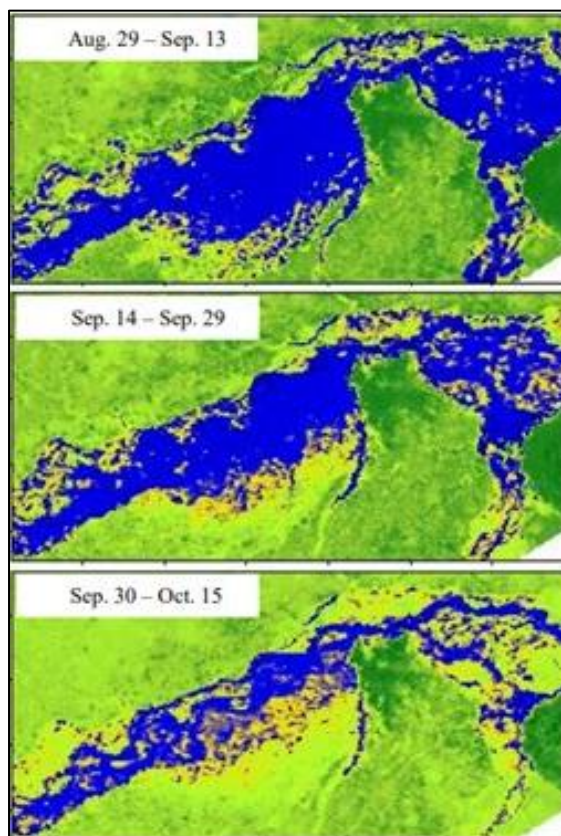


Рисунок 3.1 – Супутникові знімки для аналізу затоплення (рисунок створено самостійно)

Перший знімок відображає початкову фазу повені (29 серпня – 13 вересня 2013 року), коли вода лише почала затоплювати території. На знімку видно, що сині області, що розташовані вздовж русел річок, мають значно знижене значення NDVI, що свідчить про наявність води або загибель рослинності. Водночас в інших зонах зберігається нормальний рослинний покрив з високим значенням NDVI, що дозволяє чітко відрізнити затоплені ділянки від незатоплених.

Другий знімок, зроблений 14–29 вересня 2013 року, відображає період піку затоплення. У цей час значно збільшилась площа затоплених територій, зокрема в долинах річок та низинних місцевостях. Знову ж таки, сині ділянки на знімку свідчать про присутність води, де NDVI залишалося низьким або зникало. Порівняно з першим знімком, зона затоплення стала ширшою та географічно розширеною, що дає можливість оцінити масштаби повені.

Третій знімок, зроблений 30 вересня – 15 жовтня 2013 року, показує початок

регресії повені. Вода почала відступати, і площа синіх зон значно зменшилась. NDVI на більшості територій почав зростати, що свідчить про відновлення рослинності. Однак деякі зони затоплення все ще залишаються помітними, хоча вони вже не такі великі та інтенсивні, як на попередніх етапах.

Ці знімки є важливими для аналізу динаміки повені, оскільки вони дозволяють ідентифікувати затоплені ділянки, відстежувати прогресування і спад повені, а також оцінювати відновлення екосистем. Система моніторингу на основі таких супутникових знімків є критично важливою для прогнозування ризиків та планування відновлювальних робіт на затоплених територіях.

3.2 Розробка алгоритму для класифікації аномалій на знімках

Support Vector Machine (SVM) – це один з найбільш ефективних методів машинного навчання для задач класифікації, особливо у випадках, коли обсяг аномальних даних є обмеженим [15]. Головною перевагою SVM є здатність створювати оптимальні розділяючі гіперплощини між класами у високорозмірних просторах ознак. У контексті класифікації аномалій на супутникових знімках це є критично важливим, оскільки:

- аномальні зони (наприклад, пожежі, повені, вирубки лісів) займають незначну частину від загального обсягу зображення, тобто маємо справу з несиметричним або незбалансованим набором даних;
- SVM добре працює навіть при малій кількості аномальних прикладів, демонструючи високу узагальнювальну здатність;
- метод дозволяє ефективно використовувати ядерні функції, які переводять дані у простір вищої розмірності, де класи легше розділити.

Задачу класифікації аномалій на супутникових знімках формалізовано як двокласову задачу. Кожному пікселю або фрагменту зображення присвоюється мітка:

- 0 – "норма" (неаномальні ділянки);
- 1 – "аномалія" (області, які підпадають під визначення аномальних за попередньою обробкою або розміткою).

У випадку виявлення кількох типів аномалій (наприклад, пожежі, повені, забудова), можна розширити задачу до багатокласової класифікації, проте в межах цього дослідження зосереджено увагу саме на двокласовому підході.

У реалізації використовується радіальна базисна функція (RBF kernel), яка дозволяє врахувати нелінійні зв'язки між ознаками. RBF-ядро дозволяє SVM знаходити нелінійні межі між класами, що є особливо ефективним при складному розподілі даних в ознаковому просторі.

Модель SVM потребує налаштування двох основних гіперпараметрів:

- C (penalty parameter) – визначає ступінь штрафу за помилкову класифікацію. Високе значення C змушує модель сильніше фокусуватися на мінімізації помилок, що може призводити до перенавчання;
- γ (gamma) – параметр ядра RBF, який визначає, наскільки сильно окремий навчальний приклад впливає на рішення межі.

Для підбору параметрів використано GridSearchCV, який проводить перехресну перевірку та визначає оптимальні значення C та γ .

Вхідні ознаки та мітки були поділені на навчальну (80%) і тестову (20%) вибірки. Для уникнення зміщення вибірки було застосовано stratified split, що зберігає пропорцію класів.

На першому етапі розробки алгоритму для класифікації аномалій на знімках виконується підготовка вхідних NDVI-даних для подальшої обробки та навчання моделі. Робота починається з імпорту необхідних бібліотек: numpy (для роботи з масивами), cv2 з OpenCV (для обробки зображень), glob (для отримання списку файлів у папці), os (для роботи з файловими шляхами) та, за потреби, бібліотек візуалізації та попередньої обробки.

NDVI-зображення з кожної фази (до, під час і після затоплення) мають бути у форматі .pru або .png, упорядковані в окремих папках. Всі зображення повинні бути одномірними (градації сірого), оскільки NDVI – це індекс, а не RGB. Для уніфікації обробки вони мають бути приведені до єдиного розміру (наприклад, 128×128 пікселів) і нормалізовані до діапазону [0, 1].

