

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
НАЦІОНАЛЬНА АКАДЕМІЯ НАУК УКРАЇНИ
НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
"КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
ІМЕНІ ІГОРЯ СІКОРСЬКОГО"
ІНСТИТУТ КОСМІЧНИХ ДОСЛІДЖЕНЬ НАН УКРАЇНИ ТА ДКА
УКРАЇНИ

**МЕТОДИ КОМП'ЮТЕРНОГО ЗОРУ І
ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ
ЕКОЛОГО-ЕКОНОМІЧНОГО АНАЛІЗУ**

**ЗА РЕДАКЦІЄЮ ПРОФ. Н.М. КУССУЛЬ,
ПРОФ. А.Ю. ШЕЛЕСТОВА**

КИЇВ · НАУКОВА ДУМКА · 2024

УДК 004.932, 528.854

Методи комп'ютерного зору і глибинних нейронних мереж для еколого-економічного аналізу // — Київ: Наукова думка, 2024. — 474 с.
ISBN 978-966-00-1940-9

Монографія містить результати досліджень кафедри математичного моделювання і аналізу даних Національного технічного університету України «КПІ імені Ігоря Сікорського» для вирішення задач еколого-економічного аналізу на основі сучасних методів комп'ютерного зору і глибинного навчання. В її основу покладено результати національних і міжнародних проєктів МОН України, НФДУ та Horizon Europe.

Запропонована методологія впроваджується у Мінагрополітики та продовольства України, Держстаті, Держгеокадастрі. На міжнародному рівні результати використовуються банком EBRD, центром JRC-EC, платформою UN-SPIDER та програмою NASA Harvest по використанню супутникових даних для сільськогосподарського моніторингу. Монографія є внеском України у програму EuroGEO по інтеграції європейських практик для підтримки прийняття рішень. Наведені результати є основою для розвитку інноваційних проєктів і стартапів по супутниковому моніторингу, екології, сільському господарству та управлінню природними ресурсами.

Монографія буде корисною для науковців, які займаються розробкою та впровадженням інтелектуальних моделей, фахівців із геопросторового аналізу, представників державних органів влади та міжнародних організацій, відповідальних за управління природними ресурсами та екологічний моніторинг. Вона стане цінним ресурсом для студентів, аспірантів та викладачів технічних і природничих спеціальностей.

Підготовлено до друку за підтримки Міністерства освіти і науки України в межах конкурсного проєкту № РН/27-2023 від 25.2023 р. програми зовнішнього інструменту допомоги Євросоюзу.

Рекомендовано до друку вченою радою Національного технічного університету України «КПІ імені Ігоря Сікорського» (протокол № 10 від 09.12.2024 р.), вченою радою Інституту космічних досліджень НАН України та ДКА України (протокол № 7 від 28.11.2024 р.)

Рецензенти:

член-кореспондент НАН України *О.П. Федоров*
доктор технічних наук, професор *В.В. Лукін*

ISBN 978-966-00-1940-9 © Куссульт Н.М., Шелестов А.Ю., Лавренюк А.М., Яйлимов Б.Я., Яйлимова Г.О., Колотій А.В., Дрозд С.Ю., Савін В.В., Мікава П.В., Кириленко І.А., Яворський О.А., Охріменко А.О., Пархомчук О.М., Харь Д.Ф., Волкова Є.А., 2024

ВСТУП

Війна в Україні створила надзвичайні виклики для відновлення країни, особливо у сферах управління природними ресурсами, відбудови інфраструктури та відновлюваної енергетики. У цих умовах критично важливим є впровадження інноваційних технологій для забезпечення стійкого розвитку. Для цього потрібні сучасні методи та математичні моделі еколого-економічного аналізу, що дозволять проводити ефективний моніторинг, прогнозування та підтримку прийняття рішень.

В епоху цифровізації економіки й активного розвитку штучного інтелекту аналіз екологічних та економічних процесів має базуватись на сучасних методах глибинного навчання та комп'ютерного зору. Ці технології дозволяють обробляти великі масиви супутникових і геопросторових даних, забезпечуючи детальний аналіз і прогнозування змін у навколишньому середовищі.

Монографія містить результати досліджень кафедри математичного моделювання і аналізу даних (ММАД) Національного технічного університету України «КПІ імені Ігоря Сікорського», створеної лише три роки тому. Попри молодий вік, кафедра вже сформувалась як колектив фахівців і однодумців, які розробили комплексну методологію для вирішення актуальних задач у сфері еколого-економічного аналізу на основі сучасних методів комп'ютерного зору і глибинного навчання. Монографію написано на основі результатів національних і міжнародних проєктів, виконаних кафедрою ММАД за підтримки МОН України, НФДУ та Horizon Europe. До всіх цих проєктів активно залучені аспіранти, внесок яких в отриманні результатів важко переоцінити. Всі результати доповідались на авторитетних міжнародних конференціях, значна частина опублікована у рейтингових міжнародних виданнях. У комплексі, монографія описує новітні методи сучасної прикладної математики та науки про дані для вирішення завдань, які стоять перед Україною в умовах сучасних викликів.

Частина 1 монографії «Аналіз сучасного стану методів комп'ютерного зору і глибинних нейронних мереж для еколого-економічного аналізу» містить огляд сучасних методів глибинного навчання та комп'ютерного зору, які застосовуються для розв'язання прикладних задач у сферах екології, економіки та просторового аналізу. У цій частині розглянуто широкий спектр підходів, що включають як класичні архітектури нейронних мереж,

так і новітні алгоритми для обробки великих масивів супутникових даних та 3D реконструкції. У цій частині також обговорюються можливості інтеграції різнорідних даних для підвищення точності прогнозування та моніторингу.

Розділ 1.1 «Аналіз методів та моделей глибинного навчання для розв’язання прикладних задач» висвітлює сучасні методи штучного інтелекту, основу якого складають методи глибинного навчання як ключової технології для розв’язання складних задач. У розділі розглядаються архітектури нейронних мереж, включаючи згорткові нейронні мережі (CNN) для аналізу супутникових зображень, рекурентні нейронні мережі (RNN) для роботи з часовими рядами, а також трансформери та графові нейронні мережі (GNN), що дозволяють працювати з просторово-часовими даними. Крім основних концепцій, в цьому розділі приділено увагу практичним аспектам застосування цих методів для задач класифікації ґрунтового покриття, виявлення об’єктів, моніторингу змін у навколишньому середовищі та прогнозування кліматичних змін. Автори аналізують використання генеративних змагальних мереж (GAN) для покращення якості зображень, видалення хмарного покриття та виявлення аномалій. Також обговорюються можливості використання напівкерowanego навчання та злиття даних для підвищення точності аналізу супутникових знімків, що є особливо актуальним для екологічного моніторингу та підтримки прийняття рішень у реальних умовах.

Розділ 1.2 «Аналіз методів 3D реконструкції середовища для доповненої реальності» надає огляд сучасних методів тривимірної реконструкції, які є основою для створення доповненої реальності (ДР). Розглядаються методи, що дозволяють створювати точні тривимірні моделі оточення, зокрема шляхом аналізу зображень та відновлення їхньої глибини. Описані підходи включають використання монокулярного зображення, стереозображень, багатовидового стереозіставлення (Multi-View Stereo, MVS), а також структуру з руху (Structure from Motion, SfM), які забезпечують високу точність при роботі з двовимірними даними. Крім класичних підходів, у розділі розглянуто новітні методи 3D реконструкції на основі нейронних мереж, які забезпечують автоматизацію процесу, значно знижуючи залежність від ручного налаштування параметрів. В цьому розділі також висвітлено останні тенденції у розробці компактних і легких пристроїв доповненої реальності. Обговорюються переваги та виклики використання таких пристроїв для візуалізації 3D сцен у реальному часі, а також значення правильної реконструкції для

забезпечення реалістичності взаємодії користувачів із доповненими елементами сцени.

Розділ 1.3 «Аналіз методів та моделей комп'ютерного зору та глибинних нейронних мереж для визначення пошкоджень земного покриву» містить огляд сучасних алгоритмів для ідентифікації та моніторингу змін земного покриву, спричинених як природними, так і антропогенними факторами. У розділі розглянуто різні підходи до обробки супутникових зображень, включаючи сегментацію та класифікацію, що базуються на згорткових нейронних мережах (CNN) і трансформерах. Особливу увагу приділено методам автоматичного виявлення пошкоджень. Обговорюється використання даних високої просторової роздільної здатності для підвищення точності аналізу, а також інтеграція різних джерел даних для створення комплексних карт пошкоджень. Також наведено приклади практичного використання методів у задачах оцінки впливу військових дій на довкілля.

Частина 2 «Методи комп'ютерного зору і глибинних нейронних мереж для супутникового інтелекту» присвячена розробці й застосуванню математичних моделей і алгоритмів для аналізу геопросторових і супутникових даних. У цій частині запропоновано методи для виявлення аномалій, обробки незбалансованих даних, оптимізації розмітки графових структур, а також підвищення просторової роздільної здатності зображень. Значна увага приділяється задачам сегментації, класифікації та поліпшення якості даних, що є ключовими для аналізу земного покриву, сільськогосподарських угідь та екологічного моніторингу. Розроблені підходи вирішують практичні проблеми, що виникають під час роботи з великими масивами супутникових даних, включаючи поступове надходження інформації та необхідність збереження її інтерпретованості. Описані алгоритми дозволяють підвищити точність моделей, ефективно працюючи навіть за умов обмеженості даних. Представлені у частині 2 методи є результатом наукових досліджень, проведених на кафедрі математичного моделювання і аналізу даних НТУУ "КПІ імені Сікорського" в межах національних і міжнародних проєктів за підтримки МОН України, НФДУ та Horizon Europe.

В розділі **2.1 «Метод виявлення аномалій в даних навчання моделей комп'ютерного зору на основі методів кластеризації»** запропоновано підхід до виявлення неоднозначних та ненадійних даних, що можуть впливати на якість моделі машинного навчання. Описаний метод на основі алгоритму K найближчих сусідів (KNN)

дозволяє ідентифікувати екземпляри, які важко класифікувати через перекриття класів або наявність нетипових ознак. Проілюстровано застосування цього методу для задачі попиксельної класифікації сільськогосподарських культур, на основі використання багатоспектральних супутникових зображень. Запропонований підхід дозволяє покращити якість навчальних даних шляхом виявлення ненадійних пікселів та оптимізації наборів навчальних даних.

В розділі 2.2 «Методи сегментації зображень різної природи для випадку незбалансованого набору» запропоновано метод вирішення проблеми дисбалансу класів у навчальних даних в моделях машинного навчання. В основі підходу лежить генерація синтетичних зображень за допомогою генеративних змагальних мереж (GAN), зокрема архітектури $pix2pix$, що дозволяє створювати реалістичні дані з урахуванням багатоспектральних і текстурних характеристик. Це забезпечує підвищення точності сегментації для різних типів зображень – від супутникових знімків до медичних даних. Автор удосконалює класичний метод вагових масок та пропонує модифікацію функції втрат для покращення роботи з незбалансованими вибірками, що забезпечує значне зменшення похибок і підвищення ефективності моделей у складних задачах.

В розділі 2.3 «1+ λ GP encodings: еволюційний алгоритм для безпечної роботи з даними різних модальностей» запропоновано алгоритм 1+ λ з GP-кодуванням для класифікації даних із підвищеними вимогами до безпеки та інтерпретованості. Метод забезпечує точність і стабільність роботи з різними типами даних, знижуючи ризики, пов'язані з проблемою «чорної скриньки». Модифікації алгоритму, включаючи перезавантаження, кешування та кросовер, підвищують продуктивність і запобігають локальним мінімумам. Порівняльний аналіз демонструє переваги цього підходу в задачах класифікації медичних та табличних даних, забезпечуючи вищу точність і кращу інтерпретованість, ніж стандартні методи.

В розділі 2.4 «Задача розмітки на деревах для поступового надходження даних» представлено підхід до вирішення задач оптимальної розмітки дерев, коли дані надходять поступово, а не повністю доступні на початку обчислень. Така ситуація часто виникає через обмеження каналів зв'язку або через специфіку практичних задач, де збір даних займає значний час. Основна ідея методу полягає в модифікації графу, що відповідає дереву, таким

чином, щоб проводити попередні обчислення над уже отриманими даними. Це дозволяє зменшити кількість необхідних операцій після отримання всіх даних. Крім теоретичних аспектів, у розділі 2.4 розглядаються практичні приклади, такі як задача стереозору, де необхідно відновити тривимірну структуру сцени за двома зображеннями. Експерименти показують, що запропонований алгоритм значно скорочує час обробки даних у порівнянні з традиційними підходами, особливо у випадках, коли дані надходять із затримкою.

Розділ 2.5 «Генеративні мережі для підвищення просторового розрізнення супутникових даних на основі трансформерів з увагою» присвячений методам підвищення просторового розрізнення супутникових зображень, зокрема з використанням генеративних змагальних мереж (GAN) та трансформерів з блоками уваги. У цьому розділі розглядається задача підвищення просторового розрізнення (суперрезолюції) для супутникових даних середнього та високого просторового розрізнення, що дозволяє отримувати більш детальні зображення з розрізненням 10 м із вихідних даних розрізненням 20 м або 30 м. Запропонований метод використовує сучасні GAN-моделі з компонентами channel attention та self-attention для більш точного урахування взаємозв'язків між спектральними каналами, що особливо корисно для аналізу рослинності та ландшафтів. Це підвищує якість обробки супутникових даних, дозволяючи застосовувати результати в прикладних дослідженнях. Експерименти показали ефективність методу, зокрема для обробки різних типів покриття — сільськогосподарських угідь, лісів та водних ресурсів.

Частина 3 «Прикладні задачі супутникового інтелекту на мультимодальних даних» присвячена застосуванню розробленої у частині 2 методології для вирішення реальних задач в енергетиці, інфраструктурному плануванні, моніторингу економічної активності та управлінні природними ресурсами. Використання супутникових даних, графових моделей і методів машинного навчання дозволяє проводити комплексний аналіз і підтримувати прийняття рішень на різних рівнях. Представлені приклади демонструють, як авторські методи, розроблені на кафедрі математичного моделювання і аналізу даних НТУУ «КПІ», успішно використовуються для розв'язання прикладних задач у вітчизняних і міжнародних проєктах за підтримки МОН України, НФДУ та Horizon Europe.

В розділі 3.1 «Визначення оптимальних місць для розміщення сонячних електростанцій на території України» запропоновано

комплексний підхід до вибору територій, де встановлення сонячних електростанцій буде найефективнішим. Аналізуються наслідки війни для енергетичного сектору України та підкреслюється важливість розвитку відновлюваних джерел енергії для забезпечення енергетичної незалежності. Запропонований метод багатокритеріального аналізу враховує кліматичні, топографічні та економічні фактори. Результати дослідження свідчать, що південні та центральні регіони мають найвищий потенціал, тоді як Карпати та Полісся менш придатні через обмежену сонячну радіацію та складний рельєф.

В розділі 3.2 «**Моделювання розвитку інфраструктури сіл на основі графових даних**» представлено графові моделі для планування та оцінки інфраструктури сільських територій. Інфраструктурна мережа представлена як граф, де вузли — це об'єкти інфраструктури, а ребра — транспортні чи комунікаційні зв'язки. Основна увага приділяється оцінці доступності об'єктів, виявленню регіональних дисбалансів і кластеризації мереж для виявлення зон із подібними проблемами. Запропонований підхід дозволяє розробляти рекомендації щодо пріоритетного розвитку інфраструктури, що підтверджено аналізом на реальних даних.

В розділі 3.3 «**Аналіз індикаторів економічної діяльності на основі різнорідних даних**» наведено приклади задач щодо використання супутникових даних та інших геопросторових джерел для моніторингу економічної активності. В умовах обмеженості традиційних статистичних даних, зокрема під час війни або інших кризових ситуацій, застосування альтернативних непрямих індикаторів, таких як нічне освітлення, якість повітря та землекористування, дозволяє отримувати оперативні оцінки економічної діяльності. Особливу увагу приділено аналізу впливу військових дій на регіональну економіку, зокрема в аграрному секторі. Супутникові дані використовуються для виявлення пошкоджень, оцінки площ сільськогосподарських земель та прогнозування врожаїв. Застосування цих методів дозволяє підтримувати прийняття рішень щодо відновлення та розвитку економіки в умовах сучасних викликів.

В розділі 3.4 «**Класифікації типів земного покриття та землекористування на основі супутникових даних з використанням Transfer Learning**» досліджується застосування трансферного навчання для створення карт класифікації земного покриття в умовах обмеженості наземних даних. Використання моделей, навчених на інших територіях, дозволяє покращити точність класифікації в регіонах зі схожими характеристиками. Порівняння

методів, зокрема fine-tuning і екстракції ознак, для супутникових даних Sentinel-1 та Sentinel-2 показало, що комбіновані моделі та ансамблювання значно підвищують ефективність класифікації, особливо для сільськогосподарських угідь і регіонів, для яких недостатньо даних для навчання.

Частина 4 «Сучасні інформаційні технології для комп'ютерного зору і глибоких нейронних мереж» охоплює сучасні інформаційні технології інтеграції, обробки та представлення геопросторових даних. Детально розглянуто можливості хмарних платформ і геопорталів, які забезпечують обробку великих обсягів інформації з різних джерел. Особливу увагу приділено інструментам для спільної роботи з даними. Хмарні сервіси та геопортали забезпечують зручний доступ до даних і необхідні інструменти для створення інтерактивних рішень, що дозволяють працювати без розгортання локальної інфраструктури.

Розділ 4.1 «Сучасні підходи до злиття та гармонізації різнорідних геопросторових даних» висвітлює використання хмарних платформ для інтеграції даних із різних джерел. Зокрема, Google Earth Engine (GEE) та CREODIAS забезпечують масштабованість, доступ до великих архівів супутникових зображень і інструменти для аналізу й візуалізації. Концепція Analysis Ready Data (ARD) спрощує роботу з попередньо обробленими даними, що особливо важливо для досліджень екології та управління ресурсами. Розглянуто функціонал платформ, включаючи аналіз часових рядів, розрахунок індексів на основі супутникових даних та інші інструменти, які сприяють екологічному моніторингу та прогнозуванню. Підкреслюється значення хмарних платформ для ефективного злиття даних, що розширює можливості досліджень без потреби в локальній інфраструктурі.

В розділі 4.2 «Засоби публікації та представлення геопросторових даних в Інтернет» обговорюються підходи та засоби для публікації й візуалізації геопросторових даних через геопортали. Геопортали забезпечують доступ до картографічної інформації та дозволяють користувачам взаємодіяти з різними типами даних. Розділ містить огляд компонентів для створення ефективних геопорталів, включаючи серверні інструменти для обробки даних (GeoServer, MapServer, QGIS Server) та клієнтські бібліотеки JavaScript (Leaflet, OpenLayers, Mapbox GL JS), які дозволяють створювати інтерактивні карти та налаштовувати інтерфейси користувача для роботи з картографічними шарами.

Таким чином, дана монографія представляє комплекс сучасних математичних методів та інструментів для вирішення

актуальних задач моніторингу природних ресурсів і економічного розвитку. Запропонована методологія та отримані результати активно впроваджуються у діяльність ключових державних установ, зокрема Міністерства аграрної політики та продовольства України, Державної служби статистики України, Державної служби України з питань геодезії, картографії та кадастру (Держгеокадастр). На міжнародному рівні результати використовуються такими організаціями, як Світовий банк, Об'єднаний дослідницький центр Європейської Комісії (JRC EC), платформа UN-SPIDER, а також у рамках програми NASA Harvest, яка зосереджена на застосуванні супутникових даних для сільськогосподарського моніторингу. Монографія є внеском України у програму EuroGEO, спрямовану на інтеграцію європейських геопросторових даних для підтримки прийняття рішень.

Отримані результати можуть слугувати основою для розвитку інноваційних проєктів і стартапів у галузях супутникового моніторингу, екології, сільського господарства та управління природними ресурсами.

Монографія буде корисною для науковців, які займаються розробкою та впровадженням моделей глибинного навчання, фахівців із геопросторового аналізу, представників державних органів влади та міжнародних організацій, відповідальних за управління природними ресурсами та моніторинг екологічних змін. Крім того, вона стане цінним ресурсом для студентів, аспірантів та викладачів технічних і природничих спеціальностей.

АНАЛІЗ СУЧАСНОГО СТАНУ МЕТОДІВ КОМП'ЮТЕРНОГО ЗОРУ І ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ЕКОЛОГО- ЕКОНОМІЧНОГО АНАЛІЗУ

1. АНАЛІЗ МЕТОДІВ ТА МОДЕЛЕЙ ГЛИБИННОГО НАВЧАННЯ ДЛЯ РОЗВ'ЯЗАННЯ ПРИКЛАДНИХ ЗАДАЧ

Наталія Куссуль, професор

Володимир Кузін, магістр

Андрій Шелестов, професор

Кафедра математичного моделювання і аналізу даних

Навчально-науковий Фізико-технічний інститут

Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

nataliia.kussul@lml.kpi.ua, volHkuz@gmail.com,

andrii.shelestov@gmail.com

ВСТУП

За останні роки штучний інтелект (ШІ) став однією з головних чинників швидкого розвитку та значного прогресу, революціонізувавши різні галузі та аспекти нашого повсякденного життя. Штучний інтелект (ШІ) став трансформаційною галуззю з величезним потенціалом для революційних змін у різних сферах - від охорони здоров'я та фінансів до транспорту та освіти [1]. ШІ охоплює різноманітний набір технологій і методологій, які дозволяють машинам виконувати завдання, що традиційно вимагали людського інтелекту [2]. Серед багатьох досягнень у галузі штучного інтелекту методи глибинного навчання привернули до себе значну увагу завдяки своїй ефективності у вирішенні складних проблем у різних прикладних сферах [3-5].

Швидкий розвиток ШІ можна пояснити кількома факторами. Перш за все, розвиток обчислювальних потужностей і доступність

величезних наборів даних сприяли навчанню складних моделей ШІ. Крім того, прориви в розробці алгоритмів машинного навчання, зокрема глибинного навчання, дозволили системам ШІ видобувати важливі закономірності та інформацію з величезних масивів даних. Поява хмарних обчислень і спільноти з відкритим вихідним кодом полегшила доступ до інструментів і фреймворків ШІ, сприяючи широкому впровадженню і співпраці в різних дисциплінах. Крім того, збільшення інвестицій як з приватного, так і з державного секторів сприяло розвитку досліджень і розробок у галузі ШІ, що призвело до появи інноваційних застосувань і технологій.

Оскільки ШІ продовжує розвиватися, його вплив на суспільство є глибоким і багатогранним. Геопросторовий інтелект є важливою сферою застосування ШІ. Інтелектуальне дослідження Землі, що базується на ШІ та глибокому навчанні, аналізує геопросторові дані з різних джерел, щоб отримати практичні знання про планету. Глибокі нейронні мережі ефективно обробляють складні набори геопросторових даних для розв'язання таких задач, як класифікація ґрунтового покриву, виявлення об'єктів і моделювання клімату, автоматизуючи завдання, які раніше вимагали значних людських зусиль. Поточні дослідження спрямовані на покращення інтерпретованості, узагальнення та застосовності моделей до нових типів даних, що обіцяє широке впровадження глибинного навчання у застосуваннях інтелектуального дослідження Землі, трансформативне бачення клімату, екології, ресурсів тощо, а також загальне покращення розуміння планетарних процесів та розвитку економіки.

Останні досягнення в галузі ШІ та інструменти для впровадження машинного навчання проаналізовано в багатьох оглядах [6, 7]. Існує кілька досліджень, присвячених моделям штучного інтелекту та глибинного навчання для інтелектуального дослідження та спостереження Землі [8]. Водночас ця сфера розвивається настільки швидко, що вимагає переосмислення загальної картини кожні кілька років. У даному розділі містяться результати аналізу сучасного стану глибинного навчання та його застосування для інтелектуального дослідження Землі, управління та прийняття рішень, акцентуючи увагу на практичному досвіді його застосування в Україні.

1.1. ВИЗНАЧЕННЯ ШТУЧНОГО ІНТЕЛЕКТУ

Перш ніж приступити до класифікації методів ШІ, почнемо з визначення ШІ. Штучний інтелект (ШІ) - це здатність машин виконувати когнітивні функції та завдання, які зазвичай вимагають людського інтелекту та сприйняття. Це наука та інженерія розробки комп'ютерних систем, які можуть брати участь у процесах мислення, подібних до людських, таких як навчання, міркування, розв'язання проблем, сприйняття, прогнозування, планування та прийняття рішень [9]. Алгоритми ШІ можуть реалізовувати навчання, розпізнавання, розв'язання проблем, розуміння мови та/або логічне мислення.

На сьогоднішній день моделі ШІ поділяються на сильні та слабкі. Терміни «сильний ШІ» і «слабкий ШІ» представляють різні рівні здатності штучного інтелекту [10]. Слабкий ШІ, також відомий як «вузький ШІ», призначений для вирішення конкретної задачі або обмеженого набору задач, фокусуючись на одній когнітивній здатності. Більшість з того, що ми сьогодні називаємо «слабким ШІ», складається зі спеціалізованих алгоритмів, розроблених для досягнення успіху в розв'язанні конкретних задач, що базуються на використанні великих навчальних даних. Таким алгоритмам бракує справжнього інтелекту, що виходить за межі запрограмованих функцій, і вони зазвичай використовуються в сучасних програмах ШІ, таких як чат-боти, розпізнавання обличчя, медичні програми, віртуальні асистенти тощо [11].

З іншого боку, сильний ШІ, також відомий як «загальний ШІ» або «повний ШІ», має на меті продемонструвати інтелект і пізнання на рівні людини [12]. Він має здатність розуміти, міркувати, планувати, вирішувати проблеми, абстрактно мислити і швидко вчитися на власному досвіді. На відміну від слабого ШІ, сильний ШІ демонструє узагальнений інтелект у різних сферах і може переносити знання з однієї задачі на інші, не пов'язані з нею. Наразі сильний ШІ залишається гіпотетичною концепцією, а його розробка - довгостроковою метою [13].

1.2. МАШИННЕ НАВЧАННЯ

ШІ включає в себе різні підходи та моделі, і однією з основних парадигм є машинне навчання. Машинне навчання - це галузь штучного інтелекту (ШІ), яка передбачає використання математичних методів, що дозволяють машинам здобувати знання

на основі досвіду. Воно зосереджене на розробці алгоритмів, заснованих на емпіричних і навчальних даних, для оптимізації результатів і поліпшення прогнозів за допомогою процесів навчання [14].

ML застосовується для вирішення наукових і прикладних задач у таких галузях, як хімія, медицина, астрономія, біологія, сільське господарство, муніципальне господарство, промисловість, будівництво, моделювання навколишнього середовища, обробка природної мови, геопросторовий аналіз тощо. Різні парадигми та сфери застосування ШІ, що розглядаються в [15], показані на рис. 1. У нашому дослідженні основна увага буде зосереджена на машинному навчанні, а точніше, на моделях глибокого навчання та їх застосуванні для спостереження та інтелектуального дослідження Землі та підтримки прийняття рішень.



Рис. 1. Підрозділи штучного інтелекту [15].

Існують наступні основні методи машинного навчання [16]:

Навчання з вчителем (supervised learning) передбачає використання маркованих даних для навчання алгоритмів, що дозволяє їм прогнозувати результати. Цей підхід охоплює регресію, яка має справу з безперервними даними, і класифікацію дискретних даних. Успіх навчання з учителем значною мірою залежить від доступу до великих наборів даних. Воно знаходить

1.1. Аналіз методів та моделей глибинного навчання для розв'язання ...

застосування в різних галузях, включаючи розпізнавання зображень і мови, медичну діагностику і спостереження Землі для розв'язання таких задач, як класифікація ґрунтового покриву, картографування рослинності і виявлення об'єктів.

Навчання без вчителя (unsupervised learning) використовує немарковані дані для виявлення закономірностей і групування даних у кластери без конкретних прогнозів. Алгоритми, що використовуються в навчанні без вчителя, включають кластеризацію, зменшення розмірності та виявлення аномалій. Застосування навчання без вчителя можна знайти в задачах супутникового моніторингу, таких як виявлення аномалій для ідентифікації нестандартних ситуацій на супутникових знімках, класифікація для групування схожих регіонів при картографуванні ґрунтового покриву і зменшення розмірності для обробки великомасштабних супутникових даних.

Напівкероване навчання (semi-supervised learning) використовує переваги як невеликих маркованих наборів даних, так і великих немаркованих наборів даних. Такий підхід дозволяє поєднати інформацію з маркованих даних із закономірностями, виявленими у немаркованих даних, для покращення навчання моделі. У супутниковому моніторингу цей метод може бути корисним для розв'язання таких задач, як картографування ґрунтового покриву, де обмежені марковані зразки можуть бути доповнені великим обсягом немаркованих супутникових знімків для підвищення точності та узагальнення.

Навчання з підкріпленням (reinforcement learning) передбачає, що агент навчається через взаємодію з навколишнім середовищем методом спроб і помилок. Він отримує винагороду за дії, які наближають його до заздалегідь визначеної мети. Агент приймає рішення на основі минулого досвіду (використання) і пробує нові дії (дослідження), щоб оптимізувати процес навчання. У супутниковому моніторингу навчання з підкріпленням може застосовуватися для розв'язання таких задач, як автономна навігація дронів для збору конкретних даних, оптимізація орбіт супутників для покращення збору даних або адаптивне планування роботи датчиків для отримання релевантної інформації.

Глибинне навчання - це потужна підгрупа машинного навчання, яка використовує нейронні мережі з декількома шарами для створення ієрархічних представлень і моделювання складних взаємозв'язків у даних. Здатність ефективно обробляти величезні обсяги даних робить його добре придатним для різних застосувань, в тому числі в супутниковому моніторингу. Глибинне навчання

використовується для таких задач, як аналіз зображень і відео, виявлення об'єктів, семантична сегментація аеро- або супутникових знімків, класифікація землекористування і рослинного покриву, виявлення змін і навіть моніторинг змін у навколишньому середовищі, таких як вирубка лісів або зростання міст. Нещодавні досягнення в галузі глибинного навчання значною мірою зумовлені зростанням обчислювальних потужностей і доступністю великих масивів даних супутникового моніторингу.

У наступних розділах розглянуті кілька часто використовуваних архітектур глибинного навчання для розв'язання задач супутникового спостереження Землі, описані їх застосування та корисність у цій галузі. Ми починаємо з керованих згорткових і рекурентних нейронних мереж, за якими слідує генеративні змагальні мережі для навчання без вчителя. Нарешті, ми досліджуємо найбільш популярні моделі трансформерів і їх застосування. Це висвітлення провідних підходів глибокого навчання дає контекст щодо їх ролі в просуванні досліджень і практики супутникового моніторингу. Маючи ці передумови, розглядаються також виклики, що залишилися, і майбутні перспективи глибинного навчання для супутникового моніторингу.

1.3. ОГЛЯД МОДЕЛЕЙ ТА МЕТОДІВ ГЛИБИННОГО НАВЧАННЯ ДЛЯ СУПУТНИКОВОГО МОНІТОРИНГУ

Глибинне навчання — це форма машинного навчання, побудована на штучних нейронних мережах [17] із кількома прихованими шарами, що дозволяє моделям вивчати складні шаблони з великих обсягів даних. Глибина мережі дозволяє вивчати абстрактні представлення та вилучати ієрархічні ознаки безпосередньо з необроблених даних [18], усуваючи необхідність розробки функцій вручну.

Поширені архітектури глибокого навчання показані на рис. 2 і включають згорткові нейронні мережі (CNN) для додатків комп'ютерного зору [19], таких як класифікація зображень, рекурентні нейронні мережі (RNN) для обробки послідовних даних, таких як текст і мова [20], і генеративні змагальні мережі (GAN) [21] для генерування нових даних. Однією з популярних архітектур, яка часто використовується для навчання за подібністю, є сіамська нейронна мережа [22]. Зовсім недавно

1.1. Аналіз методів та моделей глибокого навчання для розв'язання ...

моделі-трансформери, що використовують механізми уваги, досягли найсучасніших відомих результатів у задачах обробки природної мови [23].

Глибоке навчання вимагає великих наборів маркованих даних і значних обчислювальних потужностей, до складу яких часто входять графічні процесори. Воно дозволило просунутись вперед у таких сферах, як комп'ютерний зір [24], обробка мовлення [25] та обробка природної мови [26]. Однак моделі глибокого навчання можуть бути складними «чорними скриньками», яким бракує інтерпретованості та прозорості [27].

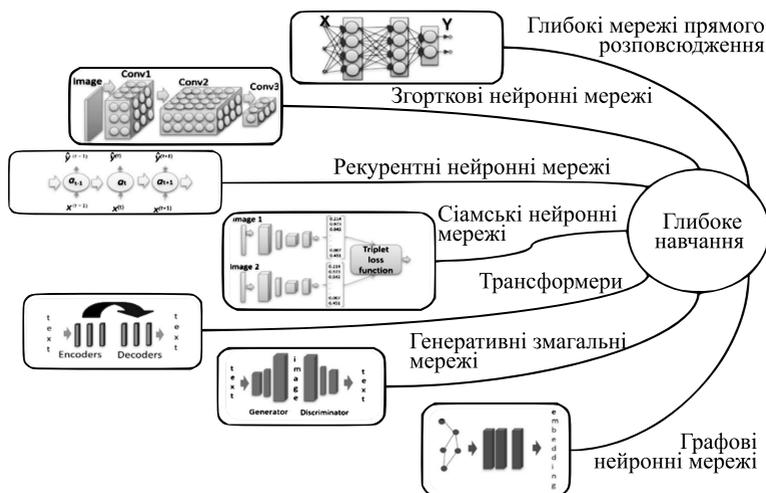


Рис. 2. Глибинні мережі [15]

Наступні розділи зосереджені на представленні декількох архітектур, що часто використовуються у супутниковому моніторингу. До них відносяться керовані моделі згорткових нейронних мереж (CNN) і рекурентних нейронних мереж (RNN), а також моделі генеративних змагальних мереж (GAN) і все більш популярні трансформери.

1.4. ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ (CNN)

Згорткові нейронні мережі (CNN) - це спеціалізований тип глибоких нейронних мереж, який широко використовується для аналізу зображень. Ключовою властивістю CNN є використання

згорткових шарів для застосування фільтрів до вхідних даних, які виявляють просторові шаблони, такі як краї, і створюють карти ознак. Кілька згорткових шарів об'єднуються в стек для вивчення ієрархічних представлень ознак. Шари об'єднання використовуються для зменшення вибірки карт ознак, зменшуючи обчислювальне навантаження та попереджуючи перенавчання, причому найчастіше використовується максимальне об'єднання шарів. Повнозв'язні шари слідує за згортковими шарами для отримання остаточних оцінок класів або прогнозування. CNN повторно вимагають великі марковані навчальні дані для налаштування фільтрів і параметрів моделі (рис. 3). Вони використовують інваріантність перетворення та композиційність візуального сприйняття для ефективного навчання ознак з пікселів. CNN знаходять різні застосування, такі як класифікація зображень, виявлення об'єктів, семантична сегментація, генерація зображень і навігація роботів. Серед популярних архітектур CNN - LeNet [28], AlexNet [29], VGG [30], ResNet [31], Inception [32], YOLO [33] та інші.

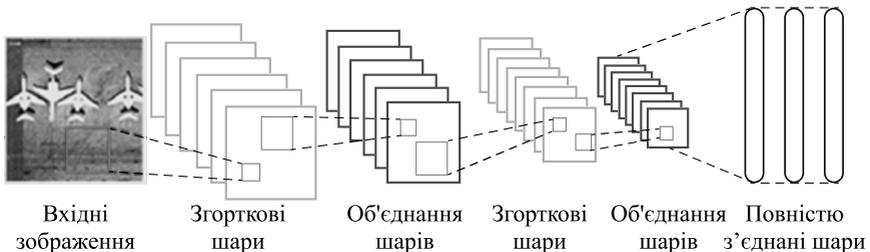


Рис. 3. Структура CNN, що складається із згорткових, об'єднаних і повнозв'язаних шарів [34]

Згорткові нейронні мережі (CNN) стали домінуючою технологією для розв'язання різних задач супутниковому моніторингу завдяки їх ефективності для аналізу супутникових даних. CNN знаходять застосування у супутникових спостереженнях завдяки наступним можливостям:

- Класифікація зображень: CNN відмінно справляються з класифікацією супутникових зображень за різними категоріями земного покриття або землекористування, а також з ідентифікацією конкретних об'єктів. Відомі архітектури, такі як ResNet і VGGNet, дають змогу отримувати високоякісні результати на основі наборів даних аеро- і супутникових знімків [35].

1.1. Аналіз методів та моделей глибокого навчання для розв'язання ...

- Виявлення об'єктів: CNN у поєднанні з такими методами, як регресія з обмежувальною рамкою і блоків прив'язок, дозволяють виявляти такі об'єкти, як транспортні засоби, кораблі і будівлі на аерознімках. Швидша R-CNN [36] є популярною моделлю CNN для виявлення об'єктів.

- Семантична сегментація: Використовуючи повні згорткові мережі [37], зображення супутникового моніторингу можна сегментувати на рівні пікселів, присвоюючи кожному пікселю мітку класу. U-Net і SegNet є загальноновживаними архітектурами CNN для розв'язання цієї задачі [38] (рис. 4).

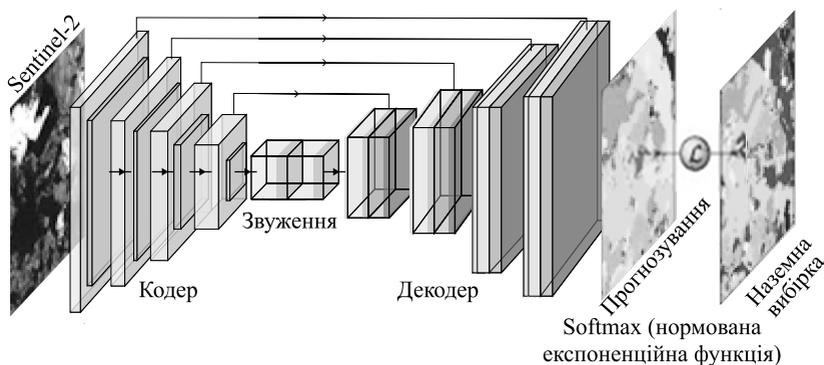


Рис. 4. Архітектура U-Net [39]

- Виявлення змін: Сіамські CNN (рис. 5), що включають дві вхідні гілки, дозволяють ефективно виявляти зміни між різночасовими зображеннями, що робить їх цінними для ідентифікації районів, які постраждали від стихійних лих [40-42].

- Злиття зображень: CNN використовуються для злиття мультиспектральних і панхроматичних зображень, створюючи кольорові зображення високого просторового розрізнення [44].

- Надвисоке просторове розрізнення: CNN, такі як SRCNN, дозволяють підвищувати просторове розрізнення, покращуючи якість зображення. SRCNN, або згорткова нейронна мережа для підвищення просторового розрізнення, - це новаторська архітектура згорткової нейронної мережі (CNN), що використовується для отримання надвисокого просторового розрізнення для одного зображення [45, 46]. Вона була запропонована в 2014 році і стала однією з перших CNN, застосованих до розв'язання задач відновлення зображень з

надвисоким просторовим розрізненням Архітектура SRCNN складається з трьох згорткових шарів - виділення фрагментів, нелінійного відображення та реконструкції (рис. 6).

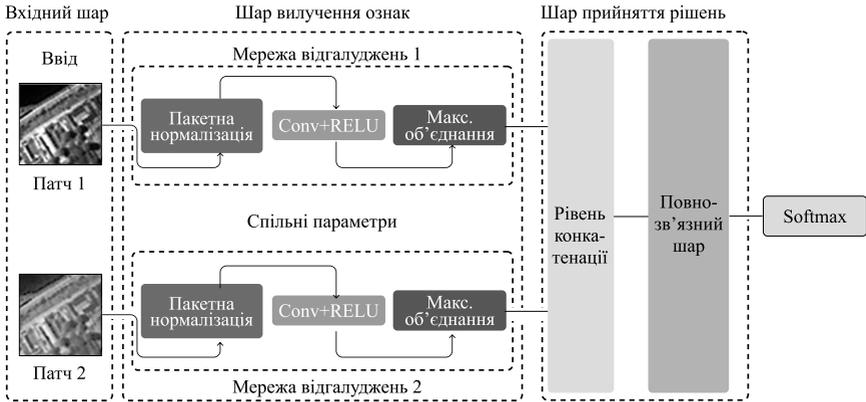


Рис. 5. Структура сіамської мережі [43]

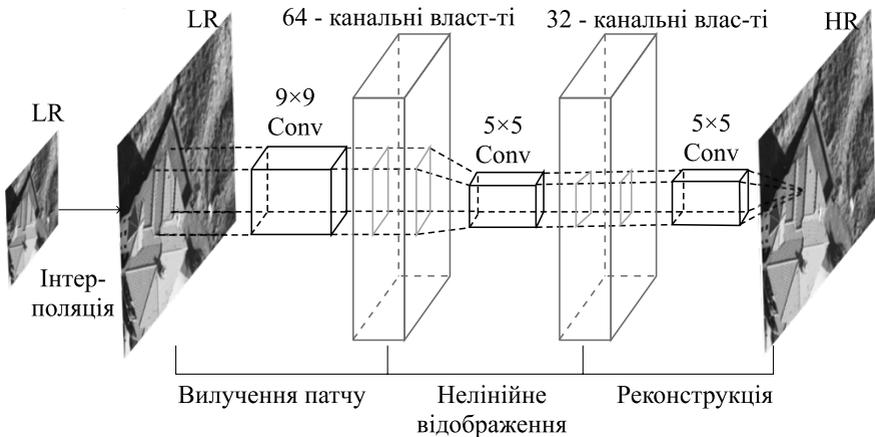


Рис. 6. Ескіз архітектури SRCNN [48]

Вона продемонструвала найвищу продуктивність порівняно з попередніми методами підвищення просторового розрізнення, заснованими на прикладах та розрідженому кодуванні. SRCNN поступово масштабує зображення низького просторового розрізнення, навчаючись наскрізному відображенню від низького

до високого просторового розрізнення. Це продемонструвало, що CNN можуть ефективно вирішувати проблеми низькорівневої обробки зображень, розширюючи сферу їх застосування за межі задач технічного зору високого рівня. Архітектура SRCNN зумовила підвищення інтересу до використання глибинного навчання для інших задач відновлення зображень, таких як фільтрація шуму та зменшення розмитості. Згодом на основі архітектури та методології навчання SRCNN були розроблені вдосконалені CNN з надвисоким просторовим розрізненням [47].

- Виявлення аномалій: CNN можуть вивчати закономірності супутникових знімків та ідентифікувати області, що відхиляються від норми, вказуючи на потенційну аномалію [49, 50].

Згорткові нейронні мережі (CNN) були адаптовані для обробки даних з тривимірних хмар точок, отриманих з LiDAR-сенсорів, у таких задачах, як класифікація, сегментація та ідентифікація об'єктів [51, 52]. Таку адаптацію можна здійснити кількома методами. Об'ємні CNN [53] використовують представлення хмари точок у вигляді тривимірної воксельної сітки, яка обробляється стандартними 3D CNN. Однак обмеження пам'яті може призвести до низької роздільної здатності. Багаторакурсні CNN [54] генерують декілька 2D-проекцій з хмари точок, які потім подаються в звичайні 2D CNN. Агрегування ознак дає прогноз для кожної точки.

PointNet [55] безпосередньо споживає сирі хмари точок, використовуючи MLP з максимальним об'єднанням для вивчення точкових ознак, інваріантних до перестановки вхідних даних, що робить його новаторським підходом. Локальне об'єднання ознак застосовує стандартні CNN на локальних фрагментах області навколо кожної 3D-точки з подальшим об'єднанням ознак. Графові CNNs [56] моделюють хмару точок як граф, з точками як вузлами, і використовують згортки графа над локальними областями для вивчення ознак.

Неперервні згортки визначають згортки на неперервній області з використанням радіальних базисних функцій з центром у точках. Кореляція ядра та деформація вивчають ваги ядра та поля деформації, щоб відповідати різним локальним геометріям. Вісімкове розбиття ієрархічно ділить простір застосовує 3D CNN до вісімкових вокселів, що містять точки [57].

1.5. РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ (RNN)

Рекурентні нейронні мережі (RNN) - це спеціалізовані штучні нейронні мережі, призначені для обробки послідовних даних, таких як текст, аудіо, часові ряди та відео.

Ключовими характеристиками RNN є циклічні зв'язки, які зберігають інформацію в послідовності, забезпечуючи динамічну поведінку в часі. RNN, такі як LSTM [58] та GRU [59], дозволяють фіксувати довгострокові залежності та обробляти послідовності різної довжини, рекурсивно застосовуючи рекурентну функцію на кожному часовому кроці (рис. 7).

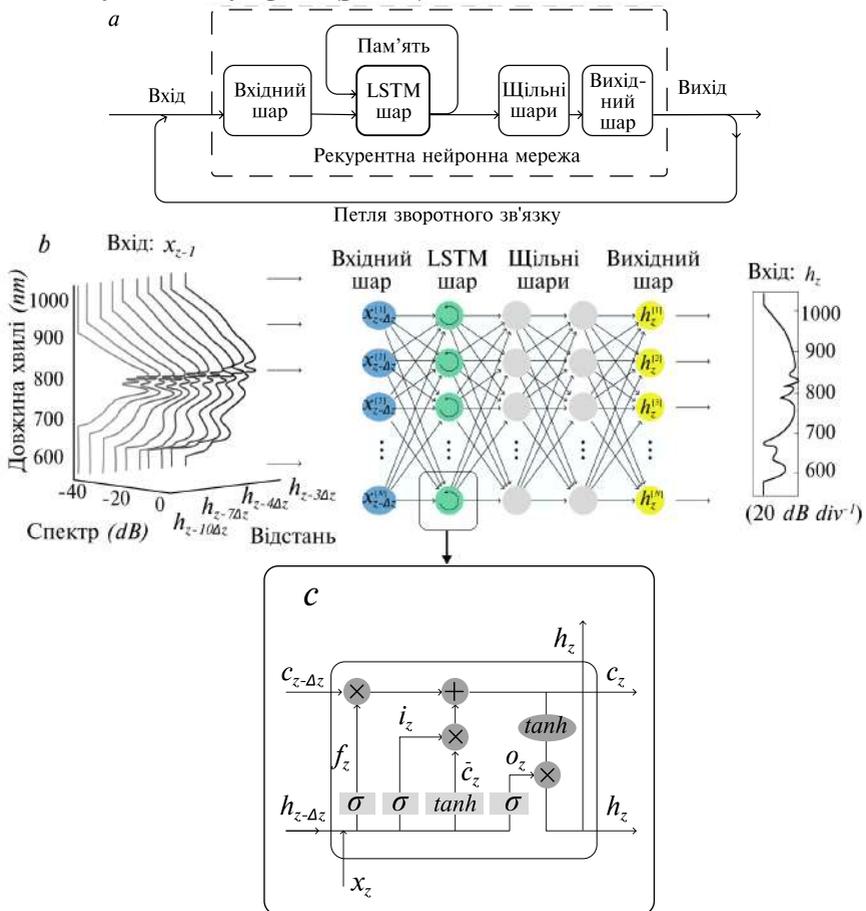


Рис. 7. Рекурентна нейронна мережа [67]

RNN знаходять широке застосування у моделюванні мови [60], розпізнаванні мовлення [61], генерації тексту [62], машинному перекладі [63], субтитруванні зображень/відео [64] та прогнозуванні часових рядів [65]. Однак під час навчання на довгих послідовностях вони можуть зіткнутися з такими проблемами, як зникаючі та вибухові градієнти. Для покращення фокусування на релевантному вхідному контексті до RNN часто додають механізми уваги [66].