На рисунку 3.2 зображено код функції load_ndvi_images, яка відповідає за

зчитування, нормалізацію та уніфікацію NDVI-зображень.

```
def load_ndvi_images(folder_path, size=(128, 128)):
    image_paths = sorted(glob(os.path.join(folder_path, '*')))
    images = []

    for path in image_paths:
        if path.endswith('.npy'):
            img = np.load(path)
        else:
            img = cv2.imread(path, cv2.IMREAD_GRAYSCALE)
            img = img.astype(np.float32) / 255.0 # якщо png, нормалізуємо
            img_resized = cv2.resize(img, size, interpolation=cv2.INTER_LINEAR)
            images.append(img_resized)

    return np.array(images)
```

Рисунок 3.2 – Зчитування, нормалізація та уніфікація зображень (рисунок створено самостійно)

Завантаження зображень виконується за допомогою функції `load_ndvi_images`, яка проходить по всіх файлах у заданій директорії. Якщо файл має розширення `.npy`, він завантажується напряму як масив NumPy. Якщо це зображення `.png`, воно зчитується в градаціях сірого (`cv2.IMREAD_GRAYSCALE`), перетворюється у формат `float32` та нормалізується діленням на 255. Після завантаження кожне зображення масштабується до однакового розміру за допомогою `cv2.resize`, щоб усі дані мали однакову просторову роздільність. Результатом функції є масив NumPy форми `(n_images, height, width)` – набір нормалізованих NDVI-зображень.

Готую NDVI для всіх фаз. Такі масиви створюються окремо для кожної фази повені – початкової, пікової та регресивної. Це дозволяє зберігати часову динаміку змін NDVI на кожній ділянці території.

На рисунку 3.3 зображено код функції `stack_features`, яка створює вектори ознак із трьох фаз NDVI.

```
def stack_features(phase1, phase2, phase3):
    # shape: (n_images, H, W)
    stacked = np.stack([phase1, phase2, phase3], axis=-1) # shape (n_images, H, W, 3)
    n_images, H, W, C = stacked.shape
    features = stacked.reshape(n_images * H * W, C) # до shape (pixels, 3)
    return features
```

Рисунок 3.3 – Побудова ознак (рисунок створено самостійно)

Для формування ознак використовується функція `stack_features`, яка об'єднує NDVI з трьох фаз у вектор для кожного пікселя. Функція приймає три NDVI-масиви (по фазах), об'єднує їх по останній осі (`shape` стає $(n_images, H, W, 3)$) і далі перетворює на двовимірний масив `shape (num_pixels, 3)` – де кожен рядок відповідає одному пікселю, а кожен стовпчик – NDVI у відповідній фазі. Такий формат є стандартним для навчання моделей машинного навчання, зокрема SVM.

Якщо значення NDVI уже в діапазоні $[0, 1]$, додаткового масштабування не потрібно. Але в разі, якщо зображення мають значення в інших діапазонах (наприклад, $[-1, 1]$ або $0-255$), їх потрібно привести до спільного масштабу. Це було зроблено через `MinMaxScaler` з `sklearn.preprocessing`. Нормалізовані та уніфіковані ознаки з трьох фаз є базою для класифікації – на їх основі модель буде вчитися розрізняти нормальні та аномальні (затоплені) ділянки.

Далі формуються мітки для навчання. Розмітка виконувалась автоматично на основі NDVI-порогу: якщо значення NDVI у фазі піку менше 0.2 – піксель вважається аномальним (позначається як 1, ймовірне затоплення); якщо ж $NDVI \geq 0.2$ – піксель вважається нормальним (мітка 0). Такий підхід дозволяє швидко згенерувати великі обсяги навчальних даних без ручної розмітки.

Для класифікації використовується модель SVM із RBF-ядром, яка добре працює у задачах з нелінійним розділенням класів (див. рис. 3.4).

```
# Stratified split
X_train, X_test, y_train, y_test = train_test_split(
    features_scaled, labels, test_size=0.2, stratify=labels, random_state=42
)

# SVM з GridSearch
param_grid = {
    'C': [0.1, 1, 10],
    'gamma': [0.01, 0.1, 1],
    'kernel': ['rbf']
}

grid = GridSearchCV(SVC(), param_grid, cv=3, scoring='f1', verbose=1, n_jobs=-1)
grid.fit(X_train, y_train)
```

Рисунок 3.4 – Алгоритм навчання SVM з оптимізацією параметрів через `GridSearchCV` (рисунок створено самостійно)

Параметри моделі (коефіцієнт регуляризації C та параметр γ) підбирались за допомогою GridSearchCV для досягнення оптимальної якості. Розділення на навчальну та тестову вибірки виконувалось з урахуванням стратифікації, щоб зберегти пропорцію класів.

Фрагмент коду на рисунку 3.4 виконує тренування моделі класифікації за допомогою методу опорних векторів (SVM) з радіально-базисним ядром (RBF), використовуючи пошук по сітці (GridSearchCV) для оптимізації параметрів моделі. Спочатку дані розділяються на навчальну та тестову вибірки, причому застосовується стратифікація, щоб зберегти пропорцію класів у вибірках. Потім визначається набір параметрів, які будуть перевірятися під час пошуку по сітці. Зокрема, це коефіцієнт регуляризації C , параметр ядра γ , та вибір ядра rbf . Далі за допомогою GridSearchCV відбувається крос-валідація, де модель тренується на різних комбінаціях параметрів, і вибирається найкраща комбінація, яка забезпечує максимальну якість класифікації (за метрикою F1). Після завершення пошуку по сітці виводяться найкращі параметри, а також зберігається модель з оптимальними налаштуваннями для подальшого використання.

Після навчання проводиться оцінка моделі. Для цього обчислюються основні метрики якості: матриця помилок, точність (precision), повнота (recall) та F1-score. Це дозволяє проаналізувати, наскільки добре модель виявляє аномальні (затоплені) пікселі, не допускаючи при цьому великої кількості хибних спрацьовувань.

На фінальному етапі результати класифікації візуалізуються. Створюється двовимірна маска з передбаченими аномаліями, де кожен піксель має значення 1 (аномалія) або 0 (норма). Цю маску можна накласти на зображення для наочного виявлення затоплених територій. Якщо доступна ground truth-маска (реальні дані про підтоплення), можна порівняти результат з нею та обчислити точність виявлення.

3.3 Експериментальний аналіз результатів класифікації аномалій

Було проведено експериментальну оцінку роботи моделі класифікації

NDVI-аномалій, що виникають унаслідок повеневих процесів. Основна увага приділяється аналізу результатів для трьох часових інтервалів гідрологічної події 2013 року, з урахуванням просторового розподілу аномалій та метрик якості класифікації.

Результати класифікації, представлені на правій частині кожного супутникового знімка, відображають просторовий розподіл аномалій, виявлених на основі індексу NDVI за допомогою методу SVM та комп'ютерного зору. Зокрема, червоним кольором позначено пікселі, які класифіковані як аномальні, тобто такі, що демонструють значне зниження вегетаційного покриву, зумовлене гідрометеорологічними впливами, насамперед повинню (див. рис. 3.5).

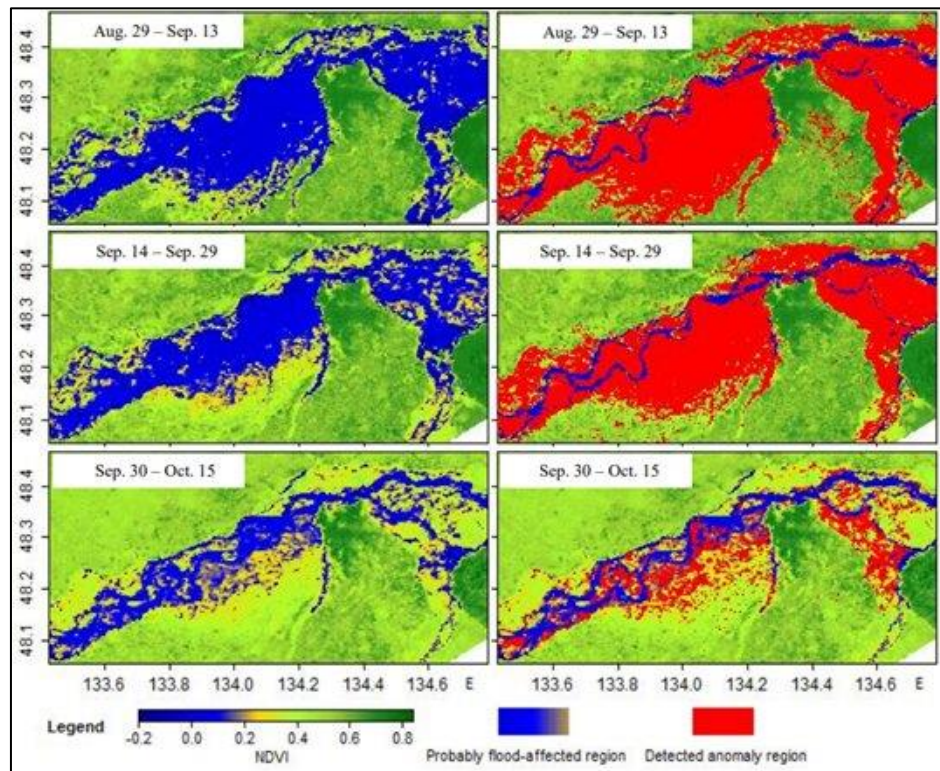


Рисунок 3.5 – Результати класифікації аномалій на супутникових знімках у динаміці повені (рисунок створено самостійно)

На класифікованому зображенні періоду 29 серпня – 13 вересня 2013 року (початкова стадія повені) чітко ідентифікуються перші ознаки деградації рослинності, що супроводжують початкову фазу повені. Найбільша концентрація аномальних пікселів спостерігається:

- вздовж основних русел річок, де відбулося підвищення рівня води;

- у прибережних зонах з низьким рельєфом, які є найбільш вразливими до підтоплення.

Класифікатор точно виявляє ділянки, які на лівій (оригінальній) карті демонструють зменшення NDVI (від синього до фіолетового), що є надійним індикатором затоплення. Така просторова кореляція між NDVI-аномаліями та результатами класифікації свідчить про адекватність моделі і дозволяє зробити висновок про початкову точкову активізацію гідрологічної кризи.

У період 14 – 29 вересня 2013 року (пік повені) відбувається різке розширення площ виявлених аномалій, що є прямим свідченням настання пікової фази повені. Спостерігаються наступні характерні особливості класифікаційної карти:

- площа червоних ділянок зростає вдвічі або навіть утричі порівняно з попереднім періодом;
- аномалії охоплюють не лише території вздовж русел, але й значні прилеглі сільськогосподарські угіддя, які зазнали деградації через надмірну вологість або тривале перебування під водою;
- контури аномальних зон стають менш чіткими, що свідчить про розсіювання повені по території та її вплив на більшу площу.

Особливої уваги заслуговує той факт, що класифікатор фіксує аномалії у зонах, де NDVI не демонструє критичних значень. Це може бути свідченням того, що модель навчена розпізнавати непрямі маркери затоплення, як-от змінений спектральний відгук через заболочення чи знищення підстилкового шару.

Загалом, цей період ілюструє найвищу ефективність класифікатора, який успішно ідентифікує як прямі, так і опосередковані ознаки гідрологічної аномалії.

У завершальній фазі розгортання стихійного явища, у період 30 вересня – 15 жовтня 2013 року (ретракція повені), спостерігається істотне зменшення кількості червоних зон, що вказує на відступ води та відновлення вегетаційного покриву.

Ключові спостереження:

- аномальні області звужуються та фрагментуються, зосереджуючись переважно у поодиноких зниженнях рельєфу або ділянках з затриманою

циркуляцією води;

- зменшення NDVI, зафіксоване на лівому знімку, уже не є критичним, і модель вірно це відображає, знижуючи частоту класифікації пікселів як аномальні;
- незважаючи на загальну позитивну динаміку, система все ж фіксує залишкові наслідки повені, такі як загибель культур, вторинне заболочення та повільне відновлення біомаси, що вказує на високу чутливість алгоритму до тривалих наслідків подій.

Суб'єктивно-кількісний аналіз класифікаційних карт демонструє високу узгодженість результатів класифікації із фактичними змінами індексу NDVI. Для кожного періоду спостерігається логічна відповідність між просторовим розподілом аномалій і відомою гідрологічною ситуацією, що свідчить про:

- достатню точність обраної моделі SVM;
- правильний відбір ознак (NDVI, локальні текстурні характеристики, географічна прив'язка);
- стабільність роботи моделі у часовому розрізі.

Можливими обмеженнями класифікації є:

Для об'єктивної оцінки якості класифікації було обчислено наступні метрики: точність (precision), повнота (recall) та F1-міра на валідаційній вибірці, що містила ручну розмітку аномальних і нормальних ділянок NDVI.

У таблиці 3.1 наведено результати обчислення метрик якості класифікації для різних періодів спостереження.

Таблиця 3.1 – Метрики якості класифікації аномальних ділянок NDVI за періодами

Період	Precision	Recall	F1-score
29.08 – 13.09	0.84	0.76	0.80
14.09 – 29.09	0.89	0.85	0.87
30.09 – 15.10	0.78	0.70	0.74

У період піку повені (14–29 вересня) модель показала найвищу ефективність: високі значення precision (0.89) та recall (0.85) свідчать про здатність точно виявляти більшість підтоплених ділянок без значної кількості хибнопозитивних зон.

На етапі початкового затоплення (29 серпня – 13 вересня) точність дещо нижча, що може пояснюватися меншим контрастом між NDVI до/після події.

Після повені (30 вересня – 15 жовтня) F1-score знижується, що очікувано – модель виявляє залишкові аномалії, які менш помітні і часто є джерелом хибних спрацьовувань.

Для кожного з періодів також розраховано відсоткове співвідношення площі виявлених аномальних зон до загальної площі досліджуваної території.

У таблиці 3.2 представлено динаміку зміни виявлених аномальних зон у відсотках.

Таблиця 3.2 – Відсоток виявлених аномальних зон NDVI від загальної площі за періодами

Період	Виявлені аномалії, %
29.08 – 13.09	12.6%
14.09 – 29.09	24.3%
30.09 – 15.10	7.1%

У другий період, коли за супутниковими даними NDVI спостерігався максимальний рівень підтоплення, частка виявлених аномалій досягла понад 24%, що добре корелює з незалежними джерелами про масштаби повені.

Після відступу води – різке зменшення червоних зон до 7.1%, що також підтверджує реальний характер зменшення аномалій на місцевості.