Це питання буде розглянуто в підрозділі 1.8. RNN є цінним інструментом для моделювання послідовних даних, використовуючи їх короткочасну пам'ять і динамічну часову поведінку, отриману завдяки циклічним зв'язкам.

Рекурентні нейронні мережі (RNN) знаходять застосування в різних задачах супутникового моніторингу, які вимагають моделювання послідовних даних. До таких застосувань відносяться:

- Аналіз часових рядів: RNN, особливо варіанти LSTM, використовуються для прогнозування врожайності сільськогосподарських культур, тенденцій вирубки лісів, кліматичних змін тощо на основі часових рядів супутникових знімків [68, 69].

- Відстеження об'єктів: RNN можуть моделювати рухи та появу об'єктів на послідовних відеоданих супутникового моніторингу [70], що дозволяє відстежувати автомобілі, кораблі, літаки тощо.

- Виявлення змін: RNN допомагають виявляти зміни в ландшафтах, міській інфраструктурі тощо з плином часу, використовуючи послідовні супутникові зображення [71].

- Підписи до зображень: RNN дозволяють генерувати текстові описи вмісту та активностей на супутникових знімках [72], наприклад, щодо змін берегової лінії.

- Аналіз хмари точок: Застосовується до послідовного сканування LiDAR-даних. RNN аналізують динамічні хмари точок для таких задач, як 4D-сегментація [73].

- Генерація зображень: умовні RNN, такі як LSTM-GAN, можуть створювати реалістичні супутникові зображення, вивчаючи просторові кореляції [74]. Архітектура GAN буде розглянута в підрозділі 1.6.

- Виявлення аномалій: RNN вивчають нормальні часові закономірності в послідовних даних повторного супутникового моніторингу, що дозволяє виявляти аномальні події [75].

- Класифікація послідовності зображень: RNN класифікують відеокадри спостереження землі або фрагменти супутникових знімків за категоріями землекористування [76].

- Видалення хмар: RNN вивчають хмарні патерни на часових рядах супутникових знімків для реконструкції чистих композитних зображень [77].

Підсумовуючи, архітектури RNN, зокрема LSTM, є цінними для розв'язання задач спостереження Землі, пов'язаних з динамікою в часі, завдяки їх здатності моделювати довготривалий контекст і пам'ять, що робить їх придатними для послідовного моделювання.

1.6. ГЕНЕРАТИВНІ ЗМАГАЛЬНІ МЕРЕЖІ

Генеративні змагальні мережі (GAN) [78] - це тип алгоритмів ШІ, які використовуються в машинному навчанні без вчителя (рис. 8). GAN складаються з генератора та дискримінатора, які змагаються в грі з нульовою сумою [79]. Генератор виробляє синтетичні дані, тоді як дискримінатор відрізняє справжні зразки від фальшивих. Завдяки цьому змагання генератор набуває досвіду у створенні все більш реалістичних синтетичних даних. Застосування GAN включають створення фотореалістичних зображень [80], синтетичного звуку [81], перетворення зображення у зображення [82], генерування зображень з тексту [83], виявлення аномалій [84] та доповнення даних [85]. GAN пропонують потужний підхід для реалізації навчання без вчителя, що дозволяє генерувати реалістичні синтетичні дані в різних прикладних областях.



Рис. 8. Загальна ілюстрація структури генеративної змагальної мережі (GAN) [86]

1.7. ВИКОРИСТАННЯ ГЕНЕРАТИВНИХ ЗМАГАЛЬНИХ МЕРЕЖ У СУПУТНИКОВОМУ МОНІТОРИНГУ

Мережі GAN знайшли різноманітні застосування в супутниковому моніторингу, надаючи інноваційні рішення для розв'язання задач аналізу та інтерпретації зображень. Нижче наведено деякі задачі в цій галузі, де GAN ефективно використовуються.

Покращення зображення. GAN відіграють вирішальну роль у підвищенні якості супутникових зображень із низьким просторовим розрізненням. Генеруючи додаткові реалістичні деталі та покращуючи просторове розрізнення, GAN дозволяють аналітикам отримувати чіткішу інформацію із супутникових зображень, допомагаючи точніше тлумачити та приймати рішення. Розкриваючи дрібніші деталі, технології суперроздільності на основі GAN дозволяють покращити візуалізацію та ідентифікацію таких об'єктів, як транспортні засоби, дерева та дороги. Зокрема, проблема була ефективно вирішена в [87]. У дослідженні пропонується методологія підвищення просторового розрізнення (супер-розрізнення) існуючих зображень із низьким просторовим розрізненням до зображень із вищим просторовим розрізненням. Основна ідея полягає в тому, щоб використовувати передові методи глибокого навчання - Generative Adversarial Networks (GAN) і навчити їх збільшувати просторове розрізнення супутникових зображень. Експериментальні результати для даних Sentinel-2 показали, що цей підхід ефективний і може бути використаний для створення продуктів надвисокого просторового розрізнення.

Видалення хмар і заповнення прогалін. Хмари часто закривають важливі ділянки супутникових зображень, перешкоджаючи їх аналізу. GAN можна навчити на безхмарних прикладах для створення безхмарних версій зображень, ефективно видаляючи хмарний покрив і відкриваючи приховану інформацію. У [88] автори пропонують метод видалення хмар для одного супутникового зображення. Складність цієї задачі полягає в труднощах відрізнити хмари від білих об'єктів на земній поверхні та коректно заповнити нерівні відсутні області. Автори пропонують двоетапний алгоритм. Перший етап – це сегментація хмар, тобто виділення хмар і видалення тонких хмар (димки) безпосередньо за допомогою U-Net. Другий етап – відновлення зображення, тобто видалення густої хмари та відновлення відповідних нерегулярних відсутніх областей за допомогою

генеративної змагальної мережі GAN. Подібним чином GAN є ефективними для заповнення відсутніх частин супутникових зображень, які є результатом несправності датчика або поганого покриття. Зокрема, у [89] представлено нову нейронну систему, засновану на умовних глибоких генеративних змагальних мережах (сGAN), оптимізованих для заповнення прогалів супутникових зображень, використовуючи сусідні значення. Достовірно доповнюючи відсутній контент, GAN дозволяють здійснювати більш повний і безперервний моніторинг областей, що становлять інтерес.

Виявлення аномалії. Використовуючи GAN, можна ефективно виявляти аномалії в супутникових даних. GAN можуть вивчати шаблони нормальності із супутникових даних, і відхилення від цих шаблонів можуть вказувати на аномалії, такі як незаконне вирубування лісів, будівництво чи забруднення, допомагаючи своєчасно та точно ідентифікувати потенційні проблеми. Запропонований метод на основі GAN [90] було апробовано на мультимедійних зображеннях Landsat за 2000-2019 роки для посушливого регіону в Алжирі. Він демонструє кращу продуктивність у виявленні змін опустелювання порівняно з DBN, DBM, CNN та іншими методами машинного навчання.

Симуляція. GAN дозволяють генерувати реалістичні змодельовані супутникові зображення для сценаріїв, коли реальних даних бракує або їх недостатньо. Ці змодельовані зображення можуть бути цінними для розширення наборів даних, дозволяючи дослідникам виконувати тести та аналізи в різних гіпотетичних ситуаціях. Автори [91] пропонують використовувати GAN для моделювання/симуляції географічних процесів, оцінки ефективності наборів даних для задачі Game of Life і розробки більш складних її варіантів як орієнтирів для майбутніх досліджень.

Реєстрація зображень. GAN використовуються для вирівнювання зображень, отриманих у різний час або з різних датчиків/кутів, забезпечуючи узгодженість даних. Таке вирівнювання підвищує точність виявлення змін і дозволяє проводити надійний аналіз часових рядів. У роботі [92] автори запропонували підхід на основі GAN для вирішення проблеми кореєстрації оптичних і SAR зображень. Спочатку вони використовували мережу на основі GAN для генерації псевдорадарного зображення з оптичного зображення, щоб забезпечити порівнянню інформацію про інтенсивність між двома зображеннями. Після цього застосувались методи, засновані на

площі та ознаках, для вирівнювання псевдо-радарного зображення з автентичним зображенням. Результати експерименту продемонстрували незамінність цього методу, особливо підкресливши ефективність генератора GAN. Зокрема, генератор GAN точно і надійно відтворює геометричну структуру оптичного зображення, відкриваючи тим самим нові можливості для MMRS (мультимодального супутникового моніторингу).

Виявлення об'єктів. GAN сприяють покращенню виявлення і класифікації об'єктів на супутникових знімках, таких як будівлі, дороги, літаки і кораблі. Використовуючи методи виявлення об'єктів на основі GAN, аналітики можуть отримати більш детальну і точну інформацію про об'єкти, присутні на знімках. У [93] було представлено SERGAN, генеративну змагальну мережу GAN з покращенням країв зображення. В цю архітектуру було включено модуль покращення країв зображень, щоб підкреслити краї об'єктів на зображеннях з надвисоким просторовим розрізненням (SR), тим самим сприяючи високоточному виявленню об'єктів.

Доповнення (аугментація) навчальної вибірки. При розв'язанні задач машинного навчання на супутникових даних часто виникає проблема незбалансованості навчальної вибірки, яку неможливо подолати традиційними підходами, оскільки вони не враховують фізичну природу багатоспектральних зображень а також їх семантичний контекст. В роботі [94] запропоновано метод аугментації навчальної вибірки для задач семантичної сегментації супутникових даних на основі GAN. Запропонований метод враховує спектральні і текстурні характеристики різних типів земного покриву і дозволяє підвищити точність класифікації міноритарних класів на 10% відсотків

1.8. ТРАНСФОРМЕРИ

Трансформери - це передова нейромережева архітектура, яка набула значної популярності в глибинному навчанні, зокрема для задач обробки природної мови (NLP). Трансформери були представлені у 2017 році [5], авторами якої були дослідники з проекту Google Brain. На відміну від рекурентних нейронних мереж (RNN), трансформери значною мірою покладаються на механізм уваги для встановлення глобальних залежностей між входом і виходом. Архітектура трансформерів показана на рис. 9.

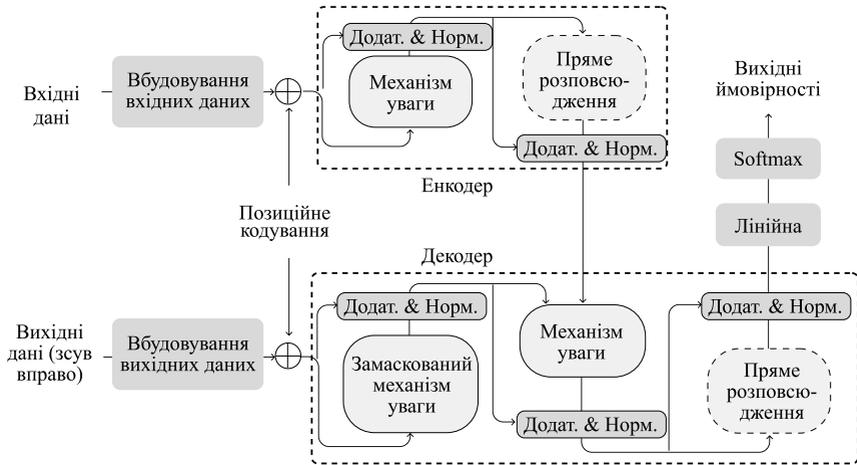


Рис. 9. Архітектура трансформерів [23]

Трансформери не використовують згортку чи рекурентність, працюючи лише з рівнем уваги. Вони розглядають кожну точку даних як незалежну від інших. Таким чином, позиційна інформація додається до моделі явно, щоб зберегти інформацію про порядок або розташування. Енкодер трансформера обробляє всю вхідну послідовність одразу, генеруючи вхідні представлення. У завданнях NLP декодер генерує вихідну послідовність токен за токеном. Важливою особливістю є здатність до багатосторонньої уваги, що дозволяє моделі фокусуватися на різних позиціях у вхідній послідовності. Щоб включити інформацію про положення токенів у послідовності, трансформери використовують позиційне кодування. Відсутність рекурентності дозволяє трансформерам навчатися паралельно, що робить їх більш ефективними, ніж RNN. Трансформери досягли найсучасніших результатів у задачах перекладу, перевершивши показники RNN і CNN, що значно сприяло їхній популярності. Серед відомих моделей трансформерів - BERT [95], GPT-2/3 [7, 8], RoBERTa [96] і T5 [97], які сприяли просуванню вперед у галузі NLP.

Трансформери набувають все більшої популярності в різних застосуваннях супутникового моніторингу завдяки їх здатності моделювати довгострокові залежності в послідовних даних. У контексті супутникового моніторингу трансформери довели свою ефективність у кількох сферах:

Задачі класифікації зображень виграють від використання трансформерів, оскільки вони розглядають вхідні зображення як

послідовності ділянок. Ця адаптація, відома як архітектура Vision Transformer (ViT) [98], продемонструвала високу продуктивність у тестах класифікації зображень.

Розв'язки задачі детекції об'єктів можна покращити за допомогою використання трансформерів детекції (Detection Transformers, DETR) [99], які замінюють традиційну архітектуру CNN і ручні етапи постобробки на архітектуру трансформерного кодера-декодера. Це дозволяє використовувати наскрізне навчання для ідентифікації об'єктів. Для семантичної сегментації зображень трансформери можуть бути адаптовані за допомогою підходу Semantic Segmentation Transformer (SETR) [100]. Тут трансформерний декодер передбачає попиксельні мітки, підвищуючи точність семантичної сегментації. Трансформери також цінні в задачах підвищення роздільної здатності [101].

Механізм уваги, притаманний трансформерам, виявляється корисним для виявлення аномалій на супутникових зображеннях [102], оскільки він дозволяє ідентифікувати патерни аномалій. У сфері підписів до супутникових зображень архітектури на основі трансформерів, такі як Multimodal Attention Transformer (MAT) [103], здатні генерувати контекстні підписи. Аналіз хмари точок на основі даних LiDAR також може отримати вигоду від трансформерів [104], оскільки вони можуть безпосередньо обробляти тривимірні хмари точок для задач класифікації та сегментації.

Загалом, трансформери є ефективним архітектурним рішенням для моделювання просторово-часових зв'язків у супутникових даних. Їх механізм уваги добре підходить для обробки різномасштабних і мультимодальних даних спостереження Землі, що сприяє їх зростаючому використанню в цій галузі.

1.9. ГРАФОВА НЕЙРОННА МЕРЕЖА (GNN)

Графова нейронна мережа (ГНМ, GNN) [104] - це модель глибинного навчання, призначена для аналізу даних, структурованих у вигляді графів. Графи складаються з вузлів (вершин) і ребер (зв'язків між вузлами), а ГНМ використовують властивості вузлів і зв'язки між ребрами для вилучення важливої інформації. Ці моделі безпосередньо оперують даними графа,

поширюючи інформацію про властивості вузлів по ребрах для аналізу і навчання.

Існують різні архітектури GNN (рис. 10), включаючи графові згорткові мережі (GCN) [105], графові мережі уваги (GAT) [106] та графові рекурентні нейронні мережі (GRNN) [107], [108]. GNN запам'ятовують представлення вузлів, які кодують як ознаки вузлів, а також топологію графа, що лежить в основі, фіксуючи контекст мережі у вкладених вузлах.

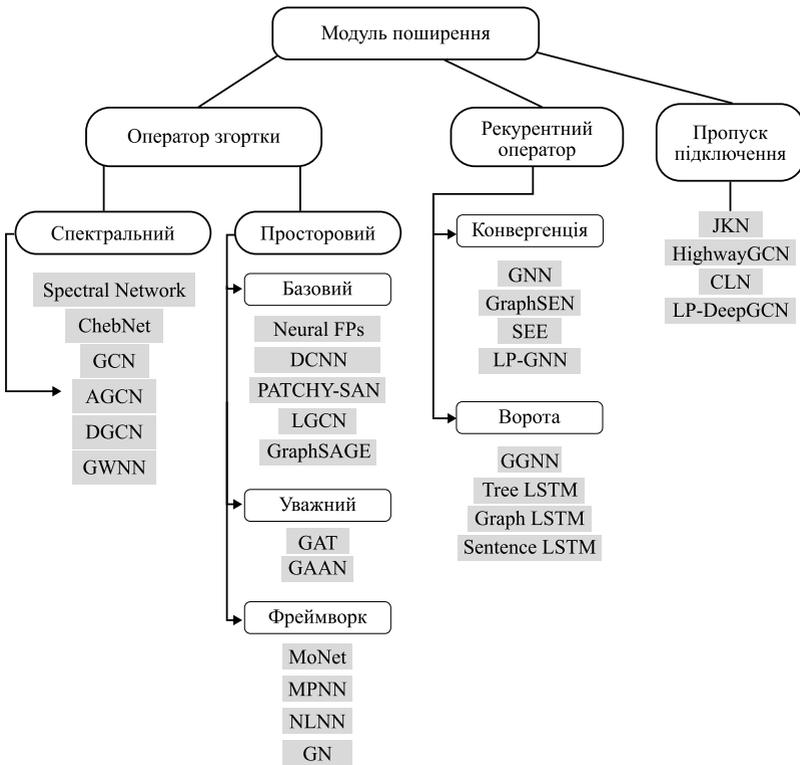


Рис. 10. Огляд обчислювальних модулів [109]

Для задач класифікації вузлів, GNN розглядають сусідні вузли та ребра, щоб зробити прогнозування для даного вузла. У задачах класифікації графів GNN вивчають репрезентації для цілих графів, щоб класифікувати їх.

GNN мають можливість динамічно оновлювати представлення вершин, пропонуючи та трансформуючи ознаки на ребрах, що дозволяє їм ефективно моделювати залежності.

Ці моделі знаходять застосування в різних галузях, таких як аналіз соціальних мереж [110], прогнозування властивостей молекул [111], рекомендаційні системи [112], графи знань [113] та прогнозування трафіку [114].

Графові нейронні мережі (ГНМ) знайшли різноманітне застосування в супутниковому моніторингу та геопросторовому аналізі завдяки своїй здатності моделювати дані у вигляді графів і ефективно фіксувати взаємозв'язки. Ось деякі застосування ГНМ у спостереженні землі.

1. Сценарні графи. GNN моделюють супутникові зображення у вигляді сценарних графів, представляючи об'єкти як вузли, а зв'язки між ними - як ребра. Такий підхід дозволяє отримувати контекстну інформацію, покращуючи загальне розуміння та аналіз. Наприклад, в [115] розглядається проблема класифікації багатомісних сцен на основі супутникових зображень з дуже високим просторовим розрізненням (VHR) шляхом дослідження глибокої графової згорткової мережі (ГЗМ). Оскільки задана сцена надвисокого розрізнення містить декілька локальних ознак, традиційні системи класифікації з однією міткою не передають справжньої семантики сцени.

З іншого боку, очікується, що підходи до класифікації за кількома мітками допоможуть краще охарактеризувати область, що розглядається. В межах багатокласової класифікації дане зображення представляється у вигляді графа суміжності регіонів (RAG) відповідних локальних областей.

2. Сегментація. GNN покращують сегментацію зображень, розглядаючи пікселі або суперпікселі як вузли графа і поширюючи інформацію між ними на основі близькості та схожості. Це допомагає досягти більш точних і послідовних результатів сегментації. В [116] автори пропонують підхід з використанням графових згорткових мереж (GCN) на основі суперпікселів для семантичної сегментації SAR-зображень. Суперпікселі та їх характеристики використовуються для побудови графа, де суперпікселі є вузлами, а ребра відображають просторові відношення. Поєднуючи суперпікселі, глибоке вилучення ознак і GCN, запропонований підхід спрямований на використання локальних ознак зображення, а також нелокальних просторових зв'язків для точної сегментації SAR-зображень. Експерименти на

даних Sentinel-1 демонструють покращену продуктивність порівняно з іншими методами.

3. Класифікація. Інтеграція шарів GNN у згорткові нейронні мережі (CNN) покращує класифікацію ґрунтового покриву та типів культур. Доповнюючи спектральні дані просторовими зв'язками, GNN сприяють підвищенню ефективності класифікації. Автори статті [117] пропонують новий метод класифікації гіперспектральних зображень під назвою FCGN (feature fusion of convolutional neural network and graph convolutional network). Вони об'єднують ознаки з двох гілок, щоб отримати багатший набір ознак, які включають як локальні деталі, так і глобальну контекстну інформацію. Вони демонструють покращену точність класифікації порівняно з використанням лише GCN або CNN на стандартних гіперспектральних наборах даних, таких як Indian Pines, Pavia University та Salinas.

4. Виявлення об'єктів. GNN можна застосовувати для виявлення об'єктів на аерознімках, формулюючи задачу як класифікацію вершин графа, враховуючи навколишній контекст. Ребра графа з'єднують об'єкти і фонові області, допомагаючи в локалізації об'єктів. В [118] запропоновано нову гібридну багатопотокову ієрархічну мережу вбудовування графів, керовану увагою (HA-MHGEN) для виявлення багатокласових геопросторових об'єктів на супутникових зображеннях з високим просторовим розрізненням. Метод будує ієрархічні просторові графи для представлення різномасштабних просторових відношень між об'єктами та семантичні графи, що інтегрують словесні вставки міток об'єктів для відображення контекстних семантичних відношень. Багатомасштабна мережа згорткових графів використовує ці графи для вивчення внутрішньо- та міжоб'єктних просторових і семантичних зв'язків. Модуль перехресної уваги об'єднує просторові та семантичні ознаки, дозволяючи моделі вловлювати явні та неявні зв'язки з обох доменів. Комплексні експерименти на наборах даних DOTA, DIOR та NWPU VHR-10 демонструють ефективність запропонованого методу порівняно з іншими сучасними підходами до виявлення об'єктів супутникового моніторингу. Модель досягає вищої продуктивності завдяки спільному навчанню взаємодоповнюючих просторових та семантичних патернів.

5. Виявлення змін. Пари часових зображень можуть бути представлені у вигляді графів, що дозволяє GNN виявляти зміни між часовими кроками на основі модифікацій структури графа та

вузлових ознак. Це полегшує моніторинг та аналіз динамічних середовищ. Автори [119] пропонують наскрізну динамічну нейронну мережу на рівні графа (DGLNN) для виявлення змін на радарних зображеннях із синтезованою апертурою (SAR). DGLNN використовує локальну структуру кожного сусіднього пікселя на рівні графа для навчання дискримінативного графового представлення. Він використовує підхід k-найближчих сусідів для реконструкції ребер між вузлами замість фіксованих ребер, що дозволяє кожному вузлу використовувати ознаки різних сусідів. Експерименти на міждоменних зображеннях SAR показують, що DGLNN досягає найвищої продуктивності порівняно з іншими методами глибинного навчання для виявлення змін SAR. Графовий підхід ефективно справляється з шумом і відсутністю явної структури на SAR-зображеннях.

6. Аналіз хмар точок. GNN особливо добре підходять для аналізу хмар точок LiDAR, де вузли представляють окремі точки і ребра, визначені за допомогою тривимірної близькості. Такий підхід дозволяє розв'язувати такі задачі, як класифікація та сегментація хмари точок. Автори [120] пропонують нову нейронну мережу згортки геометричних моментів графа (GGM-Net) для класифікації форми хмари точок. Запропоновано новий оператор згортки, який називається згортка GGM, що явно кодує локальну геометричну структуру множини точок, вивчаючи особливості з геометричних моментів точок та їхніх локальних сусідів. Це призводить до кращого розуміння геометрії поверхні та підвищує стійкість.

7. Злиття даних. GNN дозволяють об'єднувати інформацію з різних джерел, таких як гіперспектральні, LiDAR та оптичні дані, представляючи їх у вигляді вузлів графа та встановлюючи ребра для зв'язку між ними. Це полегшує комплексну інтеграцію даних. Автори пропонують підхід на основі графів [121] для об'єднання спектральної, просторової та висотної інформації з гіперспектральних зображень і даних LiDAR. Вони виділяють морфологічні особливості з гіперспектрального зображення і даних LiDAR за допомогою морфологічних відкриттів і закриттів. Ці особливості фіксують просторову інформацію та інформацію про висоту. Об'єкти нормалізуються до однієї розмірності і будується граф злиття, де вузли з'єднуються лише тоді, коли вони мають схожі спектральні, просторові та висотні характеристики. Потім характеристики проєктуються в низьковимірний підпростір, де зберігаються сусідські зв'язки. Це дозволяє зменшити розмірність зв'язку та об'єднати різномодальні дані. За словами

авторів, цей підхід на основі графів підвищує точність класифікації порівняно з використанням окремих джерел даних або простим нагромадженням ознак. В роботі [122] досліджено способи представлення багаточасткових графів для задач машинного навчання на графах із використанням топологічних методів, зокрема персистентних гомологій (ПГ) хмар точок. Також розглянуто векторні представлення графів, отримані за допомогою білінійних моделей і моделей трансляції, таких як TuckeR, MurE та PairRE. Як приклад використано багаточастковий граф із 271 типом вершин і двома типами ребер. Обчислено ПГ до другого виміру, що охоплює 1-, 2- та 3-вимірні топологічні особливості графів. Персистентні діаграми використано для представлення ПГ, а їх точки проаналізовано статистично за допомогою коефіцієнтів ексцесу, асиметрії, середнього та відхилення. Аналіз показав, що різні моделі представлень мають різні характеристики з точки зору ПГ, що вказує на їхню топологічну неоднаковість. Це підтверджує, що вибір моделі суттєво впливає на якість і точність вивчення багаточасткових графів.

8. Напівкерване навчання. GNN використовують зв'язність графів для напівкерваного навчання, коли кількість маркованих супутникових даних обмежена. Вони можуть ефективно використовувати велику кількість немаркованих даних для покращення продуктивності моделі. Автори пропонують нову графову згорткову мережеву модель [123] під назвою DGCGAN, яка поєднує GCN і DCGAN для напівкерваної класифікації вузлів. DGCGAN усуває два основні обмеження існуючих GCN - низьку точність, коли позначених вузлів мало, та недостатню робастність. Спочатку він відображає дані графа у високонелінійний простір, використовуючи симетричне нормалізоване перетворення Лапласа для отримання характеристик вузлів. Потім він перетворює ознаки вузлів у звичайні структуровані дані, такі як зображення, використовуючи бікубічну інтерполяцію, і подає їх як позитивні вибірки на дискримінатор. Модуль з розширеними можливостями вибірково покращує характеристики вузлів для кращої класифікації. Завдяки вклученню DCGAN модель розширює розмір вибірки і додає обмеження для підвищення робастності. Експерименти на мережах цитування та наборі супутникових даних показують, що DGCGAN перевершує відомі методи напівкерваного навчання, особливо коли маркованих даних дуже мало. Запропоновані методи допомагають подолати обмеження GCN і підвищити продуктивність у задачах класифікації напівкерваних вузлів.

З розвитком досліджень у галузі GNN можна очікувати все більшого застосування і впливу цих потужних моделей у супутниковому моніторингу, що дасть змогу проводити більш точний і всебічний аналіз у різних прикладних галузях.

Інноваційні моделі та технології надають нові можливості, але водночас створюють нові виклики. Нещодавно [124] було визначено деякі ключові виклики у використанні ШІ та машинного навчання для супутникового моніторингу. Ці виклики включають обмеженість навчальних наборів даних, складність моделей супутникового моніторингу, обробку великих даних, адаптацію до нетрадиційних джерел даних, труднощі трансферного навчання, недостатню інтерпретованість, високий бар'єр для входу, проблеми навчання та архітектурні обмеження. На їх подолання спрямовано сучасні дослідження в сфері супутникового інтелекту.

ВИСНОВКИ

Аналіз поточного стану досліджень в сфері глибинного навчання [125, 126, 127] свідчить про прогрес у вирішенні цих проблем. Такі стратегії, як трансферне навчання, доповнення даних і нові мережеві архітектури покращили продуктивність моделей і розв'язання складних задач. Розподілене навчання, хмарні обчислення і спеціалізовані мікросхеми зробили обробку великих обсягів супутникових даних більш можливою. Такі методи, як адаптація до предметної області, карти уваги і зрозумілий ШІ, були прийняті для покращення можливості передачі і інтерпретації даних. Фреймворки з відкритим вихідним кодом зробили глибинне навчання більш доступним. Такі стратегії, як вибір спектральних каналів і напівконтрольоване навчання, частково вирішили проблеми навчання. Інновації в CNN, трансформерах і GNN розширили можливості моделей для задач супутникового моніторингу.

Це означає, що машинне навчання інтенсивно розвивається в сфері спостереження Землі. Незважаючи на прогрес, все ще залишаються проблеми, зокрема, різноманітність наборів даних, проблеми узагальнення і потреба в моделях, результати яких краще інтерпретуються. Поточні зусилля спрямовані на подолання цих перешкод і розвиток застосувань ШІ і ML у галузі супутникових спостережень. У табл. 1 наведено порівняння

специфіки проблем застосування AI/ML в сфері спостереження Землі з традиційною обробкою зображень.

Як видно з табл. 1, супутниковий моніторинг часто є проблематичним через великі, різноманітні мультимодальні дані, де мітки, домени і завдання відрізняються від традиційної обробки зображень. Рішення включають використання немаркованих даних, навчання на основі перенесення моделей (transfer learning) та інші підходи. На сьогоднішній день рішення на основі ML активно розвиваються. У наступних розділах описано підходи та їх застосування, спрямовані на подолання описаних вище викликів у впровадженні рішень ML Earth Intelligence для прийняття рішень та сталого розвитку.

Таблиця 1. Порівняння проблем ШІ/ML у галузі супутникових спостережень з традиційною обробкою зображень

Виклик	Супутниковий моніторинг	Традиційна обробка зображень	Потенційні рішення
Розмір даних	Дуже великі (ГБ/ТБ)	Менші (МБ/ГБ)	Хмарне сховище, розподілене навчання
Різнорозмірність даних	Багатоспектральні, гіперспектральні, SAR, LiDAR	RGB, градації сірого	Мультимодальні моделі, злиття даних
Дефіцит міток	Дорогий збір базових даних	Комп'ютерне маркування	Трансферне навчання, напівконтрольоване навчання
Просторова роздільна здатність	Змішані пікселі з низькою роздільною здатністю	Чітке розділення об'єктів	Контрольоване попереднє навчання, синтез зображень
Часовий аналіз	Необхідне моделювання часових рядів	Окремих зображень достатньо	Рекурентні мережі, моделі виявлення змін
Зміщення домену	Узагальнення через датчики, географія	Послідовні домени	Адаптація предметної області, налагодження моделі
Інтерпретованість	Важлива для оперативного використання	Не дуже важлива для	Зрозумілі методи ШІ

1.1. Аналіз методів та моделей глибинного навчання для розв'язання ...

		оперативного використання	
Оцінювання	Необхідні спеціальні метрики	Достатньо стандартних показників	Схеми перевірки для конкретного домену

ПЕРЕЛІК ПОСИЛАНЬ

1. Bali O., Bali J. Artificial intelligence in ophthalmology and healthcare: An updated review of the techniques in use. *Indian Journal of Ophthalmology*. 2021. Vol. 69, no. 1. pp. 8-13. DOI: 10.4103/ijo.ijo_1848_19.
2. Makridakis S. The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*. 2017. Vol. 90. pp. 46–60. DOI: 10.1016/j.futures.2017.03.006.
3. Khan M. *Advancements in Artificial Intelligence: Deep Learning and Meta-Analysis*. Center for Open Science. 2023. DOI: 10.5281/zenodo.8106837.
4. Rajesh, S., C., K.: *Advancements in Deep Learning: A Comprehensive Review*. *REST Journal on Data Analytics and Artificial Intelligence*. 2023. Vol. 2, no. 2. pp. 65-69. DOI: <https://doi.org/10.46632/jdaai/2/2/7>.
5. Vaswani, A., Shazeer, N., Parmar, N., et al. Attention is All You Need. In *NIPS*. Presented at the (2017).
6. Nguyen, G., Dlugolinsky, S., Bobok, M. et al. Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*. 2019. Vol. 52. pp. 77–124. DOI: <https://doi.org/10.1007/s10462-018-09679-z>.
7. Sarker, I.H. *Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions*. *SN Computer Science*. 2021. Vol. 2, no. 420. pp. DOI: <https://doi.org/10.1007/s42979-021-00815-1>.
8. Brown B., Mann T., Ryder B., et al. Language Models are Few-Shot Learners. *Advances in neural information processing systems*. 2020. Vol. 33. pp. 1877-1901.
9. Saleh Z. *Artificial Intelligence Definition, Ethics and Standards*. The British University in Egypt. 2019.
10. Goertzel B., Pennachin C. *Artificial general intelligence*. New York: Springer. 2007. P. 518.
11. Kim S.-K., Huh J.-H. Consistency of Medical Data Using Intelligent Neuron Faster R-CNN Algorithm for Smart Health Care

Application. Healthcare. 2020. Vol. 8, no. 185. pp. 1-24. DOI: <https://doi.org/10.3390/healthcare8020185>.

12. J. Borana: Applications of Artificial Intelligence & Associated Technologies. Science [ETEBMS-2016], 2016. Vol. 5, no 6. pp. 64-67.

13. Reza Tizhoosh H., Pantanowitz L. Artificial Intelligence and Digital Pathology: Challenges and Opportunities. Journal of Pathology Informatics. 2018. Vol. 9, no. 38. pp. 1-6. DOI: https://doi.org/https://doi.org/10.4103/jpi.jpi_53_18.

14. Grilli E., Remondino F. Classification of 3D Digital Heritage. Remote Sensing. 2019. Vol. 11, no. 7. DOI: <https://doi.org/10.3390/rs11070847>.

15. Mukhamediev R.I., Popova Y., et al. Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges. Mathematics. 2022. Vol. 10, no. 2552. DOI: <https://doi.org/10.3390/math10152552>.

16. Nassif A.B., Shahin I., Attili I., et al. Speech Recognition Using Deep Neural Networks: A Systematic Review. IEEE Access. 2019, Vol. 7, pp. 19143–19165 (2019). DOI: <https://doi.org/10.1109/access.2019.2896880>.

17. Schmidhuber J. Deep learning in neural networks: An overview. Neural Networks. 2015. Vol. 61, pp. 85–117. DOI: <https://doi.org/10.1016/j.neunet.2014.09.003>.

18. Litjens G., Kooi T., Bejnordi B.E., et al. A survey on deep learning in medical image analysis. Medical Image Analysis. 2017. Vol. 42. pp. 60–88. DOI: <https://doi.org/10.1016/j.media.2017.07.005>.

19. LeCun Y., Kavukcuoglu K., Farabet C. Convolutional networks and applications in vision. Proceedings of 2010 IEEE International Symposium on Circuits and Systems. 2010. pp. 253-256. DOI: [10.1109/ISCAS.2010.5537907](https://doi.org/10.1109/ISCAS.2010.5537907).

20. Zhang, L., Wang, S., Liu, B. Deep learning for sentiment analysis: A survey. WIREs Data Mining and Knowledge Discovery. 2018. Vol. 8. DOI: <https://doi.org/10.1002/widm.1253>.

21. Goodfellow I., Pouget-Abadie J., Mirza M., et al. Generative adversarial networks. Communications of the ACM. 2020. Vol. 63. pp. 139–144. DOI: <https://doi.org/10.1145/3422622>.

22. Li Y., Chen C.L.P. Zhang T. A Survey on Siamese Network: Methodologies, Applications, and Opportunities. IEEE Transactions on Artificial Intelligence. 2022. Vol. 3. pp. 994–1014. DOI: <https://doi.org/10.1109/tai.2022.3207112>.

23. Lin T., Wang Y., Liu X., et al. A survey of transformers. AI Open. 2022. Vol. 3. pp. 111–132. DOI: [10.1016/j.aiopen.2022.10.001](https://doi.org/10.1016/j.aiopen.2022.10.001).

24. Chai J., Zeng H., Li A., et al. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*. 2021. Vol. 6, no. 100134. DOI: 10.1016/j.mlwa.2021.100134.
25. Mehrish A., Majumder N., Bharadwaj R., et al. A review of deep learning techniques for speech processing. *Information Fusion*. 2023. Vol. 99, no. 101869 DOI: 10.1016/j.inffus.2023.101869.
26. Otter D.W., Medina J.R., Kalita J.K. A Survey of the Usages of Deep Learning for Natural Language Processing. *IEEE Transactions on Neural Networks and Learning Systems*. 2021. Vol. 32. pp. 604–624. DOI: 10.1109/tnnls.2020.2979670.
27. Castelvechi D. Can we open the black box of AI? *Nature*. 2016. Vol. 538. pp. 20–23. DOI: 10.1038/538020a.
28. Artiemjew P., Chojka A., Rapiński J. Deep Learning for RFI Artifact Recognition in Sentinel-1 Data. *Remote Sensing*. 2020. Vol. 13, no. 7. DOI: 10.3390/rs13010007.
29. Han X., Zhong Y., Cao L., et al. Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification. *Remote Sensing*. 2017. Vol. 9, no. 848. DOI: 10.3390/rs9080848.
30. Muhammad U., Wang W., Chattha S.P., et al. Pre-trained VGGNet Architecture for Remote-Sensing Image Scene Classification. *International Conference on Pattern Recognition (ICPR)*. IEEE. 2018. pp. 1622–1627. DOI: 10.1109/ICPR.2018.8545591.
31. He K., Zhang X., Ren S., et al. Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016. pp. 770–778.
32. Ma H., Liu Y., Ren Y., Wang D., Yu L., Yu J. Improved CNN Classification Method for Groups of Buildings Damaged by Earthquake, Based on High Resolution Remote Sensing Images. *Remote Sensing*. 2020. Vol. 12, no. 260 DOI: 10.3390/rs12020260.
33. Zakria Z., Deng J., Kumar R., Khokhar M.S., Cai J., Kumar J. Multiscale and Direction Target Detecting in Remote Sensing Images via Modified YOLO-v4. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. Vol. 15, pp. 1039–1048. DOI: 10.1109/jstars.2022.3140776.
34. Zhou W., Newsam S., Li C., Shao Z. Learning Low Dimensional Convolutional Neural Networks for High-Resolution Remote Sensing Image Retrieval. *Remote Sensing*. 2017. Vol. 9, 489. DOI: 10.3390/rs9050489.
35. Alsabhan W., Alotaiby T., Dudin B. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net. *Computational*

Intelligence and Neuroscience. 2022, pp. 1–13. DOI: 10.1155/2022/4831223.

36. Girshick R., Donahue J., Darrell T., Malik J. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 IEEE Conference on Computer Vision and Pattern Recognition. 2014. pp. 580-587.

37. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015. pp. 3431-3440

38. Wang X., Jing S., Dai H., Shi A. High-resolution remote sensing images semantic segmentation using improved UNet and SegNet. Computers and Electrical Engineering. 2023. Vol. 108, no. 108734. DOI: 10.1016/j.compeleceng.2023.108734.

39. Garcha Rodriguez C., Vitria J., Mora O. Uncertainty-Based Human-in-the-Loop Deep Learning for Land Cover Segmentation. Remote Sensing. 2020. Vol. 12, no. 3836. DOI: 10.3390/rs12223836.

40. Yang L., Chen Y., Song S., Li F., Huang G. Deep Siamese Networks Based Change Detection with Remote Sensing Images. Remote Sensing. 2021. Vol. 13, no. 3394. DOI: 10.3390/rs13173394.

41. Chen T., Lu Z., Yang Y., Zhang Y., Du B., Plaza A. A Siamese Network Based U-Net for Change Detection in High Resolution Remote Sensing Images. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2022. Vol. 15, pp. 2357–2369.

42. Zhang R., Zhang H., Ning X., Huang X., Wang J., Cui, W. Global-aware siamese network for change detection on remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing. 2023. Vol. 199, pp. 61–72.

43. Dong Y., Jiao W., Long T., Liu L., He G., Gong C., Guo Y. Local Deep Descriptor for Remote Sensing Image Feature Matching. Remote Sensing. 2019. Vol. 11, no. 430. DOI: 10.3390/rs11040430.

44. Lu Y., Yang J., Xiao L. Multi-Supervised Recursive-CNN for Hyperspectral and Multispectral Image Fusion. 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. 2021. pp. 2440-2443. DOI: 10.1109/IGARSS47720.2021.9553598.

45. Dong C., Loy C.C., He K., Tang X. Learning a Deep Convolutional Network for Image Super-Resolution. Computer Vision – ECCV. 2014. Springer International Publishing, Cham. 2014. pp. 184–199.

46. Dong C., Loy C.C., He K., Tang X. Image Super-Resolution Using Deep Convolutional Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2016. Vol. 38, pp. 295–307.

47. Lin G., Wu Q., Huang X., Qiu L., Chen X. Deep Convolutional Networks-Based Image Super-Resolution. In: *Intelligent Computing Theories and Application*. Springer International Publishing, Cham (2017). pp. 338–344.
48. Pashaei M., Starek M.J., Kamangir H., Berryhill J. Deep Learning-Based Single Image Super-Resolution: An Investigation for Dense Scene Reconstruction with UAS Photogrammetry. *Remote Sensing*. 2020. Vol. 12, no. 1757. DOI: 10.3390/rs12111757.
49. Zhang L., Cheng B. Transferred CNN Based on Tensor for Hyperspectral Anomaly Detection. *IEEE Geoscience and Remote Sensing Letters*. 2020. Vol. 17, pp. 2115–2119. DOI: 10.1109/lgrs.2019.2962582.
50. Zhang L., Cheng B. Fractional Fourier Transform and Transferred CNN Based on Tensor for Hyperspectral Anomaly Detection. *IEEE Geoscience and Remote Sensing Letters*. 2022. Vol. 19, pp.1–5. DOI: 10.1109/lgrs.2021.3072249.
51. Maturana D., Scherer S. 3D Convolutional Neural Networks for landing zone detection from LiDAR. 2015 IEEE International Conference on Robotics and Automation (ICRA). 2015. pp. 3471–3478.
52. Jayakumari R., Nidamanuri R.R., Ramiya A.M.: Object-level classification of vegetable crops in 3D LiDAR point cloud using deep learning convolutional neural networks. *Precision Agriculture*. 2021. Vol. 22, pp. 1617–1633. DOI: 10.1007/s11119-021-09803-0.
53. Maturana D., Scherer S. VoxNet: A 3D Convolutional Neural Network for real-time object recognition. 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). 2015. pp. 922–928.
54. Su H., Maji S., Kalogerakis E., Learned-Miller E. Multi-view Convolutional Neural Networks for 3D Shape Recognition. 2015 IEEE International Conference on Computer Vision (ICCV). 2015. pp. 945–953.
55. Charles R.Q., Su H., Kaichun M., Guibas L.J. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. pp. 652–660.
56. Xie Z., Chen J., Peng B. Point clouds learning with attention-based graph convolution networks. *Neurocomputing*. 2020. Vol. 402, pp. 245–255. DOI: 10.1016/j.neucom.2020.03.086.
57. Miller A., Jain V., Mundy J.L. Real-time rendering and dynamic updating of 3-d volumetric data. *Proceedings of the Fourth Workshop on General Purpose Processing on Graphics Processing Units*. ACM, New York, NY, USA. 2011. pp. 1–8.

58. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9, pp. 1735–1780.

59. Chung J., Gulcehre C., Cho K., Bengio Y. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. arXiv preprint 2014. arXiv:1412.3555.

60. Ganai A.F., Khurshid F. Predicting next Word using RNN and LSTM cells: Stastical Language Modeling. 2019 Fifth International Conference on Image Information Processing (ICIIP). 2019. pp. 469-474.

61. Miao Y., Gowayed M., Metze F. EESSEN: End-to-end speech recognition using deep RNN models and WFST-based decoding. 2015 IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU). 2015. pp. 167-174

62. Lodhwal V., Choudhary G. Survey Paper: Automatic Title Generation for Text with RNN and Pre-trained Transformer Language Model. *International Journal for Research in Applied Science and Engineering Technology*. 2023. Vol. 11, pp. 2117–2124. DOI: 10.22214/ijraset.2023.49713.

63. Johnson M., Schuster M., Le Q.V., et all. Googles Multilingual Neural Machine Translation System: Enabling Zero-Shot Translation. *Transactions of the Association for Computational Linguistics*. 2017. Vol. 5, pp. 339–351.

64. Zhao B., Li X., Lu X. CAM-RNN: Co-Attention Model Based RNN for Video Captioning. *IEEE Transactions on Image Processing*. 2019. Vol. 28, pp. 5552–5565. DOI: 10.1109/tip.2019.2916757.

65. Dey M.K., Chanana S. Short-term forecasting of a univariate time series load using LSTM based RNN model. 2022 International Conference on Futuristic Technologies (INCOFT). 2022. pp. 1-6.

66. Kardakis S., Perikos I., Grivokostopoulou F., Hatzilygeroudis I. Examining Attention Mechanisms in Deep Learning Models for Sentiment Analysis. *Applied Sciences*. 2021. Vol. 11, no. 3883. DOI: 10.3390/app11093883.

67. Salmela L., Tsipinakis N., Foi A., Billet C., Dudley J.M., Genty G. Predicting ultrafast nonlinear dynamics in fibre optics with a recurrent neural network. *Nature Machine Intelligence*. 2021. Vol. 3, pp. 344–354. DOI: 10.1038/s42256-021-00297-z.

68. Ho Tong Minh D., Ienco D., Gaetano R., Lalande N., Ndikumana E., Osman F., Maurel P. Deep Recurrent Neural Networks for Winter Vegetation Quality Mapping via Multitemporal SAR Sentinel-1. *IEEE Geoscience and Remote Sensing Letters*. 2018. Vol. 15, pp. 464–468.

69. Ienco D., Gaetano R., Dupaquier C., Maurel P. Land Cover Classification via Multitemporal Spatial Data by Deep Recurrent Neural Networks. *IEEE Geoscience and Remote Sensing Letters*. 2017. Vol. 14, pp. 1685–1689.

70. Milan A., Rezatofighi S.H., Dick A., Reid I., Schindler K. Online Multi-Target Tracking Using Recurrent Neural Networks. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2017. Vol. 31, no. 1, DOI: 10.1609/aaai.v31i1.11194.

71. Lyu H., Lu H., Mou L. Learning a Transferable Change Rule from a Recurrent Neural Network for Land Cover Change Detection. *Remote Sensing*. 2016. Vol. 8, no. 506.

72. Zhao B. A Systematic Survey of Remote Sensing Image Captioning. *IEEE Access*. 2021. Vol. 9, pp. 154086–154111. DOI: 10.1109/access.2021.3128140.

73. Anders K., Winiwarter L., Lindenbergh R., Williams J.G., Vos S.E., Hufle B. 4D objects-by-change: Spatiotemporal segmentation of geomorphic surface change from LiDAR time series. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020. Vol. 159, pp. 352–363. DOI: 10.1016/j.isprsjprs.2019.11.025.

74. Wu C., Chen L., Wang G., Chai S., Jiang H., Peng J., Hong Z. Spatiotemporal Scenario Generation of Traffic Flow Based on LSTM-GAN. *IEEE Access*. 2020. Vol. 8, pp. 186191–186198. DOI: 10.1109/access.2020.3029230.

75. Kulshrestha A., Chang L., Stein A. Use of LSTM for Sinkhole-Related Anomaly Detection and Classification of InSAR Deformation Time Series. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. Vol. 15, pp. 4559–4570. DOI: 10.1109/jstars.2022.3180994.

76. Mou L., Ghamisi P., Zhu X.X. Deep Recurrent Neural Networks for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*. 2017. Vol.55, pp.3639–3655.

77. Zhou Y., Wang S., Wu T., et al. For-backward LSTM-based missing data reconstruction for time-series Landsat images. *GIScience Remote Sensing*. 2022. Vol. 59, pp. 410–430. DOI: 10.1080/15481603.2022.2031549.

78. Goodfellow I., Pouget-Abadie J., Mirza M., et al. Generative adversarial networks. *Communications of the ACM*. 2020. Vol. 63, pp. 139–144.

79. Oliehoek F.A., Savani R., Gallego J., van der Pol E., Groÿ R. Beyond Local Nash Equilibria for Adversarial Networks. *Communications in Computer and Information Science*. Springer International Publishing, Cham. 2019. pp. 73–89.

80. Santos J., Frango I. Generating photorealistic images of people's eyes with strabismus using Deep Convolutional Generative Adversarial Networks. 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE). 2020. pp. 1-4.

81. Donahue C., McAuley J., Puckette M. Synthesizing Audio with Generative Adversarial Networks. 2018. arXiv preprint arXiv:1802.04208.

82. Isola P., Zhu J.-Y., Zhou T., Efros A.A. Image-to-Image Translation with Conditional Adversarial Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE 2017. pp. 1125-1134.

83. Zhang Z. Generative Adversarial Networks for Diverse and Explainable Text-to-Image Generation. 2023. P. 1-25. DOI: 10.33612/diss.507581028.

84. Bashar M.A., Nayak R. TAnoGAN: Time Series Anomaly Detection with Generative Adversarial Networks. 2020 IEEE Symposium Series on Computational Intelligence (SSCI). 2020. pp. 33-43.

85. Sandfort V., Yan K., Pickhardt P.J., Summers R.M. Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks. Scientific Reports. Vol. 9. 2019. DOI: 10.1038/s41598-019-52737-x.

86. Khelifi L., Mignotte M. Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis. IEEE Access. 2020. Vol. 8, pp. 126385–126400. DOI: 10.1109/access.2020.3008036.

87. Lavreniuk M., Kussul N., Shelestov A., Lavrenyuk A., Shumilo L. Super resolution approach for the satellite data based on the generative adversarial networks. 2022 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 17 – 22 July, 2022, Kuala Lumpur Convention Centre (KLCC), Kuala Lumpur, Malaysia. pp. 1095 – 1098. DOI: 10.1109/IGARSS46834.2022.9884460

88. Jiahao Zheng, Xiao-Yang Liu and Xiaodong Wang Single Image Cloud Removal Using U-Net and Generative Adversarial Networks. IEEE Transactions on Geoscience and Remote Sensing. 2020. Vol. 59. pp. 6371-6385. DOI: 10.1109/TGRS.2020.3027819.

89. Akram Z., Chaker El A. Satellite image inpainting with deep generative adversarial neural networks. IAES International Journal of Artificial Intelligence. Vol. 10, pp.121-130. DOI: 10.11591/IJAI.V10.I1.PP121-130.

90. Zerrouki N., Dairi A., Harrou F., Zerrouki Y., Sun Y. Efficient land desertification detection using a deep learning-driven generative

adversarial network approach: A case study. *Concurrency and Computation: Practice and Experience*. 2021. Vol. 34. DOI: 10.1002/cpe.6604.

91. David J., Michael K. Towards Modeling Geographical Processes with Generative Adversarial Networks (GANs) (Short Paper). 14th International Conference on Spatial Information Theory (COSIT 2019). *Leibniz International Proceedings in Informatics (LIPIcs)*, 2019. Vol. 142, pp. 27:1-27:9, DOI: 10.4230/LIPIcs.COSIT.2019.27.

92. Merkle N., Auer S., Muller R., Reinartz P. Exploring the Potential of Conditional Adversarial Networks for Optical and SAR Image Matching. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2019. Vol. 11, pp. 1811–1820. DOI: 10.1109/jstars.2018.2803212.

93. Rabbi J., Ray N., Schubert M., Chowdhury S., Chao D. Small-Object Detection in Remote Sensing Images with End-to-End Edge-Enhanced GAN and Object Detector Network. *Remote Sensing*. 2020. Vol. 12, no. 1432. DOI: 10.3390/rs12091432.

94. Shumilo, L., Okhrimenko, A., Kussul, N., Drozd, S., & Shkalikov, O. (2023). Generative adversarial network augmentation for solving the training data imbalance problem in crop classification. *Remote Sensing Letters*, 14(11), 1129-1138.

95. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *ArXiv*. 2019. abs/1810.04805.

96. Liu Y., Ott M., Goyal N., et al. RoBERTa: A Robustly Optimized BERT Pretraining Approach. 2019. *arXiv preprint arXiv:1907.11692*.

97. Raffel C., Shazeer N., Roberts A., et al. Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer. *The Journal of Machine Learning Research*. 2020. Vol. 21, no. 1, pp. 5485-5551.

98. Bazi Y., Bashmal L., Rahhal M.M.A., Dayil R.A., Ajlan N.A. Vision Transformers for Remote Sensing Image Classification. *Remote Sensing*. 2021. Vol. 13, no. 516. DOI: 10.3390/rs1303051.

99. Carion N., Massa F., Synnaeve G., Usunier N., Kirillov A., Zagoruyko S. End-to-End Object Detection with Transformers. *Computer Vision – ECCV 2020*. Springer International Publishing, Cham. 2020. pp. 213–229.

100. Zheng S., Lu J., Zhao H., et al. Rethinking Semantic Segmentation from a Sequence-to-Sequence Perspective with Transformers. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. pp. 6881-6890.

101. Lavreniuk M., Shumilo L., Lavrenyuk A. Generative Adversarial Networks for the Satellite Data Super Resolution Based on the Transformers with Attention. IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, California, USA. 2023. pp. 6294-6297. DOI: 979-8-3503-2010-7/23/.

102. Jin P., Mou L., Xia G.-S et al. Anomaly Detection in Aerial Videos With Transformers. IEEE Transactions on Geoscience and Remote Sensing. 2022. Vol. 60. pp. 1-13. DOI: <https://doi.org/10.1109/tgrs.2022.3198130>.

103. Yu J., Li J., Yu Z., et al. Multimodal Transformer With Multi-View Visual Representation for Image Captioning. IEEE Transactions on Circuits and Systems for Video Technology. 2020. Vol. 30. pp. 4467-4480. DOI: <https://doi.org/10.1109/tcsvt.2019.2947482>.

104. Lu D., Xie Q., Wei M., et al. Transformers in 3D Point Clouds: A Survey.. arXiv:2205.07417. 2022. DOI: <https://doi.org/10.48550/arXiv.2205.07417>.

105. Scarselli F., Gori M., Ah Chung Tsoi, et al. The Graph Neural Network Model. IEEE Transactions on Neural Networks. 2009. Vol. 20. pp. 61-80. DOI: <https://doi.org/10.1109/tnn.2008.2005605>.

106. Kipf T.N., Welling M. Semi-supervised classification with graph convolutional networks. arXiv:1609.02907. 2016. DOI: <https://doi.org/10.48550/arXiv.1609.02907>.

107. Velickovic P., Cucurull G., Casanova A., et al. Graph attention networks. stat. arXiv:1710.10903. 2017. Vol. 1050. DOI: <https://doi.org/10.48550/arXiv.1710.10903>.

108. Hajiramezanali E., Hasanzadeh A., Narayanan K., et al. Variational graph recurrent neural networks. Advances in neural information processing systems. 2019. Vol. 32. pp. 1-11.

109. Zhou J., Cui G., Hu S., et al. Graph neural networks: A review of methods and applications. AI Open. 2020. Vol. 1. pp. 57-81. DOI: <https://doi.org/10.1016/j.aiopen.2021.01.001>.

110. Wu Y., Lian D., Xu Y., et al. Graph Convolutional Networks with Markov Random Field Reasoning for Social Spammer Detection. Proceedings of the AAAI Conference on Artificial Intelligence. 2020. Vol. 34. pp. 1054-1061. DOI: <https://doi.org/10.1609/aaai.v34i01.5455>.

111. Wieder O., Kohlbacher S., Mäilaine Kuenemann Garon A., et al. A compact review of molecular property prediction with graph neural networks. Drug Discovery Today: Technologies. 2020. Vol. 37. pp. 1-12. DOI: <https://doi.org/10.1016/j.ddtec.2020.11.009>.

112. Wu Q., Zhang H., Gao X., et al. Dual Graph Attention Networks for Deep Latent Representation of Multifaceted Social Effects in Recommender Systems. The World Wide Web Conference. ACM,

New York, NY, USA. 2019. pp. 2091-2102. DOI: <https://doi.org/10.1145/3308558.3313442>.

113. Wang Z., Chen T., Ren J., et al. Deep Reasoning with Knowledge Graph for Social Relationship Understanding. arXiv:1807.00504. 2018. DOI: <https://doi.org/10.48550/arXiv.1807.00504>.

114. Yu B., Yin H., Zhu Z. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. arXiv:1709.04875. 2018. DOI: <https://doi.org/10.48550/arXiv.1709.04875>.

115. Khan N., Chaudhuri U., Banerjee B., et al. Graph convolutional network for multi-label VHR remote sensing scene recognition. Neurocomputing. 2019. Vol. 357. pp. 36-46. DOI: <https://doi.org/10.1016/J.NEUCOM.2019.05.024>.

116. Тьркменли І., Аптоула Е., Каябол К. Superpixel based graph convolutional neural network for SAR image segmentation. Image and Signal Processing for Remote Sensing. 2021. Vol. 11862. pp. 148-153. DOI: <https://doi.org/10.1117/12.2599864>.

117. Gao L., Xiao S., Hu C., et al. Hyperspectral Image Classification Based on Fusion of Convolutional Neural Network and Graph Network. Recent Advances in Robotics and Intelligent Robots Applications. 2023. Vol. 13, no. 12. DOI: <https://doi.org/10.3390/app13127143>.

118. Tian S., Cao L., Kang L., et al. A Novel Hybrid Attention-Driven Multistream Hierarchical Graph Embedding Network for Remote Sensing Object Detection. Remote Sensing. 2022. Vol. 14, no. 19. DOI: <https://doi.org/10.3390/rs14194951>.

119. Wang R., Wang L., Wei X., et al. Dynamic Graph-Level Neural Network for SAR Image Change Detection. IEEE Geoscience and Remote Sensing Letters. 2022. Vol. 19. pp. 1-5. DOI: <https://doi.org/10.1109/lgrs.2021.3132167>.

120. Li D., Shen X., Yu Y., et al. GGM-Net: Graph Geometric Moments Convolution Neural Network for Point Cloud Shape Classification. IEEE Access. 2020. Vol. 8, pp. 124989-124998. DOI: <https://doi.org/10.1109/access.2020.3007630>.

121. Debes C., Merentitis A., Heremans R., et al. Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2014. Vol. 7. pp. 2405-2418. DOI: [10.1109/JSTARS.2014.2305441](https://doi.org/10.1109/JSTARS.2014.2305441).

122. Yavorskyi, O. and Kussul, N. (2023) "Studying the multipartite graph representations with topological data analysis", International

Scientific Technical Journal "Problems of Control and Informatics", 68(5), pp. 107–117. doi: 10.34229/1028-0979-2023-5-9.

123. Jia N., Tian X., Gao W., et al. Deep Graph-Convolutional Generative Adversarial Network for Semi-Supervised Learning on Graphs. *Remote Sensing*. 2023. Vol. 15, no. 12. DOI: <https://doi.org/10.3390/rs15123172>.

124. Farias A.D., Sun G. Data Mining and Machine Learning in Earth Observation—An Application for Tracking Historical Algal Blooms. In *CS & IT Conference Proceedings*. 2020. Vol. 10. pp. 39-58. DOI: 10.5121/csit.2020.100204.

125. Lavreniuk M., Shumilo L., Yailymov B., Kussul N. Reviewing Deep Learning Methods in the Applied Problems of Economic Monitoring Based on Geospatial Data. *Cybern Syst Anal*. 2022. Vol. 58, pp. 1008–1020. DOI: 10.1007/s10559-023-00535-9.

126. Kussul, N., Kuzin, V., Shelestov, A. (2024). A Survey of Deep Learning for Remote Sensing, Earth Intelligence and Decision Making. In: Luntovskyy, A., Klymash, M., Melnyk, I., Beshley, M., Schill, A. (eds) *Digital Ecosystems: Interconnecting Advanced Networks with AI Applications*. TCSET 2024. Lecture Notes in Electrical Engineering, vol 1198. pp 81–109. Springer, Cham. https://doi.org/10.1007/978-3-031-61221-3_5

127. Kussul, N., Shelestov, A., Basarab, R., Skakun, S., Kussul, O., & Lavrenyuk, M. (2015). Geospatial Intelligence and Data Fusion Techniques for Sustainable Development Problems. *ICTERI*, 1356, 196–203.

2. АНАЛІЗ МЕТОДІВ 3D РЕКОНСТРУКЦІЇ СЕРЕДОВИЩА ДЛЯ ДОПОВНЕНОЇ РЕАЛЬНОСТІ

Володимир Савін, аспірант
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

vladimir.savin@gmail.com

ВСТУП

В останнє десятиліття спостерігається надзвичайно швидкий розвиток технологій доповненої реальності (ДР), які відкривають новий етап взаємодії людини з інформацією та оточуючим середовищем. Сценарії використання цих технологій стрімко еволюціонують, переходячи з мобільних на самостійні носимі пристрої. Продукти, які дозволяють споживати сценарії ДР, виходять зі стадії обмежених та дорогих платформ розробки і набувають масового розповсюдження. Розмір світового ринку ДР наразі становить 25,1 млрд \$ (2023 рік). При прогнозованому загальному річному темпі зростання (CAGR) у 23,2% він має перевищити 70 млрд \$ у 2028 році [1].

Сучасні тренди у галузі доповненої реальності визначаються не лише зростанням її популярності, але й постійним удосконаленням технологічного арсеналу. Все більше компаній і дослідницьких груп зосереджують свою увагу на розробці інноваційних методів та рішень спрямованих на підвищення реалістичності взаємодії об'єктів ДР з реальним світом та користувача з об'єктами ДР. Інтенсивність розвитку цього напрямку не тільки збільшує можливості технологій ДР, але і відкриває нові перспективи для їхнього впровадження у різноманітних сферах життя, від освіти та розваг до промисловості та медицини.

Один із ключових напрямків цього еволюційного процесу є 3D реконструкція оточуючого середовища та його об'єктів, що стає невід'ємною складовою при досягненні максимальної імерсії

та реалізації потенціалу ДР. Мета 3D реконструкції полягає у відтворенні тривимірної моделі оточення на основі доступних даних: дво- та тривимірні зображення, внутрішні та зовнішні параметри камери, дані з IMU сенсорів, або систем позиціонування і т.д. 3D реконструкція є своєрідним каркасом для доповненої реальності. Якість отриманої моделі суттєво впливає на реалістичність сприйняття сценаріїв доповненої реальності користувачем. Справжній виклик полягає в тому, як забезпечити точність та достовірність тривимірної моделі. В цьому контексті, доволі часто, важливу роль відіграє оцінка карти глибини. Методи реконструкції карти глибини приймають на вхід монокулярне зображення, стереозображення, або їх послідовність, та повертають результуюче зображення, де кожний піксель представляє собою відносну, або абсолютну відстань від камери до відповідної точки простору. Оцінка глибини дозволяє системам реконструкції ефективно розміщувати об'єкти в просторі, враховуючи їхнє точне положення та взаємодію. Це стає критичним у віртуальних і доповнених середовищах, де недостовірність 3D реконструкції може призвести до неправильної взаємодії з оточенням та втрати реалістичності.

Цей науковий огляд покликаний систематизувати знання, щодо доповненої реальності, 3D реконструкції та оцінки глибини, а також проаналізувати поточний стан досліджень у цих інноваційних напрямках.

2.1. ТРИВИМІРНА РЕКОНСТРУКЦІЯ ЯК ВАЖЛИВА СКЛАДОВА ДОПОВНЕНОЇ РЕАЛЬНОСТІ

Доповнена реальність представляє собою технологію, яка дозволяє в режимі реального часу відображати штучний 2D/3D контент та інформацію поверх або поруч фізичних об'єктів реального світу. За рахунок алгоритмічного стеку, який включає в себе: супроводження об'єктів та відстеження позиції пристрою ДР в 6-ти ступенях свободи, аналіз карти глибини та 3D реконструкцію, розпізнавання об'єктів та семантичне розуміння сцени, виявлення джерел освітлення та рендерингу штучних тіней, а також багатьох інших технологій, доповнені об'єкти природньо інтегруються у фізичне середовище. Це дає змогу підвищити реалістичність сценаріїв доповненої реальності та сприймати штучні об'єкти як частину оточення.

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

На відміну від віртуальної реальності, де користувач занурюється у повністю штучне середовище, доповнена реальність надає можливість взаємодії зі штучним контентом не втрачаючи зв'язок з оточенням. Доповнені 2D/3D об'єкти прив'язуються до певних фізичних об'єктів, взаємодіють з ними та з іншими предметами сцени за рахунок оклюзій та колізій (рис. 1). Реалістичність таких взаємодій залежить від якості «каркасу», на який вони накладаються. Цим каркасом виступає 3D реконструкція середовища.

Останнім часом доповнена реальність широко застосовується в різноманітних галузях, що включають: освіту, медицину, інженерію, зв'язок та віддалену підтримку, сферу розваг та багатьох інших напрямків. Також, доповнена реальність використовується і у військових цілях.

На сьогоднішній день найдоступнішим пристроєм, який дозволяє споживати сценарії ДР, виступає мобільний телефон. Зображення, отримане з камери, ретранслюється на екран та доповнюється штучними об'єктами. Основні недоліки такої експлуатації: телефон треба тримати у руках, користувач спостерігає лише невеличку область сцени, відсутність реалістичного сприйняття середовища.



Рис. 1. Приклад сценарію ДР з урахуванням оклюзій та колізій

Стрімкий розвиток носимих пристроїв ДР націлений на позбавлення вищезгаданих недоліків та на популяризацію технології. За формфактором носимі пристрої ДР можна розділити на:

- Формфактор шолому віртуальної реальності (рис. 2, а). Пара камер ретранслює зображення середовища, яке доповнюється, на пару екранів високої роздільної здатності та частоти, що знаходяться в середині шолому перед очима

користувача. Додатковою перевагою цієї конструкції є можливість споживання сценаріїв віртуальної реальності. Основні недоліки: великий розмір та вага, що впливають на ергономічність використання.

- **Формфактор окулярів (рис. 2, б).** Зображення з камер передаються на прозорі дисплеї, наприклад Waveguide [2], Transparent MICRO LED [3], або інші. Користувач спостерігає оточуюче середовище крізь них. Доповнений контент відображається на дисплеях поверх реальних об'єктів. Основний недолік: мініатюрний розмір впливає на можливість розміщення апаратних засобів та батарей високої ємності.



Рис. 2. Приклад носимих пристроїв ДР: формфактор шолому віртуальної реальності (а) – Meta Quest Pro, формфактор окулярів (б) – XREAL Air 2 Pro

За критерієм розміщення апаратно-обчислювальних потужностей носимі пристрої ДР можна розділити на:

- **Самостійні (рис. 2).** Апаратно-обчислювальні потужності розміщені на самому пристрої.
- **Пов'язані (рис. 3).** Апаратно-обчислювальні потужності частково або повністю розміщені на пристрої-компаньйоні. Пристрої можуть з'єднуватись як провідним, так і безпровідним шляхом.



Рис. 3. Приклад пов'язаних пристроїв ДР (Magic Leap 2)

Сучасна тенденція розвитку пристроїв ДР спрямована на мініатюризацію з метою перетворити громіздкий гаджет на ергономічний повсякденний аксесуар та помічник. Однак зменшення розмірів змушує використовувати батареї невеликої ємності. Це, в свою чергу, впливає на можливість встановити або активно використовувати сенсори з підвищеним енергоспоживанням, такі як: ToF (Time of Flight) [4], LIDAR [5] та сенсори структурного світла [6]. Отже, доволі часто, реконструкцію карт глибини та/або 3D реконструкцію сцени доводиться проводити на основі даних з монокулярної, або стереокамери, що є доцільніше з точки зору оптимізації енергоспоживання.

2.2. МЕТОДИ РЕКОНСТРУКЦІЇ КАРТИ ГЛИБИНИ ПО 2D ДАНИМ

Важливою складовою 3D реконструкції є розуміння карти глибини (відстані до кожної точки спостереження). Людині зазвичай легко сприймати інформацію про тривимірну структуру об'єкта або сцени та оцінювати відстань до об'єктів. Але визначення карти глибини по зображенню або їх серії є складною задачею комп'ютерного зору, оскільки під час зйомки відбувається проєкція сцени на площину, що призводить до втрати третього виміру.

Методи реконструкції карти глибини з 2D даних можна умовно поділити на два класи в залежності від кількості вхідних зображень:

- методи, що використовують одне вхідне нерухоме зображення та спираються на монокулярні ознаки глибини;
- методи, що базуються на аналізі двох і більше зображень та оперують багатоокулярними (multi-ocular) ознаками глибини.

У другому випадку два або більше вхідних зображень можуть бути зроблені кількома фіксованими камерами з різних кутів огляду або однією камерою з динамічними об'єктами на сцені.

Таблиця 2. Основні ознаки глибини, що використовуються методами реконструкції глибини по 2D даним

Кількість вхідних зображень	Ознаки глибини
Одне зображення	Лінійна перспектива
	Атмосферне розсіювання
	Розуміння форми по затіненню
Два і більше зображень	Бінокулярний диспаратет
	Паралакс руху
	Розмиття зображення
	Силует
	Структура з руху

2.2.1. ЛІНІЙНА ПЕРСПЕКТИВА

В основі лінійної перспективи лежить ідея, що паралельні лінії, такі як дороги або стежки, збігаються вдалині. Точки перетину цих ліній менш помітні, ніж точки ліній, наближені до спостерігача. Підхід, запропонований Battiato, Curti та ін. [7], працює для зображень, що містять поверхні з жорсткою геометрією. Точка з найбільшою кількістю перетинів у певному районі вважається точкою зникнення. Основні лінії поблизу точки зникнення позначаються як лінії зникнення (рис. 4).

Між кожною парою сусідніх ліній зникнення призначається набір градієнтних площин, кожна з яких відповідає окремому рівню глибини. Пікселі ближче до точок зникнення отримують більше значення глибини, і щільність градієнтних площин вища (рис. 5).



Рис. 4. Детектування ліній і точки зникнення [7]

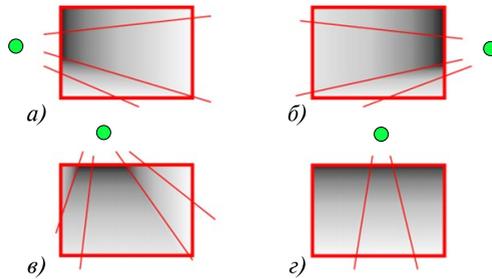


Рис. 5. Приклади евристичних правил для створення градієнтних площин глибини, де зелене коло – точка зникнення [7]

2.2.2. АТМОСФЕРНЕ РОЗСІЮВАННЯ

Підхід атмосферного розсіювання ґрунтується на тому, що потужність і напрям світла змінюються, коли світло проходить через атмосферу через наявність у ній дрібних частинок. Об'єкти, які знаходяться ближче до камери, виглядають чіткіше, тоді як більш віддалені об'єкти – розмиті. У 1997 році Krotkov та Cozman [8] представили аналіз цього перетворення, заснований на фізичній моделі розсіювання лорда Релея 1871 року. Їх алгоритм підходить для оцінки глибини зображень на відкритому повітрі, які містять частину неба (рис. 6).

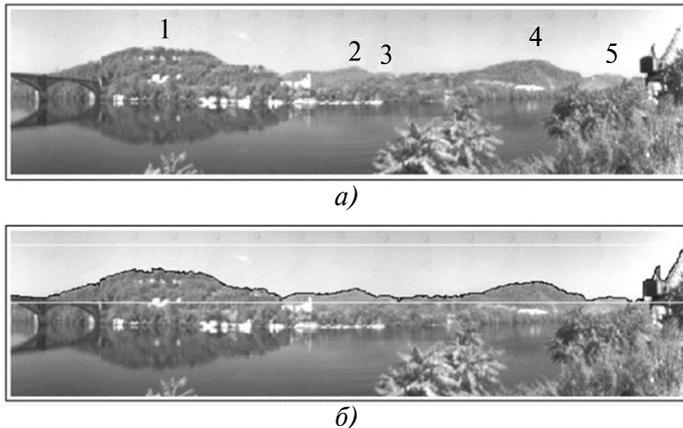


Рис. 6. Приклад детектування горизонту та зон атмосферного розсіювання [8]

2.2.3. РОЗУМІННЯ ФОРМИ ПО ЗАТІНЕННЮ

Метод розуміння форми по затіненню дозволяє визначити нормаль поверхні об'єкта, спостерігаючи за відбивною здатністю світла на цьому об'єкті. Кількість світла, яка відбивається від поверхні об'єкта, залежить від його орієнтації. Вперше цю ідею представив Woodham у 1980 році. Підхід розуміння форми по затіненню (shape from shading), використовується для аналізу одного вхідного зображення та був представлений В. К. Horn в 1989 році. Фотометричний стереоаналіз відтоді був узагальнений для багатьох інших ситуацій, таких як, наприклад, не Ламбертові поверхні. Процес реконструкції карти глибини по затіненню на основі зображень світлового поля представлений на рис. 7.

По декільком зображенням об'єкта при різному освітленні можна провести оцінку векторів нормалей у кожному пікселі [9].

Метод потребує специфічного технічного обладнання.

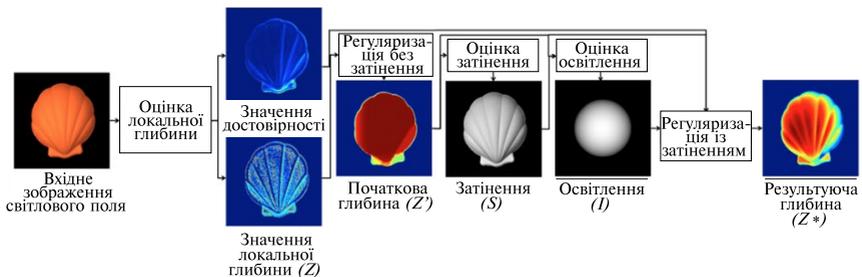


Рис. 7. Ілюстрація підходу відтворення глибини по затіненню на основі зображень світлового поля [9]

2.2.4. БІНОКУЛЯРНИЙ ДИСПАРИТЕТ

Використовуючи два зображення однієї сцени, зроблені одночасно з дещо різних точок спостереження, можна відновити глибину точки, що присутня на обох зображеннях. Спочатку знаходиться відповідний набір точок на обох зображеннях. Потім, для кожного набору точок використовується метод триангуляції для визначення глибини відповідної фізичної точки, що була спроектована на пару зображень [10, 11].

На рис. 8 проілюстрована система стереоскопічного зору для якої проводиться обрахунок бінокулярного диспаритету, де:

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

- P – точка у просторі, що належить фізичному об'єкту;
- C_l та C_r – ліва та права камера стереосистеми;
- P_l та P_r – проєкції точки на матриці лівої (C_l) та правої камер (C_r). P_l та P_r знаходяться на епіполярній лінії;
- x_l та x_r – відповідні зсуви проєкції точки від початку системи координат зображення (x координати точок P_l та P_r);
- Z – значення глибини (відстань до P);
- f – фокальна відстань;
- B – відстань між камерами стереопари (baseline).

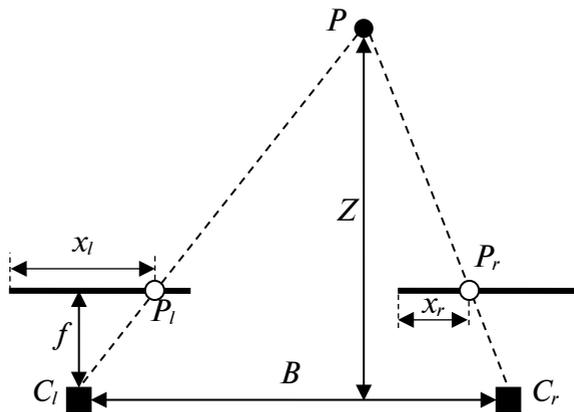


Рис. 8. Ілюстрація бінокулярного диспаритету

Значення глибини Z можна розрахувати спираючись на принципи тріангуляції, що застосовуються в системах стереоскопічного зору:

$$Z = f \frac{B}{D} \quad (1)$$

де D – значення диспаритету, який розраховується як різниця між x_l та x_r .

2.2.5. ПАРАЛАКС РУХУ

Відносний рух між камерою і сценою надає важливі ознаки для сприйняття глибини. Об'єкти, які знаходяться ближче до камери, рухаються швидше, ніж ті, що знаходяться далі. Відновлення тривимірних структур називається реконструкцією структури з руху. Рух можна розглядати як форму диспаритету

протягом часу, що представлено поняттям поля руху. Поле руху — це двовимірні вектори швидкості точок зображення та спостережуваної сцени. Основні припущення для структури з руху полягають у тому, що об'єкти не деформуються і їхні рухи є лінійними. Ці властивості було використано у кількох методах, таких як «стереоскопія погойдування (wiggle stereoscopy)» [12], де паралакс руху використовується як представлення для стереоскопічних зображень, або «стереоскопія прокручування (parallax scrolling)» [13], що широко використовується в комп'ютерній графіці, де шляхом руху переднього і заднього планів з різною швидкістю викликається відчуття глибини. Вплив цієї ознаки глибини є відносно сильним в порівнянні з іншими монокулярними ознаками глибини, а також у порівнянні з бінокулярним диспаратетом.

2.2.6. РОЗМИТТЯ ЗОБРАЖЕННЯ

Методи визначення глибини за розмиттям зображення дозволяють реконструювати карту глибини на основі ступеня розмиття, присутнього на зображеннях. У системі з тонкою лінзою об'єкти, які знаходяться у фокусі, відображаються чітко, тоді як об'єкти на інших відстанях розфокусовані, тобто розмиті. На рис. 9 показана модель тонкої лінзи з реальною точкою P , що знаходиться за межами фокусної відстані лінзи. Відповідна проєкція на площину зображення є кругова розмита пляма зі сталою яскравістю, центрованою у точці P'' та радіусом розмиття σ .

Для того щоб оцінити глибину u , нам необхідні наступні рівняння. Основне рівняння, що описує співвідношення між u , v та f для тонких лінз (2):

$$\frac{1}{u} + \frac{1}{v} = \frac{1}{f}. \quad (2)$$

Pentland [14] вивів співвідношення між відстанню u та розмиттям σ у рівнянні (3):

$$u = \begin{cases} \frac{fs}{s - f - kf\sigma}, & u > v, \\ \frac{fs}{s - f + kf\sigma}, & u < v, \end{cases} \quad (3)$$

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

де: u – глибина, v – відстань між лінзою та точкою ідеального фокусу, s – відстань між лінзою та площиною зображення, f – фокусна відстань лінзи, k – константа, визначена оптичною системою, σ – радіус розмиття.

Задача обчислення глибини u перетворюється на задачу оцінки параметрів камери (s , f та k) та параметра розмиття σ . Параметри камери можуть бути отримані шляхом її калібрування. Глибину u можна обчислити з рівняння (3), якщо відомий параметр розмиття σ .

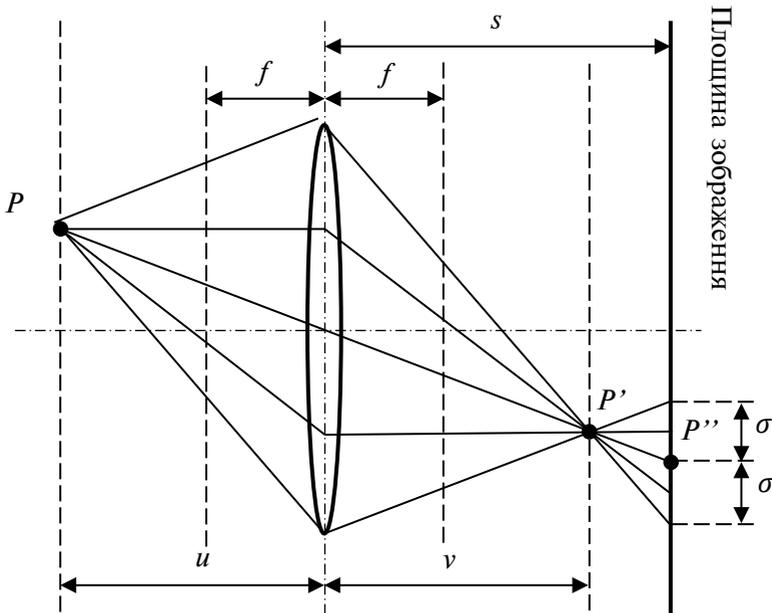


Рис. 9. Ілюстрація моделі тонкої лінзи

2.2.7. СИЛУЕТ (SHAPE-FROM-SILHOUETTE)

Силует об'єкта на зображенні відноситься до контуру, який відділяє об'єкт від фону. Методи визначення форми за силуетом вимагають кілька видів сцени, знятих камерами з різних точок спостереження. Такий процес разом із правильною текстуризацією створює повну 3D модель об'єктів у сцені. Метод відтворення форми за силуетом потребує точної калібровки камери.

Процедура 3D реконструкції, що базується на аналізі силуетів називається відтворення форми за силуетом (shape-from-silhouette) описана в [15]. Для кожного зображення силует цільового об'єкту сегментується за допомогою віднімання фону. Отримані силуети проєктуються назад у загальний 3D простір з проєкційними центрами, рівними положенням камер. Зворотне проєктування силуету створює конусоподібний об'єм. Перетин усіх конусів утворює візуальну оболонку цільового 3D об'єкта, який часто зберігається у воксельному вигляді.

На рис. 10 C позначено куб, який є прикладом 3D об'єкта; S позначає двовимірний екран; P_A та P_B – точки спостереження в 3D просторі; D_A – двовимірний багатокутник на екрані, який є силуетом куба; V_A та V_B – конусоподібний об'єм, зворотно спроектований з точок спостереження P_A та P_B .

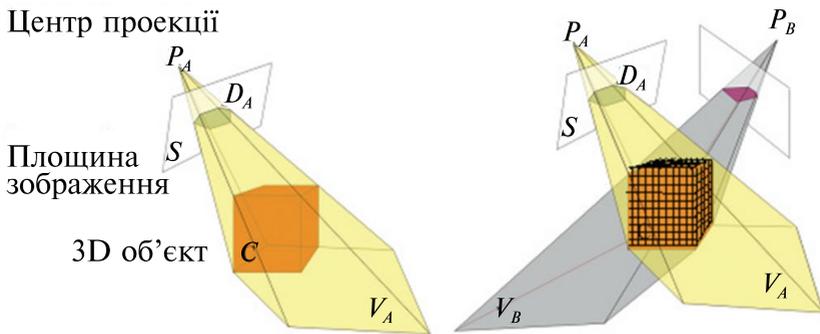


Рис. 10. Перетин об'ємів силуетів [15]

2.2.8. СТРУКТУРА З РУХУ (STRUCTURE FROM MOTION – SFM)

Метод відновлення структури з руху (SfM) використовує серію двовимірних зображень сцени або об'єкта для відновлення їх розрідженого об'єму точок та положень камери (позиція та орієнтація).

SfM базується на тих же принципах, що й стереоскопічна фотограмметрія. У стереофотограмметрії використовується триангуляція для обчислення відносних тривимірних позицій (x, y, z) об'єктів з пар стереозображень. Такі методи вимагають дорожчого спеціалізованого обладнання (стереокамера) та відповідного програмного забезпечення. На відміну від них,

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

стандартні камери добре підходять для методів SfM. Зображення часто знімають під час руху однієї або декількох камери з різних точок спостереження.

Метод відновлення структури з руху часто використовують як початковий крок 3D реконструкції, на якому відбувається генерація розрідженого об'єму точок та положень камери для наступних методів відновлення тривимірної структури сцени. Незважаючи на це, SfM може створювати 3D моделі на основі об'ємів точок з високою роздільною здатністю. Тому, більш детально розглянемо його як окремий повноцінний метод 3D реконструкції сцени.

2.3. КЛАСИЧНІ МЕТОДИ 3D РЕКОНСТРУКЦІЇ СЕРЕДОВИЩА

3D реконструкцію в режимі реального часу можна визначити як процес, при якому відбувається відновлення віртуальної тривимірної моделі сцени, або об'єкта на ній, по зображенням з камери. Окрім даних з камери необхідними є параметри камери та її положення під час зйомки. Зазвичай ця інформація відома, або обчислюється на послідовності зображень.

3D реконструкцію сцени можна зробити, використовуючи або одне зображення, або кілька знімків, зроблених з різних позицій камери. Високу популярність набрала 3D реконструкція на основі множини зображень, де використовуються такі стандартні підходи як стереозір, структура з руху (Structure from Motion – SfM) та підходи на основі даних з довільних точок спостереження (Multi-View Stereo – MVS). Активний розвиток глибинного навчання дозволив проводити реконструкцію середовища навіть по одному зображенню.

2.3.1. ВІДНОВЛЕННЯ СТРУКТУРИ З РУХУ ДЛЯ ЗАДАЧІ 3D РЕКОНСТРУКЦІЇ

Метод відновлення структури з руху (SfM) використовує серію двовимірних зображень сцени або об'єкта для відновлення їх 3D структури на базі знайденого розрідженого об'єму точок. Для створення 3D реконструкції із застосуванням SfM необхідно мати багато зображень області або об'єкта з високим ступенем перекриття, зроблених з різних точок спостереження. SfM проілюстровано на рис. 11. Алгоритм включає три основні етапи:

Співставлення відповідних ознак і вимірювання відстаней між ними на площині зображення камери d та d' . Алгоритм Scale Invariant Feature Transform (SIFT) [16] дозволяє порівнювати відповідні ознаки навіть за великих варіацій у масштабі та куті огляду, а також за умов часткового перекриття і зміни освітлення.

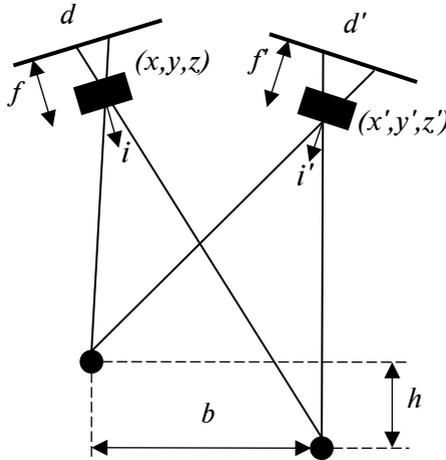


Рис. 11. Ілюстрація методу структура з руху (SfM)

При наявності відповідних місць розташування декількох точок на двох або більше зображеннях, зазвичай існує лише одне математичне рішення для визначення місця, де були зроблені фотографії. Тому можна обчислити позиції камер (x, y, z) , (x', y', z') , орієнтації i та i' , фокусні відстані f та f' , і відносні позиції відповідних ознак b та h в одному кроці, який називається пакетна корекція даних (bundle adjustment). Звідси походить термін «структура з руху». Структура сцени включає всі ці параметри, а рух відноситься до руху камери.

Наступним кроком є визначення щільного об'єму точок і 3D поверхні, використовуючи параметри камери і точки SfM.

SfM зазвичай поділяється на три типи: глобальний, інкрементний та гібридний.

Глобальний SfM [17] представлений на рис. 12. Підхід оптимізує всі положення камери одночасно, використовуючи всі доступні переміщення. У глобальному SfM початкові положення камер оцінюються на основі принципів стереозору та епіпольярної геометрії. Пакетна корекція даних (bundle adjustment) [18]

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

виконується лише один раз, що призводить до поліпшення ефективності системи.

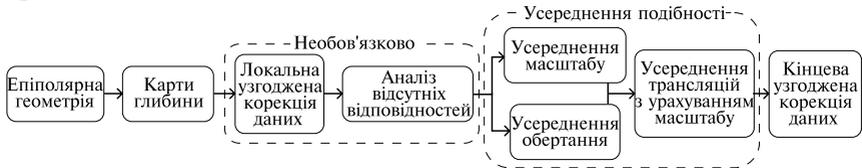


Рис. 12. Приклад алгоритму глобального SfM [17]

Процес глобального SfM включає, в основному, два етапи: оптимізацію положень камери та оптимізацію її орієнтацій. Точність оптимізації орієнтацій камери залежить від точності початкового розрахунку параметрів епіпольярного геометричного графу.

Основні компоненти епіпольярного геометричного графу:

- Центри камер (C_1 та C_2): Позиції двох камер у просторі.
- Точка в 3D просторі (P): Точка 3D сцени, яку спостерігають обидві камери.
- Точки зображення (p_1 та p_2): Проекції тривимірної точки P на площини зображень двох камер.
- Базисна лінія: Лінія, що з'єднує центри двох камер.
- Епіпольярна площина: Площина, що проходить через тривимірну точку P та центри камер.
- Епіполі (e_1 та e_2): Точки, де базисна лінія перетинає площини зображень.
- Епіпольярні лінії: Лінії на площинах зображень, вздовж яких лежать відповідні точки.

Інкрементний SfM [19] здатний обробляти великі обсяги даних. Цей підхід, зазвичай, використовується саме для реконструкції розріджених об'ємів точок з неупорядкованого набору зображень. Метод включає кілька етапів, таких як калібрування камери, відстеження необхідних ознак, визначення положень камери, тріангуляція та пакетна корекція даних (bundle adjustment). Алгоритм можна описати наступним чином.

1. Ініціалізація вхідних зображень з урахуванням приблизної фокусної відстані.

2. Використання SIFT (Scale Invariant Feature Transform) дескриптору [16] для пошуку необхідних ключових точок на зображенні.

3. Застосування порівняльного аналізу для визначення схожості знайдених ключових точок.

4. Визначення положення камери для першої пари зображень на основі п'яти точок.

5. Здійснення тріангуляції для знаходження перших 3D точок, що формують об'єми точок у тривимірному просторі та виконання пакетної корекції даних (bundle adjustment).

6. Використання методу прямої лінійної трансформації (Direct Linear Transform – DLT) для визначення положення кожної використаної камери.

7. Здійснення тріангуляції для додавання нових точок до об'ємів точок з подальшою пакетною корекцією даних для уточнення результатів.

8. Повторення кроків 5 та 6 до тих пір, поки не завершиться додавання нових камер. Для уточнення 3D об'єму точок модель оптимізується за допомогою глобальної пакетної корекції даних (global bundle adjustment) [18].

Гібридний SfM використовує глобальний SfM для знаходження параметрів камери та інкрементний SfM для реконструкції розріджених об'ємів точок.

SfM підхід часто застосовують на початковому етапі 3D реконструкції. Отримані положення камери та розріджені об'єми точок подаються на вхід наступних методів, які уточнюють отримані дані для відновлення щільної та деталізованої тривимірної моделі середовища. Один з таких методів – багатовидове стереозіставлення (Multi-View Stereo - MVS).

2.3.2. БАГАТОВИДОВЕ СТЕРЕОСПІВСТАВЛЕННЯ

Алгоритми багатовидового стереоспівставлення (Multi-View Stereo — MVS) [20] приймають на вхід велику кількість зображень з даними про їх відповідні положення камери та повертають щільні тривимірні моделі з покращеною точністю. MVS підхід заснований на патчах (Patch-based Multi-view Stereo – PMVS) [21] і дозволяє ефективно отримувати щільні об'єми точок. Метод включає три етапи: ініціалізацію, розширення та фільтрацію. Основна ідея PMVS полягає у відтворенні набору вирівняних патчів, що повністю покривають поверхню об'єкта. Модель патча є ключовим елементом PMVS. Процес реконструкції моделі за допомогою PMVS продемонстровано на рис. 13. Патч *P* описується як

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

тривимірний прямокутник, для якого конфігурація визначається центральними координатами, одиничним вектором нормалі, екземпляром зображення та колекцією зображень, на яких P розпізнається.



Рис. 13. Ілюстрація проміжних результатів MVS підходу заснованого на патчах

Ініціалізація патча передбачає наступні етапи:

1. Використання детектор Харріса та різницю гаусіанів (Difference of Gaussian – DoG), щоб виявити ключові точки на послідовності зображень.

2. Застосування техніки епіполярного порівняння для зіставлення ключових точок, що дають початкові відповідності.

3. Формування початкових патчів з початкових відповідностей за допомогою триангуляції.

4. Створення колекції розпізнаваних зображень для патча P за допомогою використання кутового тесту, що порівнює вектор спостереження направлений від камери до патча та вектор нормалі відповідної поверхні.

5. Оновлення центру та нормалі шляхом зменшення оцінки фотометричної невідповідності.

6. Використання фотометричного диспаритету для оцінки ефективності створення патча P .

Розповсюдження патча здійснюється поділом кожного зображення на систематичні сітки розміром $N \times N$ пікселів.

1. Збір всіх сусідніх клітинок зображення з кожного розпізнаного зображення в патчі P .

2. Створення нового патча P для зібраних клітинок зображення.

3. Оптимізація шляхом зменшення значення фотометричного диспаритету.

4. Оптимізація нового розпізнаного набору зображень за допомогою порівняння по глибині.

5. Визначення ефективності розширення нового патча.

Фільтрація патча виконується для оптимізації створених щільних об'ємів точок.

2.3.3. РЕКОНСТРУКЦІЯ ПОВЕРХНІ

Алгоритм відтворення поверхні за допомогою методу Пуассона (Poisson Surface Reconstruction – PSR) [22], використовується для створення цілісної структури. Цей метод розглядає завдання відтворення поверхні як просторову задачу Пуассона [22] і може бути описаний наступними етапами: дискретизація задачі, визначення векторного поля, вирішення рівняння Пуассона та відновлення ізоповерхні. Основні етапи відтворення поверхні за методом Пуассона включають наступні.

1. Використання дерева октантів (octree) для ілюстрації ступеню функції розмірів функцій та дискретизації задачі вирішення структури Пуассона.

2. Для визначення векторного поля використовується функція вузла дерева октантів (octree), яка схожа на градієнтне поле функції індикатора.

3. Для вирішення рівняння Пуассона використовується описане векторне поле так, щоб градієнтне поле функції індикатора було суміжним з векторним полем.

4. Для того, щоб зобразити відповідну ізоповерхню використовується оцінена функція індикатора.