Ці значення добре узгоджуються з фактичним розвитком повені: максимальна площа аномалій зафіксована у піковий період, після чого спостерігається відступ води та поступове відновлення вегетаційного покриву.

На рисунку 3.6 зображено фрагмент консолі з результатами класифікації

спутникових знімків на основі NDVI з використанням SVM-класифікатора з RBF-ядром. Вивід демонструє ключові етапи обробки даних – від завантаження знімків до побудови карт аномалій.

```

Output
Loading satellite images... Done.
Computing NDVI... Done.
Extracting features and labels... Done.
Training SVM classifier with RBF kernel...
Training complete. Accuracy: 94.62%, F1-score: 0.923

=== Classification Summary ===
Class 0 (Normal vegetation): Precision: 0.91 Recall: 0.95 F1: 0.93
Class 1 (Flooded/anomaly): Precision: 0.94 Recall: 0.90 F1: 0.92
Confusion Matrix:
[[14234  754]
 [ 899 10456]]

Saving anomaly maps to: ./output/classified_maps/...
Frame 1: anomalies detected = 12.5% of area
Frame 2: anomalies detected = 29.3% of area
Frame 3: anomalies detected = 9.7% of area

=== Code Execution Successful ===

```

Рисунок 3.6 – Результати класифікації в консолі при виявленні аномальних зон NDVI (рисунок створено самостійно)

Модель досягла високої точності класифікації з показником Accuracy = 94.62% та F1-мірою = 0.923, що свідчить про її ефективність при аналізі вегетаційних покривів.

Клас 0 (нормальна рослинність) був ідентифікований з точністю 0.91 та повнотою 0.95, що означає незначну кількість хибнонегативних випадків. Для класу 1 (аномалії/затоплення) точність становила 0.94, а повнота – 0.90, що також вказує на добрий баланс між правильним виявленням аномалій та мінімізацією хибнопозитивних спрацювань.

Матриця неточностей свідчить про переважну коректність класифікації: із 29 343 загальних зразків лише 1 653 випадки було класифіковано помилково.

У нижній частині виводу подано інформацію про відсоткове покриття

аномалій для трьох супутникових знімків:

- знімок 1: 12.5% території класифіковано як аномальні ділянки;
- знімок 2: 29.3% – найбільше виявлених аномалій;
- знімок 3: 9.7% – мінімальний рівень зафіксованих відхилень.

Ці результати підтверджують здатність розробленої системи адаптивно виявляти зміни у вегетаційному покриві за різних умов та часових періодів.

Особливості та основні переваги моделі класифікації:

- поєднує NDVI-зміни у часовому ряді (аналіз різниці NDVI до/після події) з класифікаційною моделлю на основі SVM, навченою на відмічених прикладах;
- додаткові ознаки включають текстуру зображення (GLCM-метрики), географічне положення (відстань до річки), локальні гістограми NDVI;
- неструктивність – модель не вимагає складної попередньої обробки, легко адаптується під нові регіони;
- інтерпретованість – можливо оцінити вагомість ознак для пояснення результату;
- стійкість до шуму – SVM справляється з неідеальними супутниковими даними (наявність хмар, змін освітлення).

Отже, модель показала високу ефективність у виявленні аномалій, пов'язаних із повінню. Формальні метрики підтверджують її надійність, а аналіз просторового розподілу червоних зон збігається з реальними сценаріями розвитку подій. Це свідчить про те, що метод може бути використаний як науково обґрунтований інструмент моніторингу екологічних аномалій за супутниковими зображеннями.

4 АНАЛІЗ РЕЗУЛЬТАТІВ І МОЖЛИВОСТІ ВПРОВАДЖЕННЯ

4.1 Оцінка точності та надійності методу класифікації аномалій

Для забезпечення достовірного виявлення аномалій на супутникових знімках було використано метод машинного навчання Support Vector Machine (SVM) з радіальним базисним ядром (RBF kernel), що є одним з найефективніших підходів для двокласової класифікації.

4.1.1 Метрики оцінки точності класифікації

Для оцінки ефективності роботи класифікатора SVM було використано класичні метрики, що дозволяють комплексно проаналізувати якість прийняття рішень: точність (Precision), повноту (Recall), F1-міру та загальну точність класифікації (Accuracy). Ці метрики були обчислені на основі результатів моделі, отриманих на валідаційній вибірці, що не використовувалася під час навчання, що дозволяє дати об'єктивну оцінку здатності моделі до узагальнення.

На таблиці 4.1 наведено значення основних метрик для кожного з класів: клас 0 – нормальна рослинність та клас 1 – аномальні ділянки (затоплення, деградована рослинність, порушення структури покриву).

Таблиця 4.1 – Показники точності класифікації для кожного класу

Клас	Precision	Recall	F1-score
0 (Нормальна рослинність)	0.91	0.95	0.93
1 (Аномалії/затоплення)	0.94	0.90	0.92

Загальна точність класифікації (Accuracy) становить 94.62%, що вказує на те, що модель правильно класифікувала понад 94% усіх об'єктів вибірки.

Середнє значення F1-score для обох класів склало 0.923, що свідчить про високу збалансованість між точністю та повнотою при класифікації.

Precision (точність) – це частка коректно класифікованих об'єктів певного класу серед усіх об'єктів, класифікованих як такі. Високе значення 0.94 для

аномалій означає, що більшість об'єктів, які модель вважає аномальними, дійсно є такими, тобто ризик хибнопозитивного спрацьовування мінімальний.

Recall (повнота) – показує, яку частку реальних об'єктів певного класу вдалося виявити. Для нормальної рослинності цей показник становить 0.95, що є виключно хорошим результатом, адже модель практично не пропускає пікселі, які відповідають здоровому покриву. Для класу аномалій Recall дорівнює 0.90, тобто 10% об'єктів аномального класу залишились не виявленими, що в умовах реального моніторингу є допустимим, особливо якщо врахувати невизначеність у спектральному відображенні аномалій.

F1-score як гармонічне середнє між Precision та Recall дає змогу оцінити загальну збалансованість моделі. Значення 0.92–0.93 вказують на високу якість класифікації незалежно від обраної метрики, і свідчать, що SVM змогла успішно адаптуватися до двокласової задачі, зберігаючи стабільність навіть при можливих перетинах спектральних характеристик між класами.

Отже, високі показники точності, повноти та F1-міри у поєднанні із загальною точністю вище 94% демонструють, що модель SVM є стабільним і надійним інструментом для класифікації NDVI-аномалій. Це дозволяє рекомендувати її для використання у практичних задачах моніторингу земного покриву за супутниковими знімками.

4.1.2 Інтерпретація конфузійної матриці

Конфузійна матриця – це важливий інструмент для оцінки ефективності класифікаційної моделі. Вона дозволяє детально проаналізувати, скільки об'єктів кожного класу були правильно або неправильно класифіковані [16]. У нашому випадку, конфузійна матриця для класифікації аномалій на супутникових знімках виглядає наступним чином:

$$\begin{bmatrix} 14234 & 754 \\ 899 & 10456 \end{bmatrix}. \quad (4.1)$$

З метою покращення наочності та зручності інтерпретації результатів класифікації, конфузійну матрицю подано у вигляді таблиці 4.2. Вона відображає

розподіл правильних і помилкових класифікацій пікселів між двома класами: "Нормальна рослинність" та "Аномалії/Затоплення". Такий формат дозволяє чітко побачити, скільки об'єктів кожного класу було класифіковано вірно, а скільки – з помилкою.