2.3.4. ПОЄДНАННЯ МЕТОДІВ SfM, MVS ТА РЕКОНСТРУКЦІЇ ПОВЕРХНІ

У [23] запропонований підхід 3D реконструкції, який поєднує в собі SfM, MVS та реконструкцію поверхні. Алгоритм умовно зображений на рис. 14. Процедура 3D реконструкції дозволяє отримувати окремі 3D моделі, разом з розрідженим та щільним об'ємом 3D точок, а також грубі структури з колекції зображень.

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

Цей метод можна використовувати в різних сферах та для виконання різноманітних завдань.

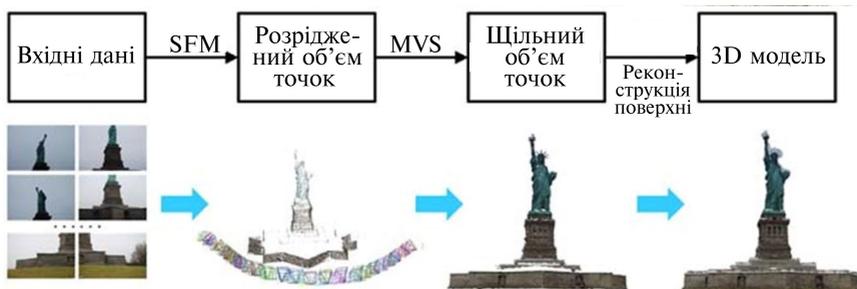


Рис. 14. Ілюстрація роботи методу, що поєднує SfM, MVS та реконструкцію поверхні [23]

Інкрементальний підхід SfM використовується для отримання розріджених об'ємів точок з вхідних зображень, при цьому обчислюються різні параметри для кожного зображення. Цей підхід включає етапи калібрування камери, відстеження особливостей, обчислення позицій камери, триангуляції та пакетного коригування даних (bundle adjustment). Для отримання щільних об'ємів точок використовується підхід MVS на основі патчів, що включає ініціалізацію, розширення та фільтрацію патчів. Після отримання щільних об'ємів точок для створення моделі використовується підхід реконструкції поверхні за методом Пуассона, яка включає етапи дискретизації задачі, визначення векторного поля, розв'язання рівняння Пуассона та побудову ізоповерхні.

2.4. СУЧАСНІ МЕТОДИ 3D РЕКОНСТРУКЦІЇ СЕРЕДОВИЩА

У сучасному світі нейронні методи для відновлення карт глибини та 3D реконструкції стали більш популярними порівняно зі стандартними та класичними підходами, такими як Structure from Motion (SfM) та Multi-View Stereo (MVS). Причини цього включають кілька ключових аспектів:

- *Висока точність і деталізація.* Нейронні мережі, зокрема глибокі нейронні мережі, можуть навчатися на великих наборах даних і знаходити складні, нелінійні залежності між зображеннями та їх тривимірними представленнями. Це дозволяє їм досягати більш високої точності та деталізації в

порівнянні з традиційними методами, які часто базуються на простих геометричних припущеннях. Наприклад, на відміну від класичних підходів, сучасні методи дозволяють отримувати якісні карти глибин та 3D реконструкцію навіть в областях з однорідними та періодичними текстурами.

- *Автоматизація і узагальнення.* Глибокі нейронні мережі здатні автоматично витягати особливості та патерни з вхідних даних, що зменшує потребу в ручному налаштуванні параметрів та попередньому обробленні даних, як це часто потрібно у традиційних методах. Це робить їх більш універсальними та здатними до узагальнення на нові сцени та умови зйомки.
- *Зменшення чутливості до шумів.* Нейронні методи мають вбудовану здатність до зменшення впливу шумів та артефактів в даних завдяки використанню навчання на великих і різноманітних наборах даних. Це дозволяє отримувати більш стабільні результати навіть при наявності шумів у вхідних зображеннях.
- *Інтеграція різних джерел даних.* Нейронні мережі можуть інтегрувати інформацію з різних даних, таких як RGB-зображення, глибинні карти, та інші сенсорні дані, для створення більш комплексних і точних 3D моделей.

2.4.1. HIGHRES-MVSNET

R. Weillharter та ін. [24] використали архітектуру глибокого навчання для 3D реконструкції із зображень високої роздільної здатності. Традиційні MVS-техніки для уточнення значення глибини кожного пікселя використовують обчислені ознаки та зв'язки між кількома видами сцени [25]. Використання ознак, виділених нейронною мережею під час навчання, є достойною альтернативою. Архітектура HighRes-MVSNet зосереджується на зниженні вимог до пам'яті, необхідної для використання великої кількості даних, які доступні завдяки сучасним камерами з високою роздільною здатністю зображень. Підхід використовує архітектуру енкодера-декодера, зображену на рис. 15. В енкодері система спочатку виконує 3 згортки у початковому шарі, після чого йде шар об'єднання регіонів даних (pooling) і ще один згортковий шар. Таким чином, розмір обсягу ознак зменшується до однієї восьмої від вхідних даних зображення.

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

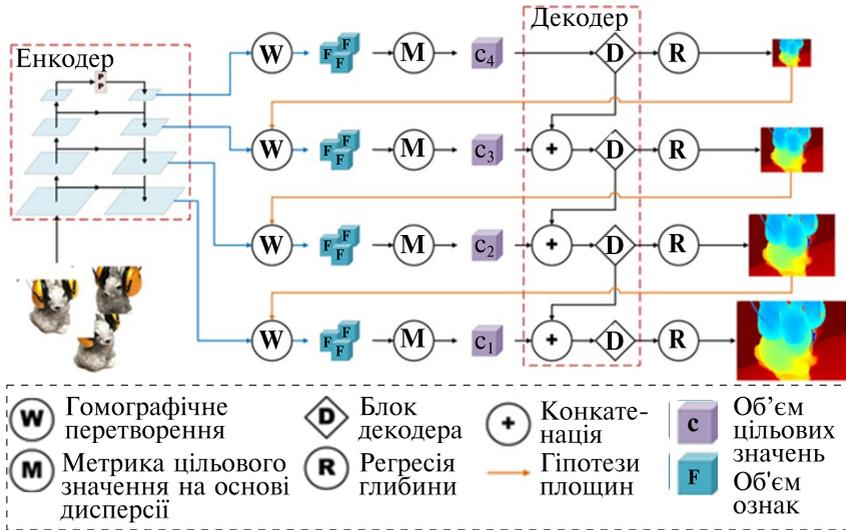


Рис. 15. Архітектура мережі HighRes-MVSNet [24]

Потім використовується архітектура U-Net для вилучення ознак на декількох масштабах, і на кожному масштабі ознаки проєктуються в нижчий вимірний підпростір для контролю розміру вихідної карти ознак. Диференційована функція гомографічного викривлення використовується для побудови 3D об'ємів цільових значень з попередньо вилучених ознак на кожному масштабі. Функція викривлення задається наступним чином:

$$H_i(d) = K_i \cdot R_i \cdot \left(I - \frac{t_0 - t_i \cdot n_0^T}{d} \right) \cdot R_0^T \cdot K_0^T, \quad (4)$$

де $H_i(d)$ є гомографією між i -тою картою ознак і картою ознак на глибині d . K_i , R_i та t_i відповідають параметрам камери, що вказують на поточний кадр, n_0 – головна вісь поточної камери. N об'ємів ознак F_i збираються у об'єм цільових значень C за допомогою метрики втрат на основі варіації:

$$C = \frac{\sum_{i=1}^N (F_i - \bar{F}_i)^2}{N}, \quad (5)$$

де \bar{F}_i – усереднений об'єм ознак.

Об'єми цільових значень декодуються від грубого до детального рівня та об'єднують усі виходи з найдетальнішим

масштабом. Декодерна система має чотири блоки, кожен з яких відповідає за результат на одному з чотирьох етапів. Кожен блок декодера складається з шести 3D-згорткових блоків, кожен з яких містить дві 3D-згортки з залишковим з'єднанням. Декодер надає два виходи: об'єм цільових значень, який об'єднується з вхідними даними наступного етапу, та класифікований об'єм цільових значень, який обробляється шаром softmax і регресією глибини для створення карти глибини, що ініціює об'єми ознак наступного етапу.

Класифікація здійснюється за допомогою шару 3D-згортки, за яким іде шар ReLU та ще один шар 3D-згортки. На найбільш грубому етапі результат створюється лише з сирого об'єму цільових значень. Використовуючи концепцію каскадного об'єму цільових значень, ці об'єми цільових значень формуються в більш точні діапазони глибин залежно від попередньої оцінки. Глибина обчислюється на кожному масштабі шляхом збільшення роздільної здатності класифікованих об'ємів цільових значень до необхідного розміру виходу перед використанням регресії глибини.

2.4.2. 3D-FHNET

Тривимірна ієрархічна мережа об'єднання була представлена в [26]. В її основі лежать ідеї використання як техніки комбінування ознак з кількох видів, так і стратегія ієрархічного прогнозування. Це забезпечує можливість об'єднання реконструкції з однієї та декількох точок спостереження з метою отримання точних результатів. Техніка комбінування ознак спрямована на постійне підвищення якості реконструкції моделі зі збільшенням кількості нових ракурсів. Ієрархічна стратегія прогнозування впроваджена в мережу для точного відтворення дрібних деталей об'єктів. Модель представлена у вигляді воксельного подання, де кожен воксель позначається нулем або одиницею для кожної воксельної сітки. На рис. 16 показана архітектура системи моделі.

Вхідними даними моделі можуть бути як одне, так і кілька зображень, на яких присутній об'єкт представлений з різних точок спостереження. На етапі навчання моделі можна подавати численні зображення одного й того самого об'єкта або сцени. Ці зображення проходять через мережу енкодера, яка вилучає ознаки з поданих даних. Мережа використовується для вилучення ознак

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

із зображень з роздільною здатністю 128×128 пікселів. Енкодер використовує залишковий двовимірний енкодер. Кожне вхідне зображення проходить через шість залишкових згорткових блоків енкодера. Кожен із цих блоків виконує три згортки та одну операцію об'єднання регіонів даних (pooling). Для кожного блоку дані проходять одночасно двома шляхами. Один шлях обробляє дві згортки, а другий шлях — згортку розміром 1×1 . Ці процеси супроводжуються функцією активації ReLU. Ознаки, отримані з обох шляхів, об'єднуються та проходять через шар max-pooling. Нарешті, дані перетворюються у вектор ознак.

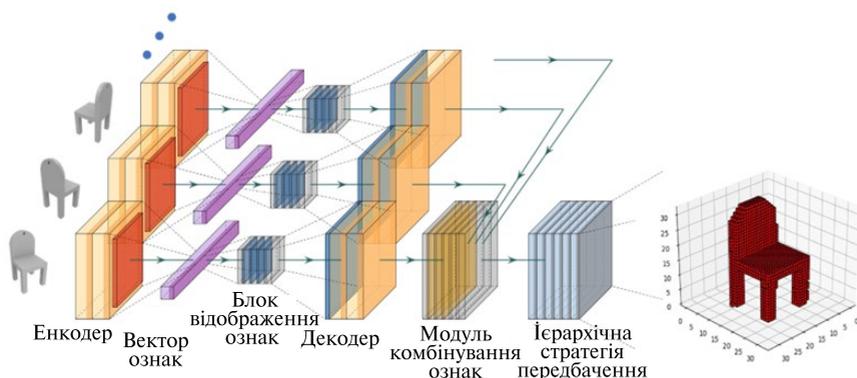


Рис. 16. Архітектура моделі 3D-FHNet [26]

Модуль відображення ознак використовується для перетворення двовимірних ознак у тривимірні, відображаючи вектори ознак, отримані з енкодера. Кожен вектор ознак проходить через повнозв'язний шар, а потім через модуль відображення ознак.

Тривимірні дані декодується за допомогою залишкового тривимірного декодера. Декодер перетворює тривимірні ознаки в тривимірні об'єми. Він приймає ознаки з модуля відображення ознак та пропускає їх через шість тривимірних залишкових декодерних блоків. Результат потім нормалізується шаром softmax до тривимірному об'єму передбаченої ймовірності. Кожен блок містить три операції зворотної згортки та одну операцію розпакування (unpooling). Дані одночасно проходять двома шляхами. Один із шляхів містить дві тривимірні згортки, а інший шлях — згортку $1 \times 1 \times 1$. Усі ці процеси супроводжуються функцією активації ReLU. Дані надходять до наступного операційного блоку після об'єднання та проходження

через шар розпакування (unpooling). Для об'єднання ознак усіх отриманих зображень використовується модуль інтеграції ознак. Людина може отримати уявлення про об'єкт, рухаючись навколо нього та спостерігаючи його з різних ракурсів. Аналогічно, модель може отримати поточну передбачену ймовірність зайнятості вокселів, розглядаючи зображення. Коли кількість вхідних видів об'єкта збільшується, кількість воксельних сіток також зростає, відповідно точність моделі покращується.

Модель використовує ієрархічну стратегію прогнозування для виведення зайнятості вокселів у виді 0-1. Значення 0 вказує на відсутність зайнятості, а значення 1 вказує на зайнятість відповідного вокселя. Спочатку модель встановлює поріг, і воксельна сітка з передбаченою ймовірністю, рівною або більшою за поріг, буде класифікована як зайнята, а ті, що мають менше значення, як незайняті. Це також допомагає відновити дрібні деталі об'єкта. Таку метрику якості, як точність, можна обчислити, порівнюючи передбачену зайнятість вокселів 0-1 з фактичною зайнятістю вокселів.

2.4.3. ATLAS

Одним з варіантів представлення 3D об'єкта, або площини в комп'ютерній графіці, є усічена знакова функція відстані (Truncated Signed Distance Function - TSDF). Метод 3D-реконструкції сцени, що безпосередньо регресує TSDF із набору RGB-зображень та відповідних положень камери, представлений у [27].

ATLAS приймає на вхід послідовність RGB-зображень довільної довжини, внутрішні параметри камери та положення камери відповідні до кожного кадру. Зображення проходять через основу 2D CNN для вилучення ознак. Потім ці ознаки зворотно проєктуються в 3D-воксельний об'єм і акумулюються та усереднюються з вже існуючими даними. Після того як ознаки зображень об'єдналися в 3D, відбувається безпосередня регресія TSDF за допомогою 3D CNN (рис. 17).

Після акумуляції ознак у воксельному об'ємі використовується тривимірна згорткова мережу енкодера-декодера для уточнення ознак і регресії вихідного TSDF. Кожен шар енкодера і декодера використовує набір залишкових блоків розміром $3 \times 3 \times 3$. Зменшення масштабу реалізується за допомогою згортки $3 \times 3 \times 3$ з кроком 2, а збільшення масштабу використовує

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

трилінійну інтерполяцію з наступним застосуванням згортки $1 \times 1 \times 1$ для зміни розміру ознак. Розмір ознак подвоюється при кожному зменшенні масштабу і зменшується вдвічі при кожному збільшенні масштабу. Усі згорткові шари супроводжуються batchnorm та активацією ReLU.

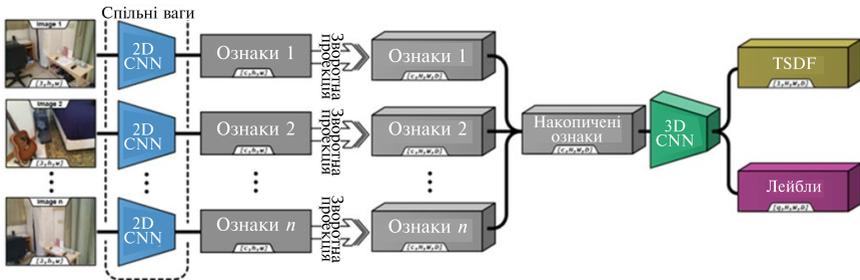


Рис. 17. Архітектура моделі ATLAS [27]

На верхньому шарі енкодера-декодера використовується згортка $1 \times 1 \times 1$, що супроводжується функцією активації \tanh для регресії кінцевих значень TSDF.

Крім того, модель має проміжні виходи на кожній декодованій роздільній здатності перед збільшенням масштабу. Ці додаткові виходи використовуються як для проміжного контролю, щоб допомогти мережі швидше навчатися, так і для покращення якості наступних ітерацій.

2.4.4. SIMPLERECON

На відміну від багатьох сучасних методів 3D реконструкції, що застосовують важкі тривимірні згорткові шари, тим самим обмежуючи своє застосування в умовах обмежених обчислювальних ресурсів, SimpleRecon [28] робить акцент на високоякісному прогнозуванні глибини. Традиційний та доступний підхід об'єднання карт глибини у поєднанні із запропонованим якісним відновленням глибини з кількох ракурсів призводить до точних 3D реконструкцій.

На вхід методу подаються: опорне зображення I_0 , набір вхідних зображень I_n , де $n \in \{1, \dots, N-1\}$, а також внутрішні параметри камер та відносні позиції камер. Під час навчання використовуються карти глибини D_{gt} , що відповідають вхідним RGB-зображенням. Під час тестування модель виконує

передбачення щільних карт глибини \hat{D} для кожного опорного зображення.

SimpleRecon доповнює архітектуру енкодера-декодера для прогнозування глибини об'ємом цільових значень (рис. 18).

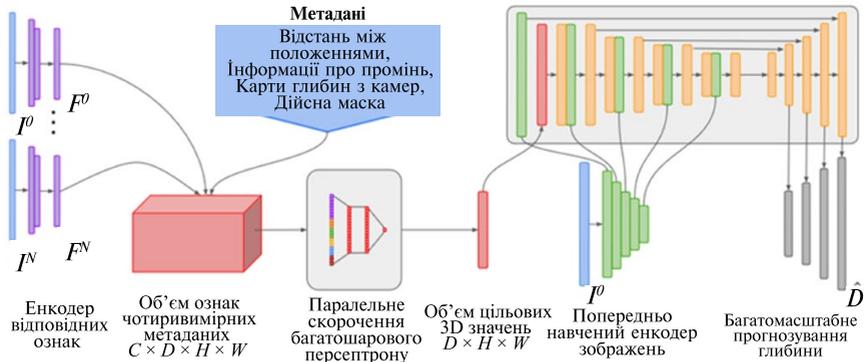


Рис. 18. Архітектура моделі SimpleRecon [28]

Енкодер зображень вилучає відповідні ознаки з опорних зображень, що подаються у об'єм цільових значень. Вихід об'єму цільових значень обробляється за допомогою двовимірної згорткової мережі енкодера-декодера, доповненої ознаками вилученими за допомогою окремого попередньо навченого енкодера зображень. Ключова ідея підходу полягає у включенні доступних метаданих до об'єму цільових значень разом із типовими глибинними ознаками зображення, що дозволяє мережі використовувати корисну інформацію, таку як геометричні дані та відносна позиція камер. Ці метадані дозволяють мережі краще визначати відносну важливість кожного вхідного зображення для оцінки глибини для певного пікселя.

Об'єм цільових значень є чотиривимірним тензором розмірністю $C \times D \times H \times W$, де для кожного просторового положення (k, i, j) існує вектор ознак розмірністю C , де k – індекс площини глибини. Вектор ознак C складається з ознак опорного зображення та набору ознак вхідних зображень, що деформуються враховуючи специфічні метадані.

Мережа базується на двовимірній згортковій архітектурі енкодера-декодера. Об'єднання об'єму цільових значень відбувається за рахунок підсумовування результатів добутку точок між опорним зображенням і кожним вхідним зображенням та дає

результати, які конкурентоспроможні з сучасними методами оцінки глибини.

В якості енкодера зображень та енкодера відповідності ознак використовується невеликий, але потужніший енкодер EfficientNetv2 S [29]. Для ефективного створення карт відповідності ознак застосовуються перші два блоки ResNet18 [30].

В SimpleRecon об'єднання ознак зображення в енкодер об'єму цільових значень відбувається на зразок DeepVideoMVS [31]. Глибинні ознаки зображення об'єднуються на кількох масштабах, додаючи пропуски з'єднання між енкодером зображення та енкодером об'єму цільових значень на всіх роздільних здатностях.

Функція втрат представлена у вигляді:

$$L = L_{depth} + \alpha_{grad}L_{grad} + \alpha_{normals}L_{normals} + \alpha_{mv}L_{mv}, \quad (6)$$

де: L_{depth} – функція втрат регресії глибини; L_{grad} – функція втрат багатомасштабного градієнту та нормалей; L_{mv} – функція втрат багатовидової регресії глибини; $\alpha_{grad} = \alpha_{normals} = 1.0$ та $\alpha_{mv} = 0.2$ – коефіцієнти підібрані експериментально на валідаційному наборі даних.

2.4.5. MARIGOLD

Підхід Marigold [32], запропонований Bingxin Ke та ін., базується на використанні дифузійної моделі та пропонує протокол тонкого налаштування для монокулярної реконструкції карти глибини. Враховуючи щільну карту глибини, що повертає алгоритм, та її високу точність, підхід також застосовується і для задач 3D реконструкції (рис. 19).

Основний принцип нового підходу полягає у використанні багатих візуальних знань, що зберігаються в сучасних генеративних візуальних моделях. Marigold розроблена на основі попередньо навченої Stable Diffusion моделі та доналаштована з використанням синтетичних даних.

Однією з основних цілей Marigold є ефективність навчання, оскільки дифузійні моделі зазвичай потребують багато ресурсів для навчання. Тому запропонована модель базується на попередньо навченій text-to-image LDM (Stable Diffusion v2 [33]), яка навчилася дуже хорошим апостеріорним ознакам зображень на наборі даних LAION-5B [34].



Вхідне
зображення

Карта глибини

3D реконструкція

Рис. 19. Приклади 3D реконструкції із застосуванням Marigold [32]

Для кодування зображення x та його відповідної карти глибини d в латентний простір, з метою навчання умовного розшумлювача, використовується оригінальний зафіксований варіаційний автоенкодер (VAE) Stable Diffusion. Карта глибини дублюється в три канали, щоб імітувати RGB-зображення, та подається на енкодер. Доналаштується лише U-Net, оптимізуючи стандартну дифузійну задачу відносно латентного коду глибини. Відповідність співставлення карти глибини до зображення досягається шляхом об'єднання двох латентних кодів перед їх подачею в U-Net. Перший шар U-Net модифіковано для прийняття об'єднаних латентних кодів. Підхід доналаштування Marigold представлений на рис. 20. Загальна схема виконання підходу представлена на рис. 21.

Вхідне зображення x кодується за допомогою оригінального варіаційного автоенкодера (VAE) Stable Diffusion у латентний код $z^{(x)}$ і об'єднується з латентним кодом глибини $z_t^{(d)}$ перед подачею в модифіковану доналаштовану U-Net мережу на кожній ітерації розшумлення. Після T ітерацій розшумлення, отриманий

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

латентний код глибини $z_0^{(d)}$ декодується в зображення, три канали якого усереднюються для отримання кінцевої оцінки \hat{d} .

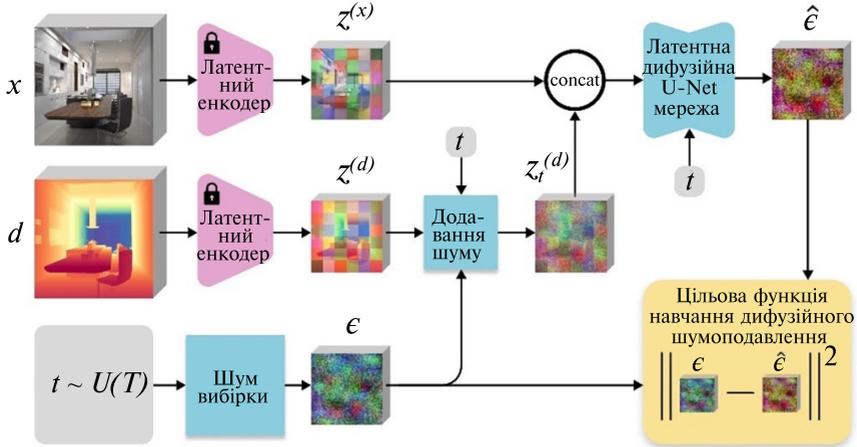


Рис. 20. Огляд підходу доналаштування Marigold [32]

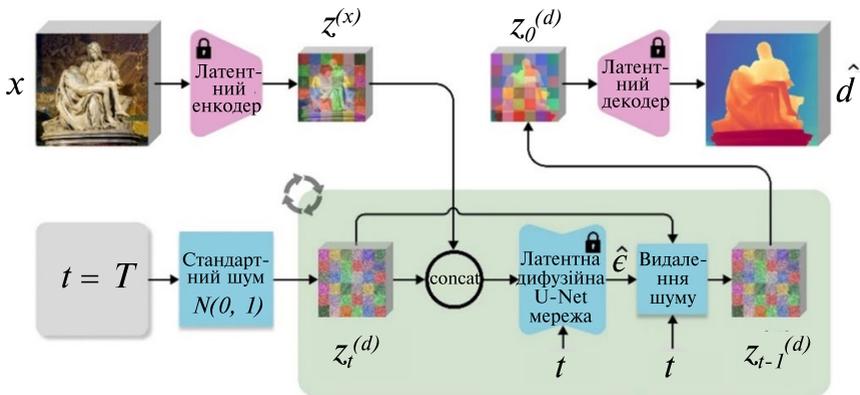


Рис. 21. Загальна схема Marigold для реконструкції карти глибини [32]

Основний недолік Marigold – тривалий час виконання, що робить цей підхід непридатним для систем, які оперують в умовах реального часу.

ВИСНОВКИ

Представлений аналіз дозволяє систематизувати знання та оцінити поточний стан розвитку методів доповненої реальності, 3D реконструкції та оцінки глибини по 2D даним. Розглянуті основні підходи та технології, що використовуються для побудови тривимірних моделей, демонструють стрімкий розвиток даного наукового та інноваційного напрямку. Незважаючи на це залишається низка відкритих питань, які потребують подальших досліджень та удосконалення з метою покращення природності та імерсивності досвіду користувача в доповненій реальності.

По-перше, необхідно розширювати та адаптувати існуючі набори даних до конкретних конфігурацій камер кінцевих пристроїв. Кожний носимий пристрій доповненої реальності має свої специфічні сенсори та їх параметри. Зазвичай наявні набори даних не покривають необхідний кінцевий домен. Для покращення точності та надійності методів 3D реконструкції на кінцевому пристрої необхідно включати набори даних, що відповідають конкретним типам камер та їх характеристикам. Збір та анотація даних — це доволі тривала по часу та витратна процедура. Тому виникає необхідність адаптації існуючих наборів даних під кінцевий домен.

По-друге, для повсякденного використання пристроїв доповненої реальності, важливо зосередити зусилля на покращенні точності реконструкції сцени в складних умовах. До таких сцен можна віднести динамічні сцени з великою кількістю рухомих об'єктів та сцени, в яких присутні відбивні поверхні. Подолання цих викликів сприятиме покращенню якості 3D реконструкції середовища і матиме суттєвий вплив на якість сприйняття користувачем сценаріїв доповненої реальності.

Нарешті, пристрої споживання сценаріїв доповненої реальності, такі як смартфони та носимі окуляри ДР, обмежені з точки зору наявних обчислювальних ресурсів та ємності батареї. Якісні методи 3D реконструкції, зазвичай, мають високу обчислювальну складність і не відповідають вимогам обробки в реальному часі та вимогам по енергоспоживанню. Адаптація, портування, оптимізація методів 3D реконструкції та квантизація відповідних моделей під кінцевий пристрій без суттєвого погіршення їх якості є критичною задачею для забезпечення ефективної роботи сценаріїв ДР, збільшення часу експлуатації носимих пристроїв та їх подальшої мініатюризації.

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

Таким чином, подальші дослідження в напрямку адаптації існуючих наборів даних, покращення якості реконструкції складних сцен та оптимізація рішень для виконання на носимих пристроях є ключовими напрямками для досягнення нових висот у галузі 3D реконструкції середовища та популяризації використання доповненої реальності в повсякденному житті.

ПЕРЕЛІК ПОСИЛАНЬ

1. «Market Research Report: Augmented & Virtual Reality Market by Enterprise (Small, Medium, Large), Technology (AR and VR), Offering (Hardware, Software), Device Type (AR, VR Devices), Application (AR Application, VR Application) and Region - Global Forecast,» 10/2023. URL: <https://www.marketsandmarkets.com/Market-Reports/augmented-reality-virtual-reality-market-1185.html>.

2. Grayson C., «Holographic Waveguides: What You Need To Know To Understand The Smartglasses Market,» 4/5/2017. URL: <https://www.uploadvr.com/waveguides-smartglasses/>.

3. «Samsung's New Transparent MICRO LED Display Blurs the Boundaries Between Content and Reality,» 8/1/2024. URL: <https://news.samsung.com/global/video-ces-2024-samsungs-new-transparent-micro-led-display-blurs-the-boundaries-between-content-and-reality>.

4. Kumar P., «What is a ToF sensor?,» 25/11/2021. URL: <https://www.e-consystems.com/blog/camera/technology/what-is-a-time-of-flight-sensor-what-are-the-key-components-of-a-time-of-flight-camera/>.

5. «What is LiDAR?,» URL: <https://www.synopsys.com/glossary/what-is-lidar.html>.

6. «What is Structured Light Imaging?,» 2018. URL: <https://www.roboticstomorrow.com/article/2018/04/what-is-structured-light-imaging/11821>.

7. Battiato S., S. Curti, M. Cascia & M. Tortora, «Depth map generation by image classification», SPIE Proc. Vol 5302, EI2004 conference 'Threedimensional image capture and applications VI', 2004.

8. F. Cozman & E. Krotkov, «Depth from scattering», IEEE Computer society conference on Computer Vision and Pattern Recognition, Proceedings, Pages: 801–806, 1997.

9. M. W. Tao, P. P. Srinivasan, J. Malik, S. Rusinkiewicz & R. Ramamoorthi, «Depth from shading, defocus, and correspondence

using light-field angular coherence», IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015.

10. E. Trucco & A. Verri, *Introductory techniques for 3-D computer vision*, Prentice Hall, 1998.

11. D. Scharstein, R. Szeliski & R. Zabih, «A Taxonomy and Evaluation of Dense Two-Frame Stereo Correspondence Algorithms», *International Journal of Computer Vision*, № 47, pp. 7-42, 2002.

12. «Stereokinetic Phenomenon from Michael Bach's "Optical Illusions & Visual Phenomena"», URL: <https://michaelbach.de/ot/mot-ske/index.html>.

13. «Parallax scrolling», Wikipedia, the free encyclopedia, URL: https://en.wikipedia.org/wiki/Parallax_scrolling.

14. A. P. Pentland, «Depth of Scene from Depth of Field», *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 9, № 4, pp. 523-531, 1987.

15. T. Matsuyama, «Exploitation of 3D video technologies», *International Conference Informatics Research for Development of Knowledge Society Infrastructure (ICKS)*, 2004.

16. D. G. Lowe, «Object Recognition from Local Scale-Invariant Features», *Proc. of the International Conference on Computer Vision*, 1999.

17. Z. Cui & P. Tan, «Global Structure-from-Motion by Similarity Averaging», *IEEE International Conference on Computer Vision (ICCV)*, pp. 864-872, 2015.

18. S. E. Hazrat, A. Saaidi & K. Sat, «Structure from motion for 3D object reconstruction based on local and global bundle adjustment», *2015 Third World Conference on Complex Systems (WCCS)*, pp. 1-6, 2015.

19. H. Yin & H. Yu, «Incremental SfM 3D reconstruction based on monocular», *13th International Symposium on Computational Intelligence and Design (ISCID)*, pp. 17-21, 2020.

20. Y. Furukawa & C. Hernández, «Multi-View Stereo: A Tutorial», *Foundations and Trends® in Computer Graphics and Vision*, v. 9, pp. 1-148, 2015.

21. Y. Furukawa & J. Ponce, «Accurate, Dense, and Robust Multi-View Stereopsis», *IEEE Conference on Computer Vision and Pattern Recognition*, 2007.

22. J. M. Juszczyk, A. Wijata, J. Czajkowska, M. Krecichwost, M. Rudzki, M. Biesok, B. Pyciński, J. Majewski, J. Kostecki & E. Pietka, «Wound 3D Geometrical Feature Estimation Using Poisson Reconstruction», *IEEE Access*, v. 9, pp. 7894-7909, 2021.

1.2. Аналіз методів 3D реконструкції середовища для доповненої...

23. Y. Cai, M. Cao, L. Li & X. Liu, «An End-to-End Approach to Reconstructing 3D Model From Image Set», *IEEE Access*, v. 8, pp. 192268-193284, 2020.

24. R. Weilharter & F. Fraundorfer, «HighRes-MVSNet: A Fast Multi-View Stereo Network for Dense 3D Reconstruction From High-Resolution Images», *IEEE Access*, v. 9, pp. 11306-11315, 2021.

25. P.-H. Chen, H.-C. Yang, K.-W. Chen & Y.-S. Chen, «MVSNet++: Learning DepthBased Attention Pyramid Features for Multi-View Stereo», *IEEE Transactions on Image Processing*, v. 29, pp. 7261-7273, 2020.

26. Q. LU, Y. LU, M. XIAO, X. YUAN & W. JIA, «D-FHNet: ThreeDimensional Fusion Hierarchical Reconstruction Method for Any Number of Views», *IEEE Access*, v. 7, pp. 172902-172912, 2019.

27. Z. Murez, T. As, J. Bartolozzi, A. Sinha, V. Badrinarayanan & A. Rabinovich, *Atlas: End-to-End 3D Scene Reconstruction from Posed Images*, 2020.

28. M. Sayed, J. Gibson, J. Watson, V. Prisacariu, M. Firman & C. Godard, «SimpleRecon: 3D Reconstruction Without 3D Convolutions», *ECCV 2022*, 2022.

29. M. Tan & Q. V. Le, «Efficientnetv2: Smaller models and faster training», *ICML*, 2021.

30. K. He, X. Zhang, S. Ren & J. Sun, «Deep Residual Learning for Image Recognition», *IEEE Conference on Computer Vision and Pattern Recognition*, 2016.

31. A. Duzceker, S. Galliani, C. Vogel, P. Speciale, M. Dusmanu & M. Pollefeys, «Deepvideomvs: Multi-view stereo on video with recurrent spatio-temporal fusion», в *CVPR*, 2021.

32. B. Ke, A. Obukhov, S. Huang, N. Metzger, R. C. Daudt & K. Schindler, «Marigold: Repurposing Diffusion-Based Image Generators for Monocular Depth Estimation», *The IEEE/CVF Conference on Computer Vision and Pattern Recognition 2024*, 2024.

33. R. Rombach, A. Blattmann, D. Lorenz, P. Esser & B. Ommer, «High-resolution image synthesis with latent diffusion models», *Computer Vision and Pattern Recognition*, 2021.

34. C. Schuhmann, R. Beaumont, R. Vencu, C. Gordon, R. Wightman, M. Cherti, T. Coombes, A. Katta, C. Mullis & M. Wortsman, «LAION-5B: An open large-scale dataset for training next generation image-text models», *NeurIPS*, 2022.

3. АНАЛІЗ МЕТОДІВ ТА МОДЕЛЕЙ КОМП'ЮТЕРНОГО ЗОРУ ТА ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ВИЗНАЧЕННЯ ПОШКОДЖЕНЬ ЗЕМНОГО ПОКРИВУ

Поліна Мікава, аспірант
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

geor.polina@gmail.com

ВСТУП

У сучасному світі, який стикається з різноманітними екологічними викликами, важливість моніторингу стану навколишнього середовища та його змін набуває все більшого значення. Кліматичні зміни, антропогенні дії та природні катаклізми чинять дедалі сильніший вплив на наші екосистеми, ресурси та загалом на планету. Земна поверхня, яка охоплює ліси, сільськогосподарські угіддя, водойми, пустелі та урбанізовані зони, піддається постійному впливу людської діяльності та природних факторів. Оцінка цих впливів та вивчення пошкоджень земної поверхні є важливою задачею не лише для екологів і науковців, а й для урядів, громадських організацій і міжнародної спільноти загалом.

Традиційні методи моніторингу стану земної поверхні, такі як польові дослідження та візуальний огляд територій, є надзвичайно важливими, однак

використання в умовах сучасних викликів обмежене. Зокрема, ці методи займають багато часу, потребують значних людських ресурсів і часто є небезпечними в умовах природних катастроф або в зоні військових конфліктів. Крім того, традиційний моніторинг може не завжди охоплювати великі території з достатньою точністю або своєчасністю, що обмежує його ефективність.

Зі швидким розвитком інформаційних технологій і зростанням обсягів даних про земну поверхню з'являються нові можливості для моніторингу та аналізу змін у навколишньому

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

середовищі. Одним з таких напрямків є використання методів комп'ютерного зору та глибинних нейронних мереж для аналізу пошкоджень земної поверхні. Ці передові технології відкривають нові горизонти для автоматизації процесу моніторингу, підвищують точність і швидкість аналізу, а також забезпечують можливість обробки великих обсягів даних у реальному часі. Використання супутникових знімків, аерофотознімків, даних з безпілотників та інших джерел інформації стає основою для побудови більш ефективних та надійних систем оцінки стану земної поверхні.

Методи комп'ютерного зору дозволяють автоматизувати процес аналізу зображень і виявляти зміни на земній поверхні, які не завжди можуть бути помітними для людського ока. Глибинні нейронні мережі, у свою чергу, забезпечують можливість навчання систем на великих наборах даних, що підвищує їх здатність розпізнавати складні патерни та закономірності в зображеннях. Це робить їх незамінними інструментами для аналізу широкого спектра пошкоджень, починаючи від змін у лісових масивах і сільськогосподарських угіддях, закінчуючи моніторингом міських зон і водних ресурсів.

Однією з ключових переваг методів комп'ютерного зору та глибинних нейронних мереж є їх здатність обробляти великі обсяги інформації з високою швидкістю і точністю. У зв'язку з цим вони можуть бути використані для оцінки наслідків природних катастроф, таких як землетруси, повені, урагани або лісові пожежі. Ці методи дозволяють оперативно отримувати точну інформацію про масштаби пошкоджень і прогнозувати їх подальший розвиток. Наприклад, під час лісової пожежі комп'ютерні системи можуть швидко ідентифікувати згорілі території, оцінювати ступінь пошкоджень і навіть надавати рекомендації щодо відновлення лісових ресурсів.

Ще однією сферою, де методи комп'ютерного зору та глибинних нейронних мереж мають вирішальне значення, є моніторинг сільськогосподарських угідь. Сільське господарство залежить від стану землі, її родючості та здатності до самовідновлення. Забруднення ґрунтів, ерозія, засолення та інші негативні процеси можуть призводити до значних втрат у врожайх, що, своєю чергою, впливає на продовольчу безпеку. Використання комп'ютерного зору для моніторингу стану сільськогосподарських земель дозволяє ідентифікувати проблемні ділянки та розробляти ефективні заходи для покращення ситуації. Завдяки точності аналізу зображень можна своєчасно виявляти пошкодження

посівів, зони, що постраждали від шкідників або хвороб, та приймати швидкі рішення для зменшення негативних наслідків.

Важливість комп'ютерного зору та глибинних нейронних мереж також зростає в контексті зростання міст і розвитку урбанізованих територій. Стрімке зростання населення планети і збільшення потреб у житлових та комерційних зонах призводять до постійного розширення міст, що, в свою чергу, впливає на земну поверхню. У містах відбуваються інтенсивні будівельні роботи, що спричиняють зміну ландшафтів, втрату природних територій і підвищене навантаження на екосистеми. В цьому контексті методи комп'ютерного зору можуть бути використані для аналізу стану інфраструктури, моніторингу змін в урбанізованих зонах і виявлення потенційно небезпечних територій, де можуть виникнути проблеми з екологією або інфраструктурними об'єктами.

Однією з важливих особливостей методів глибинного навчання є здатність адаптуватися до нових умов і типів даних. Це особливо важливо для аналізу пошкоджень земної поверхні внаслідок військових дій або техногенних катастроф. Наприклад, під час військових конфліктів екосистеми та земна поверхня зазнають великих руйнувань через бомбардування, обстріли або інші види бойових дій. Звичайні методи моніторингу є надто небезпечними для використання в таких умовах, і тут на допомогу приходять технології комп'ютерного зору, які можуть автоматично оцінювати масштаби пошкоджень на основі супутникових зображень.

Глибинні нейронні мережі, натомість, можуть навчатися на цих даних і з часом ставати точнішими в ідентифікації зон, які постраждали найбільше. Це дозволяє оперативно надавати інформацію про стан територій, зруйнованих внаслідок військових конфліктів, і розробляти ефективні стратегії для їхнього відновлення. Крім того, методи комп'ютерного зору можуть бути використані для моніторингу шкідливих відходів, що утворюються внаслідок техногенних катастроф або військових дій, таких як хімічне забруднення або радіоактивні відходи.

Ще однією важливою перевагою використання методів комп'ютерного зору та глибинних нейронних мереж є їх економічна ефективність. Хоча впровадження цих технологій може вимагати значних початкових інвестицій у обладнання та програмне забезпечення, у довгостроковій перспективі вони значно знижують витрати на моніторинг та аналіз стану земної поверхні. Автоматизація процесів і можливість отримувати точні

дані без необхідності залучення великої кількості людей роблять ці технології привабливими для урядів, екологічних організацій та приватних компаній, які займаються управлінням природними ресурсами або розвитком інфраструктури.

Ще одним аспектом, на який варто звернути увагу, є здатність методів комп'ютерного зору та глибинних нейронних мереж до прогнозування змін у земній поверхні. Це особливо важливо в контексті кліматичних змін, які можуть мати непередбачувані наслідки для різних регіонів планети. Зокрема, ці технології можуть бути використані для створення моделей, які прогнозують, як зміни клімату вплинуть на конкретні екосистеми або земні ресурси. Це відкриває нові можливості для планування заходів з адаптації до кліматичних змін та розробки ефективних стратегій для зменшення їхніх негативних наслідків.

Отже, використання методів комп'ютерного зору та глибинних нейронних мереж для аналізу пошкоджень земної поверхні є важливим кроком на шляху до покращення моніторингу навколишнього середовища та забезпечення сталого управління природними ресурсами. Ці технології не тільки підвищують точність і швидкість аналізу, а й відкривають нові можливості для автоматизації процесів, що раніше були обмежені через необхідність людського втручання або великі витрати часу та ресурсів. В умовах сучасних викликів, коли зміни клімату, військові конфлікти та техногенні катастрофи можуть мати катастрофічні наслідки для екосистем і природних ресурсів, ці технології стають незамінними для збереження навколишнього середовища та забезпечення екологічної безпеки в Україні.

3.1. МЕТОДИ ВИЗНАЧЕННЯ НЕЗАКОННИХ ЗВАЛИЩ

Незаконні звалища становлять серйозну загрозу для екології, здоров'я людей і довкілля в цілому. Вони є джерелом забруднення повітря, води та ґрунтів, сприяють деградації екосистем і порушують природний баланс територій. Визначення та моніторинг незаконних звалищ — важливий елемент аналізу стану земного покриву, оскільки вони мають прямий вплив на якість земельних ресурсів і життєздатність навколишніх екосистем. Своєчасна ідентифікація таких об'єктів дозволяє вчасно вживати заходів для їх ліквідації та мінімізувати шкоду. Однією з основних проблем, пов'язаних з незаконними звалищами, є їх прихована природа. Часто такі об'єкти створюються у віддалених або

важкодоступних місцях, де контроль з боку екологічних служб ускладнений. Через це їх важко виявити за допомогою традиційних методів моніторингу, таких як польові дослідження або перевірки на місцевості. Проте розвиток сучасних технологій, таких як супутникова зйомка, комп'ютерний зір та глибокі нейронні мережі, дозволяє значно підвищити ефективність визначення незаконних звалищ і отримувати точні дані про їхній стан.

Наприклад, дослідження [1] зосереджено на застосуванні сучасних методів машинного навчання для виявлення незаконних звалищ сміття за допомогою супутникових зображень. Автори відзначають, що незаконні звалища сміття спричиняють значний негативний вплив на навколишнє середовище та здоров'я людей, особливо серед вразливих груп населення, які живуть поблизу таких звалищ. Ці звалища створюють серйозні екологічні загрози, включаючи забруднення повітря та води, а також ризики для здоров'я, такі як захворювання дихальної системи та отруєння важкими металами.

Однією з основних проблем, з якими стикаються муніципальні органи влади в країнах, що розвиваються, є недостатня інформація про місцезнаходження та розміри цих звалищ. Традиційні методи моніторингу, які базуються на наземних обстеженнях, є дорогими та трудомісткими, що обмежує їх застосування на великих територіях. У цьому контексті автори пропонують використовувати супутникові зображення та технології глибокого навчання, зокрема згорткові нейронні мережі (CNN), для автоматизованого виявлення таких звалищ.

Дослідження проводилося на прикладі провінції Буенос-Айрес, Аргентина, яка є одним із найбільш населених регіонів країни. Швидке зростання міських територій призвело до збільшення обсягів твердих побутових відходів, що, в свою чергу, перевантажило наявні системи утилізації та сприяло утворенню нелегальних звалищ. У дослідженні використовувалися супутникові зображення, отримані з Sentinel-2, із просторовим розрізненням 10 м.

Для сегментації зображень і виявлення звалищ була застосована архітектура U-Net, яка є різновидом згорткових нейронних мереж, спочатку розроблених для біомедичної сегментації зображень. Ця архітектура дозволяє отримувати достатньо точні результати навіть при обмеженій кількості навчальних даних, що є критично важливим у контексті виявлення нелегальних звалищ на великих територіях.

Особливої уваги заслуговує вибір спектральних каналів для аналізу супутникових зображень. В [1] використано комбінацію трьох каналів RGB, ближнього інфрачервоного (NIR) і двох короткохвильових інфрачервоних каналів (SWIR-1 і SWIR-2). Таке поєднання дозволяє ефективніше виділяти зображення звалищ на фоні інших типів земного покриття, зокрема рослинності, що часто оточує нелегальні звалища.

Результати показали, що модель досягає високої точності виявлення, демонструючи Intersection over Union (IoU) на рівні 0,675, що є добрим показником для подібних завдань. Однак дослідники також зазначають деякі обмеження їхнього підходу, такі як труднощі у виявленні невеликих звалищ через обмежене просторове розрізнення зображень та можливість помилкової класифікації деяких об'єктів, таких як новобудови, які можуть помилково бути ідентифіковані як звалища.

В [1] запропоновано низку напрямків для майбутніх досліджень, включаючи використання зображень за інші періоди часу, що дозволило б відслідковувати динаміку змін нелегальних звалищ, а також вдосконалення методів постобробки для зниження кількості хибних позитивних результатів.

В [2] запропоновано сучасний підхід до моніторингу полігонів для утилізації відходів за допомогою супутникових зображень та методів машинного навчання. Основною проблемою, яку автори намагалися вирішити, є негативний вплив полігонів на навколишнє середовище через недостатнє планування та регулювання. Полігони часто є неконтрольованими і створюють серйозні загрози для здоров'я людей та екосистеми, виділяючи шкідливі гази, такі як метан, і спричиняючи термічне забруднення. Традиційні методи моніторингу, які включають інспекції на місці, є дорогими, складними для виконання та можуть становити загрозу для здоров'я, тому автори використали супутникові зображення як до ефективної альтернативи.

Для дослідження використано супутникові знімки з двох різних платформ — Landsat і Sentinel з 2013 по 2023 рік. Аналізуючи полігони, автори застосували три алгоритми машинного навчання: Classification and Regression Tree (CART), найвигідніший Баєсівський класифікатор та Support Vector Machine (SVM). Ці алгоритми використовувались для класифікації супутникових зображень для відділення полігонів від інших типів земного покриття, таких як вода, забудовані території та рослинність. Завдання полягало в тому, щоб автоматично

виявляти місця утилізації відходів на основі супутникових зображень і аналізувати їх вплив на довкілля.

Отримані результати показали, що найбільш стабільним і точним був алгоритм SVM, застосований для даних Landsat. Ця модель демонструвала високі показники точності протягом усього періоду дослідження (2013-2023 рр.), зокрема у 2014 році точність, прецизійність, повнота і F1-оцінка були на рівні 1, що свідчить про ідеальну роботу моделі. У той час як інші алгоритми, такі як CART і наївний Баєсівський класифікатор, мали коливання у своїй продуктивності залежно від року, CART досягав максимальних показників у 2014 році, але у 2018 та 2022 роках продуктивність моделі суттєво знизилась (F1-оцінка – 0.1333). Наївний Баєсівський класифікатор також не показав надійних результатів і в деяких випадках всі оцінки падали до нуля, що вказує на неефективність цього підходу для обробки таких даних.

Супутникові знімки Sentinel також використовувались для класифікації, і тут алгоритм SVM показав стабільні результати в деякі роки (наприклад, 2013 та 2019 роки), але також мав певні коливання. Інші алгоритми для Sentinel, такі як CART і наївний Баєсівський класифікатор, продемонстрували нижчу ефективність. Особливо слабкі результати показав наївний Баєс для даних Sentinel, де точність і F1-оцінки в основному були або на рівні 0, або не перевищували 0.1, що свідчить про значні труднощі у прогнозуванні на основі цього алгоритму.

Крім того, дослідження продемонструвало, що використання супутникових даних дозволяє спостерігати за полігонами на великих територіях і протягом тривалого періоду часу. Супутники Landsat і Sentinel мають глобальне покриття та надають відкриті дані, що робить їх економічно вигідними для моніторингу місць утилізації відходів. Дані супутників дозволяють спостерігати за полігонами в режимі реального часу, аналізуючи просторові і часові зміни в місцях утилізації відходів. Це особливо важливо для запобігання пожежам на полігонах та виявлення гарячих точок, де ймовірні вибухи через накопичення метану. Окрім того, таке спостереження допомагає відслідковувати виділення газів, оцінювати стабільність полігонів і виявляти інші екологічні ризики, пов'язані з неконтрольованими звалищами.

Попри успіхи у застосуванні алгоритму SVM автори [2] зазначають, що моделі дозволяли виявляти значні коливання у продуктивності залежно від року, що може бути пов'язане з технічними змінами у супутниках, які використовувались для отримання даних, а також із зовнішніми екологічними

чинниками, такими як зміни клімату, сезонні коливання та погодні умови. Крім того, автори визнають, що дослідження обмежене лише даними з двох супутників (Landsat та Sentinel), що не дає повної картини, особливо стосовно викидів метану чи інших газів, які можуть залишатися поза межами видимості цих супутників.

Автори пропонують у майбутніх дослідженнях розширити набір супутників та використати додаткові алгоритми машинного навчання для покращення стабільності та точності моделей. Окрім цього, варто враховувати екологічні фактори, такі як зміни клімату, щоб глибше зрозуміти, як вони впливають на точність моделювання. Зокрема, цікаво буде дослідити вплив сезонних змін та погодних умов на показники полігонів. Ще однією перспективною ідеєю для майбутніх робіт є впровадження систем моніторингу в реальному часі за допомогою дронів, що дозволить отримувати більш точні і своєчасні дані, доповнюючи супутникові спостереження.

Дослідження пропонує розробити комплексну методологію, яку можна було б використовувати для моніторингу полігонів у різних містах, що допоможе в боротьбі з забрудненням, викликаним неконтрольованими звалищами. Такий підхід не тільки економічний, але й ефективний у часі, забезпечуючи широкий кут огляду та дозволяючи відстежувати зміни на великих територіях протягом тривалого часу.

Стаття [3] досліджує застосування глибинного навчання для виявлення та локалізації нелегальних сміттєзвалищ на супутникових знімках. Автор поставив перед собою завдання створити ефективний інструмент, який би допоміг у боротьбі з нелегальними звалищами, що становлять серйозну екологічну загрозу. Головна мета дослідження полягала в тому, щоб розробити методи, які дозволяють автоматично визначати та окреслювати межі нелегальних звалищ на супутникових знімках за допомогою технологій глибинного навчання. Враховуючи обмежену кількість даних, зокрема зображень, що містять відходи, автор використовував слабко контрольовану сегментацію, яка дозволяє навчати моделі при наявності даних мінімального об'єму.

В [3] автор дослідив два основних підходи до слабко контрольованої сегментації: на основі теплових карт (heatmap-based) та на основі навчання за множинними екземплярами (Multiple Instance Learning, MIL). Обидва підходи мають свої переваги та недоліки, і їхнє порівняння було важливим для

визначення найбільш ефективного методу виявлення нелегальних звалищ.

Перший підхід, тепловий, включав використання згорткової нейронної мережі (CNN), яка спочатку навчалася класифікувати наявність або відсутність відходів на зображенні. Після навчання, з використанням техніки GRAD-CAM++, було побудовано теплову карту, яка дозволяла виявити області з найбільшою ймовірністю наявності відходів. Цей підхід показав хороші результати в локалізації відходів, проте мав проблему з поганою чіткістю меж виявлених сміттєзвалищ, що було пов'язано з нижчим просторовим розрізненням кінцевих ознак порівняно з оригінальним зображенням. Іншими словами, теплові карти дозволяли точно визначати області, де знаходяться відходи, але не могли чітко окреслити їх межі.

Другий підхід, на основі MIL, передбачав навчання CNN для класифікації малих патчів (фрагментів) зображення, що були отримані з зображення з високим просторовим розрізненням. Кожний патч проходив обробку для отримання відповідних ознак, які потім агрегувалися в єдине представлення зображення, яке передавалося на класифікаційний шар. Після навчання модель могла класифікувати набори патчів різних розмірів, що дозволяло створювати більш точні теплові карти з кращою деталізацією контурів. Цей підхід виявився ефективнішим у контексті визначення точних меж звалищ, що є важливим для точного картографування таких об'єктів.

Для проведення дослідження автор використовував набір даних AerialWaste, який складається з 10977 супутникових знімків, зібраних з різних джерел, включаючи AGEA Orthophotos, WorldView-3 та GoogleEarth. Ці зображення мають різне просторове розрізнення та розміри, що вимагало ретельної додаткової уніфікації перед використанням для навчання моделі. Зокрема, для вирівнювання даних було застосовано методи попередньої обробки, які включали стандартизацію розмірів зображень та їх просторового розрізнення. Крім того, для покращення продуктивності моделей було використано методи розширення даних, що включали симуляцію реальних супутникових умов, таких як підвищення яскравості та додавання шуму до зображень.

Однією з головних проблем, з якими зіткнувся автор [3], була нестача точно розмічених даних. Особливо це стосувалося позитивних зображень, на яких зображені відходи. Розмітка таких зображень вимагала великих зусиль, оскільки потрібно було не

тільки визначити, чи є відходи на зображенні, а й чітко їх локалізувати, що особливо складно в умовах супутникових знімків, де об'єкти можуть мати різний розмір, форму та орієнтацію. Крім того, ще однією значною проблемою було різноманіття зображень з різних джерел, що вимагало їх стандартизації для створення єдиного набору даних, придатного для навчання моделей глибинного навчання.

Результати дослідження показали, що підхід на основі теплових карт дозволяє досягти точної локалізації, але не може чітко окреслити межі сміттєзвалищ, що знижує точність сегментації. З іншого боку, підхід на основі МІЛ забезпечує кращу деталізацію меж, що робить його більш придатним для завдань, де важлива висока точність локалізації та сегментації. Однак, обидва підходи мають свої обмеження, і для досягнення найкращих результатів їх варто поєднувати або вдосконалювати.

У подальшій роботі автор планує зосередитися на покращенні методик розмітки, розширенні застосування методів обробки даних та дослідженні інших слабо контрольованих методів навчання, що можуть підвищити точність сегментації та локалізації. Це включає розвиток нових методів створення анотацій для супутникових зображень, які дозволять зменшити трудомісткість цього процесу, а також дослідження додаткових варіантів слабо контрольованого навчання, які можуть покращити результати виявлення нелегальних сміттєзвалищ.

В статті [4] для автоматизації процесу виявлення незаконних сміттєзвалищ автори використовували технології глибокого навчання, зокрема архітектуру нейронної мережі ResNet50 з додатковими компонентами Feature Pyramid Network (FPN).

ResNet50 є добре відомою глибокою згортковою нейронною мережею, що складається з 50 шарів, і була обрана завдяки своїй здатності ефективно навчатися на складних зображеннях без виникнення проблеми зникання градієнта, що часто спостерігається в глибоких мережах. Ключовим елементом, що використовується в ResNet50, є залишкові блоки (residual blocks). Ці блоки забезпечують прямий зв'язок між шарами, дозволяючи мережі зберігати інформацію та краще навчатися на великих наборах даних, як у випадку з аерофотознімками. Однак, щоб покращити здатність виявлення об'єктів різних розмірів у зображеннях, до ResNet50 була додана архітектура Feature Pyramid Network (FPN) (рис. 1). FPN дозволяє моделі працювати з об'єктами на різних масштабах. Вона інтегрує ознаки різних рівнів абстракції, поєднуючи деталі високої роздільної здатності з

семантичними ознаками, що витягуються на нижчих рівнях. Це важливо для класифікації зображень незаконних сміттєзвалищ, оскільки відходи можуть мати різні форми, розміри та контексти в межах одного зображення.

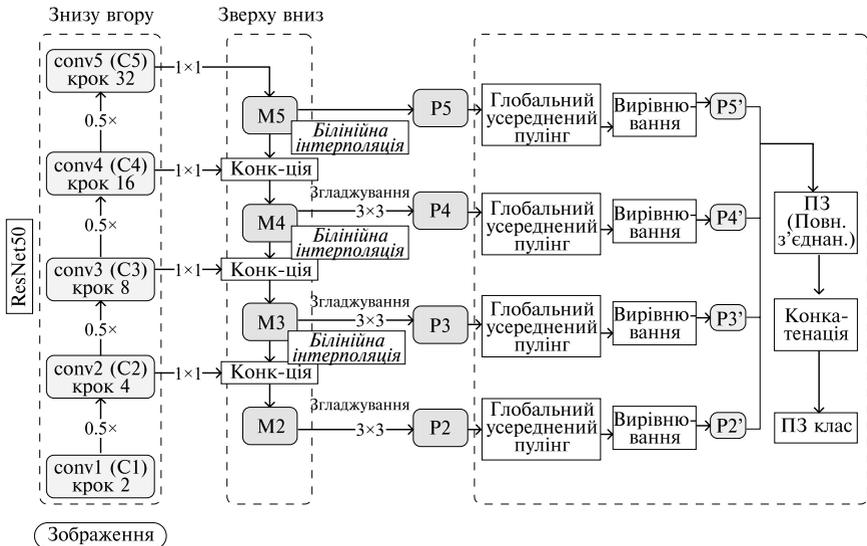


Рис. 1. Архітектура ResNet50, розширена FPN [4]

Модель обробляла зображення за допомогою кількох рівнів масштабування. Виходи з кожного рівня FPN передавались через глобальний середній пулінг (Global Average Pooling), а потім оброблялись на кінцевому етапі повнзв'язаного шару для виконання класифікації. Завдяки цій багатошаровій архітектурі, модель могла ефективно працювати зі зображеннями, де сміттєзвалища були розміщені в різних частинах території або мали різну масштабність.

Для навчання ResNet50 в даному дослідженні застосовувався підхід трансферного навчання, при якому початкові ваги моделі були взяті з мережі, попередньо навченої на наборі даних ImageNet. Це дозволило швидше адаптувати модель до нової задачі з обмеженим обсягом даних. В процесі навчання початкові шари ResNet50 були заморожені, що дозволило зосередити процес оптимізації на більш високих шарах, які витягували семантичні особливості, важливі для виявлення сміттєзвалищ.

Класифікація виконувалась на основі вихідного значення моделі, що відповідало ймовірності того, що зображення містить незаконне сміттєзвалище. Поріг для класифікації був встановлений на рівні 0.44, що забезпечило оптимальне співвідношення між точністю (precision) та відгуком (recall).

Цей підхід дозволяє ефективно розпізнавати об'єкти різних розмірів у зображеннях з високим просторовим розрізненням (20 см на піксель). З метою навчання та тестування моделі було створено датасет із близько 3000 зображень, з яких приблизно 33% містять незаконні сміттєзвалища, визначені експертами з допомогою даних ортофотозйомки.

Методи дослідження включають використання згаданих нейронних мереж для класифікації сцен з незаконними сміттєзвалищами. Ключовим моментом є врахування масштабних варіацій об'єктів, що робить завдання складним через різноманітність у формах, розмірах та контекстах зображень. Інструментами, які використовуються для досягнення цих цілей, є САМ-карти (Class Activation Maps), які візуалізують зони зображень, що сприяють класифікації, та оцінка точності класифікатора на основі метрик precision, recall, F1-score.

Основними результатами є висока ефективність класифікатора, який досяг точності 88.6% за precision та 87.7% за recall у тестовій вибірці. Зазначається, що застосування багатомасштабної архітектури FPN підвищує якість класифікації. Модель показує здатність виявляти різні типи об'єктів сміттєзвалищ, однак були виявлені проблеми з класифікацією в зонах зі слабкими або непрямими ознаками відходів.

Обмеженням дослідження є той факт, що для навчання використовувались лише зображення з одного регіону з певним просторовим розрізненням, що може обмежувати здатність моделі до узагальнення на інших територіях або зображеннях іншого типу. Також зазначено, що обмежена кількість доступних даних ускладнює навчання моделі на більш різноманітних прикладах.

У майбутніх дослідженнях планується розширення датасету за рахунок нових зображень, використання інших типів даних, таких як багатоспектральні зображення, а також вивчення можливостей класифікації типів відходів на місцях.

3.2. МЕТОДИ ОЦІНКИ ПОШКОДЖЕНЬ ВНАСЛІДОК ВОЄННИХ ДІЙ

В [5] досліджується застосування сучасних технологій глибокого навчання, зокрема згорткових нейронних мереж (CNN) і трансформерів (ViTs), для аналізу зон конфліктів в Україні. Використання таких моделей у поєднанні з різними типами даних спостереження Землі, включаючи радарні зображення з синтезованою апертурою (SAR), дані високого просторового розрізнення (VHR) та мультиспектральні зображення, дозволяє підвищити точність і детальність оцінки руйнувань, викликаних військовими діями.

Однією з головних цілей дослідження є оцінка ефективності моделей трансформерів для аналізу зображень зон конфліктів. Трансформери, зокрема Vision Transformers (ViTs), продемонстрували значний потенціал у захопленні складних патернів і довготривалих залежностей у зображеннях, що важливо для точного оцінювання рівня руйнувань інфраструктури. Ці моделі мають перевагу над традиційними CNN завдяки здатності аналізувати зображення на рівні сегментів і забезпечувати більш глибоке розуміння сцен.

У [5] також акцентується увага на багатомодальному поєднанні різних типів зображень для підвищення точності аналізу. Наприклад, SAR-зображення можуть бути використані для виявлення металевих об'єктів під рослинністю, тоді як мультиспектральні зображення забезпечують інформацію про матеріали, а VHR-зображення мають високе просторове розрізнення. Комбінування цих типів даних дозволяє отримати більш повну картину руйнувань і забезпечити точнішу оцінку стану території.

Важливим аспектом дослідження є аналіз викликів, з якими стикаються дослідники при використанні цих технологій. Основною проблемою є недостатня кількість розмічених даних, необхідних для навчання моделей глибокого навчання. Висока вартість і обмежена доступність високоякісних зображень, таких як зображення з супутників Maxar WorldView-4, значно ускладнюють проведення детального аналізу. Хоча дані супутників Sentinel-1 і Sentinel-2 є безкоштовними, їх просторове розрізнення є суттєво нижчим, що може обмежити можливості для проведення глибоких досліджень.

Попри ці виклики, у статті також розглядаються нові можливості, які відкриваються завдяки подальшому розвитку

трансформерів. Наприклад, Conditional Vision Transformers (CPEs) пропонують нові підходи до адаптації трансформерів до різних послідовностей вхідних даних, що дозволяє покращити точність завдань класифікації зображень. Інша модель, Detection Transformers (DETR), спрощує процес виявлення об'єктів, роблячи його більш ефективним для реального часу.

Практичне застосування цих технологій включає як військові, так і гуманітарні контексти. Для військових цілей моделі глибокого навчання можуть надавати дані в реальному часі для підтримки тактичного прийняття рішень, включаючи виявлення переміщень військ і оцінку руйнувань на полі бою. У гуманітарному контексті точна оцінка руйнувань може допомогти у реагуванні на катастрофи, розподілі ресурсів і зусиллях з відновлення інфраструктури.

Стаття підкреслює значущість використання глибоких нейронних мереж, особливо трансформерів, у дистанційному зондуванні для аналізу зон конфліктів, акцентуючи на їх потенціалі у наданні точної та детальної інформації про стан постраждалих територій. Це дослідження також встановлює основу для подальших розробок у цій галузі, що може суттєво вплинути на підвищення ефективності наукових, військових та гуманітарних зусиль у регіонах, що зазнали руйнувань через військові дії.

В [6] міститься детальний аналіз наслідків військових дій у Секторі Газа на основі сучасних технологій супутникових спостережень Землі та методи глибокого навчання. Дослідження було спрямоване на вивчення масштабів руйнувань, спричинених ракетними ударами та артилерійськими обстрілами, а також на оцінку рівнів пошкоджень будівель та сільськогосподарських земель у регіоні, який протягом багатьох років є зоною активного конфлікту.

Основними питаннями, які ставили перед собою автори, були: визначення впливу ракетних ударів на критичну інфраструктуру, аналіз змін у темпах пошкодження будівель під час різних періодів конфлікту, оцінка впливу ударів на житлові, освітні, медичні та культові об'єкти, визначення пропорцій пошкоджень будівель різного ступеня, а також вивчення впливу конфлікту на сільськогосподарські землі та можливі наслідки для продовольчої безпеки.

Для досягнення цих цілей дослідники використовували супутникові зображення з високим просторовим розрізненням, отримані з китайського супутника LuoJia3-01. Зображення, які

охоплювали період з 17 жовтня 2023 року по 2 березня 2024 року, дозволили створити детальні карти руйнувань у Секторі Газа. Було використано 40 супутникових знімків, кожен з яких охоплював площу 12×12 км. Для обробки та аналізу зображень було використано кілька методів.

Основним інструментом для виявлення пошкоджень був алгоритм глибокого навчання [6], який дозволяв автоматично виявляти воронки від ракетних ударів та пошкоджені будівлі. В алгоритмі була використана база даних, що включала супутникові зображення до і після військових дій, що дозволило моделі точно ідентифікувати рівні пошкоджень. Для автоматизованого виявлення пошкоджень будівель використовувалась сітка на основі глибинних нейронних мереж, яка включала елементи уваги для виявлення незначних відмінностей у рівнях пошкоджень. Було застосовано сіамську нейронну мережу, яка використовується для порівняння пар зображень і виявлення змін у них. Цей метод дозволив точно визначити тип пошкодження (знищене, сильно пошкоджене, помірно пошкоджене, незначно пошкоджене) для кожної будівлі.

Для оцінки впливу конфлікту на сільськогосподарські угіддя використовувалась методологія на основі класифікації земель за допомогою алгоритму випадкового лісу (Random Forest). Спочатку було обчислено індекс нормалізованої різниці між червоним і зеленим (Normalized Red-Green Difference Index, NRGDI) для виявлення змін у стані рослинності. Потім ці дані використовувались для тренування моделі, яка класифікувала землі на постраждалі та непостраждалі. Виявлення воронок від ракетних ударів здійснювалося за допомогою одноступеневої моделі на основі глибинного навчання. Виявлені воронки експортувались у форматі GeoJSON, що дозволило інтегрувати ці дані з платформою QGIS для проведення просторового аналізу. Модель була натренована на великій кількості прикладів воронок різних розмірів та форм, що підвищило її точність.

Результати досліджень свідчать про серйозні руйнування, спричинені конфліктом. Було виявлено 3747 воронок від ракетних ударів, що дозволило точно визначити місця розташування та розмір цих воронок, а також дати оцінку потенційним місцям знаходження нерозірваних боєприпасів. Найбільше постраждав Північний сектор Газа, де зафіксовано найбільшу кількість воронок. Це свідчить про високу інтенсивність бойових дій у цьому регіоні. Автори також зазначили, що після оголошення перемир'я 24 листопада 2023 року спостерігалось тимчасове

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

зменшення кількості вибухів, проте бойові дії поновилися з новою силою наприкінці грудня 2023 року.

Що стосується пошкоджень будівель, дослідження виявило, що станом на 2 березня 2024 року було пошкоджено або знищено 58,4% усіх будівель у Секторі Газа. Найбільші руйнування були зафіксовані в Північному секторі Газа та у місті Газа, де було пошкоджено 77,6% та 81,4% будівель відповідно. Загалом у регіоні було зруйновано 44 305 будівель, ще 53 975 зазнали серйозних пошкоджень, 34 020 – помірних, а 35 870 – незначних пошкоджень. Окрім житлових будинків, значні пошкодження отримали також лікарні, навчальні заклади, місця поклоніння та кладовища. Всього було пошкоджено 101 лікарню та медичний заклад, 283 місця поклоніння, включаючи мечеті та церкви, 295 навчальних закладів та 32 кладовища. Ці руйнування ускладнюють доступ населення до медичних послуг, освіти, релігійних обрядів та навіть поховань, що додатково загострює гуманітарну кризу в регіоні.

Ще одним важливим аспектом дослідження було вивчення змін у сільськогосподарських землях. Аналіз показав, що внаслідок конфлікту площа оброблюваних земель зменшилася на 34,1%, що еквівалентно 62,9 км² від загальної площі сільськогосподарських угідь у 184,7 км². Найбільші втрати були зафіксовані в Північному секторі Газа та у місті Газа, де скорочення площі сільськогосподарських угідь склало більше 45%. Це призвело до значного зниження місцевого виробництва сільськогосподарської продукції, що створює серйозну загрозу для продовольчої безпеки населення.

Однак у статті [6] також підкреслюються певні обмеження дослідження. Зокрема, автори відзначають, що супутникові дані не завжди дозволяють точно визначити тип боєприпасів або оцінити повний екологічний вплив від їх використання. Крім того, відсутність систематичних даних ускладнює проведення кількісного аналізу інтенсивності збройного насильства на глобальному рівні. Це підкреслює необхідність інтеграції супутникових даних з іншими джерелами інформації для більш повного аналізу ситуації.

У контексті майбутніх досліджень автори пропонують розширити аналіз на інші регіони, використовуючи додаткові джерела даних, такі як радіолокаційні супутникові зображення (SAR) та індекси забудови, що дозволить краще зрозуміти пошкодження як у міських, так і в сільських районах. Також дослідники підкреслюють важливість використання цих даних для

оцінки ефективності методів реконструкції та гуманітарної допомоги після конфлікту.

Загалом, стаття є важливим внеском у розуміння наслідків сучасних збройних конфліктів, використовуючи передові технології для детального аналізу руйнувань. Отримані результати можуть бути корисними як для наукової спільноти, так і для організацій, що займаються гуманітарною допомогою та реконструкцією в постконфліктних зонах.

Дослідження [7] присвячене виявленню та оцінці пошкоджень сільськогосподарських полів в Україні, спричинених російською агресією, з використанням класифікаційних підходів та супутникових зображень. Зокрема, авторка аналізує можливість застосування методів машинного та глибинного навчання для виявлення кратерів від снарядів на полях.

Наукові питання включають оцінку впливу війни на українські сільськогосподарські землі та визначення ефективності існуючих класифікаційних підходів для автоматизованого виявлення пошкоджень на основі супутникових даних.

Для дослідження було використано супутникові зображення Planet SkySat з високим просторовим розрізненням (0.5×0.5 м), зібрані з регіону Бахмута. Основна мета полягала в класифікації ділянок зображень (патчів) за наявністю або відсутністю пошкоджень від обстрілів.

Обробка даних включала попереднє оброблення зображень через методи розтягування гістограми (min-max stretch) для покращення видимості кратерів. Після цього великі супутникові зображення були розбиті на менші патчі розміром 128x128 пікселів, які далі використовувались для тренування моделей.

Для класифікації патчів застосовувались дві основні архітектури нейронних мереж: ResNet-50 та Vision Transformer (ViT).

Vision Transformer (ViT) (рис. 2) — це модель, яка використовує трансформери для класифікації зображень. Вона розбиває зображення на менші патчі та обробляє їх як послідовності, що дозволяє моделі вивчати як локальні, так і глобальні ознаки зображення. ViT Small Patch була вибрана як варіант, що працює з невеликими патчами розміром 16×6 пікселів, що підвищує здатність моделі розпізнавати тонкі деталі.

Алгоритм класифікації передбачав виконання кількох етапів, включаючи аугментацію даних для запобігання перенавчанню та збільшення різноманіття навчального набору. Зокрема, патчі зображень випадково повертались, віддзеркалювались по

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

горизонталі та вертикалі, а також нормалізувалися за середнім значенням і стандартним відхиленням. У процесі навчання також використовувалась техніка *upsampling* для збалансування кількості патчів з різних класів.

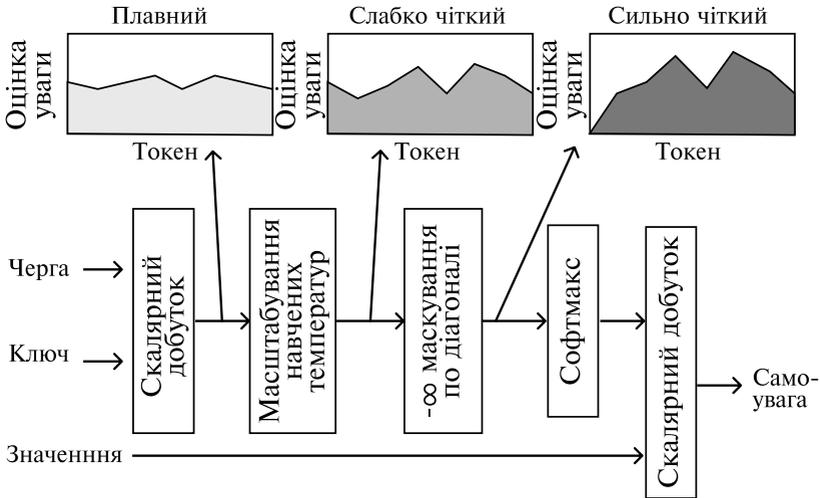
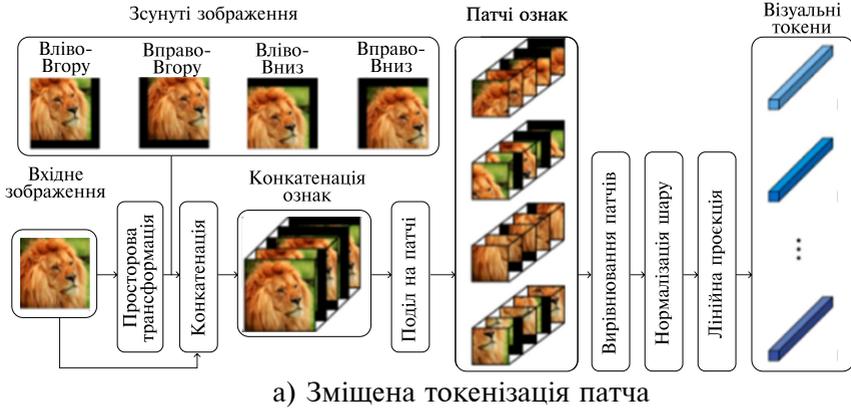


Рис. 2. ViT архітектура моделі [7]

Під час гіперпараметричного пошуку було протестовано кілька важливих параметрів, зокрема розмір батчу, нормалізація, швидкість навчання та використання попередньо натренованих

вагів. Наприклад, для моделі ResNet-50 критично важливими параметрами виявилися розмір батчу, значення weight decay та базовий розмір зображень. Для ViT Small Patch особливе значення мали dropout та weight decay, що впливали на регуляризацію моделі.

У результаті дослідження було виявлено, що обидві моделі демонструють високу ефективність у класифікації пошкоджених та непошкоджених ділянок сільськогосподарських полів. Найкраща модель ResNet-50 досягла значення AUROC 0.916 на валідаційному наборі, тоді як модель ViT Small Patch показала аналогічні результати з меншим розміром патчів. Проте, виявлено, що ефективність моделей може знижуватися через нерівномірний розподіл класів у тестовому наборі даних, а також через можливі відмінності в текстурі ґрунту та рельєфі.

У статті [8] проведено дослідження, яке аналізує пошкодження культурної спадщини Сирії внаслідок громадянської війни. Основна мета полягала в тому, щоб вивчити, як сучасні супутникові технології можуть допомогти у виявленні мародерства та руйнувань на археологічних об'єктах. Стаття ставить питання про поширеність та типи пошкоджень, які можна ідентифікувати за допомогою супутникових зображень, а також досліджує ефективність цього методу у моніторингу культурної спадщини під час війни.

Для збору даних використовувалися супутникові знімки високої роздільної здатності, зокрема знімки GeoEye та WorldView за 2012 та 2013 роки, що охоплюють 30 ключових археологічних об'єктів у Сирії. Додатково аналізувались вільно доступні супутникові зображення з Google Earth і Bing Maps. Команда дослідників вручну порівняла новіші зображення з довоєнними, щоб виявити сліди мародерства, зруйнованих об'єктів, будівництва військових гарнізонів та інших пошкоджень. Особлива увага приділялась аналізу за допомогою бази даних археологічних об'єктів Сирії, яка містить інформацію про понад 15 тисяч об'єктів, що допомогло ідентифікувати масштаби пошкоджень.

Проведений аналіз виявив значне поширення пошкоджень археологічних об'єктів по всій Сирії, при цьому основними причинами виявились мародерство та військові дії. У процесі аналізу було виявлено кілька типів пошкоджень: мародерські ями, що зазвичай мають діаметр до 3 метрів; знищення археологічних шарів через будівництво військових гарнізонів, траншей та доріг; а також шкоду від артилерійських обстрілів. При цьому супутникові знімки також дозволяли ідентифікувати пошкодження

на археологічних об'єктах, які були розташовані в місцях активних бойових дій. Методологія дозволила дослідникам не тільки виявити масштаби пошкоджень, а й проаналізувати географічні та хронологічні закономірності мародерства.

Запропонована методологія є потужним інструментом для моніторингу руйнувань і мародерства. На відміну від більш суб'єктивних джерел, таких як журналістські звіти або свідчення очевидців, супутникові дані дозволяють незалежно та точно виявляти масштаби пошкоджень, особливо в умовах обмеженого доступу до цих територій для археологів.

Однак, виявлені також певні обмеження використання супутникових зображень. Однією з головних проблем є те, що супутникові знімки не завжди можуть показати пошкодження на окремих архітектурних спорудах або в густо заселених районах, де вони можуть бути приховані під сучасними будівлями. Ще одним обмеженням є відсутність постійних оновлень супутникових даних, що ускладнює відстеження динаміки пошкоджень у реальному часі. Більше того, без можливості провести наземну перевірку отриманих даних залишається ймовірність неточності оцінок, які базуються виключно на дистанційних спостереженнях земної поверхні.

В статті [9] аналізуються пошкодження будівель у місті Ракка під час громадянської війни в Сирії на основі радарних супутникових зображень. Це дослідження важливе для оцінки руйнувань під час бойових дій, а також для розуміння потенціалу використання супутникових даних для гуманітарних цілей.

Основною метою дослідження є виявлення та оцінка змін у міських структурах Ракки через бойові дії за допомогою часових рядів зображень, отриманих від радарного супутника Sentinel-1. Супутникові знімки мають високе часове просторове розрізнення, що дозволяє проводити моніторинг змін протягом тривалого часу. Автор використовує метод аналізу постійних розсіювачів (PS) для виявлення стабільних точок на знімках, що дозволяє відслідковувати зміни в інтенсивності радарного відображення, пов'язані з руйнуванням будівель. Для валідації результатів автор порівнює отримані дані із мануальними оцінками пошкоджень, зробленими програмою ООН UNOSAT, яка базувалася на зображеннях високого просторового розрізнення (VHR). Також детально аналізуються пошкодження за певний період, що охоплює зображення, отримані в 2014-2017 роках. Протягом цього часу місто Ракка було місцем інтенсивних бойових дій та авіаударів, особливо у 2017 році під час битви за місто. Автор

виділяє кілька ключових місць, таких як Велика мечеть Ракки, стадіон та міст через Євфрат, для глибшого аналізу. За допомогою методу PS було виявлено значні пошкодження на цих об'єктах. Наприклад, Велика мечеть зазнала руйнувань у липні 2017 року, що співпадає з часом другої битви за Ракку.

Однак, автор зазначає, що цей метод має певні обмеження. Зокрема, супутникові зображення не дозволяють виявляти пошкодження середнього або низького рівня, такі як тріщини в стінах або часткові руйнування дахів, оскільки такі зміни незначно впливають на амплітуду відображеного сигналу. Крім того, метод не дозволяє ідентифікувати зміни, які не пов'язані зі структурними пошкодженнями, наприклад зміни кольору через пожежі або осідання ґрунту.

Важливим аспектом дослідження є порівняння результатів, отриманих за допомогою радарних знімків, з даними UNOSAT. Хоча між ними є певна кореляція, радарні дані дозволили виявити лише частину пошкоджень, особливо тяжких руйнувань. За оцінками на основі даних Sentinel-1 було зафіксовано близько 2900 випадків руйнування, тоді як дані UNOSAT повідомляють про понад 11 000 пошкоджених об'єктів. Це свідчить про те, що радарні знімки, надані супутником Sentinel-1, є надійним індикатором серйозних пошкоджень, але не є достатніми для точного виявлення менш помітних руйнувань.

Автор також обговорює можливості покращення точності аналізу пошкоджень шляхом комбінування оптичних та радарних зображень. Такий підхід вже використовувався у дослідженнях землетрусів та зсувів і може бути застосований у майбутніх дослідженнях руйнувань під час конфліктів. У висновках наголошується на необхідності подальшого розвитку SAR технологій для гуманітарних операцій та покращення часової роздільної здатності супутникових місій, що дозволить забезпечити оперативну відповідь у надзвичайних ситуаціях.

Стаття [10] також присвячена аналізу руйнувань у містах під час конфліктів за допомогою супутникових знімків. Основною метою дослідження є розробка нової схеми виявлення пошкоджень у міських зонах, яка б базувалася на часових рядах даних і дозволяла б підвищити точність і швидкість оцінки масштабів руйнувань. Автори застосували нову методику, названу «Temporal-Knowledge-Guided Detection Scheme» (TKDS), в поєднанні з моделлю «Pixel-based Transformer Network» (PtNet) для аналізу міських руйнувань на прикладах сирійської громадянської війни та російсько-української війни. Дослідження демонструє

1.3. Аналіз методів та моделей комп'ютерного зору та глибоких ...

ефективність цієї технології в автоматичному виявленні пошкоджених будівель і критичної інфраструктури.

Важливою частиною дослідження є порівняння точності нової моделі TKDS-PtNet з існуючими методами (рис. 3).

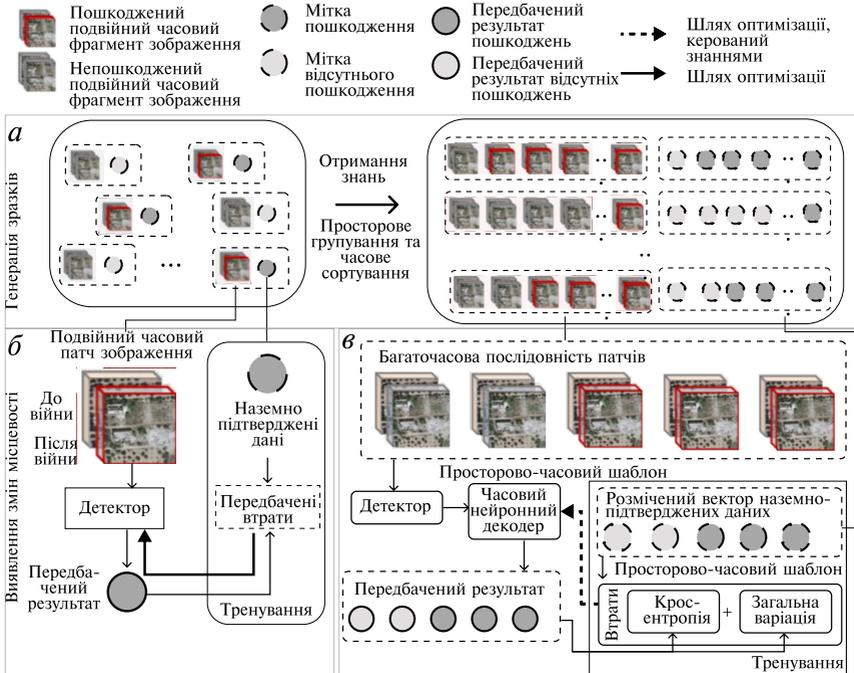


Рис. 3. Порівняння моделі TKDS-PtNet з існуючими методами (а – генерація патчів зображення , б – розповсюджені методи виявлення руйнувань, в – запропонована нова схема) [10]

Виявилось, що запропонована модель дозволяє значно покращити показники ідентифікації руйнувань, зокрема, на 44% у сирійських містах і на 34% в українських містах у порівнянні з попередніми методами. Ці показники були отримані шляхом аналізу супутникових зображень з просторовим розрізненням 0,5 м та 10 м. TKDS-PtNet дозволила виявити не тільки руйнування житлових будівель, але й оцінити вплив пошкоджень на критичну інфраструктуру, таку як лікарні та школи. У сирійських містах, таких як Алеппо, Хомс і Дейр-ез-Зор, було ідентифіковано значну кількість пошкоджених будівель, а в

Маріуполі виявлено значні руйнування індустріальних зон, таких як Азовсталь.

Однією з ключових проблем, яку вирішує ця технологія, є дисбаланс класів, оскільки зруйновані будівлі становлять лише незначну частину від усіх міських структур, що значно ускладнює автоматичне розпізнавання. Технологія TKDS включає знання про те, що під час війни зруйновані будівлі рідко відновлюються, що дозволяє моделі краще прогнозувати руйнування на основі часових рядів зображень. Це суттєво покращує точність оцінки руйнувань у конфліктних зонах.

Автори дослідження [10] зазначили високу ефективність TKDS-PtNet при використанні супутникових зображень середнього просторового розрізнення (10 м), доступних для громадськості, що робить технологію особливо корисною для моніторингу в реальному часі в умовах війни. Це дозволяє отримувати дані про пошкодження навіть в тих випадках, коли високоточні зображення недоступні через конфіденційність або інші обмеження.

Окрім оцінки масштабів руйнувань, модель також допомагає оцінити вплив цих руйнувань на населення та міську інфраструктуру. Наприклад, в сирійських містах приблизно 116 800–158 600 людей проживали в зонах пошкоджень, що могло призвести до серйозних наслідків для системи охорони здоров'я та освіти. У Маріуполі було виявлено значні пошкодження житлових будівель та індустріальних об'єктів, зокрема в районах Азовсталі, що могло мати серйозний вплив на місцеву економіку та населення.

Окрім переваг, автори також зазначають про деякі обмеження, такі як неможливість точної ідентифікації частково пошкоджених будівель та необхідність додаткової верифікації результатів для забезпечення максимальної точності. Однак, запропонована модель значно покращує можливості автоматизованого моніторингу міських руйнувань під час війни і може бути використана для подальших досліджень і оцінок впливу конфліктів на міські території.

Стаття [11] присвячена використанню глибокого навчання для виявлення руйнувань, спричинених війною, на основі високоякісних супутникових знімків. Автори використовують модель U-Net для семантичної сегментації, але пропонують її покращену версію під назвою «Hybrid U-Net», що забезпечує точніше виявлення руйнувань завдяки кращій обробці багатомасштабних ознак.

Основна мета дослідження полягає у побудові системи, яка дозволяє автоматично виявляти зони руйнувань без потреби в попередніх знімках місцевості. Для цього було зібрано датасет із супутникових зображень зруйнованих районів Сирії, де кожен піксель позначено вручну для точного навчання моделі. Знімки містять дані з чотирьох міст, які зазнали значних пошкоджень під час громадянської війни.

Застосована модель U-Net, завдяки своїй симетричній структурі та використанню багаторівневих пропускових з'єднань, дозволяє ефективно працювати з невеликими датасетами. Однак стандартний варіант моделі не використовує всю інформацію, доступну на різних масштабах зображення, що обмежує її точність при виявленні невеликих об'єктів чи складних структур. Щоб виправити це, автори розробили нову архітектуру Hybrid U-Net яка дозволяє зберігати симетрію мережі та інтегрує глибокі і дрібні ознаки з декількох рівнів.

В процесі проведення експериментів було продемонстровано, що Hybrid U-Net суттєво перевершує інші моделі, зокрема базову U-Net та її варіанти, такі як MACU-Net і U-Net++. Показники точності моделі значно покращились: середній індекс збігу (IoU) зріс на 7%, а коефіцієнт Dice — на 8% порівняно зі стандартною U-Net. Крім того, модель показала високу ефективність навіть на зображеннях з низьким рівнем руйнувань.

Основна перевага Hybrid U-Net полягає в її здатності розпізнавати зони руйнувань різного масштабу з точністю до окремих пікселів. Це дозволяє виявляти як великі руйнування інфраструктури, так і дрібні пошкодження, зберігаючи при цьому чіткість меж зруйнованих і незруйнованих територій. Модель також добре справляється з різними типами супутникових зображень, що робить її універсальним інструментом для аналізу даних у контексті війни.

Автори статті [11] також провели порівняльний аналіз різних методів семантичної сегментації. Виявилось, що Swin-Unet, що використовує трансформерні блоки для сегментації, є найкращою альтернативою серед існуючих моделей, проте Hybrid U-Net перевершує його за всіма основними метриками. Зокрема, точність Hybrid U-Net у відновленні контурів пошкоджених будівель є значно вищою, що робить її найефективнішою моделлю серед розглянутих.

Таким чином, авторами дослідження [11] була продемонстрована важливість поєднання багаторівневих ознак для досягнення більшої точності в задачах сегментації зображень,

особливо у контексті виявлення військових руйнувань. Модель Hybrid U-Net, запропонована авторами, може стати основою для розробки нових технологій моніторингу пошкоджень інфраструктури під час конфліктів.

У статті [12] описуються різноманітні супутникові методи, які були використані для аналізу змін у промисловій діяльності, викидах забруднювачів і впливу бойових дій на територію України. Дослідження покладається на синергію кількох супутникових платформ для збору даних про атмосферні забруднювачі, теплові аномалії та пожежі, що дозволило зробити оцінки, незважаючи на обмеженість наземних вимірювань через військові дії.

Основним методом вимірювання забруднення повітря було використання даних із супутника Copernicus Sentinel-5 Precursor та його інструмента TROPospheric Monitoring Instrument (TROPOMI). Цей інструмент дозволяє проводити щоденні глобальні вимірювання тропосферного двоокису азоту (NO_2) з просторовим розрізненням 3,5x5,5 км. NO_2 є короткоживучим газом у нижній атмосфері, що робить його ідеальним індикатором для вивчення змін у викидах, пов'язаних з промисловою та транспортною діяльністю, оскільки його концентрації є високими поблизу джерел викидів. TROPOMI вимірює випромінювання у видимому та ультрафіолетовому діапазонах, що дозволяє оцінити кількість NO_2 у тропосфері.

Для оцінки викидів вуглекислого газу (CO_2) використовувалися дані із супутника NASA Orbiting Carbon Observatory-2 (OCO-2). OCO-2 вимірює середню молярну частку CO_2 у стовпі сухого повітря (XCO_2), що дозволяє оцінити зниження використання викопного палива в регіонах, які зазнали найбільших економічних і соціальних потрясінь через війну. CO_2 є триваложивучим газом, що накопичується в атмосфері, тому для відокремлення антропогенних джерел від природних процесів використовувалися аномалії XCO_2 відносно середніх значень по широтах. Ці аномалії допомагають виявляти відхилення, викликані змінами у викидах внаслідок скорочення промислової діяльності та війни.

Ще одним важливим методом було використання даних про теплові аномалії та пожежі, які фіксувалися за допомогою Visible Infrared Imaging Radiometer Suite (VIIRS), що працює на борту супутника Suomi-NPP. Цей інструмент знімає зображення в середньому та тепловому інфрачервоному діапазоні з роздільною здатністю 375 метрів, що дозволяє точно визначати місця вогнищ. Завдяки VIIRS, автори дослідження виявили аномальні вогнища

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

уздовж лінії фронту, що, ймовірно, пов'язані з артилерійськими обстрілами, підпалами будівель та іншими військовими діями, на відміну від типових пожеж, пов'язаних з сільськогосподарською діяльністю.

Для візуалізації змін на місцевості та підтвердження теплових аномалій також використовувалися зображення із супутника Sentinel-2, який забезпечує високоякісні багатоспектральні знімки з просторовою роздільною здатністю 10 м, 20 м та 60 м для різних спектральних каналів. Це дозволило створити детальні карти теплових аномалій у промислових зонах та біля лінії фронту. Наприклад, у районі Маріуполя в 2021 році зображення Sentinel-2 показували аномалії через роботу металургійних заводів, але після початку війни ці теплові сигнали зникли, що свідчить про припинення промислової діяльності через бойові дії.

Крім того, для аналізу змін рівнів NO₂ упродовж тривалішого періоду, починаючи з 2015 року, використовували дані інструмента Ozone Monitoring Instrument (OMI) на борту супутника NASA Aura. OMI має подібний принцип вимірювання, але нижче просторове розрізнення, що дозволяє фіксувати загальні тенденції зміни рівнів NO₂ з моменту запуску супутника у 2005 році. Це дало можливість порівняти сучасні дані з рівнями NO₂ до пандемії COVID-19 та війни.

Дослідники також застосували різні методи обробки даних для аналізу змін у концентраціях NO₂. Для цього створювалися карти середніх рівнів NO₂ за період із березня по серпень для кожного року (2019–2022), які дозволили виявити постійні зниження концентрацій та їх географічний розподіл. Окрім загальних даних, було проведено аналіз за умови спокійних вітрових умов (швидкість вітру менше 3 м/с), що дозволило точніше оцінити локальні викиди в районах без значного переносу забруднюючих речовин.

Сукупність цих методів і використаних супутникових інструментів дозволила авторам детально вивчити вплив війни на економічну діяльність і довкілля України.