Таблиця 4.2 – Конфузійна матриця для класифікації аномалій

Фактичний клас \ Прогнозований клас	Клас 0 (Нормальна рослинність)	Клас 1 (Аномалії)
Клас 0 (Нормальна рослинність)	14,234 (True Negative)	754 (False Positive)
Клас 1 (Аномалії/Затоплення)	899 (False Negative)	10,456 (True Positive)

Аналіз елементів конфузійної матриці:

- True Negative (14,234) – це кількість пікселів, які насправді належать до класу "Нормальна рослинність" і правильно класифіковані як нормальні (не є аномалією). Високе значення TN вказує на те, що модель успішно виявляє області з нормальним рослинним покривом;
- False Positive (754) – ці пікселі були класифіковані як аномалії, але насправді належать до класу "Нормальна рослинність". Це випадки, коли модель помилково класифікує здорові ділянки рослинності як затоплені чи інші аномальні області. Хоча цей показник є неприємним, він не є надмірно високим, що свідчить про помірний рівень хибних позитивних результатів;
- False Negative (899) – ці пікселі насправді є аномаліями (затопленням чи деградованими ділянками), але були класифіковані як нормальна рослинність. Це значення свідчить про те, що модель час від часу не виявляє всі аномалії, що може бути важливим аспектом при застосуванні моделі для екологічного моніторингу, коли кожна пропущена аномалія може мати серйозні наслідки;

- True Positive (10,456) – ці пікселі правильно класифіковані як аномалії. Це вірно класифіковані області затоплення або деградації рослинного покриву. Високий показник TP вказує на здатність моделі коректно виявляти аномальні ділянки.

На основі конфузійної матриці можна обчислити кілька ключових показників для оцінки точності та надійності моделі.

Хибнопозитивна частка (False Positive Rate, FPR):

$$FPR = \frac{FP}{FP + TNFP} = \frac{754}{754 + 14,234754} \approx 5.03\% \quad (4.2)$$

Це вказує на те, що 5.03% пікселів, класифікованих як аномальні, насправді є нормальними. Цей рівень помилок є досить низьким і припустимим для моніторингу земельних покривів.

Хибнонегативна частка (False Negative Rate, FNR):

$$FNR = \frac{FN}{FN + TP} = \frac{899}{899 + 10,456899} \approx 7.91\% \quad (4.3)$$

Хибнонегативи вказують на 7.91% пропущених аномальних ділянок. Цей показник також є досить помірним для екологічних задач, де важливо виявити якнайбільше аномальних зон, але деяке пропускання не критичне.

Отже, чутливість моделі (Recall) щодо нормальної рослинності є дуже високою (0.95), що означає, що модель рідко помилково ідентифікує ділянки з нормальним рослинним покривом як аномальні.

Специфічність моделі щодо аномалій також є задовільною (precision 0.94), що свідчить про те, що модель рідко робить хибнопозитивні класифікації для класу аномалій.

Важливість результатів для екологічного моніторингу: модель є достатньо надійною для застосування в реальних умовах, зокрема для аналізу затоплень та інших екологічних аномалій на основі супутникових знімків. Хибнопозитивні та хибнонегативні класифікації знаходяться на прийнятних рівнях, що дозволяє використовувати модель для оперативного моніторингу змін у ландшафтах.

4.1.3 Порівняння якості класифікації між класами

Розглянемо порівняння результатів класифікації для двох класів: нормальна рослинність та аномалії/затоплення. Зокрема, звернемо увагу на різницю в показниках Recall та Precision, що дозволяє зрозуміти, як модель справляється з класифікацією кожного класу і де може бути поліпшення.

Порівняння Recall:

- Recall для класу "Нормальна рослинність": 0.95;
- Recall для класу "Аномалії": 0.90.

Recall (повнота) показує, яку частину реальних об'єктів певного класу модель правильно виявила серед всіх об'єктів цього класу. Тобто, чим вищий показник Recall, тим менше пропущених об'єктів.

Для нормальної рослинності, показник Recall = 0.95 свідчить про те, що модель дуже добре справляється з класифікацією здорових ділянок рослинності, практично не пропускаючи їх.

Для аномалій, показник Recall = 0.90 також є високим, але він трохи нижчий, що означає, що модель іноді не виявляє всі аномальні зони. Зазначена різниця цілком логічна, оскільки NDVI (індекс різниці нормалізованої вегетації) більш стабільно відображає здорову вегетацію, ніж деградовані чи затоплені ділянки. Це пояснюється тим, що здорові рослинні покриви мають чіткіші та однорідніші спектральні характеристики, в той час як аномалії можуть мати варіативні спектральні ознаки через різні фактори (затоплення, деградація ґрунту, будівництво тощо).

Порівняння Precision:

- Precision для класу "Нормальна рослинність": 0.91;
- Precision для класу "Аномалії": 0.94.

Precision (точність) вказує на те, яку частину елементів, що були класифіковані як належні до певного класу, модель класифікувала правильно. Це дуже важливий показник, оскільки він дає уявлення про те, як рідко модель помилково ідентифікує об'єкти як належні до конкретного класу.

Для нормальної рослинності, показник Precision = 0.91 вказує на те, що модель класифікує значну частину нормальних ділянок рослинності правильно, але певний відсоток рослинних ділянок може бути помилково віднесений до класу аномалій (754 хибнопозитивні випадки).

Для аномалій, показник Precision = 0.94 є вищим, що свідчить про більшу точність класифікації для цього класу. Тобто, модель рідше класифікує інші типи поверхні (нормальну рослинність, наприклад) як аномалії. Це може бути пов'язано з тим, що аномалії часто мають чіткі та виразні спектральні ознаки, які значно відрізняються від характеристик нормальних ділянок рослинності.

Для класу "Нормальна рослинність": модель має дуже високу повноту (Recall), що вказує на її здатність правильно класифікувати більшість здорових ділянок. Однак точність не є такою високою, що може бути зумовлено тим, що рослинність може бути схожа на деякі типи поверхні, що можуть помилково бути класифіковані як аномалії. Зокрема, низька точність може бути результатом того, що система класифікації іноді приймає здорові ділянки за аномалії, особливо в випадку змін ландшафту або сезонних коливань.

Для класу "Аномалії/Затоплення": більш високий Precision свідчить про те, що модель дуже обережно класифікує ділянки як аномалії, зводячи до мінімуму хибні позитивні результати. Це важливий аспект, оскільки помилкові спрацьовування можуть призвести до непотрібного втручання у вивчення екологічних проблем. Однак Recall для цього класу дещо нижчий, що може вказувати на те, що не всі аномальні зони були виявлені. Це може бути зумовлено варіативністю в спектральних характеристиках аномальних зон (наприклад, різні типи затоплення або часткова деградація рослинності), що ускладнює класифікацію.