Дослідження [13] аналізує наслідки бойових дій у зоні АТО на екосистеми та окремі види тварин, зокрема рідкісних змії із Червоної книги України — *Elaphe dione* та *Nierophis caspius*. Основна увага приділяється впливу пожеж, спричинених воєнними діями, на природні та сільськогосподарські території. У ході дослідження було використано кілька методів збору та аналізу даних. Серед них — дистанційне зондування Землі за допомогою супутникової системи Terra MODIS, яка дозволила ідентифікувати

місця пожеж за тепловими каналами супутника. Дані MODIS автоматично фіксували осередки займання з точністю до одного квадратного кілометра, що дозволило отримати картину масштабів пожеж на природних територіях.

Доповненням до цього були знімки з супутника Landsat 8, які використовували для верифікації результатів та уточнення локалізації пожеж на різних типах ландшафтів. Щоб оцінити пошкодження біотопів, дослідники застосовували ГІС-моделювання. Воно допомогло побудувати просторові моделі поширення пожеж, а також оцінити площі знищених лісових і степових територій. Застосовані інструменти дозволили аналізувати дані з високою точністю та прогнозувати можливі наслідки для рідкісних видів тварин, які населяють ці території. Наприклад, за допомогою програмного забезпечення DIVA GIS та 19 біокліматичних параметрів було змодельовано ймовірні місця перебування змій до початку бойових дій.

Статистичний аналіз був проведений за допомогою дисперсійного аналізу ANOVA та *t*-тесту, що дало можливість визначити значущі відмінності у частотності пожеж між різними роками, місяцями та типами ландшафтів. Було створено загальну лінійну модель (GLM), яка показала, що в 2014 році кількість пожеж значно зросла порівняно з попередніми роками, що підтверджується статистично значущими результатами ($p < 0.0001$).

Значна частина даних щодо змій *Elaphe dione* та *Hierophis caspius* була зібрана під час польових досліджень до початку бойових дій, що дозволило скласти картину їхнього поширення у Луганській та Донецькій областях. На основі цих даних було виявлено, що понад 50% біотопів, придатних для цих видів змій, знаходяться в зоні АТО або поблизу неї. Це підвищує ризик локального зникнення цих видів через масштабні пожежі та механічні руйнування природних середовищ існування.

Комбінація даних дистанційного зондування, ГІС-моделювання та статистичного аналізу дозволила авторам оцінити вплив бойових дій на біорізноманіття регіону. Понад 81% усіх пожеж відбулися на природних територіях, зокрема лісах і степах, що призвело до втрати 18% лісових масивів та 23% степових екосистем. Це підтверджує значний негативний вплив бойових дій на природні екосистеми Східної України.

Дослідження вказує на масштабні втрати природних ресурсів, а також потенційні довготривалі наслідки для регіональних екосистем і біорізноманіття, зокрема для рідкісних видів змій. Подальший моніторинг та заходи з відновлення пошкоджених

екосистем будуть необхідні для мінімізації негативних наслідків війни.

В [14] автори також зосередилися на моніторингу пожеж, які виникли внаслідок бойових дій в Україні, використовуючи супутникові дані. Запропонована методика виявлення великих і небезпечних пожеж шляхом аналізу теплових аномалій. Підхід [14] був унікальним, оскільки дозволяв розрізняти пожежі, спричинені військовими діями, від тих, що виникли через економічну діяльність або необережність. Це стало важливим інструментом для аналізу впливу війни на екологічну ситуацію.

Автори [15] показали, що супутникові дані MODIS, Landsat-8,9 і Sentinel-2 надають надійну інформацію для моніторингу пожеж, спричинених військовими конфліктами в Україні. Була розроблена методологія оцінки індексу пожежонебезпечного потенціалу (FPI), реалізована в хмарній платформі Google Earth Engine (GEE). Це дозволило автоматизувати виявлення військових пожеж, спрощуючи їхнє відстеження в реальному часі та полегшуючи аналіз наслідків для навколишнього середовища.

В [16] методи дистанційного зондування використані для моніторингу лісових пожеж у Луганській та Донецькій областях, спричинених конфліктом у Східній Україні впродовж 2006–2022 рр. Застосовуючи зображення MODIS та Sentinel-2, були оцінені масштаби вигорілих площ біля лінії фронту та виявлено, що найбільше постраждали луки та сільськогосподарські угіддя. Особливо активно пожежі виникали поблизу зон активних військових дій, а пожежі біля міських об'єктів були частими протягом усього періоду конфлікту.

В статті [17] проаналізовано навмисні підпали на сільськогосподарських угіддях Іраку та північно-східної Сирії, спричинені Ісламською державою у 2019-2020 рр. Використовуючи супутникові дані MODIS, Landsat-8 і Sentinel-2, було виявлено, що більшість пожеж були спричинені навмисними підпалами, які відображали зміну тактики ІДІЛ від прямого насильства до економічного саботажу. Ці дії мали на меті послабити економіку регіону, спалюючи сільськогосподарські культури та створюючи довготривалі екологічні й економічні наслідки.

Особливу увагу вчених привертає вплив наслідків війни на зміну землекористування та сільськогосподарську діяльність, оскільки конфлікти часто призводять до втрати оброблюваних земель та зниження сільськогосподарського виробництва. В [18] досліджені наслідки війни в Боснії та Герцеговині,

використовуючи супутникові зображення Landsat TM для ідентифікації покинутих сільськогосподарських угідь. За допомогою методів виявлення змін та контрольованої класифікації ідентифіковано значне скорочення оброблюваних площ у післявоєнний період.

Авторами дослідження [19] було розроблено методологію аналізу просторово-часових змін у сільськогосподарських угіддях під впливом українсько-російської війни (рис. 4).

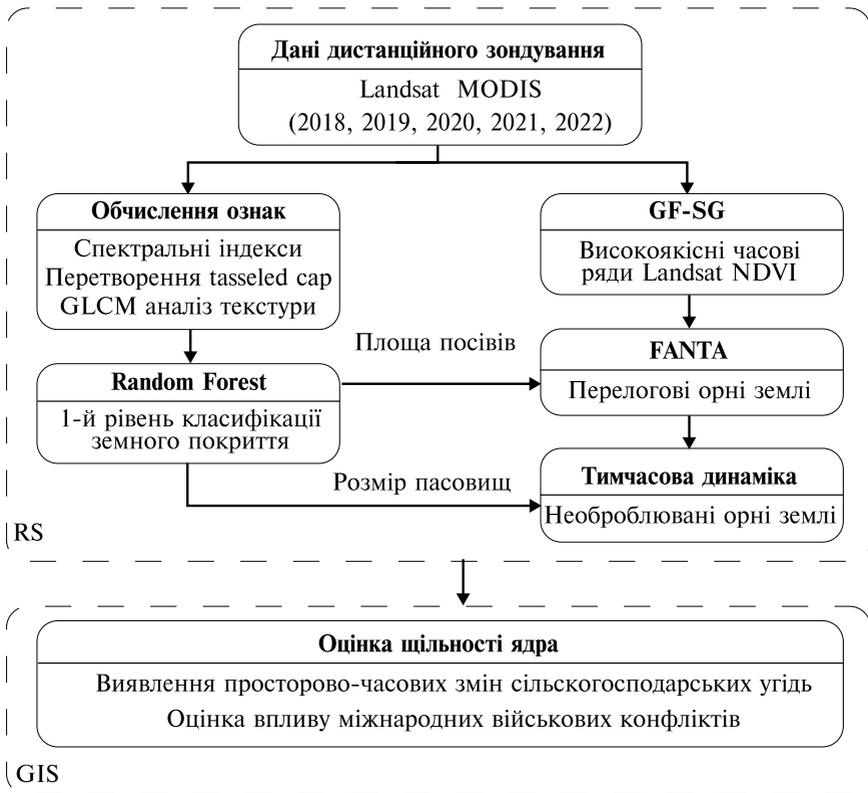


Рис. 4. Методологія картографування сільськогосподарських угідь з аналізом просторово-часових змін сільськогосподарських угідь та оцінка наслідків війни [19]

Одним із ключових використаних методів є алгоритм випадкових лісів (Random Forest, RF), який застосовано для

класифікації типів земного покриву. Це метод машинного навчання, який використовує численні деревоподібні моделі для обробки супутникових даних і побудови точних карт землекористування. Алгоритм базується на аналізі багатьох спектральних індексів, таких як NDVI (нормалізований диференційний вегетаційний індекс), MNDWI (індекс водного середовища), NDBI (індекс забудованих територій) і BSI (індекс оголених ґрунтів). Важливим аспектом методу є застосування текстурних характеристик зображень, таких як яскравість, зелена складова та вологість. Це дозволяє отримати детальні карти різних типів земного покриву, включаючи рілля, лісові масиви, водні об'єкти та забудовані території.

Для покращення якості даних використовувався метод інтерполяції NDVI, зокрема технологія заповнення прогалін та фільтрування Савітського-Голея (*англ.* gap filling and Savitzky-Golay filtering (GF-SG)). Цей метод дозволяє обробляти супутникові зображення, заповнюючи прогаліни, що виникають через хмарність або інші перешкоди під час зйомки. Використовуючи дані приладу MODIS, метод GF-SG дозволяє створити більш точні часові ряди NDVI, що забезпечує якісні дані для подальшого аналізу. Він дозволяє отримати дані з просторовим розрізненням 30 м, що є критичним для дослідження великих площ сільськогосподарських угідь.

Також важливу роль у дослідженні відіграє алгоритм FANTA (Fallow-land Algorithm based on Neighborhood and Temporal Anomalies). Цей метод використовується для виявлення земель, які перебувають у стані пара, або не використовуються. Алгоритм FANTA дозволяє проаналізувати просторові аномалії в рослинному покриві на основі часових рядів NDVI. Він не потребує даних польових спостережень і дозволяє точно визначати закинуті або незасіяні землі на основі змін у показниках вегетації протягом певного періоду часу. Такий підхід є особливо корисним у зонах конфлікту, де доступ до польових даних обмежений або неможливий.

Ще одним використаним в [19] методом є аналіз щільності ядра (kernel density estimation), який застосовано для просторового аналізу розподілу закинутих або занедбаних земель. Цей метод дозволяє побудувати карти щільності, на яких видно «гарячі точки» — місця з найбільшою концентрацією покинутих сільськогосподарських угідь. Карти ядерної щільності є візуально зрозумілими інструментами для виявлення регіонів, що

потребують більшої уваги у відновленні сільськогосподарського виробництва.

Таким чином, використовуючи дані Landsat та платформу GEE, автори [19] виявили значне зростання покинутих орних земель з 2018 по 2022 рік, що свідчить про негативний вплив війни на сільське господарство України. Проведений аналіз показав, що військові дії призвели до значного скорочення оброблюваних площ, що впливає на продовольчу безпеку країни.

В [20] досліджується вплив військового конфлікту на сільськогосподарські землі Донецької та Луганської областей України, використовуючи супутникові дані. Основна мета цього дослідження полягала у кількісному аналізі змін у використанні сільськогосподарських земель через конфлікт, що триває з 2014 року, і який має значні соціально-економічні наслідки для регіону.

У дослідженні [20] було використано супутникові зображення Landsat-7, Landsat-8 та Sentinel-2 для 2013 року (до початку конфлікту) та 2018 рік (під час конфлікту). За допомогою багатозарового перцептрона (MLP) ці зображення були класифіковані на сільськогосподарські угіддя та не сільськогосподарські землі, після чого була побудована карта змін землекористування. Були виділені чотири категорії змін: стабільні не сільськогосподарські землі, стабільні сільськогосподарські угіддя, приріст сільськогосподарських угідь і їх втрати.

У подальших дослідженнях, наприклад в статті [21], автори оцінювали природоохоронні території (смарагдова мережа — Emerald Network) на окупованих територіях Східної України. Було виявлено, що 25% лісового покриву було втрачено внаслідок бойових дій, що означає перелом у 20-річному прогресі сталого розвитку в регіоні. В [21] було також зазначено, що війна суттєво вплинула на виробництво соняшнику, зміну ґрунтового покриву та землекористування.

Стаття [22] присвячена аналізу впливу війни в регіоні Тиграй (Ефіопія) на сільськогосподарські угіддя з використанням супутникових даних. Основна мета дослідження полягала в оцінці змін обсягів культивування земель до та під час військового конфлікту, що тривав з листопада 2020 року до листопада 2022 року. Через труднощі доступу до наземних даних внаслідок конфлікту, використанням супутникових зображень стало важливим джерелом інформації для аналізу змін у землекористуванні та забезпечення продовольчої безпеки.

Для дослідження використовувалися супутникові знімки та методи машинного навчання для класифікації змін у

культивованих площах. У статті застосована архітектура довготривалої пам'яті (LSTM), яка дозволила створити карти сільськогосподарських угідь за 2020 (до війни) та 2021 роки (під час війни). Для аналізу використовувалися дані супутників Sentinel-1, Sentinel-2 та Shuttle Radar Topographic Mission (SRTM), що дозволило оцінити зміни площ сільськогосподарських земель, а також побудувати карти змін для визначення стабільних, нових та втрачених земель.

Щодо моніторингу впливу війни на сільськогосподарські ділянки, вчені зосереджуються не лише на виявленні пожеж та покинутих земель, але й на розпізнаванні кратерів від обстрілів та місцезнаходження нерозірваних боєприпасів. Такі дослідження є критично важливими для регіонів, що постраждали від тривалих збройних конфліктів, оскільки вони допомагають ідентифікувати небезпечні ділянки для подальшого очищення та оцінити вплив військових дій на землю, що є необхідним для безпечного повернення до використання цих територій у сільському господарстві.

В дисертаційному дослідженні [23] розглянуті методи виявлення мінних полів у Зімбабве, замінованих протягом 1974-1980 рр., за допомогою супутникових даних. Використовуючи часові ряди супутникових знімків і комбінуючи різні методи дистанційного зондування, були ідентифіковані ключові індикатори, пов'язані з мінними полями, навіть за умов використання даних нижчого просторового розрізнення. Ці індикатори стали важливою частиною протимінної діяльності, допомагаючи локалізувати небезпечні ділянки для подальшого розмінування.

Питання розробки методів автоматичного виявлення бомбових кратерів на територіях, які зазнали авіаударів під час Другої світової війни, розглянуто в [24]. Тут порівняно три підходи для автоматизованої ідентифікації кратерів, використовуючи моделі цифрового рельєфу, отримані за допомогою LiDAR. Ці методи включають алгоритми, які спочатку застосовувалися для виявлення позаземних кратерів (наприклад, на Місяці), геоморфологічні методи виділення країв і технології розпізнавання зображень на основі сучасної нейронної мережі (Mask R-CNN). Дослідження проводилося на восьми пілотних ділянках у північно-західній Чехії, які постраждали від бомбардувань під час Другої світової війни.

Основною методологією в [24] є порівняння результатів трьох різних підходів до автоматизованого виявлення кратерів. Перша

методика включала використання вже існуючих алгоритмів для виявлення позаземних кратерів. Друга ґрунтувалася на геоморфометричному аналізі рельєфу, що дозволяло виділяти контури кратерів. Третя методика використовувала нейронну мережу Mask R-CNN для ідентифікації кратерів за допомогою навчання моделі на даних з точними розмірами кратерів. Для дослідження використовувалися LiDAR-дані з високим просторовим розрізненням (0.2–2 м), що дозволило отримати детальні цифрові моделі рельєфу.

Отримані результати показали, що метод на основі нейронної мережі Mask R-CNN виявився найбільш ефективним серед трьох підходів. Цей метод забезпечив найбільшу точність у виявленні кратерів, особливо при використанні просторового розрізнення 0.5 м, яке виявилось найкращим для точного розпізнавання кратерів. Інші методи, такі як алгоритми для позаземних кратерів і методи виділення країв, показали значно гірші результати через високу кількість помилкових спрацювань та низьку чутливість до менших або розмитих кратерів, які часто трапляються на Землі через ерозію або вплив рослинності.

В [25] розглядається методика автоматичного виявлення кратерів від засобів ураження на основі супутникових зображень з дуже високим просторовим розрізненням (VHR). Основна мета дослідження полягає в оцінці щільності нерозірваних боєприпасів (UXO) на сільськогосподарських полях Камбоджі, які були забруднені вибуховими речовинами під час В'єтнамської війни. Традиційні методи очищення земель є небезпечними та трудомісткими, тому використання сучасних методів дистанційного зондування розглядається як альтернатива, здатна знизити ризики та підвищити ефективність виявлення UXO.

В [25] використано двоетапна система виявлення кратерів (рис. 5), яка заснована на машинному навчанні та статистичних методах аналізу зображень. На першому етапі застосовувався статистичний класифікатор, який поєднував гістограму орієнтованих градієнтів (HOG) і спектральну інформацію для початкового розпізнавання кратерів.

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

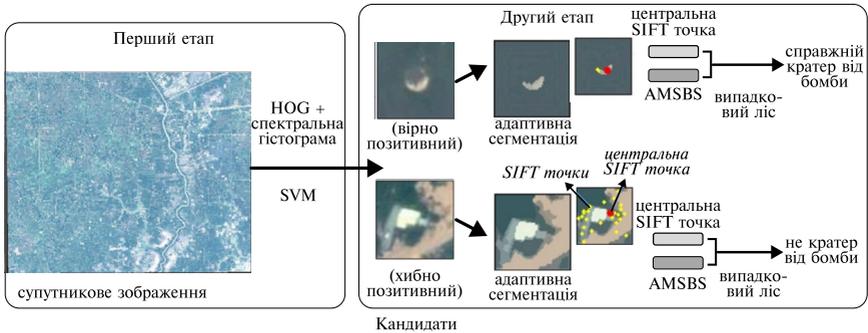


Рис. 5. Двоетапна система виявлення кратерів [25]

Цей підхід дозволив виявити потенційні кратери, однак виникла проблема з великою кількістю хибних позитивних результатів через схожість кратерів із природними та штучними об'єктами, такими як ставки або дерева.

Другий етап передбачав вдосконалення результатів за допомогою нових методів класифікації, які використовували просторові ознаки об'єктів і текстурні дескриптори SIFT. Було розроблено спеціальний дескриптор, заснований на адаптивному сегментуванні за методом середньозміщення, який допомагав відокремити кратери від інших об'єктів. Після цього використовувався алгоритм класифікації Random Forest, який дозволяв відділити істинні кратери від хибних позитивних об'єктів.

В [25] використовувалися супутникові зображення WorldView-2, що охоплюють територію Камбоджі площею 100 км². Використовувалися різні спектральні діапазони (близький інфрачервоний, червоний, зелений та синій канали) для підвищення точності розпізнавання об'єктів. Отримані результати свідчать про те, що запропонований метод збільшив виявлення істинних кратерів на 160% порівняно з традиційними алгоритмами розпізнавання об'єктів, такими як згорткові нейронні мережі (CNN). Крім того, цей підхід дозволив оцінити, що від 44% до 50% бомб у цьому регіоні можуть залишатися нерозірваними.

Дослідження [25] має велике значення для постконфліктних регіонів, оскільки дозволяє не лише оцінити кількість нерозірваних боєприпасів, але й ідентифікувати райони, які потребують пріоритетного розмінування. Автоматизація процесу виявлення кратерів за допомогою супутникових знімків може значно знизити витрати на очищення земель, а також зменшити ризики для місцевих жителів і працівників розмінування.

В [26] досліджено питання автоматизованого виявлення бомбових кратерів часів В'єтнамської війни за допомогою машинного навчання та декласифікованих супутникових знімків КН-9. Основною метою дослідження є покращення методів ідентифікації кратерів для підвищення точності виявлення небезпечних зон, забруднених нерозірваними боєприпасами (УХО), що є актуальною проблемою для В'єтнаму, Лаосу та Камбоджі.

У дослідженні використовувалися зображення, зняті супутниками КН-9 у 1972-1973 рр., для двох регіонів Південно-Східної Азії: провінції Куангчі та трикордонної зони (межі В'єтнаму, Лаосу та Камбоджі). Супутникові зображення були оброблені за допомогою NASA Ames Stereo Pipeline для створення ортографічних карт з просторовим розрізненням 1 м. Для формування навчальної вибірки були вручну розмінені кратери на частині зображень. Це дозволило провести навчання нейронної мережі U-Net для подальшого автоматичного виявлення кратерів. Моделі використовувалися для семантичної сегментації зображень та оцінки точності виявлення кратерів на основі їх розмірів та форми.

Ця робота демонструє потенціал використання декласифікованих супутникових даних для підвищення точності виявлення зон ризику УХО. Хоча модель працює з обмеженнями, такими як ерозія кратерів та покриття рослинністю, її застосування може сприяти підвищенню ефективності операцій з розмінування в постконфліктних регіонах.

В [27] запропоновані методи автоматизованого виявлення артилерійських кратерів за допомогою супутникових знімків високого просторового розрізнення та глибинного навчання. Основна мета дослідження полягала у побудові точних карт кратерів, які з'явилися під час конфлікту на сході України у 2014 році, які можуть бути корисними при проведенні робіт з розмінування, оцінці шкоди для сільськогосподарських земель та подальшого екологічного відновлення регіону.

Для дослідження використовувалися знімки супутника WorldView-2 з просторовим розрізненням 0,5 м за вересень 2014 року. Основними інструментами для автоматизованого виявлення кратерів стали дві моделі: нейронна мережа U-Net та базовий класифікатор на основі алгоритму Random Forest. Модель U-Net, спеціально розроблена для сегментації зображень, використовувалась для виявлення та картографування кратерів. Інформація про кратери була отримана шляхом ручного

маркування супутникових зображень, що дозволило налаштувати модель для подальшої автоматичної ідентифікації.

Результати аналізу пошкодження ґрунтового покриву внаслідок військових дій у Київській територіальній громаді Чернігівської області під час російсько-української війни наведено в [28]. Основна мета дослідження полягала у кількісній оцінці шкоди, завданої ґрунтам у цьому регіоні, використовуючи дані спостереження земної поверхні, на основі супутникових знімків високого просторового розрізнення. Авторами було використано супутникові дані Махаг для оцінки кількості воронок від вибухів і обсягу переміщеного ґрунту. Було ідентифіковано 4914 воронок на території громади, з яких 2912 були в межах орних земель. Діаметр воронок варіювався від 0,5 до 13,8 метрів. На основі морфометричних параметрів воронок було оцінено ймовірний калібр снарядів і обсяг переміщеного ґрунту, який склав 3136 м³. Автори пропонують виділити дві основні зони навколо воронок: зону бомбтурбації та зону забруднення. У зоні бомбтурбації ґрунт зазнав значних фізичних змін, таких як переміщення, ущільнення та забруднення, тоді як у зоні забруднення ґрунти переважно не постраждали фізично, але зазнали хімічного забруднення вибуховими речовинами та уламками боєприпасів.

Для оцінки обсягів забруднення ґрунтів також було враховано ризики вертикальної та горизонтальної міграції важких металів, таких як свинець, кадмій, мідь і цинк, які можуть проникати в глибші шари ґрунту та забруднювати підземні води. Загальна площа зони бомбтурбації становить 44,3 га, а зони забруднення – 386,9 га. Автори також виявили ознаки ущільнення ґрунтів через маневри військової техніки, що може призвести до зниження продуктивності сільськогосподарських земель до 50%.

На відміну від попередніх досліджень в [29] проведено оцінку постраждалих площ внаслідок повномасштабного вторгнення Росії в Україну не лише для окремої території, але для всієї України впродовж 2022-2023 рр. Для цього використовувався інтегрований підхід, що поєднував супутникові дані, статистичні індикатори та методи машинного навчання для автоматичного виявлення пошкоджень сільськогосподарських угідь (рис. 6).

Основними джерелами даних стали зображення супутника Sentinel-2, які містять спектральні смуги з просторовим розрізненням 10 м. Ці дані забезпечують регулярне оновлення інформації про стан сільськогосподарських полів, що є критично важливим у контексті війни, коли поля можуть бути пошкоджені або знищені через бойові дії.

Для аналізу було обрано червоний, зелений, синій та ближній інфрачервоний спектральні канали, які дозволяють найбільш точно оцінити зміни у стані рослинності та ґрунтів. Одним із ключових інструментів, що використовувався у дослідженні, був індекс NDVI (Normalized Difference Vegetation Index), який вимірює інтенсивність рослинного покриття та його стан, а також індекс GCI (Green Chlorophyll Index), що допомагає визначити вміст хлорофілу в рослинах. Оскільки бойові дії можуть призводити до пошкоджень рослинного покриття або ґрунту, аналіз змін цих індексів дозволяв ідентифікувати аномалії, що вказують на військові пошкодження.

Методологія аналізу включала кілька етапів. Спершу вручну були ідентифіковані пошкоджені поля для створення навчальної та тестової вибірки. Експерти проводили візуальну інтерпретацію супутникових зображень для кожного з 22 двотижневих періодів, які охоплюють 2022 рік. Для мінімізації ризику помилок кожне поле оцінювалось трьома експертами, і лише ті поля, щодо яких усі експерти зробили один висновок, були відмічені як пошкоджені. Цей підхід допоміг забезпечити достовірність навчальних даних.

Для автоматизованого виявлення пошкоджених полів використано алгоритм Random Forest [29]. Алгоритм був налаштований на класифікацію полів на пошкоджені та непошкоджені, базуючись на статистичних характеристиках спектральних каналів та індексів рослинності, таких як середні, мінімальні, максимальні значення і дисперсії кожної з цих змінних для поля. Модель навчалась на наборі даних за 2021 рік до початку військових дій і за 2022 рік, що дозволило навчити її розрізняти звичайні сезонні зміни від аномалій, спричинених військовими діями. Для кожного періоду створювалась окрема модель, враховуючи можливі зміни у рослинному покритті.

Після класифікації полів модель також використовувалась для виявлення пошкоджених областей всередині полів. Для цього проводилась сегментація спектральних каналів і індексів рослинності. На полях з розвинутою рослинністю (значення NDVI більше 0,65) особливо ефективним для виявлення пошкоджень виявився індекс GCI у поєднанні зі спектральними каналами B2 (синій) та B3 (зелений). Для полів зі слабо розвинутою рослинністю використовувались комбінації індексів NDVI та GCI разом з аналізом спектральних смуг для ідентифікації різних типів пошкоджень, таких як воронки від вибухів або сліди від військової техніки.

1.3. Аналіз методів та моделей комп'ютерного зору та глибинних ...

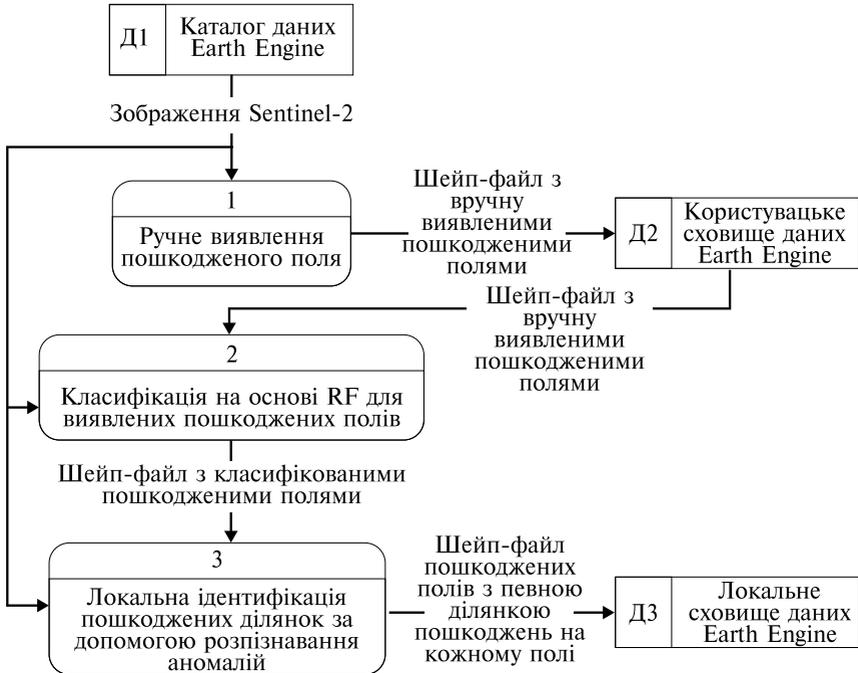


Рис. 6. Процес визначення пошкоджень [29]

Для точнішого виявлення пошкоджених пікселів в [29] були застосовані порогові значення, що ґрунтуються на відхиленнях спектральних показників пікселів від середнього значення в межах поля. Також застосовувалась сегментація індексів рослинності шляхом фільтрації зображень із використанням ковзаючого вікна, що дозволяло виявляти аномалії у вигляді відхилень від фільтрованих даних.

Ця методика дозволила не тільки точно виявляти пошкоджені поля, а й деталізувати різні види пошкоджень на їх поверхні. Сегментація аномалій у комбінації з багаточасовими статистичними індикаторами, отриманими з супутникових даних, забезпечила високу точність моделі, з середньою оцінкою F1 близько 0,87, що підтвердило ефективність запропонованого підходу.

Війна завдає значної шкоди не лише міській інфраструктурі та сільськогосподарським угіддям, але також серйозно впливає на водні об'єкти, які є життєво важливими для екосистем і населення.

Дослідження, що базуються на супутникових спостереженнях, дозволяють оцінити масштаби цих наслідків, надаючи інформацію для прийняття рішень щодо відновлення та захисту водних ресурсів.

Автори статті [30] провели детальний моніторинг затоплень річок Ірпінь і Дніпро після руйнувань водопропускних споруд. Зокрема, досліджувалося затоплення заплави річки Ірпінь водами Київського водосховища та річки Дніпро поблизу села Отрадокам'янка після вибуху на Каховській ГЕС. Для аналізу використано супутникові зображення Sentinel-2 та індекси SAVI (індекс регульованої різниці рослинності) і NDWI (індекс вологості води), що дозволило визначити зміни площ водно-заболочених територій.

У своїй комплексній праці, [31] автори вивчали наслідки руйнування Каховської дамби, яка спричинила масштабні повені вздовж річки Дніпро. Вони використовували дані з різних супутникових платформ для моніторингу змін гідрологічного режиму, які вплинули як на природні екосистеми, так і на сільськогосподарські території.

В [32] наведено результати аналізу впливу російсько-української війни на річки та водні системи України, зокрема Дніпро та його водосховища. Основна мета дослідження полягала в оцінці наслідків для водних ресурсів та інфраструктури, зокрема внаслідок руйнування Каховської дамби в червні 2023 р. Для проведення досліджень використано супутникові дані, звіти з місця подій та інші офіційні джерела для аналізу як прямих, так і непрямих впливів війни на населення, сільське господарство, водопостачання та екосистеми.

Основним методологічним підходом [32] є використання супутникових знімків (Sentinel-1, Sentinel-2, Landsat 8 та 9) для моніторингу змін рівня води та стану водосховищ. Також використано дані з гідрологічних станцій по вимірюванню рівня води в річках і водосховищах. Автори зазначають, що через складність доступу до окупованих територій, основним джерелом інформації стали супутникові дані та повідомлення місцевих ЗМІ.

В статті [33] проведено аналіз руйнувань Каховського водосховища, викликане російськими збройними силами, та досліджено його екологічні наслідки. Особлива увага приділялася затопленню сіл і забрудненню вод у нижній течії Дніпра та північно-західній частині Чорного моря. Вчені оцінили бактеріологічне та хімічне забруднення води та його вплив на якість питної води та рибальство в регіоні. Також були оцінені

сценарії розвитку екологічної ситуації на постраждалих територіях у найближчій перспективі.

ВИСНОВКИ

Зміни у кліматі, антропогенні дії, природні катастрофи та військові конфлікти роблять моніторинг стану земної поверхні все більш важливим завданням для вчених, екологів, урядів та міжнародних організацій. Традиційні методи оцінки стану навколишнього середовища, такі як польові дослідження та візуальний огляд, вимагають багато часу, людських ресурсів та є небезпечними, або навіть неможливими, у зонах конфліктів або катастроф. Однак із розвитком інформаційних технологій та сучасних підходів математичного моделювання з'явилися нові можливості для автоматизації цього процесу завдяки використанню методів комп'ютерного зору та глибинних нейронних мереж для аналізу пошкоджень земної поверхні.

Методи комп'ютерного зору та глибинного навчання є одними з найефективніших інструментів для моніторингу змін на земній поверхні. Завдяки автоматизації процесу аналізу зображень і можливості ефективного обробки великих обсягів даних, ці технології стали ключовими у розв'язанні завдань екологічного моніторингу. Для навчання глибоких нейронних мереж використовуються великі масиви супутникових та аерофотознімків, що дозволяє розпізнавати складні патерни на земній поверхні.

Однією з основних переваг цих методів є їх здатність працювати з великими обсягами інформації, що дозволяє оперативно отримувати точну інформацію про масштаби пошкоджень після катастроф, природних катаклізмів або військових конфліктів. Наприклад, під час лісової пожежі алгоритми комп'ютерного зору можуть швидко ідентифікувати згорілі території та оцінювати ступінь пошкоджень. У сільському господарстві ці технології дозволяють ідентифікувати проблемні ділянки, постраждалі від шкідників чи хвороб, що дозволяє приймати оперативні рішення для мінімізації втрат врожаю.

Методи комп'ютерного зору та глибокі нейронні мережі особливо ефективні для моніторингу природних катастроф, таких як землетруси, повені, урагани та лісові пожежі. Ці технології дозволяють автоматично ідентифікувати масштаб і зони руйнувань, що стає основою для швидкої оцінки ситуації та

прийняття відповідних рішень щодо відновлення постраждалих територій. Наприклад, методи комп'ютерного зору можуть оцінювати руйнування лісів після пожежі та розробляти стратегії для відновлення ресурсів.

Також ці технології застосовуються для оцінки наслідків військових конфліктів. В умовах війни звичайні методи моніторингу стають небезпечними, тому комп'ютерний зір забезпечує безпечне та точне виявлення пошкоджень, дозволяє в автоматичному режимі оцінювати масштаби руйнувань на основі супутникових знімків.

Методи комп'ютерного зору також можуть використовуватись для прогнозування змін у земній поверхні, що є особливо важливим у контексті кліматичних змін та на постконфліктних територіях. Це відкриває нові можливості для адаптації до кліматичних викликів та розробки стратегій для зменшення негативних наслідків.

Важливою сферою застосування комп'ютерного зору є сільське господарство. Забруднення ґрунтів, ерозія та інші негативні процеси можуть призводити до значних втрат урожаю, що впливає на продовольчу безпеку. Використання супутникових даних дозволяє ідентифікувати проблемні ділянки сільськогосподарських угідь та приймати відповідні рішення для покращення ситуації.

Швидка урбанізація також створює виклики для моніторингу змін земної поверхні. Зростання міст призводить до знищення природних зон, змін ландшафтів і тиску на екосистеми. Методи комп'ютерного зору дозволяють аналізувати стан інфраструктури, виявляти екологічно небезпечні зони та прогнозувати зміни урбанізованих територій.

ПЕРЕЛІК ПОСИЛАНЬ

1. M. R. Devesa and A. V. Brust, "Mapping illegal waste dumping sites with neural-network classification of satellite imagery," Oct. 2021, doi: 10.48550/arxiv.2110.08599.
2. Sharma, K., & Sood, M. (2024). Monitoring, classification and analysis of waste disposal sites using machine learning. *Procedia Computer Science*, 235, 1558-1567. <https://doi.org/10.1016/j.procs.2024.04.147>.

3. Сорренті, С. (2023). Detection of Illegal Landfills using Deep Learning: A Weakly Supervised Approach (Магістерська дисертація, Політехнічний університет Мілана).

4. Torres, R.N.; Fraternali, P. Learning to Identify Illegal Landfills through Scene Classification in Aerial Images. *Remote Sens.* **2021**, *13*, 4520. <https://doi.org/10.3390/rs13224520>.

5. Pushkarenko, Y., & Zaslavskiy, V. (2024). Research on the state of areas in Ukraine affected by military actions based on remote sensing data and deep learning architectures. *Radioelectronic and Computer Systems*, 2(110), 5-18. <https://doi.org/10.32620/reks.2024.2.01>.

6. Holail, S., Saleh, T., Xiao, X., Xiao, J., Xia, G.-S., Shao, Z., Wang, M., Gong, J., & Li, D. (2024). Time-series satellite remote sensing reveals gradually increasing war damage in the Gaza Strip. *National Science Review*. <https://doi.org/10.1093/nsr/nwae304>.

7. Митнюк, С. (2023). Identifying the Effects of Russian Aggression on Agricultural Fields in Ukraine through Classification Approaches and Satellite Imagery (Bachelor Thesis). Український Католицький Університет, Львів.

8. Casana, J., & Panahipour, M. (2014). Satellite-Based monitoring of looting and damage to archaeological sites in Syria. *Journal of Eastern Mediterranean Archaeology & Heritage Studies*, 2(2), 128–151. <https://doi.org/10.5325/jeasmedarcherstu.2.2.0128>.

9. Braun, A. (2018). Assessment of Building Damage in Raqqa during the Syrian Civil War Using Time-Series of Radar Satellite Imagery. *GI_Forum*, 1, 228–242. https://doi.org/10.1553/giscience2018_01_s228.

10. Hou, Z., Qu, Y., Zhang, L., Liu, J., Wang, F., Yu, Q., Zeng, A., Chen, Z., Zhao, Y., Tang, H., Wang, Y., Li, X., Li, Y., Peng, S., Ran, J., Yao, X., Meng, X., Liu, S., & Zhou, C. (2024). War city profiles drawn from satellite images. *Nature Cities*, 1(5), 359–369. <https://doi.org/10.1038/s44284-024-00060-6>.

11. Nabiee, S., Harding, M., Hersh, J., & Bagherzadeh, N. (2022). Hybrid U-Net: Semantic segmentation of high-resolution satellite images to detect war destruction. *Machine Learning With Applications*, 9, 100381. <https://doi.org/10.1016/j.mlwa.2022.100381>.

12. Ialongo, I., Bun, R., Hakkarainen, J., Virta, H., & Oda, T. (2023). Satellites capture socioeconomic disruptions during the 2022 full-scale war in Ukraine. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-42118-w>.

13. Vasyliuk, O., V., Nekrasova, O. D., Shyriaieva, D., V., & Kolomytsev, G. O. (2015). A review of Major impact factors of hostilities influencing biodiversity in the Eastern Ukraine (Modeled on selected animal Species). http://www.irbis-nbuv.gov.ua/cgi-bin/irbis_nbuv/cgiirbis_64.exe?I21DBN=LINK&P21DBN=UJRN&Z21ID=&S21REF=10&S21CNR=20&S21STN=1&S21FMT=ASP_meta&C21COM=S&2_S21P03=FILA=&2_S21STR=vzl_2015_49_2_8.

14. Oreshchenko, A., & Osadchyi, V. (2024). Using satellite data to monitor fires, including those caused by hostilities on the territory of Ukraine. In *Studies in systems, decision and control* (pp. 315–335). https://doi.org/10.1007/978-3-031-66764-0_16.

15. Yailymov, B., Yailymova, H., Shelestov, A., and Shumilo, L., "Monitoring of Fires Caused by War in Ukraine Based on Satellite Data," 2023 13th International Conference on Dependable Systems, Services and Technologies (DESSERT), Athens, Greece, 2023, pp. 1-5, doi: 10.1109/DESSERT61349.2023.10416520.

16. Rodriguez-Jimenez, F., Novo, A., & Hall, J. V. (2024). Influence of wildfires on the conflict (2006–2022) in eastern Ukraine using remote sensing techniques (MODIS and Sentinel-2 images). *Remote Sensing Applications Society and Environment*, 35, 101240. <https://doi.org/10.1016/j.rsase.2024.101240>.

17. Jaafar, H., Sujud, L., & Woertz, E. (2022). Scorched earth tactics of the “Islamic State” after its loss of territory: intentional burning of farmland in Iraq and Syria. *Regional Environmental Change*, 22(4). <https://doi.org/10.1007/s10113-022-01976-2>.

18. Witmer, F. D., & O’Loughlin, J. (2013). Satellite data methods and application in the evaluation of war outcomes: Abandoned agricultural land in Bosnia-Herzegovina after the 1992–1995 conflict. In *Geographies of Peace and Armed Conflict* (pp. 216–227). Routledge.

19. Ma, Y., Lyu, D., Sun, K., Li, S., Zhu, B., Zhao, R., Zheng, M., & Song, K. (2022). Spatiotemporal analysis and war impact

assessment of agricultural land in Ukraine using RS and GIS technology. *Land*, 11(10), 1810. <https://doi.org/10.3390/land11101810>.

20. Skakun, S., Justice, C. O., Kussul, N., Shelestov, A., & Lavreniuk, M. (2019). Satellite data reveal cropland losses in South-Eastern Ukraine under military conflict. *Frontiers in Earth Science*, 7. <https://doi.org/10.3389/feart.2019.00305>.

21. Skakun, S., Abys, C., Adegbenro, M., Becker-Reshef, I., Duncan, E., Eun, J., ... & Prishchepov, A. (2022, December). High-Impact Hot Spots of Land Cover Land Use Change in Ukraine. In *2022 12th International Conference on Dependable Systems, Services and Technologies (DESSERT)* (pp. 1-5). IEEE.

22. Kerner, H. R., Nakalembe, C., Yeh, B., Zvonkov, I., Skakun, S., Becker-Reshef, I., & McNally, A. (2024). Satellite data shows resilience of Tigrayan farmers in crop cultivation during civil war. *Science of Remote Sensing*, 100140. <https://doi.org/10.1016/j.srs.2024.100140>.

23. Maathuis, B. (2001). *Remote sensing based detection of landmine suspect areas and minefields* (Doctoral dissertation, Staats-und Universitätsbibliothek Hamburg Carl von Ossietzky).

24. Dolejš, M., Pacina, J., Veselá, M., & Brütt, D. (2020). Aerial Bombing crater identification: exploitation of precise digital terrain models. *ISPRS International Journal of Geo-Information*, 9(12), 713. <https://doi.org/10.3390/ijgi9120713>.

25. Lin, E., Qin, R., Edgerton, J., & Kong, D. (2020). Crater detection from commercial satellite imagery to estimate unexploded ordnance in Cambodian agricultural land. *PLoS ONE*, 15(3), e0229826. <https://doi.org/10.1371/journal.pone.0229826>

26. Barthelme, P., Darbyshire, E., Spracklen, D. V., & Watmough, G. R. (2024). Detecting Vietnam War bomb craters in declassified historical KH-9 satellite imagery. *Science of Remote Sensing*, 10, 100143. <https://doi.org/10.1016/j.srs.2024.100143>.

27. Duncan, E. C., Skakun, S., Kariryaa, A., & Prishchepov, A. V. (2023). Detection and mapping of artillery craters with very high spatial resolution satellite imagery and deep learning. *Science of Remote Sensing*, 7, 100092. <https://doi.org/10.1016/j.srs.2023.100092>.

28. Bonchkovskiy, O. S., Ostapenko, P. O., Shvaiko, V. M., & Bonchkovskiy, A. S. (2023). Remote sensing as a key tool for assessing war-induced damage to soil cover in Ukraine (the case study of Kyivska territorial hromada). *Journal of Geology Geography and Geoecology*, 32(3), 474–487. <https://doi.org/10.15421/112342>.

29. Kussul, N., Drozd, S., Yailymova, H., Shelestov, A., Lemoine, G., & Deininger, K. (2023). Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103562. <https://doi.org/10.1016/j.jag.2023.103562>.

30. Vlasova, O. V., Shevchenko, A. M., Shevchenko, I. A., & Kozytsky, O. M. (2023). MONITORING OF WATER BODIES AND RECLAIMED LANDS AFFECTED BY WARFARE USING SATELLITE DATA. *Міжвідомчий Тематичний Науковий Збірник Меліорація І Водне Господарство*, 2, 59–68. <https://doi.org/10.31073/mivg202302-371>.

31. Xu, H., Barbot, S., & Wang, T. (2024). Remote sensing through the fog of war: Infrastructure damage and environmental change during the Russian-Ukrainian conflict revealed by open-access data. *Natural Hazards Research*. <https://doi.org/10.1016/j.nhres.2024.01.006>.

32. Gleick, P., Vyshnevskiy, V., & Shevchuk, S. (2023). Rivers and water systems as weapons and casualties of the Russia-Ukraine war. *Earth S Future*, 11(10). <https://doi.org/10.1029/2023ef003910>

33. Vyshnevskiy, V., Shevchuk, S., Komorin, V., Oleynik, Y., & Gleick, P. (2023). The destruction of the Kakhovka dam and its consequences. *Water International*, 48(5), 631–647. <https://doi.org/10.1080/02508060.2023.2247679>.

МЕТОДИ КОМП'ЮТЕРНОГО ЗОРУ І ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ СУПУТНИКОВОГО ІНТЕЛЕКТУ

1. МЕТОД ВИЯВЛЕННЯ АНОМАЛІЙ В ДАНИХ НАВЧАННЯ МОДЕЛЕЙ КОМП'ЮТЕРНОГО ЗОРУ НА ОСНОВІ МЕТОДІВ КЛАСТЕРИЗАЦІЇ

Антон Охріменко, аспірант
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

antoh-ipt21@iit.kpi.ua

ВСТУП

Якість та продуктивність моделей машинного навчання значною мірою залежать від розміру вибірки та якості навчальних даних. У загальному випадку, чим більше даних, тим кращою буде модель. Але якість навчальних даних також важлива, оскільки не можна просто дублювати дані чи постійно відбирати їх із того самого джерела. Дані мають бути різноманітними, щоб охопити якомога більший об'єм у просторі ознак. З огляду на задачу класифікації набір даних має бути роздільним, наприклад, повинні існувати граничні поверхні, які чітко відокремлюють точки даних, які належать до різних класів. В ідеальному випадку такі поверхні мають бути достатньо гладкими для уникнення перенавчання моделі. В цьому випадку дані утворюють певні кластери, кожен з яких містить екземпляри даних лише одного класу.

Проблема перекриття класів унеможливує побудову чітких та однозначних граничних поверхонь [1]. Як наслідок, дані не можуть бути розділені на окремі кластери, а значить, частину даних не можна чітко розрізнити між собою у просторі ознак. Крім того, в просторі ознак існують деякі підпростори, які містять суміш точок різних класів без будь-якої структури.

При наявності вказаної проблеми важливими є наступні питання. Чи підходить даний набір даних для розв'язання даної задачі класифікації? Чи потрібно удосконалити процес збору даних? Як досягти найкращого можливого результату, використовуючи даний набір даних, якщо проблему з накладанням класів не вдалося виправити?

Для глибокого розуміння проблеми розглянемо причини виникнення проблеми «перекриття» класів в просторі ознак. Ця ситуація може бути спричинена похибками в процесі збору даних та/або їх розмітки, або недостатньою інформативністю ознак. В останньому випадку додавання нових ознак, що еквівалентно додаванню додаткових вимірів до простору ознак, може значно покращити придатність даних для розв'язання поставленої задачі. В той же час, збільшення розмірності простору ознак, в свою чергу, може призводити до перенавчання моделі. Як наслідок, дослідникам потрібен алгоритм для визначення недоліків датасетів, тобто виявлення частки неоднозначних даних і підпросторів із такими даними у навчальному та тестовому наборі даних. Результати роботи алгоритму можна використати для прийняти рішення щодо модифікації процесу збору даних, додавання нових ознак або збільшення кількості і точності екземплярів даних у «сумнівних» підпросторах і навколо них.