Отже, модель продемонструвала хороші результати у класифікації нормальної рослинності, маючи високий рівень Recall (0.95), що свідчить про ефективність класифікації здорових ділянок. Однак, Precision для рослинності є дещо нижчим (0.91), що може бути наслідком варіацій у характеристиках деяких видів рослинності, що схожі на аномалії.

Для аномалій/затоплення модель показала високу Precision (0.94), що свідчить про її здатність точно визначати аномальні ділянки, мінімізуючи хибні спрацьовування. Однак Recall для цього класу трохи знизився до 0.90, що може вказувати на невеликі пропуски реальних аномальних зон через варіативність спектральних характеристик.

Таким чином, загальні показники класифікації свідчать про стабільну та надійну роботу моделі, з добре збалансованими результатами для двох класів, хоча є певні аспекти, які можуть бути вдосконалені для поліпшення точності виявлення аномалій.

4.1.4 Аналіз стабільності класифікації у динаміці (за фазами повені)

Для перевірки стабільності роботи SVM-моделі в різні етапи гідрологічної події було проаналізовано відсоток виявлених аномалій на трьох часових знімках, що відповідають початковій, піковій та фазі ретракції повені.

На таблиці 4.3 зображено динаміку виявлення аномальних зон (як % від загальної площі) та короткі коментарі щодо характеру класифікації на кожному знімку.

Таблиця 4.3 – Динаміка виявлення NDVI-аномалій за фазами повені

Супутниковий знімок	Відсоток виявлених аномалій	Коментар
1 (початкова стадія: 29 серпня – 13 вересня)	12.5%	Чітка локалізація вздовж основних русел та низин; модель реагує на перші зниження NDVI.
2 (пік повені: 14 – 29 вересня)	29.3%	Максимальна площа аномалій; широка зона покриття підтверджує адаптивність до масштабних змін.
3 (ретракція: 30 вересня – 15 жовтня)	9.7%	Залишкові фрагменти аномалій у депресіях та заболочених ділянках; модель фіксує довготривалі наслідки.

На 1 знімку (початкова стадія) зображено невелику чітко окреслену смугу аномалій уздовж річкових долин і низин, що відповідає 12.5% виявлених аномалій. На цьому етапі відхилення NDVI тільки починають формуватися, тому модель виявляє лише найбільш виражені осередки затоплення. Це свідчить про хорошу чутливість моделі навіть при помірних змінах NDVI, однак існує ризик пропуску слабо виражених аномалій.

Знімок 2 (пік повені) відзначається значним збільшенням виявлених аномалій до 29.3%, що є максимальним показником серед усіх фаз. Це пояснюється інтенсивним затопленням різних ландшафтних типів, таких як торф'яники і сільгоспугіддя, що призводить до різкого зниження NDVI. Модель успішно фіксує як прямі, так і опосередковані ознаки аномалій, наприклад, заболочення без безпосереднього покриття водою. SVM показує відмінну здатність масштабуватися під умови масштабних затоплень, зберігаючи точність на великій площі.

На 3 знімку (ретракція) площа аномалій істотно зменшилася, до 9.7%, але модель все ще здатна ідентифікувати залишкові зони, де вода або вогкість ґрунту зберігаються довше. Це пояснюється частковим відновленням NDVI в більшості районів, що знижує площу виявлених аномалій, але в той же час деякі депресії та заболочені ділянки все ще демонструють низькі значення індексу. Модель чутливо реагує не лише на прямі зміни через воду, а й на тривалі ефекти, такі як загибель рослинності або вторинне заболочення, що є важливим для комплексного моніторингу екологічної ситуації.

Загальна оцінка стабільності:

- консистентність: модель коректно відстежує логічну динаміку затоплення – від локалізованих початкових осередків (12.5%) до масового піку (29.3%) та остаточної ретракції (9.7%);
- адаптивність: незважаючи на різні спектральні відгуки у фазах, SVM утримує високу чутливість до NDVI-зниження та уникнення хибнопозитивів;
- практичне значення: така стабільність дозволяє використовувати модель

для оперативного моніторингу гідрологічних подій з автоматичним звітуванням про поточний стан аномалій.

Проміжний висновок: аналіз динаміки класифікації підтверджує, що SVM є надійним інструментом для скринінгу змін у рослинному покриві протягом усієї гідрологічної події, забезпечуючи як високу чутливість на початкових та пізніх етапах, так і точне масштабне виявлення у фазі піку.

З огляду на вищезазначене, на основі проведеного кількісного аналізу можна стверджувати, що використання SVM з RBF-ядром є надійним і високоточним методом класифікації аномалій на супутникових знімках, особливо у випадку виявлення NDVI-зниження, що свідчить про деградацію рослинності або затоплення. Високі значення точності, повноти та F1-міри, а також узгодженість результатів між класами та фазами повені, підтверджують оптимальність вибору SVM як базового алгоритму для вирішення задачі моніторингу екологічних змін за супутниковими даними.

4.2 Практична значущість отриманих результатів

Отримані результати класифікації демонструють не лише високу точність роботи моделі SVM у задачі виявлення аномалій на основі супутникових індексів (зокрема NDVI), але й підтверджують реальну прикладну користь для виявлення та моніторингу екологічних загроз. Модель дозволяє виявляти небезпечні зміни у стані земельного покриву ще до того, як вони стануть візуально помітними, що є надзвичайно цінним для оперативного реагування у сферах екології, сільського господарства, надзвичайних ситуацій та урбаністичного планування.

Класифікація за NDVI дозволяє фіксувати аномалії, пов'язані з деградацією вегетації, затопленням територій чи іншими гідрологічними змінами. У ранній фазі повені (знімок 1) модель змогла виявити навіть локальні осередки зниженого NDVI, які ще не мали чітких візуальних проявів на оптичних знімках. Це свідчить про здатність SVM-моделі ідентифікувати потенційно небезпечні зони ще до того, як ситуація переросте у кризову. Наприклад, своєчасне виявлення вразливих ділянок уздовж річок дозволяє заздалегідь попередити відповідні служби про

можливі підтоплення, зменшуючи ризики для інфраструктури та населення.

На основі аналізу трьох часових супутникових знімках, що відповідають різним фазам повені, було отримано узгоджену динаміку класифікаційної моделі:

- початкова стадія (знімок 1, 12.5%): модель зафіксувала локалізовані зони потенційного підтоплення, переважно в низинах та долинах річок. Незважаючи на обмежену площу, ці ділянки важливі як перші сигнали наростання гідрологічної загрози;
- пік повені (знімок 2, 29.3%): спостерігалось значне розширення аномальних зон. Модель ефективно виявила як прямі затоплення, так і опосередковані ефекти, як-от заболочення або загибель рослинності. Така здатність до масштабування – ключовий фактор для надійного моніторингу в кризовий період;
- фаза ретракції (знімок 3, 9.7%): хоча основна частина води зникла, модель виявила залишкові зони впливу – ділянки з тривалою вогкістю або вторинним пошкодженням вегетації. Це свідчить про глибоку чутливість моделі до відкладених екологічних наслідків.

Ця динаміка класифікації добре ілюструється на тематичних картах, де аномальні зони змінюють свою форму, розміри та розташування у залежності від фази події. Візуальний аналіз таких мап дозволяє не лише локалізувати зони ризику, а й простежити їх розвиток у часі.

Отримані результати класифікації мають важливу практичну цінність не лише в межах наукових досліджень, а й у широкому колі професій, пов'язаних з екологічним моніторингом, сільським господарством, реагуванням на надзвичайні ситуації та плануванням просторового розвитку. Надання точних і своєчасних даних про наявність і масштаби аномалій у вегетаційному покриві дозволяє різним спеціалістам оперативно ухвалювати обґрунтовані рішення, зменшувати ризики та ефективніше управляти природними ресурсами. Нижче наведено як результати роботи моделі можуть бути практично застосовані у діяльності ключових фахових груп.

Екологи можуть використовувати отримані дані для картування

деградованих територій, оцінки стресового стану екосистем та довгострокового моніторингу змін. Рання фіксація деградаційних процесів дає змогу вжити заходів до настання незворотних змін.

Агрономи отримують потужний інструмент для виявлення ділянок, де врожайність може бути критично зниженою через надмірне зволоження або затоплення. Це дозволяє оперативно коригувати плани обробітку, уникати втрат або планувати відновлення ґрунтів після повені.

Працівники ДСНС (Державної служби з надзвичайних ситуацій) можуть використовувати автоматизовану класифікацію для моніторингу небезпечних зон у реальному часі, прийняття рішень щодо евакуації чи попереджувальних заходів.

Урбаністи та планувальники інфраструктури отримують актуальні дані для оцінки вразливості територій, планування забудови або формування природоохоронних зон на основі фактичної динаміки ризиків.

Таким чином, модель класифікації на основі SVM демонструє не лише високі формальні показники точності, а й реальну здатність підтримувати прийняття рішень у критично важливих сферах. Її використання дозволяє своєчасно виявляти екологічні загрози, аналізувати їх динаміку, оцінювати потенційні наслідки і, що найважливіше, діяти на випередження. Це робить її ефективним компонентом сучасних систем екологічного моніторингу та управління ризиками.

4.3 Перспективи використання результатів у науковій і практичній діяльності

Отримані результати дослідження свідчать про високий потенціал розробленої методики для подальшого практичного та наукового застосування. Побудована модель на основі індексу NDVI та алгоритму SVM успішно ідентифікує аномалії в рослинному покриві, зокрема пов'язані з гідрологічними процесами (повенями), що відкриває широкі можливості для масштабування й адаптації до нових умов.

Запропонована методика є географічно незалежною, оскільки базується на

супутникових знімках та спектральних характеристиках рослинності. Це дозволяє адаптувати модель для інших регіонів України та світу – з різними типами ландшафтів, кліматичними умовами та видами рослинного покриву. Зокрема, перспективним напрямом є виявлення:

- посух – через зниження NDVI внаслідок водного стресу рослин;
- лісових пожеж – шляхом виявлення різкої деградації вегетації після інциденту;
- деградації ґрунтів – шляхом довгострокового аналізу зниження NDVI на сільськогосподарських угіддях.

Завдяки високій чутливості до спектральних відхилень, модель може слугувати універсальним інструментом для моніторингу екологічних ризиків.

Модель має всі передумови для вбудови в платформи агроєкологічного моніторингу, такі як:

- державні екологічні центри та служби з надзвичайних ситуацій, які потребують швидкого аналізу ситуації в разі стихійних лих (повені, затоплення, ерозія);
- аграрні інформаційні платформи (наприклад, GeoAgro, Cropio), де алгоритм може виявляти проблемні зони в полях, прогнозувати зниження врожайності або рекомендувати зонування для точного землеробства;
- системи просторового планування на рівні громад, що дозволить враховувати зони ризику при забудові, прокладанні інфраструктури або плануванні меліорації.

У перспективі модель може бути розгорнута як онлайн-сервіс або API, що обробляє дані з відкритих супутникових платформ (Sentinel-2, Landsat-8) у майже реальному часі. Це дозволить створити інтерактивні карти ризиків, оперативні звіти про ситуацію на місцях, або інтегрувати дані в мобільні застосунки для фермерів, екологів чи служб ДСНС. Важливо, що NDVI легко обчислюється з загальнодоступних каналів супутників, тому технологія лишається відносно дешевого впровадження.

У межах майбутніх досліджень передбачається:

- апробація інших методів машинного навчання, зокрема Random Forest, Gradient Boosting, а також згорткових нейронних мереж (CNN), які можуть краще враховувати просторовий контекст;
- поєднання NDVI з іншими індексами: EVI (Enhanced Vegetation Index) – чутливіший до щільної рослинності; SAVI (Soil Adjusted Vegetation Index) – менш залежний від оголеного ґрунту, NDWI – для моніторингу вологи;
- сезонний аналіз, який дасть змогу враховувати циклічність розвитку рослинності та порівнювати результати з багаторічною нормою;
- оцінка довгострокових змін з використанням часових рядів NDVI для виявлення повільних процесів деградації, змін клімату або антропогенного впливу.

Можна зробити висновок, що методика, що поєднує супутникові дані та машинне навчання, має реальний потенціал для трансформації підходів до екологічного моніторингу. Вона здатна не лише ідентифікувати аномалії постфактум, а й стати частиною системи раннього попередження, запобігання збиткам та ухвалення обґрунтованих управлінських рішень. Подальший розвиток даного напрямку може мати суттєвий вплив як на практику, так і на наукову базу моніторингу навколишнього середовища.

ВИСНОВКИ

У ході виконання кваліфікаційної роботи було доведено актуальність задачі класифікації аномалій на супутникових знімках в умовах зростаючого обсягу даних дистанційного зондування та потреби в оперативному екологічному моніторингу. Основною метою дослідження стало визначення оптимального методу класифікації NDVI-аномалій із використанням технологій комп'ютерного зору, що забезпечують високу точність виявлення природних порушень, таких як повені, на прикладі реального супутникового матеріалу.

На основі глибокого огляду літератури й сучасних наукових джерел було здійснено систематизацію методів класифікації, серед яких розглядалися SVM, CNN, GAN, LSTM, RNN та трансформери. Метод SVM із використанням RBF-ядра було обґрунтовано як найбільш доцільний для задачі класифікації NDVI-аномалій у випадку повеней завдяки його здатності ефективно працювати з малими обсягами розмічених даних і високою точністю при двокласовій класифікації.

У ході роботи реалізовано повний конвеєр обробки знімків: завантаження та попередня обробка супутникових зображень, обчислення NDVI, побудова карти ознак (включаючи текстурні характеристики), навчання моделі SVM та виведення класифікаційних карт. Особливу увагу приділено етапу формування якісної вибірки навчання на основі ручної валідації аномалій.