Найбільш простим методом дослідження датасету є його візуалізація у двовимірному просторі. Датасети з великим числом ознак неможливо візуалізувати без додаткових перетворень. У цьому випадку для відображення даних з простору з великою розмірністю у простір з меншою розмірністю можна використовувати такі алгоритми, як PCA [2] та tSNE [3], та нанести отриманий результат на двовимірний графік. До недоліків цих методів відноситься залежність від суб'єктивності дослідника та нездатність ефективної візуалізації та аналізу даних великої розмірності через великі втрати інформації в процесі перетворення.

Однак у більшості випадків дослідник не може вплинути на процес збору даних і змушений працювати з даними, в яких наявна проблема перекриття класів. У цьому випадку йому також

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

потрібен алгоритм, який дозволить оцінити потенційну точність класифікації на заданому наборі даних і визначити ненадійні екземпляри даних для корекції процесу навчання моделі.

Визначені на попередніх кроках «сумнівні» підпростори в просторі ознак можуть бути використані для корекції результатів (передбачень) моделі. Для прикладу, для екземплярів даних, що потрапляють у ненадійну частину простору ознак, можна використовувати інші правила та навіть інші моделі.

Для задачі класифікації зображень визначення неоднозначних екземплярів даних стає особливо важливим. Як правило, згортова нейронна мережа (CNN) [4] простір зображень відображає у простір ознак. Таким чином вхідне зображення перетворюється на вектор ознак. Остаточна класифікація виконується саме на базі цього одновимірного вектору. Виявлення неоднозначних екземплярів даних у просторі ознак є важливою науковою задачею, розв'язання якої дозволяє покращити якість розпізнавання зображень з використанням CNN. Варто зауважити, що вищевказане перетворення у простір ознак не детерміноване, а роздільність класів залежить не лише від якості даних, а також від якості роботи згорткових шарів нейронної мережі.

На тему проблеми перекриття класів у датасетах проведено численні дослідження [5-13]. У даному розділі запропоновано новий метод виявлення неоднозначних екземплярів даних на основі метода К найближчих сусідів (KNN – K Nearest Neighbors) [14], продемонстровано його роботу на супутникових даних (багатоспектральних оптичних знімках) в задачі класифікації сільськогосподарських культур та розглянуто можливі варіанти використання даного алгоритму під час розробки моделей машинного навчання [15].

1.1. ПОСТАНОВКА ЗАДАЧІ

Дві можливі проблеми, які можуть виникнути під час розв'язання задачі класифікації, — це перекриття класів і викиди (рис. 1). Проблема викидів полягає у наявності серед множини екземплярів класу поодиноких представників з нехарактерними ознаками. В просторі ознак такі поодинокі екземпляри потрапляють у підпростір, де розташовані «типові» представники іншого класу (рис. 1-а). Вона характеризується наявністю в просторі ознак областей, де рівномірно представлені декілька класів. З цими проблемами часто стикаються фахівці при розробці

моделей машинного навчання на геопросторових і, зокрема, супутникових даних. В даному розділі запропоновано алгоритм, який дозволяє розв'язати обидві задачі одночасно, виявляючи неоднозначні та ненадійні дані в датасеті. Неоднозначними або ненадійними будемо вважати складні для розпізнавання екземпляри даних, які будь-яка класифікаційна модель з високою ймовірністю не зможе правильно розпізнати. Пошук таких ненадійних екземплярів даних у датасеті може стати важливим допоміжним інструментом для дослідника протягом усього циклу розробки моделі машинного навчання.

В якості набору даних, який досліджувався, розглянуто навчальну вибірку для задачі класифікації земного покриву, використану для побудови нейромережевої задачі класифікації в [16]. До її складу входять дані оптичного супутника Sentinel-2 з просторовим розрізненням 10 м для Київської області. Для уникнення проблеми хмарності, в даному дослідженні використовується композит, отриманий з супутникових знімків Київської області Sentinel-2 впродовж липня 2021 року. Даний композит має 4 канали: синій (490 нм), зелений (560 нм), червоний (665 нм) та інфрачервоний (842 нм).

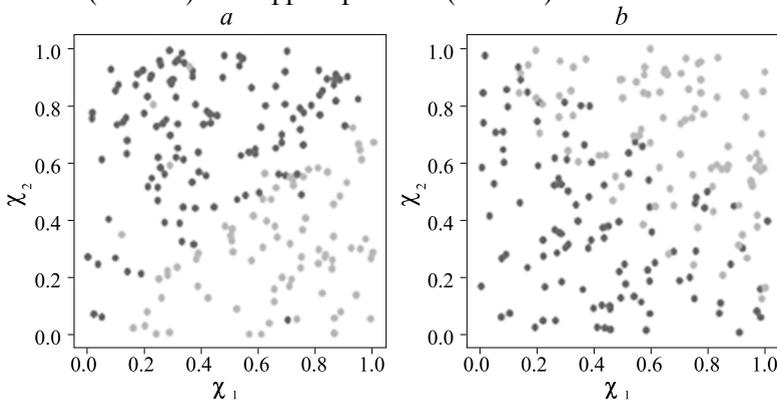


Рис. 1. Проблема викидів (а) та проблема перекриття класів (б).

Фрагмент 3-канального зображення композиту для Київської області в палітрі true color, яка включає канали 490, 560 та 665 нм, показано на рис. 2-а. Цей композит використовувався для побудови карти класифікації земного покриву з використанням згорткової нейромережевої моделі, розробленої Інститутом космічних досліджень НАНУ-ДКАУ [17], [18]. Приклад фрагменту карти класифікації показаний на рис. 2-б.

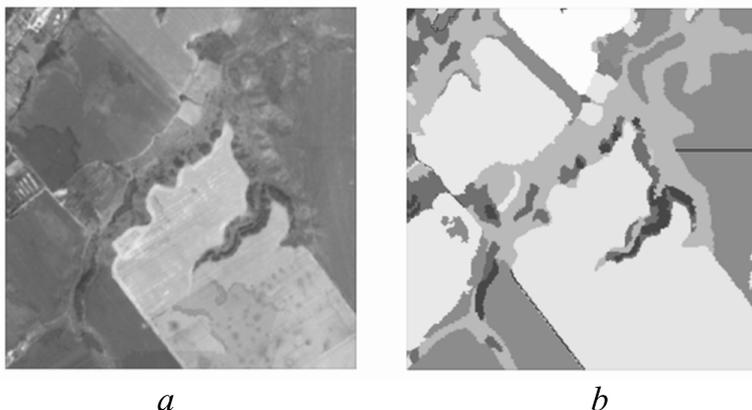


Рис. 2. Фрагмент 3-канального супутникового зображення (а) та відповідної карти класифікації земного покриття (б)

У даному розділі розглядається задача попиксельної класифікації [19, 20], що зводить дану проблему до задачі класифікації на декілька класів за чотирма ознаками. Для формування навчального датасету виберемо 8 класів сільськогосподарських культур, при цьому інші культури віднесено до окремого класу “Інші культури”. Класи, які не відносяться до сільськогосподарських культур, були відкинута, наприклад забудовлі чи водні об’єкти.

Для зменшення об’єму досліджуваного набору даних з обраних 8 класів випадковим чином виберемо 25 000 відповідних йому пікселів на супутниковому композиті. Якщо певний клас включає меншу кількість пікселів, для проведення експерименту будуть використані всі наявні пікселі.

На рис. 3 наведено візуальне представлення отриманого датасету. Для візуалізації чотиривимірних даних на площині розмірність даних була понижена до двовимірної за допомогою алгоритмів PCA та tSNE.

Отриманий датасет містить 9 класів та має проблему перекриття класів. Для візуалізації ми використовуємо редуковані двовимірні дані. Слід зазначити, що всі обчислення запропонованого алгоритму виконано на повних чотиривимірних даних, а сам алгоритм здатний працювати з даними будь-якої розмірності. Запропонований метод визначення неоднозначних даних описано в наступному підрозділі.

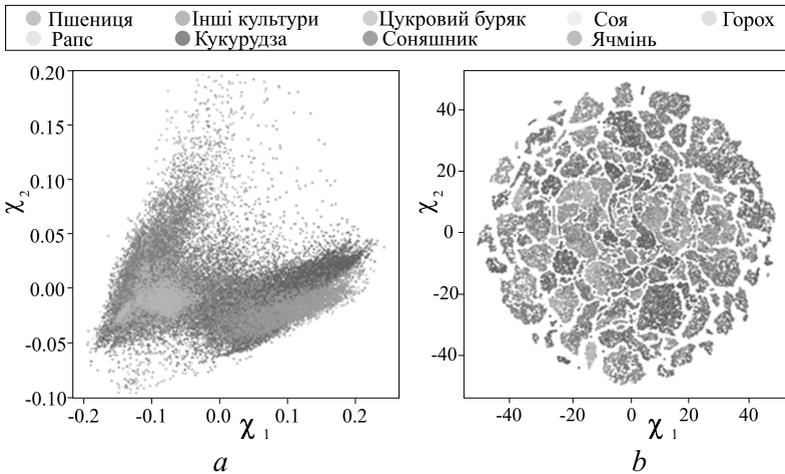


Рис. 3. Візуалізація датасету за допомогою PCA (a) та tSNE (b)

1.2. РОЗВ'ЯЗАННЯ ЗАДАЧІ

Нехай \hat{X} — множина екземплярів даних, а $\vec{x}_i \in \hat{X}$ — i -й екземпляр даних з цієї множини. Аналогічно \hat{Y} — множина міток класів, до яких можуть належати екземпляри даних \vec{x}_i , і $y_i = \hat{Y}$ — істинний клас для екземпляра даних \vec{x}_i .

Потрібно відповісти на питання: чи можливо деякий екземпляр даних \vec{x}_i правильно класифікувати як клас y_i . Для цього буде використано ансамбль класифікаторів KNN з різними номерами сусідів $n = [0, 1, \dots, N]$, $n \in \mathbb{N}$. Для кожного $\vec{x}_i \in \hat{X}$ буде отримано вектор \vec{m}_i , де елемент m_i^j — це результат класифікації \vec{x}_i за допомогою класифікатора KNN з параметром числа сусідів рівним j , який було навчено за допомогою набору даних $\hat{X} \setminus \vec{x}_i$.

$$\vec{m}_i : m_i^j = KNN(\vec{x}_i, j, \hat{X} \setminus \vec{x}_i). \quad (1)$$

Таким чином, кожен екземпляр даних \vec{x}_i матиме відповідний йому вектор \vec{m}_i та з цих векторів можна побудувати матрицю M :

$$M : M_i^j = m_i^j. \quad (2)$$

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

Тепер кожний вектор \vec{m}_i можемо порівняти з істинним класом y_i . Розглянемо декілька можливих випадків: більшість елементів \vec{m}_i відповідають справжньому класу y_i ; перші елементи \vec{m}_i відповідають справжньому класу y_i , решта — ні; більшість елементів \vec{m}_i не відповідають справжньому класу y_i ; передбачений клас m_i^j постійно змінюється в залежності від j , відбуваються “стрибки між класами”.

Будемо вважати, що для того щоб вважати екземпляр даних надійним та однозначним, перші дві умови є обов'язковими. Але перша умова завжди істинна, коли і друга істинна, тому залишається лише одна умова.

Екземпляр даних не може бути надійним, якщо справджується третя або четверта умова. Третя умова означає, що цей екземпляр з високою долею ймовірності є викидом, а четверта — що екземпляр даних у просторі ознак оточений іншими екземплярами з іншими мітками класу та, ймовірно, належить до зони перекриття класів.

Таким чином, перша умова C_1 : з перших k елементів вектора \vec{m}_i хоча б r має дорівнювати істинному класу y_i . k , r — гіперпараметри, що представляють собою невеликі цілі числа. У загальному випадку найкращі значення цих параметрів залежать від щільності набору даних у просторі ознак.

Друга умова C_2 : екземпляр даних є ненадійним, якщо y_i не є найчастішим класом серед перших k елементів вектора \vec{m}_i .

Остання умова C_3 : якщо присутня часта зміна класів, екземпляр даних є ненадійним. З математичної точки зору це можна розглядати як одновимірну згортку вздовж вектора \vec{m}_i з ядром $K=[1, 1]$. Якщо два сусідні елементи однакові, результат згортки буде нульовим. Для кожного випадку зміни класів результат згортки буде ненульовим. Результат згортки не повинен дорівнювати деякому цілому числу q , яке повинно бути достатньо невеликим.

Таким чином, остаточне правило для класифікації екземпляру даних можна представити наступним чином:

$$C_1 \wedge \bar{C}_2 \wedge \bar{C}_3, \quad (3)$$

де k , r , q — гіперпараметри. Змінюючи їх значення, ми можемо зробити одну умову важливішою за іншу. Як правило, $q < r, q < k$.

Алгоритм визначення ненадійних представників даних в датасеті мовою псевдокоду можна представити наступним чином.

```
FOR data_sample, label IN dataset:
    vector knn_results
    FOR i IN 1, 2, ..., n:
        knn_results[i] = // KNN classification of 'data_sample'
                        // with neighbour number 'i'
    Condition_1 = // BOOL: the most of first elements of 'knn_results'
                // is equal to 'label'
    Condition_2 = // BOOL: 'label' is not most frequent class of
                'knn_results'
    Condition_3 = // BOOL: convolution of 'knn_results' with [-1, 1]
                gives
                // non-zero result more than the threshold
    IF (Condition_1 AND (NOT Condition_2) AND (NOT Condition_3)
):
        // data_sample is reliable
ELSE:
        //data_sample is not reliable
```

1.3. АНАЛІЗ РЕЗУЛЬТАТІВ

За результатами роботи алгоритму на супутниковому композиті визначено ненадійні точки в задачі класифікації за 4-ма ознаками. Надійні та ненадійні точки представлено на рис. 4. Також обраховано відсоток ненадійних точок по кожному класу та в цілому. Отримані результати наведено у табл. 1.

Як видно з табл. 1, більшість точок з датасету потрапила до ненадійних даних, що свідчить про неможливість точної попиксельної класифікації обраних 8 видів сільськогосподарських культур на основі одного знімку. Це узгоджується з емпіричними результатами сучасних досліджень в сфері дистанційного зондування Землі, які свідчать про те, що різні типи сільськогосподарських культур неможливо відрізнити по одному знімку. Тому в сучасних роботах для класифікації сільськогосподарських культур використовуються часові ряди супутникових даних, отриманих протягом всього вегетаційного

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

сезону [21], [22]. Для подолання цієї проблеми необхідно розширити датасет різночасовими знімками з додатковими каналами та/або використовувати просторові властивості знімків, наприклад за допомогою згорткових нейронних мереж.

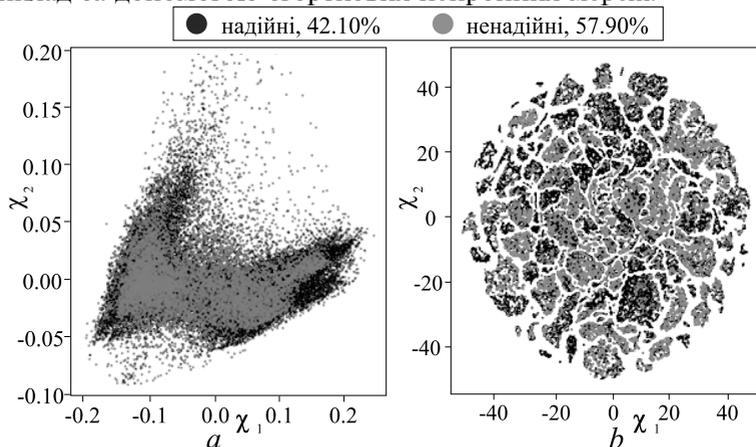


Рис. 4. Візуалізація визначених ненадійних точок датасету за допомогою PCA (a) та tSNE (b). Зеленим кольором позначено надійні точки червоним – ненадійні

Таблиця 1 Загальна кількість пікселів та частка ненадійних даних по кожному класу

Назва культури	К-сть пікселів, тис.	Відсоток ненадійних точок, %
Пшениця	25	51.36
Ріпак	25	63.17
Кукурудза	25	68.00
Цукровий буряк	25	78.66
Соняшник	25	61.99
Соя	25	54.88
Ячмінь	25	47.44
Горох	18	60.55

Інші культури	25	35.80
Разом	218	57.90

1.4. МОЖЛИВОСТІ ПРАКТИЧНОГО ЗАСТОСУВАННЯ

Алгоритм визначення ненадійних екземплярів даних можна вважати ще одним інструментом, який може бути використаний протягом усього циклу розробки моделі машинного навчання, від збору даних до розгортання моделі для використання у реальних умовах (рис. 5).

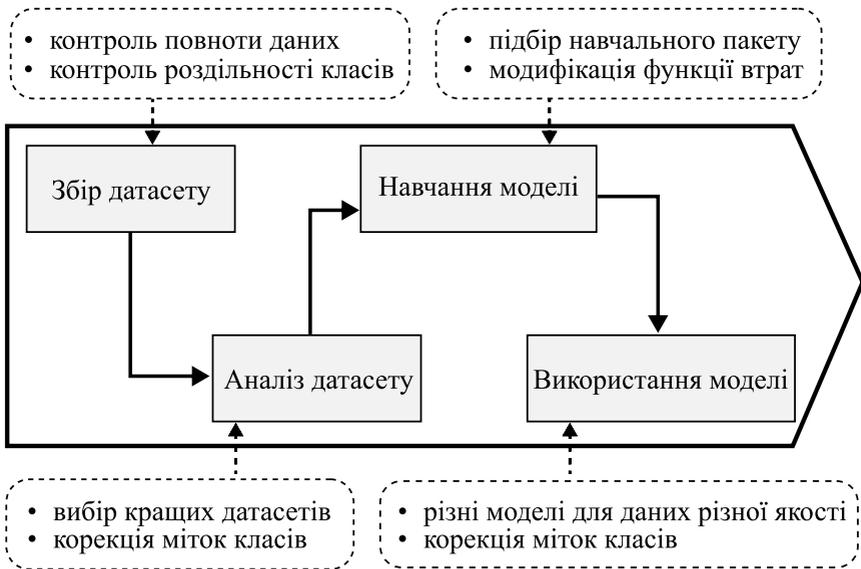


Рис. 1. Можливості використання алгоритму в повному циклі розробки моделі машинного навчання

Нижче наведено опис застосувань запропонованого методу.

Оцінка якості датасету. Представлений метод може бути корисним як в процесі збору даних, так і для аналізу наявних датасетів. Більшість сучасних задач машинного навчання вимагають великих датасетів, з великою розмірністю простору ознак та кількістю екземплярів даних. Досить часто наявний набір даних не в повній мірі відповідає поточній задачі. Тому в багатьох

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

випадках потрібно конструювати окремих датасет, наприклад, застосовувавши аутсорсинг або краудсорсинг [23], [24].

Подібна ситуація виникає, наприклад, в тому випадку, коли в якості навчальних даних в державних системах агромоніторингу використовується інформація про посіви, надана фермерами. Пілотний проєкт, проведений в попередні роки виконавцями проєкту з залученням даних від респондентів Державної служби статистики України, показав, що недостовірні інформація в таких даних може складати до 30%. У цьому випадку надзвичайно важливо мати інструмент для контролю якості отриманих даних, що дозволить виявити проблему ще на ранніх стадіях виконання робіт і скорегувати процес збору даних.

Можлива і протилежна ситуація, коли для розв'язуваної задачі є в наявності декілька датасетів. Зазвичай вибираються найкращі з них або їх комбінації. За допомогою розробленого методу можна визначити відсоток неоднозначних даних і, таким чином, вибрати дані найкращої якості або сформувати новий об'єднаний датасет з найменшою часткою ненадійних даних.

Корекція формування пакету даних для навчання. Розроблений метод дозволяє також покращити процес навчання моделі. Один з можливих методів полягає у зміні стратегії формування пакету даних для навчання. Під час навчання моделі можна використовувати надійні дані для навчання частіше, ніж ненадійні. Змінюючи частоту потрапляння ненадійних даних у навчальний пакет до повного видалення неоднозначних екземплярів даних, можна надати моделі нові властивості.

Отримана модель прийматиме рішення більшою мірою (суттєво) на основі надійних зразків даних, а не на ненадійних. Це дозволить зробити правильний прогноз у підпросторах, де немає перекриття класів, і приділяти менше уваги підпросторам, де класи перекриваються, оскільки у таких областях неможливо правильно визначити належність до класу.

Особлива стратегія ансамблювання. Можливість оцінювання якості окремих екземплярів даних дозволяє навчити кілька моделей, кожна з яких буде використовуватись лише у певних зонах простору ознак. Таким чином, правила класифікації для підпростору з надійними екземплярами даних будуть відрізнятися від ненадійних. Тоді остаточний ансамбль моделей буде складатися з двох підмножин: перша — з моделей, призначених

для надійних даних, а друга — для даних, які знаходяться біля неоднозначних екземплярів даних у просторі ознак. Подібний підхід до побудови динамічних ансамблів моделей у випадку незбалансованих вибірок запропоновано в [13].

Варто зауважити, що ненадійний екземпляр даних може або лежати в зонах, що перекриваються, або бути викидом. Зрозуміло, що в останньому випадку друга підмножина класифікаторів використовуватися не може, тому потрібно фільтрувати такі випадки.

Модифікація датасету. В багатьох методах роботи з незбалансованими датасетами та класами, які перекриваються, пропонується видалити з датасету екземпляри даних, які відносяться до найбільш представленого класу та знаходяться у зонах перекриття класів [25]. Натомість, можна внести зміни до їх істинного класу без зайвого видалення даних. В цьому випадку потрібно замінити мітки класів у зонах, де присутнє перекриття класів. Цільова мітка істинного класу, на яку необхідно поміняти мітки екземплярів даних у таких зонах, сильно залежить від поточних цілей. Для найкращих метрик має сенс змінити всі мітки класів на мітку найбільш представленого класу. Для боротьби з проблемою дисбалансу класів, усі мітки класів у сумнівній зоні можна змінити на найменш представлений клас.

Як і в попередньому підрозділі, при цьому потрібно відфільтрувати викиди, для яких мітки класів можна змінити на мітки екземплярів даних, які оточують їх у просторі ознак.

ОБГОВОРЕННЯ І ВИСНОВКИ

В розділі 1 наведено результати розробки методу для дослідження аномалій в даних і, зокрема, вирішення проблеми перекриття класів разом з іншими можливими випадками, такими як викиди та незбалансованість класів. Існує багато причин виникнення описаних проблеми, найважливішими з яких є недостатня точність процесу збору даних при формування датасету та недостатня кількість ознак і, відповідно, мала розмірність простору ознак. Незалежно від причин, деякі екземпляри даних просто неможливо класифікувати правильно, оскільки вони мають схожі ознаки з іншими екземплярами, які мають іншу мітку класу. Одним з прикладів таких задач є задача сегментації супутникових знімків для визначення типів землекористування. Через схожість спектральних характеристик таких культур, як пшениця та ячмінь,

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

їх неможливо розділити у просторі ознак. Такі екземпляри даних заважають процесу навчання моделі та можуть стати причиною неправильного прогнозування на реальних даних.

В даному розділі представлено новий метод, який не залежить від розмірності простору ознак та дозволяє сформулювати більш чітке уявлення про якість датасетів. На відміну від методів візуальної оцінки, заснованих на декомпозиції, представлений метод дозволяє отримати детерміновані числові показники якості даних, такі як відсоток надійних даних. Крім того, він дозволяє чітко відрізнити достовірні екземпляри даних від недостовірних, відкриваючи можливість їх подальшої модифікації.

В якості апробації запропонованого підходу розглянуто практичну задачу попиксельної класифікації чотириканального супутникового композиту для визначення сільськогосподарських культур. Було визначено ненадійні точки, які важко класифікувати правильно, та обчислено відсоток ненадійних даних в цілому та окремо по кожному класу. Більшість точок з датасету, частка яких становить 59.7%, не можуть бути чітко відділені від точок іншого класу у просторі ознак. Особливо важкими для класифікації виявилися цукровий буряк та ріпак — частка ненадійних точок 78.66% і 63.17% відповідно. Це показує необхідність використання більшої кількості знімків та оптичних каналів для задач класифікації типів землекористування або використовувати математичну модель, яка б враховувала просторовий розподіл даних на знімку.

Запропонований метод може бути використаний протягом усього циклу розробки моделі машинного навчання, в тому числі етапів контролю та корекції процесу збору навчальних даних, а також вибору найкращих датасетів та їх компонування. Після виявлення неоднозначних екземплярів даних, можна застосувати різні правила для них і для надійних даних, як під час навчання, так і під час роботи на реальних даних. Метод також надає можливості по модифікації набору даних, зміні міток класів ненадійних зразків даних відповідно до поточних задач, таких як балансування класів тощо.

ПЕРЕЛІК ПОСИЛАНЬ

1. Chawla N.V. Data Mining for Imbalanced Datasets: An Overview. Data Mining and Knowledge Discovery Handbook. 2005. pp. 853-867. DOI: 10.1007/0-387-25465-x_40.

2. Abdi H., Williams L.J. Principal component analysis. *WIRES Computational Statistics*. 2010. Vol. 2, no. 4. pp. 433-459. DOI: 10.1002/wics.101.
3. Van Der Maaten L., Hinton G. Visualizing data using t-SNE. *Journal of Machine Learning Research*. 2008. Vol. 9, no. 86. pp. 2579-2605.
4. O'Shea K., Nash R. An Introduction to Convolutional Neural Networks. arXiv preprint arXiv. 2015. DOI: 10.48550/ARXIV.1511.08458.
5. Mikołajczyk A., Grochowski M. Data augmentation for improving deep learning in image classification problem. 2018 International Interdisciplinary PhD Workshop (IIPHDW). 2018. pp. 117-122. DOI: 10.1109/IIPHDW.2018.8388338.
6. Shorten C., Khoshgoftaar T.M. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019. Vol. 6, no. 1. DOI: 10.1186/s40537-019-0197-0.
7. Almutairi W.A., Janicki R. On relationships between imbalance and overlapping of datasets. *EPIc Series in Computing*. 2020. Vol. 69. pp. 141-150. DOI: 10.29007/h71z.
8. Kramer O. Dimensionality Reduction with Unsupervised Nearest Neighbors. *Intelligent Systems Reference Library*. 2013. Vol. 51. pp. 13-23. DOI: 10.1007/978-3-642-38652-7.
9. Garcıa V., Mollineda R.A., Sınchez J.S. On the k-NN performance in a challenging scenario of imbalance and overlapping. *Pattern Analysis and Applications*. 2008. Vol. 11, no. 3-4. pp. 269-280. DOI: 10.1007/s10044-007-0087-5.
10. Nwe M.M., Lynn K.T. KNN-Based Overlapping Samples Filter Approach for Classification of Imbalanced Data. *Studies in Computational Intelligence*. 2020. pp. 55-73. DOI: 10.1007/978-3-030-24344-9_4.
11. Chen L., Fang B., Shang Z., Tang Y. Tackling class overlap and imbalance problems in software defect prediction. *Software Quality Journal*. 2018. Vol. 26, no. 1. pp. 97-125. DOI: 10.1007/s11219-016-9342-6.
12. Tang Y., Gao J. Improved classification for problem involving overlapping patterns. *IEICE Transactions on Information and Systems*.

2.1. Метод виявлення аномалій в даних навчання моделей комп'ютерного...

2007. Vol. E90-D, no. 11. pp. 1787-1795. DOI: 10.1093/ietisy/e90-d.11.1787.

13. Ldssig N., Oppold S., Herschel M. Metrics and Algorithms for Locally Fair and Accurate Classifications using Ensembles. Datenbank-Spektrum. 2022. Vol. 22, no. 1. pp. 23-43. DOI: 10.1007/s13222-021-00401-y.

14. Cover T.M., Hart P.E. Nearest Neighbor Pattern Classification. IEEE Transactions on Information Theory. 1967. Vol. 13, no. 1. pp. 21-27. DOI: 10.1109/TIT.1967.1053964.

15. Okhrimenko A., Kussul N. KNN-Based Algorithm of Hard Case Detection in Datasets for Classification. In Proceedings of the 11th International Conference on Applied Innovations in IT. 2023. DOI: 10.25673/101926.

16. Makarichev V., Vasilyeva I., Lukin V., Vozel B., Shelestov A., Kussul N. Discrete Atomic Transform-Based Lossy Compression of Three-Channel Remote Sensing Images with Quality Control. Remote Sensing. 2022. Vol. 14, no. 1. pp. 125. DOI: 10.3390/rs14010125.

17. Lavreniuk M., Kussul N., Novikov A. Deep learning crop classification approach based on sparse coding of time series of satellite data. IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. 2018. pp. 4812-4815. DOI: 10.1109/IGARSS.2018.8518263.

18. Kussul N., Shelestov A., Lavreniuk M., Butko I., Skakun S. Deep learning approach for large scale land cover mapping based on remote sensing data fusion. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 2016. pp. 198-201. DOI: 10.1109/IGARSS.2016.7729043.

19. Okhrimenko A., Kussul N. KNN-Based Algorithm of Hard Case Detection in Datasets for Classification. Proceedings of International Conference on Applied Innovation in IT. 2023. Vol. 11, no. 1, pp. 113-118. DOI:10.25673/101926.

20. Охріменко А.О., Куцуль Н.М. Метод виявлення складних для розпізнавання зразків у наборах даних для задач класифікації у машинному навчанні. Проблеми керування та інформатики. 2023. Vol. 68, no. 4, с. 84–95. doi: 10.34229/1028-0979-2023-4-7.

21. Shelestov A., Lavreniuk M., Kussul N., Novikov A., Skakun S. Large scale crop classification using Google earth engine platform. 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 2017. pp. 3696-3699. DOI: 10.1109/IGARSS.2017.8127801.

22. Garnot V.S.F., Landrieu L., Giordano S., Chehata N. Time-Space Tradeoff in Deep Learning Models for Crop Classification on Satellite Multi-Spectral Image Time Series. IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium. 2019. pp. 6247-6250. DOI: 10.1109/igarss.2019.8900517.

23. Zheng F., Tao R., Maier H.R., See L., Savic D., Zhang T., et al. Crowdsourcing Methods for Data Collection in Geophysics: State of the Art, Issues, and Future Directions. Reviews of Geophysics. 2018. Vol. 56, no. 4. pp. 698-740. DOI: 10.1029/2018RG000616.

24. Laso Bayas J., See L., Fritz S., Sturn T., Perger C., Дьбрауер М., et al. Crowdsourcing in-situ data on land cover and land use using gamification and mobile technology. Remote Sensing. 2016. Vol. 8, no. 11. pp. 905. DOI: 10.3390/rs8110905.

25. Kaur H., Pannu H.S., Malhi A.K. A systematic review on imbalanced data challenges in machine learning: Applications and solutions. ACM Computing Surveys. 2019. Vol. 52, no. 4. pp. 1-36. DOI: 10.1145/3343440.

2. МЕТОДИ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ РІЗНОЇ ПРИРОДИ ДЛЯ ВИПАДКУ НЕЗБАЛАНСОВАНОГО НАБОРУ

Антон Охріменко, аспірант

Кафедра математичного моделювання і аналізу даних

Навчально-науковий Фізико-технічний інститут

Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського»

antoh-ipt21@iit.kpi.ua

ВСТУП

Незбалансованість навчальних вибірок — це фундаментальна проблема при навчанні будь-якої моделі машинного навчання. Окрім очевидної схильності модель добре вивчати лише ті дані, які найбільш представлені у наборі даних, виникає проблема оцінки якості її роботи на тестовому наборі даних, який так само може бути незбалансованим. Іншою перешкодою є перекриття класів — подібність екземплярів різних класів між собою аж до неможливості розрізнення. У випадку, коли ці дві проблеми наявні одночасно, створення ефективної моделі машинного навчання значно ускладнене.

Розширення набору даних за рахунок найменш представлених класів зведе до нуля проблему незбалансованості класів. В свою чергу, збільшення кількості ознак, які характеризують кожний екземпляр даних, може вирішити проблему перекриття класів. Для задачі сегментації зображень це еквівалентно збільшенню кількості каналів у зображенні. У будь-якому випадку, виникає необхідність отримати нові дані для розширення вже наявного набору. Це не завжди можливо, через фізичну неможливість, через обмеження бюджету або ж з інших причин. Наприклад, для задачі сегментації супутникових знімків, неможливо отримати додаткові зображення через фізичні обмеження руху супутників. Для задачі сегментації гістологічних мікроскопічних знімків, отримання нових даних потребує виконання складних операцій з отримання культури клітин, їх фарбування та дослідження за допомогою мікроскопу.

У наступних підрозділах розглядаються методи компенсації дисбалансу класів у задачі сегментації без використання додаткових навчальних даних.

2.1. ВДОСКОНАЛЕННЯ МЕТОДУ ГЛИБИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ЗЕМНОГО ПОКРИВУ ТА ВИЯВЛЕННЯ ТИПУ СІЛЬСЬКОГОСПОДАРСЬКИХ КУЛЬТУР

Карти класифікації земного покриву, в тому числі типів сільськогосподарських культур, мають важливе значення для сільського господарства, моніторингу довкілля та розвитку сільських громад. Точна класифікація сприяє розв'язанню проблем виробництва сільськогосподарських культур та оцінці урожайності [1], оцінці ризиків та аналізу умов навколишнього середовища [2]. Ці карти є необхідними для оцінки земельного покриття та землекористування, дозволяючи вивчати соціальні та економічні аспекти розвитку сільських територій. Вони також допомагають оцінити важливі екологічні та сільськогосподарські показники для оцінки ступеню опустелювання, стійкого використання землі та досягнення цілей сталого розвитку [2]. Крім того, інвентаризація сільськогосподарських культур за допомогою класифікації супутникових даних стала необхідною для прийняття рішень на рівні країни в багатьох регіонах світу. Послуги, такі як CropScape Сполучених Штатів [3] і система Sen-4-CAP Європейського Союзу [4], підтримують сільськогосподарську політику в Північній Америці і Європі.

2.1.1. ОГЛЯД ЛІТЕРАТУРИ

Стрімкий ріст індустрії та доступності даних спостереження Землі призвів до нових досліджень щодо можливостей впровадження штучного інтелекту для спостереження за земною поверхнею. Сучасні методи глибокого навчання пропонують потенціал покращення якості супутникових продуктів для точної оцінки сільського господарства та економічних аспектів розвитку сільських територій [5]. Глибоке навчання, зокрема згорткові нейронні мережі, стало перспективним підходом до технологій картографування відповідно до мінливих потреб у класифікації [6]. В той же час глибокі моделі навчання стикаються з двома критичними викликами, що ускладнюють масштабованість, універсальність та застосування в реальному світі: необхідність великої кількості розмічених супутникових даних і наявність

2.2. Методи сегментації зображень різної природи для випадку...

дисбалансу даних через розподіл покриття земної поверхні та типів сільськогосподарських культур. Це призводить до існування менш представлених і більш представлених класів. Крім того, складність взаємозв'язків між багатоспектральними та текстурними характеристиками обмежує можливості методів аугментації.

Зазначені вище питання не можуть бути вирішені за допомогою традиційних технік аугментації комп'ютерного зору, таких як обертання, випадкове видалення та змішування [7]. Замість цього, найбільш ефективним рішенням є використання передових технологій, а саме генеративних змагальних нейронних мереж (GANs) [8]. Незважаючи на популярність GANs в різних наукових галузях, їх застосування для обробки даних дистанційного спостереження земної поверхні залишається недостатньо розвиненим і в основному обмежується обробкою зображень і задачами супер-роздільності. Дослідження [9] представляє GAN-підходи для підвищення просторового розрізнення та масштабування супутникових зображень і підтверджує високу якість аналізу текстурних характеристик реального світу такими GAN. В [10] показано, що модель GAN може генерувати реалістичні супутникові зображення за текстурними та багатоспектральними характеристиками. У дослідженні [11] показано, що моделі GAN здатні вивчати закономірності часових змін багатоспектральних характеристик супутникових даних для прогнозу наступного зображення в послідовності і, таким чином, заповнювати прогалини в часових рядах. Схожий висновок був зроблений для складних багатоспектральних характеристик різних типів сільськогосподарських культур у дослідженні [12]. Крім того, такі методи, як «pixel-to-pixel» (pix2pix), вже дозволяють створювати реалістичні супутникові зображення за допомогою існуючих карт покриття земної поверхні [13]. З врахуванням потенціалу використання моделей GAN нижче запропоновано новий метод застосування GAN для вирішення питань дисбалансу даних у класифікації земної поверхні та типів сільськогосподарських культур. Цей підхід можна розглядати як першу методологію аугментації супутникових зображень на основі GAN, використовуючи підхід pix2pix [7], тим самим вперше вводячи цей метод аугментації в галузь використання даних дистанційного зондування Землі.

2.1.2. ПОСТАНОВКА ЗАДАЧІ

При виконанні досліджень в якості пілотної було обрано територію Київської області, яка розташована в центральній-північній частині України та має площу 28 131 км². Область розташована на межі двох природних зон — полісся та лісостепу. Частка землі сільськогосподарського призначення в Київській області становить 44% від загальної площі, основна частина якої розташована в південній частині області (рис. 1).

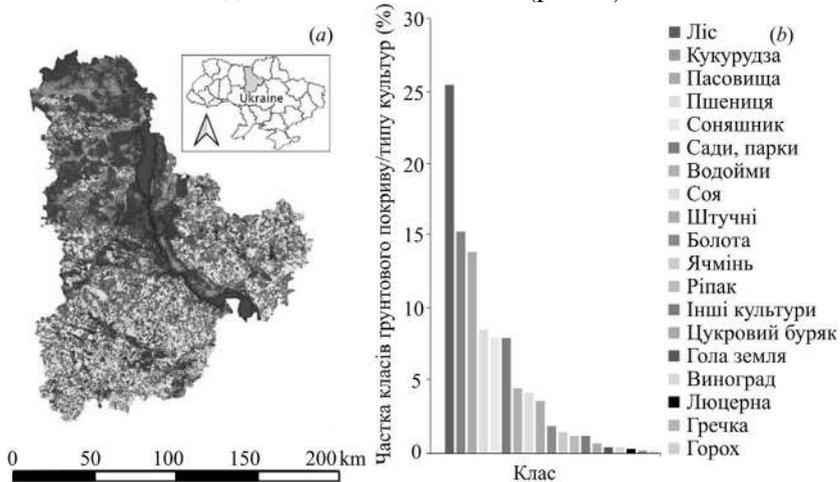


Рис. 1. Ґрунтовий покриття та розподіл культур для території досліджень; а) Карта посівів Київської області 2021; б) Частка рослинного покриття та розподіл культур, представлених у Київській області

При проведенні експерименту була використана карта класифікації на основі супутникових знімків Sentinel-1 і Sentinel-2, надана Інститутом космічних досліджень НАНУ-ДКАУ, отримана в межах проєкту Всесвітнього банку по інвентаризації сільськогосподарських земель в Україні з точністю 95% для 2021 р. [14].

Супутникові дані, які було використано для сегментації сільськогосподарських культур, були отримані за допомогою супутника Sentinel-2 за липень у вигляді безхмарного композиту зі спектральними каналами червоного, зеленого, синього та ближнього інфрачервоного діапазонів. Композит мав просторове розрізнення 10 м із рівнем обробки L2, включаючи радіометричну

2.2. Методи сегментації зображень різної природи для випадку...

корекцію, атмосферну корекцію, маскування хмар та мозаїку. Далі композит був розділений на 4250 зображень розміром 256×256 пікселів і 4 канали, та розподілений на незалежні набори даних для навчання і тестування з 2125 зображень у кожному. З точки зору представленості пікселів малих класів набір даних, який використовувався для навчання як генератора GAN, так і моделі класифікації, для навчання є сильно незбалансованим.

Ефективна архітектура GAN дозволяє генерувати реалістичні синтетичні супутникові зображення для аугментації навчальних даних. Взаємозв'язок між супутниковими зображеннями та сегментаційними масками ґрунтується на використанні текстурних та багатоспектральних ознак в межах зображень. Було розроблено модель, яка здатна генерувати реалістичні супутникові зображення для будь-якої штучно створеної сегментаційної маски. Запропонований метод [15] дозволяє створювати синтетичні пари супутникових зображень і масок, генерувати розподіли сільськогосподарських культур, які не зустрічаються у природному середовищі, та надає можливість керування балансом класів в наборі даних [16]. У даному дослідженні для створення синтетичних супутникових зображень з 4 каналами було використано сегментаційні маски розміром 256×256 пікселів.

Для побудови моделі генератора використано трансляцію зображень в зображення [17], яка спрямована на перетворення зображень з одного домена в інший із відмінною розмірністю простору ознак. Результат аугментаційного алгоритму показано на рис. 2.

Спочатку модель $pix-2-pix$ GAN була налаштована на генерацію реалістичних супутникових зображень на основі сегментаційної карти. Потім реальні сегментаційні карти були модифіковані для отримання штучних масок з більшою часткою менш представлених класів. Після цього початкові і згенеровані супутникові дані були об'єднані в єдину навчальну колекцію даних, яка використовувалася для навчання моделі сегментації з вищою точністю розділення менш представлених класів.

2.1.3. РОЗВ'ЯЗАННЯ ЗАДАЧІ

В якості базової моделі для задачі семантичної сегментації була використана класична модель U-Net із вхідним розміром $256 \times 256 \times 4$ пікселів. U-Net — це широко використовувана архітектура глибокого навчання при розв'язанні задач моніторингу земель [18]. Її ключовою властивістю є включення додаткових

з'єднань від шарів, які зменшують розмір простору ознак до відповідних шарів, які розширюють його.

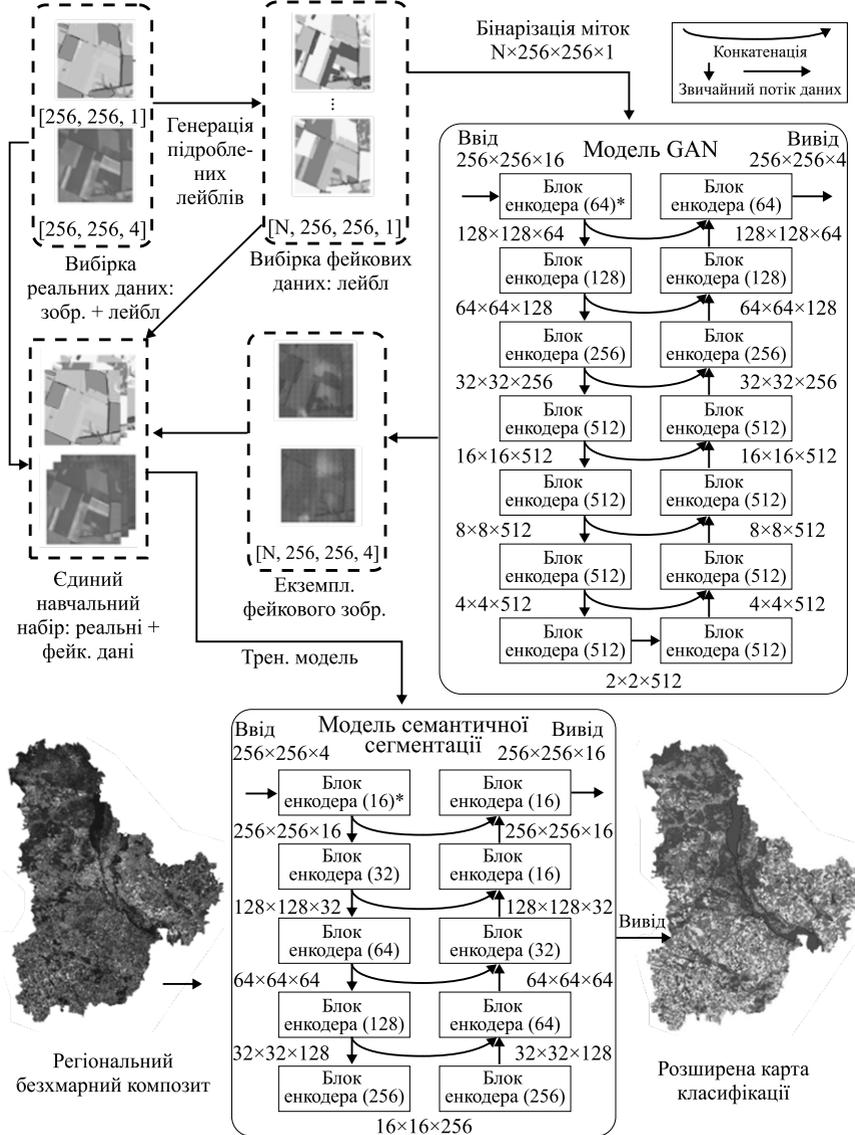


Рис. 2. Пропонована схема аугментації GAN для сегментування типів сільськогосподарських культур з використанням моделі сегментації глибокого навчання.

Така архітектура дозволяє виділяти високорівневі ознаки на кожному кроці, зберігаючи при цьому просторову інформацію в зображенні. Крім того, це допомагає вирішувати проблему зникнення градієнтів при певних умовах.

У класичній моделі U-Net [18] кожний блок енкодера або декодера містить два 3×3 згорткових шари, за якими застосовується функція активації ReLU. Водночас кількість каналів подвоюється на кожному блоку енкодера (крім першого, де є 64 канали). На кожному блоку декодера вона зменшується вдвічі. Max-pooling із кроком 2 в блоках енкодера використовується для зменшення розміру карт ознак, тоді як в декодері для масштабування використовуються зворотні згортки. Вихідний шар мережі представляє собою згортку 1×1 з сигмоїдною функцією активації.

Для навчання моделі сегментації U-Net для класифікації сільськогосподарських культур був використаний алгоритм оптимізації Adam із швидкістю навчання 2×10^{-4} та функція втрати focal loss з параметром гамма, який дорівнював 2. Було обрано саме цю функцію втрати, оскільки вона є дуже популярною і, у більшості випадків, найбільш ефективною функцією втрат при розв'язанні задач з використанням незбалансованих наборів даних.

2.1.3.1. ГЕНЕРАТИВНА ЗМАГАЛЬНА МЕРЕЖА

Генеративна змагальна мережа (GAN) для генерації супутникових даних складається з двох моделей нейронних мереж: генератора для побудови зображення на основі сегментаційних масок, і дискримінатора, який дозволяє відрізнити реальні та штучно згенеровані зображення (рис. 3).

Генератор використовується для створення реалістичних фрагментів супутникових зображень, які не може розрізнити дискримінатор. В свою чергу, дискримінатор навчається розрізняти реальні та штучні зображення. Обидві моделі працюють з вхідними даними розміром $256 \times 256 \times 4$ пікселів.

Для побудови генератора використано модель pix-2-pix на основі U-Net з 7 блоками енкодера і декодера, в яких присутні 6 обхідних з'єднань [19] та гіперболічний тангенс в якості активаційної функції на вихідному шарі. Для дискримінатора використано глибоку згорткову нейронну мережу з 5 шарами 2D-згортки, включаючи нормалізацію пакету та активаційні функції Leaky ReLU, а також вихідний згортковий шар із

сигмоїдною активаційною функцією. Функцію втрат дискримінатора оптимізовано за допомогою бінарної крос-ентропії:

$$BCE = \frac{1}{n} \sum_{i=1}^n y_i \times \log_2 \hat{y}_i + (1 - y_i) \times \log_2 (1 - \hat{y}_i), \quad (1)$$

де n — кількість вибірок у навчальному датасеті, y_i — мітка екземпляру i та \hat{y}_i — вихід нейронної мережі для цієї вибірки. Функція втрати генератора комбінує бінарну крос-ентропію дискримінатора та середньоквадратичну помилку між створеними зображеннями та реальними зображеннями за формулою:

$$Loss_{gen} = MSE(y_i, \hat{y}_i) + 0.01 \times BCE(y_i, \hat{y}_i). \quad (2)$$

Для оптимізації параметрів під час навчання використано алгоритм Adam з швидкістю навчання 2×10^{-4} та коефіцієнтом $\beta=0.5$.