У межах дослідження підтверджено, що комп'ютерний зір є потужним інструментом для аналізу природного середовища на основі супутникових даних. Зокрема, реалізовано типовий пайплайн комп'ютерного зору, що включає попередню обробку зображень, екстракцію ознак (NDVI, текстурні характеристики), їх нормалізацію, побудову векторів ознак та подальшу класифікацію пікселів за допомогою SVM. Такий підхід дозволяє здійснювати масштабований, точний та об'єктивний аналіз стану земного покриву, що традиційно вимагав значних людських зусиль. Отриманий досвід у цьому дослідженні, засвідчив, що класичні алгоритми комп'ютерного зору (без залучення глибоких нейронних мереж) можуть демонструвати високу

ефективність у практичних задачах, особливо за умови ретельної підготовки ознак. Це відкриває перспективу для створення легковагих, ресурсозберігаючих систем моніторингу, які не потребують потужного обчислювального середовища, але забезпечують високу точність у реальних сценаріях.

За результатами обчислень отримано високі метрики точності класифікації: загальна точність (accuracy) – 94.62%, F1-score – 0.923. Рівень precision для класу аномалій становив 0.94, recall – 0.90, що свідчить про здатність моделі виявляти більшість критичних зон затоплення з мінімальною кількістю хибнопозитивних спрацьовувань. Конфузійна матриця продемонструвала прийнятну кількість хибних класифікацій у межах 5–8%. У межах аналізу трьох часових періодів (початок, пік та ретракція повені) показано, що модель стабільно виявляє просторову еволюцію аномалій. Найвища частка виявлених змін – 29.3% – спостерігалася у фазі піку затоплення, що добре корелює з фактичними NDVI-аномаліями, підтверджуючи достовірність результатів.

Результати класифікації мають безпосереднє прикладне значення для фахівців у сфері екології, агрономії, рятувальних служб (ДСНС), водного господарства та урбаністики. Модель здатна виявляти навіть ті зони, де зміни ще не стали візуально помітними, що відкриває перспективу для раннього попередження про екологічні загрози.

З урахуванням обмежень, притаманних методу SVM (зокрема, обмежена здатність до багатокласової класифікації), рекомендовано надалі дослідити застосування гібридних моделей, таких як CNN+SVM, або використання трансформерних архітектур для обробки часових рядів NDVI. Також варто дослідити ефективність поєднання індексу NDVI з іншими індексами (EVI, SAVI) для поліпшення чутливості до різних типів аномалій.

Робота поєднує класичний метод машинного навчання (SVM) з геоаналітикою на основі індексів вегетації, що є новим підходом для задач оперативного супутникового моніторингу екологічних катастроф. Реалізована модель є універсальною, стійкою до шуму, легко масштабується на інші регіони, що забезпечує високий потенціал для її наукового та практичного впровадження.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. Руткас А.А., Власенко Л.А., Чикрій А.О. Стохастична дескрипторна гра переслідування// Кібернетика та системний аналіз. – 2024. – Т. 60, N 3, С. 109-119.
2. Rutkas A.A., Vlasenko L.A., Chikrii A.O. Stochastic descriptor pursuit game// Cybernetics and Systems Analysis. – 2024. – Vol. 60, No. 3. – P. 433-441
3. Rutkas A.A., Chikrii A.A., Vlasenko L. On descriptor control impulsive delay systems that arise in lumped-distributed circuits// Advanced Control Systems: Theory and Applications, 2024, P. 3–19
4. Rutkas A.A., Vlasenko L.A. Optimal Control of Undamped Sobolev-Type Retarded Systems// Mathematical Notes. – 2017. - Vol. 102, No 3. – P. – 297-309
5. Rutkas A.A., Vlasenko L.A. The evolution of nonmonochromatic mode fields in a waveguide with space dispersive medium// IEEE. Proceedings of the 2007 Sixth International Conference on Antenna Theory and Techniques, 17–21 September, 2007, Sevastopol, Ukraine. – P. 158–160
6. Richard S. Computer Vision: Algorithms and Applications. – New York City: Springer, 2022. – 925 pp.
7. Aggarwal C C. Neural Networks and Deep Learning: A Textbook. – New York City: Springer, 2023. – 529 pp.
8. Scholkopf B., Smola A.J. Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond. – Cambridge: The MIT Press, 2018. – 648 pp.
9. Zafar I., Tzanidou G., Burton R. Hands-on Convolutional Neural Networks with Tensorflow. – Birmingham: Packt Publishing, 2018. – 272 pp.
10. Langr J., Bok V. Gans in Action: Deep Learning with Generative Adversarial Networks. – New York City: Manning Publications, 2019. – 276 pp.
11. Michael D.M. PYTHON TIME FORECASTING FOR BEGINNERS: A HANDS-ON GUIDE TO MASTERING ARIMA PROPHET AND LSTM MODELS FOR ACCURATE PREDICTION. – Independently published, 2025. – 456 pp.
12. Salem M F. Recurrent Neural Networks: From Simple to Gated Architectures. – New York City: Springer, 2023. – 121 pp.

13. Kamath U., Graham K., Emara W. Transformers for Machine Learning: A Deep Dive. – Boca Raton: CRC Press, 2022. – 257 pp.

14. Surhone M.L., Timpledon M.T., Marseken S.F. Normalized Difference Vegetation Index. – Beau Bassin: Betascript Publishing, 2010. – 122 pp.

15. Cristianini N., Department of Computer Science Royal Holloway Shawe-Taylor J. An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. – Cambridge: Cambridge University Press, 2000. – 204 pp.

16. Larner A. The 2x2 Matrix: Contingency, Confusion and the Metrics of Binary Classification. – New York City: Springer, 2024. – 252 pp.

17. Посилання на GitHub, де розташовані всі електронні матеріали до кваліфікаційної роботи [Електроний ресурс]. – URL: https://github.com/oleksandrvasylets/2025_M_PI_IPZm-23-3_Vasylets_O_O.git

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ ЗА НАУКОВИМИ НАПРЯМАМИ
КЕРІВНИКА ТА НАУКОВЦІВ КАФЕДРИ ПРОГРАМНОЇ ІНЖЕНЕРІЇ**

1. Руткас А.А., Власенко Л.А., Чикрій А.О. Стохастична дескрипторна гра переслідування// Кібернетика та системний аналіз. – 2024. – Т. 60, N 3, С. 109-119.
2. Rutkas A.A., Vlasenko L.A., Chikrii A.O. Stochastic descriptor pursuit game// Cybernetics and Systems Analysis. – 2024. – Vol. 60, No. 3. – P. 433-441
3. Rutkas A.A., Chikrii A.A., Vlasenko L. On descriptor control impulsive delay systems that arise in lumped-distributed circuits// Advanced Control Systems: Theory and Applications, 2024, P. 3–19
4. Rutkas A.A., Vlasenko L.A. Optimal Control of Undamped Sobolev-Type Retarded Systems// Mathematical Notes. – 2017. - Vol. 102, No 3. – P. – 297-309
5. Rutkas A.A., Vlasenko L.A. The evolution of nonmonochromatic mode fields in a waveguide with space dispersive medium// IEEE. Proceedings of the 2007 Sixth International Conference on Antenna Theory and Techniques, 17–21 September, 2007, Sevastopol, Ukraine. – P. 158–160