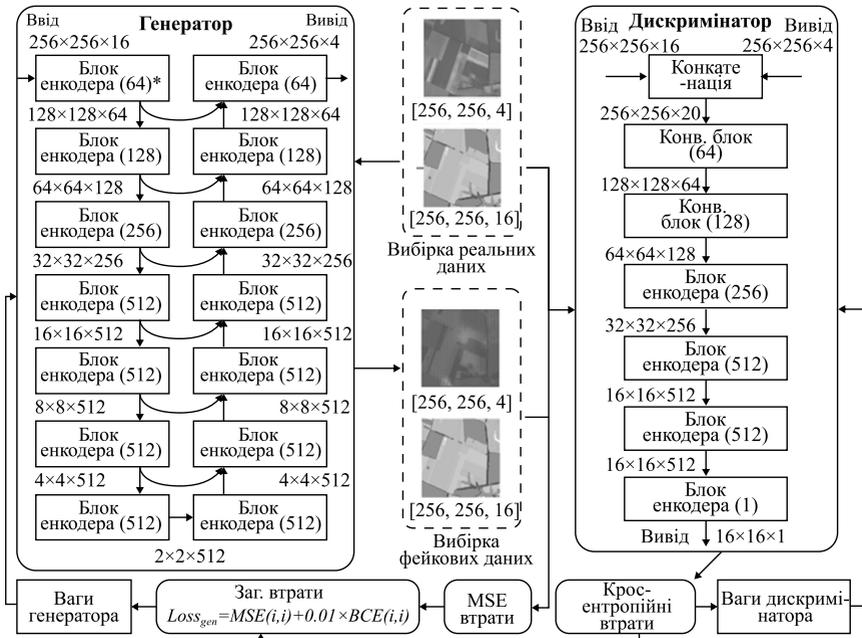


Рис. 3. Схема навчання моделі GAN

2.1.3.2. СХЕМА АУГМЕНТАЦІЇ

Для навчання генерації зображень за допомогою GAN шляхом модифікації початкових масок із навчального набору даних були створені штучні сегментаційні маски. Цей підхід дозволяє зберегти просторові шаблони сільськогосподарських полів, подібних до реального середовища. Спочатку підраховується кількість пікселів для кожного класу, здійснюється їх сортування за частотою та створюється словник заміन. Цей словник перетворює найбільш поширений клас на найменш поширений, другий найбільш поширений на другий найменш поширений і т.д. Нарешті, всі пікселі класу сільськогосподарських культур замінюються на нові; кількість пікселів, які займають найменш представлені класи, збільшується, і стає одного порядку з кількістю пікселів найбільш представлених класів. Таким чином, вирішується проблема дисбалансу навчальних даних.

2.1.3.3. КЛАСИЧНИЙ ПІДХІД ДО АУГМЕНТАЦІЇ

Запропонований метод було порівняно з класичними методами генерації штучних зображень [7]. В першому методі для оцінки статистичних характеристик кожного класу та генерації синтетичних сегментаційних масок використовується метод Монте-Карло. Потім заповнюються синтетичні супутникові зображення шляхом вибору по черзі пікселів на основі ймовірнісного розподілу вибраного класу сільськогосподарських культур у багатоспектральному просторі ознак. Цей підхід, який часто використовується при розв'язанні задач глибокого навчання, допомагає контролювати розподіл даних та запобігає перенавчанню, надаючи набір сегментаційних масок та синтетичних супутникових зображень для навчання поряд із реальними даними.

Другий метод, запропонований в [20], включає в себе вибір пікселів безпосередньо з реальних зображень за допомогою тієї ж штучної сегментаційної маски, що і попередні методи. Випадковий реальний набір даних вибирається для кожної маски та класу, забезпечуючи достатню кількість відповідних пікселів сільськогосподарських культур. Потім шляхом вибору пікселів з реального зображення заповнюється призначений клас на синтетичному зображенні. Цей підхід дозволяє зберегти стабільність значень пікселів шляхом вибору з одного класу в малій області, враховуючи незначні відмінності у властивостях пікселів на різних регіонах.

2.1.4. ОБГОВОРЕННЯ І ВИСНОВКИ

В експерименті було створено 2384 синтетичних супутникових зображень з штучними масками як з використанням методів GAN, так і статистичних методів. Потім було навчено чотири моделі: (I) з використанням реальних супутникових даних; (II) на основі комбінування реальних супутникових даних із синтетичними зображеннями на основі статистичного методу; (III) з використанням синтетичних зображень на основі методу вибірки пікселів; (IV) на основі синтетичних зображень, отриманих методом GAN. було застосовано стандартні аугментації, такі як обертання і відображення, і використано функцію втрати focal loss для вирішення проблеми дисбалансу класів. Далі результати цих чотирьох методів було перевірено на незалежному наборі даних для тестування, який складався із 2 125 реальних зображень. Отримані результати представлено в табл. 1.

Модель (I) досягла 77.3% загальної точності (Overall accuracy, OA) і 64.1% перетину над об'єднанням (Intersection over Union, IoU), але середні точності для класу сільськогосподарських угідь (Average accuracies of cropland, AAC) для точності користувача (User Accuracy, UA), точності виробника (Producer Accuracy, PA) та IoU були дуже низкими через великий дисбаланс представлення класів сільськогосподарських культур у реальних даних. Генерація нових зразків із використанням статистичної моделі покращила представленість малих класів у наборі даних і не спричинила перенавчання. В результаті точність для більшості класів моделі (II) не змінилася, але точність малих класів значно зросла, що призвело до підвищення AAC на 8.5% для UA, 5.3% для PA і 9.0% для IoU. Метод вибірки пікселів в цілому показав схожі результати, і AAC для малих класів моделі (III) збільшилося на 6.7% для UA, 6.2% для PA і 8.0% для IoU.

Модель (IV), навчена за допомогою запропонованої методології аугментації GAN, випередила модель (I), модель (II) та модель (III). В порівнянні з моделлю (II) середні значення UA зросли на 2.7%, PA на 1.1% і IoU на 1.2%. Також OA та загальний IoU збільшилися на 1.4% та 1.6% відповідно.

Точність UA та PA для 4 з 8 класів сільськогосподарських культур та IoU для 7 із 8 класів у моделі (IV) є найвищими у експерименті. Є лише 2 винятки, де показники інших моделей значно вищі, ніж у моделі (IV): це кукурудза, де модель (IV) має найкращий результат лише за PA та IoU, та цукровий буряк, де модель (IV) випередила модель (III) лише за UA.

2.2. Методи сегментації зображень різної природи для випадку...

Таблиця 1 Порівняння метрик моделей класифікації с/г культур (найвищі метрики виділено жирним шрифтом)

с/г культура	Модель (I)			Модель (II)			Модель (III)			Модель (IV)		
	UA (%)	PA (%)	IoU	UA (%)	PA (%)	IoU	UA (%)	PA (%)	IoU	UA (%)	PA (%)	IoU
соняшник	80.4	92.7	75.7	83.5	91.0	77.1	82.8	89.6	75.5	82.8	92.9	77.9
кукурудза	83.8	90.0	76.6	83.9	89.4	76.3	82.6	89.6	75.4	87.6	88.2	78.4
пшениця	71.5	83.5	62.7	72.2	83.2	63.1	72.7	82.4	63.0	73.2	85.8	65.3
соя	80.8	54.9	48.6	73.4	60.7	49.8	76.7	55.1	47.1	73.0	68.2	54.5
ріпак	37.7	29.3	19.7	42.7	32.1	22.4	44.4	31.9	22.8	52.0	37.1	27.6
ячмінь	45.8	22.4	17.7	44.4	22.9	17.8	40.1	22.3	16.7	48.2	30.0	22.7
цукровий бурак	0.0	0.0	0.0	61.2	33.8	27.8	50.2	47.9	32.4	65.8	15.5	14.3
інші	26.6	3.2	2.7	32.7	4.9	41.0	30.1	6.9	34.7	33.2	9.7	43.8
ААС (%)	53.3	47.0	37.9	61.8	52.3	46.9	59.9	53.2	45.9	64.5	53.4	48.1
ОА (%)	77.3	64.1		77.4	64.6		77.0	64.0		78.8	66.2	

Загалом аугментація GAN покращила продуктивність класифікації сільськогосподарських культур на 11.2%, 6.4% і 10.2% для середніх значень UA, PA та IoU відповідно, при цьому OA та загальний IoU покращилися на 1.5% і 2.1%. Отримані карти класифікації на основі моделей (I)–(IV) представлені на рис. 4.

Слід відзначити, що для основних класів, таких як кукурудза, пшениця та соняшник, які є більш представленими, якість в обох картах сегментації є високою. В той же час для менш представленого класу ріпаку (темно-червоного кольору) результат, отриманий на основі моделі (I), має дефекти та артефакти та набагато меншу якість порівняно з моделлю (IV). Це можна пояснити тим, що GAN, на відміну від класичних статистичних методів генерації, дозволяє створити штучні приклади, які збережуть подібність не лише в точкових статистичних характеристиках класів, але й у відповідних текстурах.

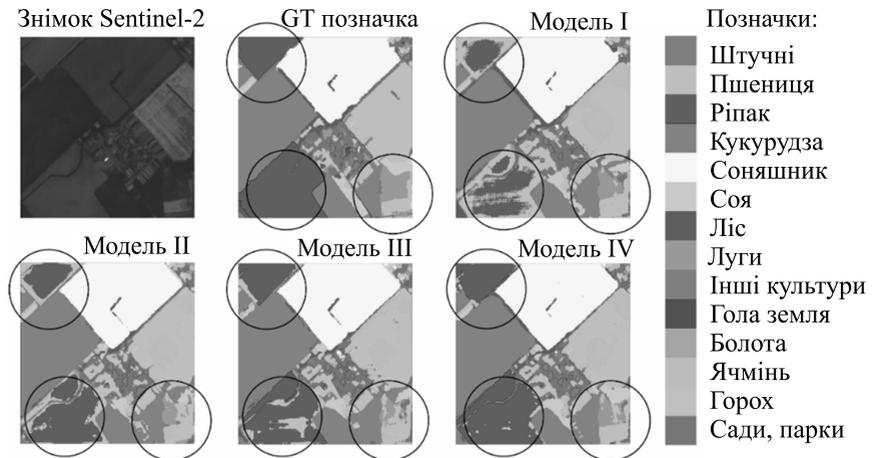


Рис. 4. Порівняння реальної карти сегментації (GT позначка) і результатів класифікації, отриманих лише на основі реальних зображень Sentinel-2 (Модель I), із даними, створеними за допомогою статистичного методу (Модель II), із даними, створеними за допомогою методу вибірки пікселів (Модель III), та із даними, створеними за допомогою методу GAN (Модель IV)

2.2. ВДОСКОНАЛЕННЯ МЕТОДУ ГЛИБИННОГО НАВЧАННЯ ДЛЯ СЕГМЕНТАЦІЇ ГІСТОЛОГІЧНИХ ЗОБРАЖЕНЬ

Датасети гістологічних зображень, як і датасети супутникових знімків, характеризуються сильним дисбалансом класів, а отримання додаткових даних значно ускладнене або ж зовсім неможливе. Гістологічні зображення тканин широко використовуються при виявленні патологій, зокрема злоякісних пухлин. Використання методів комп'ютерного зору дозволяє частково автоматизувати обробку даних, що може використовуватися як допоміжний інструмент під час роботи лікарів при встановленні клінічного діагнозу [22]. У порівнянні з традиційними алгоритмами машинного зору, де ознаки виділяються вручну, глибокі нейронні мережі показують кращі результати у задачах сегментації тканин, окремих клітин чи виділенні границь (меж) [25].

2.2.1. ОГЛЯД ЛІТЕРАТУРИ

Подальше покращення результатів може відбуватися за рахунок зміни архітектури моделі або її окремих шарів. У роботі [21] розглядається модифікації згорткового шару, де вхідні дані ущільнюються безпосередньо перед операцією згортки. Це дозволяє виділяти більше ознак на кожному послідовному шарі нейронної мережі, зберігаючи при цьому просторові властивості. Як наслідок, загальна кількість шарів зменшується, а також зменшується час обробки зображення.

Для боротьби з незбалансованістю навчальних вибірок, присутньою у більшості публічно доступних наборах даних, авторами [23] запропоновано використання зваженої функції втрат відповідно до частоти класів у вибірці. Менш представленим класам відповідають більші вагові коефіцієнти, а більш представленим класам — відповідно менші. Таким чином, вплив кожного класу на зміни параметрів моделі стає приблизно рівним. Також у даному розділі представлено алгоритм післяопераційної обробки результатів роботи моделі, який враховує впевненість моделі та передбачену відстань до межі клітини для кожного пікселя. Таким чином отримується повна оцінка форми клітини та фільтруються хибні передбачення пікселів фону.

Подібний підхід продемонстровано у роботі [24] присвяченій сегментації уражень шкіри, де в ролі функції втрат використовується зважена контурна крос-ентропія (WCCE). Вона змушує модель приділяти більше уваги контурам областей інтересу, що загалом покращує якість сегментації та точного розпізнавання границь уражених зон.

У роботі [26] для подолання проблеми незбалансованості класів використовується узагальнена функція втрат Дайса (Dice Loss). Вклад кожного класу в остаточне значення функції регулюються ваговими коефіцієнтами, які обернено пропорційні площі, що даний клас займає на конкретному зображенні. Окрім того, наведено кроки попередньої обробки даних, такі як зміна розмірів та розбиття зображень, нормалізація та аугментація.

Більшість публічно доступних набрів даних складаються з невеликої кількості зображень, а деякі класи зустрічаються набагато частіше за інші [23]. Можливо розширити навчальну вибірку за рахунок штучно згенерованих зображень. Генеративні змагальні мережі здатні створювати реалістичні гістологічні зображення за заданою сегментаційною маскою [28], що дозволяє згенерувати багато зображень з найменш представленими класами

та вирівняти розподіл класів у об'єднаному датасеті з реальний та штучних даних.

Для покращення розпізнавання границь окремих клітин, автори [27] вводять додатковий клас, який відповідає цій межі, а його пікселі знаходяться поруч зі границею на невеликій відстані. Загальне число пікселів такого класу дуже мале, що посилює незбалансованість класів у датасеті. Тому при навчанні використовується зважена крос-ентропія, де нововведеному класу відповідає більший ваговий коефіцієнт у порівнянні з рештою класів. Також більші вагові коефіцієнти отримали пікселі, як клітин так і фону, які лежать у безпосередній близькості від нового класу, тобто поруч з границею — чим далі від границі, тим менший коефіцієнт.

2.2.2. ПОСТАНОВКА ЗАДАЧІ

Для подальших експериментів у цьому розділі використано датасет MoNuSAC2020 [29], який був вперше представлений на змаганні з сегментації гістологічних знімків MoNuSAC (A Multi-organ Nuclei Segmentation and Classification Challenge) у 2020 році. Він представляє собою набір отриманих з мікроскопу зображень біологічних тканин, пофарбованих гематоксилином-еозином. У анотації датасету вказано клас та границі кожної клітини.

Загалом датасет містить 310 зображень різного розміру, з них 209 для навчання та 101 для тестування. На зображеннях присутні чотири типи клітин з чотирьох органів. Загальне число розмічених клітин перевищує 46 000, у зборі даних брали участь 37 різних лікувальних закладів та 71 пацієнт. Датасет має 5 класів: епітеліальні клітини, лімфоцити, нейтрофіли, макрофаги та один додатковий клас «Фон», що позначає відсутність перелічених клітин. Приклад розміченого зображення з датасету зображено на рис. 5.

Зображення з датасету поділено на фрагменти розміром по 256×256 кожне. Більшість оригінальних зображень мають значно більший розмір, аніж вказаний, тому у результаті загальне число фрагментів становило 1 131 у наборі для навчання, та 439 у наборі для тестування.

Для навчального набору даних обраховано відсоток ненадійних точок по кожному класу та загалом. Дані наведено у табл. 2. Більша половина представників усіх класів була визнана ненадійними екземплярами. Класи «Нейтрофіл» та «Макрофаг» є найменш чисельними та одночасно найбільш ненадійними

2.2. Методи сегментації зображень різної природи для випадку...

класами. Незважаючи на це, явна тенденція щодо залежності відсотку надійності від числа представників класу відсутня. Наприклад, більш чисельний клас «Епітелій» має меншу частку надійних екземплярів ніж клас «Лімфоцит».

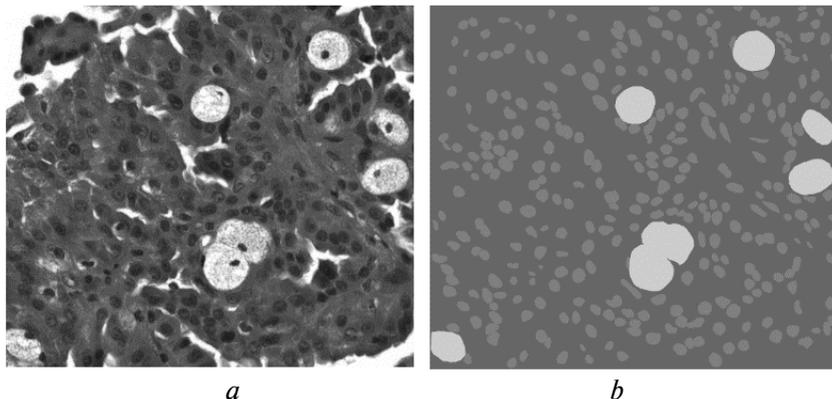


Рис. 5. Приклад зображення (а) та істинної маски сегментації (б) з датасету MoNuSAC2020

Таблиця 2 Загальне число пікселів та частка ненадійних даних по кожному класу

Назва класу	Кількість пікселів, тис.	Відсоток надійних точок, %
Фон	60 719	44.68
Епітелій	8 990	34.66
Лімфоцит	3 138	42.28
Нейтрофіл	136	24.12
Макрофаг	1 136	24.06
Разом	74 121	43.01

2.2.3. РОЗВ'ЯЗАННЯ ЗАДАЧІ

Для розв'язання поставленої задачі пропонується використовувати просторові вагові коефіцієнти при обчисленні функції втрат. Для кожного фрагменту зображення на основі значень його пікселів генерується відповідна йому вагова маска.

Отримані маски використовуються для модифікації процесу тренування моделей глибокого навчання, шляхом зміни функції

втрат. Звичайну функцію втрат можна описати наступною залежністю:

$$Loss = F(\hat{Y}, \hat{Y}'), \quad (3)$$

де \hat{Y}, \hat{Y}' — істинна маска сегментації та маска, яку вивела модель, відповідно.

Запропонований метод ускладнює цю функцію, додаючи залежність від маски, яка виконує роль вагових коефіцієнтів для кожного пікселю:

$$Loss = F(\hat{Y}, \hat{Y}', \hat{M}), \quad (4)$$

де \hat{M} — вагова маска такої ж розмірності як і \hat{Y} .

Слід зазначити відмінності даного способу від інших методів введення вагових коефіцієнтів у функцію втрат. Відмінності від застосування вагових коефіцієнтів для кожного окремого класу у даному випадку очевидні, оскільки значення вагової маски у запропонованому підході не залежить прямо від істинного класу пікселів на фрагментів. Інший же підхід, який характеризується застосуванням вагових коефіцієнтів для кожного фрагменту з набору даних, є більш вузьким у порівнянні з представленим. Він має лише один коефіцієнт на індивідуальний фрагмент, який входить до набору даних, а запропонований метод має по одному коефіцієнту для кожного пікселю у кожному фрагменті. Відповідно, сукупність таких коефіцієнтів, впорядкована за координатами відповідних пікселів, може розглядатися як окреме зображення або ж маска, звідки і пішла їх назва.

2.2.3.1. ПОКРАЩЕННЯ АЛГОРИТМУ ВИЯВЛЕННЯ НЕОДНОЗНАЧНИХ ДАНИХ

Перші експерименти на датасеті MoNuSAC2020 з використанням вагових масок показали необхідність вдосконалення даного методу, а саме в частині алгоритму виявлення неоднозначних екземплярів даних.

Оригінальна версія алгоритму розглядає кожен піксель як окремий елемент, жодним чином не пов'язаний з сусідніми пікселями, замінюючи задачу сегментації на задачу по-піксельної класифікації. Незважаючи на таке спрощення, це показувало хороший результат в області обробки супутникових знімків, де вирішальним фактором є колір, а не форма, розмір чи інші ознаки. У даній же області, колір хоч і є важливою ознакою, але й інші властивості, зокрема форма, мають більше значення ніж раніше.

2.2. Методи сегментації зображень різної природи для випадку...

Тому виникла необхідність врахувати просторові властивості при визначенні неоднозначних пікселів.

При визначенні, які пікселі є сусідніми у просторі ознак, у першій версії алгоритму обчислювалася евклідова відстань між ними у просторі ознак:

$$\|\vec{X}_{i,j} - \vec{X}_{p,q}\|_{L_2}, \quad (5)$$

де $\hat{Y}: \{\vec{X}_{i,j}\}$ — зображення \hat{X} , що складається з пікселів $\vec{X}_{i,j}$, а i, j та p, q — координати пікселів на зображенні. Довжина вектору $\vec{X}_{i,j}$ дорівнює числу каналів у зображенні, в даному випадку це 3. Значення каналу k в індивідуальному пікселі позначимо як $X_{i,j,k}$.

Основна ідея вдосконалення алгоритму полягає у тому, що при визначенні відстані у просторі ознак між двома пікселями, враховувати значення їхніх сусідніх пікселів в межах деякого радіусу R . Очевидно, що такі сусідні пікселі мають впливати на кінцеву величину відстані менше, ніж цільові два пікселі. Тому доцільно враховувати відстані між сусідніми пікселями з певним, нижчими за одиницю коефіцієнтами. Нехай K — така матриця коефіцієнтів, розмірами $[2R+1 \times 2R+1]$. Центральний її елемент дорівнює одиниці, решта знаходяться в межах $[0, 1)$:

$$K = \begin{pmatrix} K_{1,1} & \cdots & K_{1,R+1} & \cdots & K_{1,2R+1} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ K_{R+1,1} & \cdots & 1 & \cdots & K_{R+1,2R+1} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ K_{2R+1,1} & \cdots & K_{2R+1,R+1} & \cdots & K_{2R+1,2R+1} \end{pmatrix}. \quad (6)$$

$$0 \leq K_{i,j} < 1, i \neq R+1, j \neq R+1$$

Різниця між каналом k двох цільових пікселів $\vec{X}_{i,j}$ та $\vec{X}_{p,q}$, з урахуванням сусідніх пікселів обчислюється за наступною формулою:

$$\|X_{i,j,k} - X_{p,q,k}\|_{ch} = \sum_{f=-R}^{+R} \sum_{g=-R}^{+R} K_{f+R+1,g+R+1} (X_{i+f,j+g,k} - X_{p+f,q+g,k}). \quad (7)$$

Це зважена середня різниця значень певного каналу пікселів. З урахуванням дистрибутивності множення, та комутативності додавання перепишемо ще в наступному вигляді:

$$\begin{aligned} \|X_{i,j,k} - X_{p,q,k}\|_{ch} &= \sum_{f=-R}^{+R} \sum_{g=-R}^{+R} K_{f+R+1,g+R+1} X_{i+f,j+g,k} - \\ &- \sum_{f=-R}^{+R} \sum_{g=-R}^{+R} K_{f+R+1,g+R+1} X_{p+f,q+g,k}. \end{aligned} \quad (8)$$

Отримані два доданки є нічим іншим як формулою згортки з ядром K над k каналом пікселів $\vec{X}_{i,j}$ та $\vec{X}_{p,q}$ відповідно. Для того, щоб уникнути обчислення згортки кожного разу при визначенні різниці між двома пікселями, є сенс обрахувати згортку заздалегідь для всього зображення. Нехай \hat{X}' — зображення, отримане шляхом по-канальної згортки ядра K з оригінальним зображенням \hat{X} :

$$\begin{aligned} X_{i,j,k}' &= \sum_{f=-R}^{+R} \sum_{g=-R}^{+R} K_{f+R+1,g+R+1} X_{i+f,j+g,k}, \quad \forall i,j,k \\ \hat{X}' &= K * \hat{X}. \end{aligned} \quad (9)$$

У результаті, відстань між двома пікселями у просторі ознак з урахуванням їх сусідів ($L2_{nn}$) обчислюється як:

$$\begin{aligned} \|\vec{X}_{i,j} - \vec{X}_{p,q}\|_{L2_{nn}} &= \sqrt{\sum_k (X_{i,j,k}' - X_{p,q,k}')^2} = \\ &= \|\vec{X}_{i,j}' - \vec{X}_{p,q}'\|_{L2}. \end{aligned} \quad (10)$$

Як висновок, визначення неоднозначних пікселів у наборі зображень з урахуванням просторовості, математично еквівалентне застосуванню згортки з ядром K до всього набору зображень, та запуску на ньому оригінального, по-піксельного алгоритму виявлення неоднозначних даних. Застосування згортки зводить дану задачу до попередньої.

Нову версію алгоритму використано для визначення неоднозначних пікселів у датасеті MoNuSAC2020. У якості ядра

2.2. Методи сегментації зображень різної природи для випадку...

згортки K , вибрано гауссівське ядро розмірами 5×5 . Застосування такого ядра до зображення є нічим іншим як гауссівським розмиттям цього зображення. Далі застосовано звичайну, по-піксельну версію алгоритму на невеликій підмножині датасету. На її основі визначено приналежність до неоднозначних даних для повного датасету та згенеровано відповідні вагові маски. Статистика що до частки неоднозначним даних по кожному класу та загалом представлено у табл. 3.

Для класів «Фон», «Епітелій» та «Лімфоцит» значно виросла частка надійних екземплярів. Це можна спробувати пояснити тим, що представники даних класів є подібними до інших, якщо розглядати задачу по-піксельної класифікації. Натомість, врахування просторових властивостей зображення, а саме значень у сусідніх пікселях, дає змогу краще розрізнити дані класи. Натомість, для класів «Нейтрофіл» та «Макрофаг» ситуація протилежна – збільшилася частка ненадійних екземплярів, для цих класів врахування просторовості зменшило їх відмінності від інших класів. Це може бути пов'язаним з наявністю викидів та екстремальних значень серед представників цих класу, вплив яких зменшився через врахування просторовості. Іншим поясненням може бути малі розміри цих клітин: розглядаючи окремі екземпляри класів, можна зауважити що значна частка їхніх сусідів будуть вже представниками інших класів.

Таблиця 3 Загальне число пікселів та частка ненадійних даних по кожному класу з урахуванням сусідніх пікселів

Назва класу	Кількість пікселів, тис.	Відсоток надійних точок, %
Фон	60 719	78.43
Епітелій	8 990	53.45
Лімфоцит	3 138	52.74
Нейтрофіл	136	1.23
Макрофаг	1 136	4.49
Разом	74 121	73.04

2.2.3.2. НАБОРИ ВАГОВИХ МАСОК

Згідно з даними табл. 3, майже всі пікселі у найбільшому класі «Фон» є надійними, а більшість пікселів з інших класів є ненадійними. У попередніх експериментах з супутниковими

знімками перевірялося, даним якого саме типу слід надати перевагу через вагові маски — чи надійним, чи ненадійним. У даному випадку, з огляду на статистику датасету, очевидним є надати перевагу неоднозначним даним. Надати перевагу нормальним пікселям — означає зробити фокус моделі на найбільш представленому класі, який відповідає фону, та значно зменшити акцент моделі на найменш представлені класи, які відповідають різним типам клітин.

Згенеровано 2 набори вагових масок, де неоднозначні пікселі мали більші значення відповідних коефіцієнтів у вагових масках. Для повноти експерименту, також було згенеровано ще один набір вагових масок, де фокус надавався нормальним даним. Морфологічні перетворення було вирішено не застосовувати через неоднорідну структуру вагових масок. Повна інформація про набори представлена у табл. 4.

Приклади вагових масок з різних наборів зображені на рис. 6.

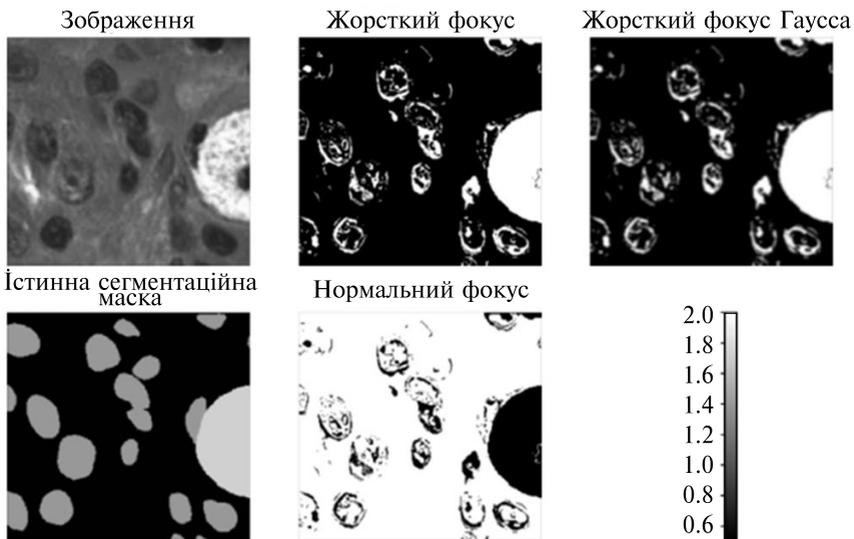


Рис. 6. Візуалізація гістологічного зображення та відповідної йому маски з набору

З цих зображень можна зробити висновок, що деякі клітини повністю віднесені до неоднозначних даних, а інші — лише частково. У таких клітинах до неоднозначних даних віднесені

2.2. Методи сегментації зображень різної природи для випадку...

лише їх периферичні області, що вказує на особливу складність розпізнавання межі клітини та фону. Більшість пікселів, що відповідають фону, віднесені до надійних даних, окрім невеликої частки структур, що схожі за своїми спектральними властивостями на клітини.

Таблиця 4 Список перетворень, застосованих до різних наборів вагових масок)

№	Назва набору	Фокус вагових коефіцієнтів	Гауссове розмиття
1	Normal focus	нормальні пікселі (4:1)	-
2	Hardcase focus	неоднозначні пікселі (4:1)	-
3	Hardcase focus Gauss	неоднозначні пікселі (4:1)	5×5

2.2.3.3. АРХІТЕКТУРА МОДЕЛІ ТА СХЕМА ЕКСПЕРИМЕНТУ

У зв'язку з набагато складнішою структурою даних на зображенні та великою варіабельністю текстур, прийнято рішення використати іншу архітектуру моделі, а саме SegNet [30], який має вдвічі більше параметрів за попередню модель, засновану на U-Net. На рис. 7 представлена архітектура моделі. Вона приймає на вхід дані розмірністю $[N \times 256 \times 256 \times 3]$, та видає результат розмірністю $[N \times 256 \times 256 \times 5]$, де N — кількість зображень у навчальному пакеті.

Оптимізація параметрів моделі виконувалася з використанням оптимізатора Adam за параметрами $\beta_1=0.9$ та $\beta_2=0.999$. Швидкість навчання змінювалася динамічно в межах $[1 \cdot 10^{-1}, 1 \cdot 10^{-5}]$.

Для навчання базової моделі у якості функції втрат використовувалося стандартна крос-ентропія. Під час навчання моделі з використанням методу вагових масок, використовувалася модифікована крос-ентропія:

$$BCE(\hat{Y}, Y', \hat{M}) = \frac{-1}{n} \sum_{i,j} M_{ij} \sum_{k=1}^c Y_{ijk} \log(Y_{ijk}'), \quad (11)$$

де \hat{Y}, \hat{Y}' — сегментаційні маски, істинна і передбачена відповідно, \hat{M} — вагова маска, n — кількість пікселів в одному фрагменті, C — кількість класів.

Всього було навчено 4 моделі — одна базова і 3 — з використанням різних наборів вагових масок.

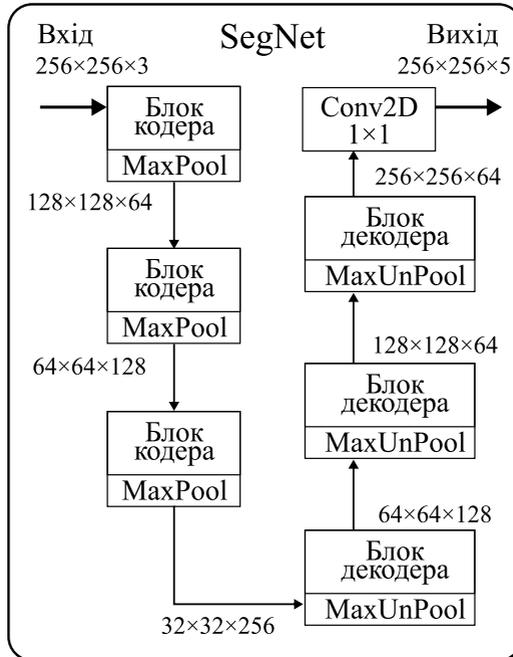


Рис. 7. Архітектура сегментаційної моделі

2.2.4. ОБГОВОРЕННЯ І ВИСНОВКИ

Навчені моделі оцінено на незалежному наборі даних, який не використовувався при навчанні. Обраховано метрики, такі як точність, влучність (precision), повнота (recall) та IoU. Детальні результати наведені у табл. 5.

Як і очікувалось, модель, що тренувалася з акцентом на нормальні дані, не продемонструвала покращення метрик малих класів у порівнянні з базовою моделлю.

2.2. Методи сегментації зображень різної природи для випадку...

Таблиця 5 Порівняння метрик моделей сегментації гістологічних зображень (метрики, вищі за базову модель, виділено жирним шрифтом)

Назва класу	Model (I)			Model (II)			Model (III)			Model (IV)		
	UA (%)	PA (%)	IoU	UA (%)	PA (%)	IoU	UA (%)	PA (%)	IoU	UA (%)	IoU	
Фон	93.0	96.1	89.6	93.6	96.0	90.1	93.0	95.7	89.3	92.9	94.5	88.1
Епітелій	81.9	71.9	62.1	76.9	74.3	60.8	82.7	73.5	63.7	83.7	69,7	61.4
Лімфоцит	81.0	71.3	61.1	77.5	72.5	59.9	84.8	68.2	60.7	79,0	74,4	62.1
Нейтрофіл	0.0	0.0	0.0	0.0	0.0	0.0	48.3	42.9	29.4	23,0	10.1	7.6
Макрофаг	4.9	3.0	1.9	24.8	2.3	2.1	11.4	11.9	6.2	5.4	9.6	3.6
ААС (%)	52.1	48.5	42.9	54.6	49.0	42.6	64.0	58.4	49.9	56.8	51.7	44.6
ОА (%)	90.5		83.4	90.7		83.6	90.3		83.4	89.1		82.6

Інші дві моделі розрізняють малі класи суттєво краще за базову модель. Вагові маски цих моделей мали більше значення коефіцієнтів для неоднозначних пікселів, ніж для нормальних, а до набору масок останньої моделі також було застосовано Гауссове розмиття з ядром 5×5. Модель, що вчилася з використанням набору масок Hardcase focus, перевищує базову модель майже в усіх метриках, які стосуються малих класів, а загальні метрики змінилися незначно. Особливо слід відзначити те, що базова модель нездатна розпізнати клас «Макрофаг», а використання вагових масок дало можливість правильно розпізнавати цей клас майже в половині випадків (рис. 8).

У попередніх дослідах, для задачі сегментації найкраще працювали вагові маски, де більші значення коефіцієнтів відповідали неоднозначним пікселям. У даному експерименті ситуація протилежна. Це може бути пов'язано з наявністю домінантного класу «Фон», число екземплярів якого набагато більше за усі інші класи разом узяті. Алгоритм визначення неоднозначним даних відніс більшість екземплярів цього класу до однієї категорії. Як наслідок, модель мала шанси вивчити малі

класи лише якщо цій категорії буде присвоєний низький пріоритет.

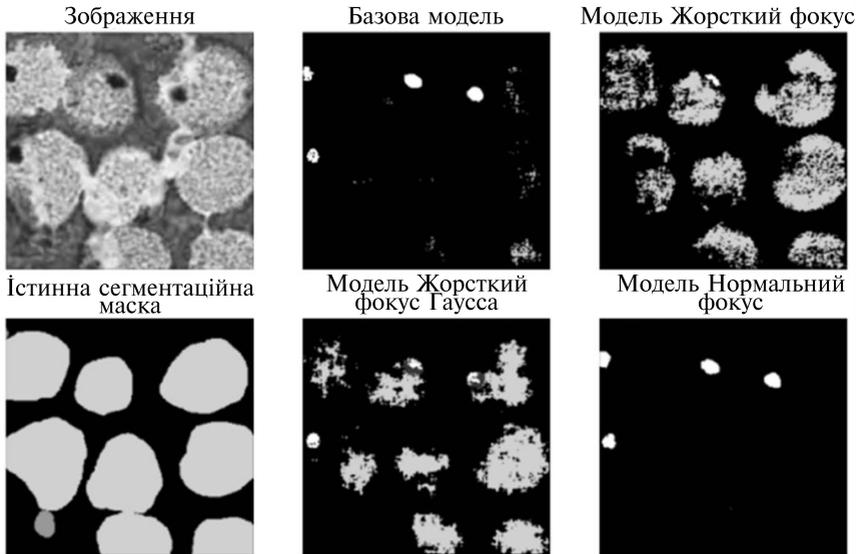


Рис. 8. Візуалізація гістологічних зображень, істинних масок сегментації (істинні класи), результатів роботи базової моделі та результати роботи моделей з використанням вагових масок

Представники доміантного класу знаходяться у просторі ознак у великих кількостях, і у разі наявності проблеми перекриття класів, з більшою імовірністю будуть вибрані як сусіди під час роботи алгоритму виявлення неоднозначних даних. Це узгоджується з реальними результатами, коли модель має тенденцію вивчати найбільш представлений клас, ігноруючи малі класи. У даному датасеті, приблизно половина пікселів класів «Епітелій» та «Лімфоцит» знаходилися у просторі ознак достатньо далеко, щоб бути чітко розрізненими від інших класів та не отримати такого суттєвого фокусу під час навчання, як класи «Нейтрофіл» чи «Макрофаг». Тим не менш, метрики цих класів також збільшилися у порівнянні з базовою моделлю.

ВИСНОВКИ

На основі результатів проведених досліджень та отриманих результатів можна зробити наступні висновки. Запропоновано

2.2. Методи сегментації зображень різної природи для випадку...

новий підхід до аугментації даних для розв'язання задачі класифікації сільськогосподарських культур на основі моделі GAN pix2pix для генерації реалістичних зображень, які відповідають багатоспектральним та текстурним характеристикам. Це дозволило усунути проблему дисбалансу набору даних для глибокого навчання методами семантичної сегментації. Запропонований метод було порівняно з класичними підходами до генерації зображень на основі статистичних характеристик багатоспектральних ознак класів сільськогосподарських культур. Запропонований метод був протестований на основних аугментаціях та функціях втрат, які застосовуються в випадку дисбалансу класів. В результаті запропонований метод виявився кращим порівняно з моделями, навченими на основі лише реальних даних та класичних підходів. Для більшості класів сільськогосподарських культур спостерігалось значне підвищення точності для всіх мало представлених класів. Загальна точність моделі, навченої за запропонованим підходом, покращилася на 1.5% і 2.1% для OA та IoU, в той час як середні значення UA, RA та IoU для класів сільськогосподарських культур зросли на 11.2%, 6.4% та 10.2% порівняно з моделлю, навченою без синтетичних зображень.

Також розглянуто застосування методу вагових масок для сегментації гістологічних знімків. Дані з обраного датасету мали сильний дисбаланс у розподілі класів, а подальший аналіз датасету вказав на наявність проблеми перекриття класів. Запропоновано вдосконалену версію алгоритму виявлення неоднозначних екземплярів даних, яка враховує просторові властивості зображення, а саме значення сусідніх пікселів при обрахунку відстані у просторі ознак. Доведено, що дану версію алгоритму можна звести до попередньої шляхом застосування до зображення операції згортки з ядром коефіцієнтів. Проведено порівняння розробленого методу зі стандартною процедурою навчання моделі на тих самих даних і тією самою архітектурою моделі. За результатами порівняння, використання розробленого методу збільшує точність розпізнавання усіх малих класів, які відповідають різним типам клітин, однак значення загальних метрик залишається незмінними. Для даної задачі найкращі результати давали маски, де ненадійним пікселям присвоювалися більші значення вагових коефіцієнтів. Це пояснюється наявністю домінантного класу, більшість представників якого мали статус надійних.

ПЕРЕЛІК ПОСИЛАНЬ

1. Franch B., Vermote E., Skakun S., Santamaria-Artigas A., Kalecinski N., Roger J.-C., et al. The ARYA crop yield forecasting algorithm: Application to the main wheat exporting countries. *International Journal of Applied Earth Observation and Geoinformation*. 2021. Vol. 104. pp. 102552. DOI: 10.1016/j.jag.2021.102552.
2. Kussul N., Lavreniuk M., Kolotii A., Skakun S., Rakoid O., Shumilo L. A workflow for Sustainable Development Goals indicators assessment based on high-resolution satellite data. *International Journal of Digital Earth*. 2019. Vol. 13, no. 2. pp. 309-321. DOI: 10.1080/17538947.2019.1610807.
3. Boryan C., Yang Z., Mueller R., Craig M. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, cropland data layer program. *Geocarto International*. 2011. Vol. 26, no. 2. pp. 341-358. DOI: 10.1080/10106049.2011.562309.
4. Defourny P., Bontemps S., Bellemans N., Cara C., Dedieu G., Guzzonato E., et al. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. *Remote sensing of environment*. 2019. Vol. 221. pp. 551-568. DOI: 10.1016/j.rse.2018.11.007.
5. Moazzam S.I., Khan U.S., Tiwana M.I., Iqbal J., Qureshi W.S., Shah S.I. A review of application of deep learning for weeds and crops classification in agriculture. *2019 International Conference on Robotics and Automation in Industry (ICRAI)*. 2019. pp. 1-6. DOI: 10.1109/ICRAI47710.2019.8967350.
6. Xu W., Deng X., Guo S., Chen J., Sun L., Zheng X., et al. High-resolution u-net: Preserving image details for cultivated land extraction. *Sensors*. 2020. Vol. 20, no. 15. pp. 4064. DOI: 10.3390/s20154064.
7. Shorten C., Khoshgoftaar T.M. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019. Vol. 6, no. 1. pp. 60. DOI: 10.1186/s40537-019-0197-0.
8. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., et al. Generative adversarial networks.

2.2. Методи сегментації зображень різної природи для випадку...

Communications of the ACM. 2020. Vol. 63, no. 11. pp. 139-144. DOI: 10.1145/3422622.

9. Pham V.D., Bui Q.T. Spatial resolution enhancement method for Landsat imagery using a Generative Adversarial Network. *Remote Sensing Letters*. 2021. Vol. 12, no. 7. pp. 654-665. DOI: 10.1080/2150704x.2021.1918789.

10. Abady L., Barni M., Garzelli A., Tondi B. GAN generation of synthetic multispectral satellite images. *Image and Signal Processing for Remote Sensing XXVI*. 2020. Vol. 11533. pp. 122-133. DOI: 10.1117/12.2575765.

11. Xu Z., Du J., Wang J., Jiang C., Ren Y. Satellite image prediction relying on GAN and LSTM neural networks. *ICC 2019 - 2019 IEEE International Conference on Communications (ICC)*. 2019. pp. 1-6. DOI: 10.1109/icc.2019.8761462.

12. Christovam L.E., Shimabukuro M.H., Galo M.D.L.B., Honkavaara E. Pix2pix conditional generative adversarial network with MLP loss function for cloud removal in a cropland time series. *Remote Sensing*. 2021. Vol. 14, no. 1. pp. 144. DOI: 10.3390/rs14010144.

13. Andrade H.J., Fernandes B.J. Synthesis of satellite-like urban images from historical maps using conditional GAN. *IEEE Geoscience and Remote Sensing Letters*. 2022. Vol. 19. pp. 1-4. DOI: 10.1109/lgrs.2020.3023170.

14. Kussul N., Shelestov A., Yailymova H., Yailymov B., Lavreniuk M., Ilyashenko M. Satellite agricultural monitoring in Ukraine at country level: World Bank Project. *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. 2020. pp. 1050-1053. DOI: 10.1109/igarss39084.2020.9324573.

15. Shumilo L., Okhrimenko A., Kussul N., Drozd S., Shkalikov O. Generative adversarial network augmentation for solving the training data imbalance problem in crop classification. *Remote Sensing Letters*. 2023. Vol. 14, no. 11. pp. 1131-1140. DOI: 10.1080/2150704X.2023.2275551.

16. Bowles C., Chen L., Guerrero R., Bentley P., Gunn R., Hammers A., et al. Gan augmentation: Augmenting training data using generative adversarial networks. *arXiv preprint arXiv*. 2018. DOI: 10.48550/ARXIV.1810.10863.

17. Isola P., Zhu J.Y., Zhou T., Efros A.A. Image-to-image translation with conditional adversarial networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017. pp. 1125-1134. DOI: 10.1109/cvpr.2017.632.

18. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. 2015. pp. 234-241. DOI: 10.1007/978-3-319-24574-4_28.

19. Wang P., Bai X. Thermal infrared pedestrian segmentation based on conditional GAN. *IEEE transactions on image processing*. 2019. Vol. 28, no. 12. pp. 6007-6021. DOI: 10.1109/tip.2019.2924171.

20. Rawat W., Wang Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*. 2017. Vol. 29, no. 9. pp. 2352-2449. DOI: 10.1162/neco_a_00990.

21. Ahmed N. Real-time and accurate deep learning-based multi-organ nucleus segmentation in histology images. *Journal of Real-Time Image Processing*. 2024. Vol. 21. DOI: 10.1007/s11554-024-01420-0.

22. Wu Y., Cheng M., Huang. Sh. et al. Recent Advances of Deep Learning for Computational Histopathology: Principles and Applications / Yawen Wu, Michael Cheng, Shuo Huang et al. // *Cancers*. 2022. Vol. 14. P. 1199. DOI: 10.3390/cancers14051199.

23. Nasir E., Fraz M. NuRISC: Nuclei Radial Instance Segmentation and Classification. *Lecture Notes in Electrical Engineering*. Vol. 810 LNEE. 2023. DOI: 10.1007/978-981-16-6775-6_4.

24. Liang S., Tian Sh., Yu L., Kang X. Improved U-Net based on contour attention for efficient segmentation of skin lesion. *Multimedia Tools and Applications*. 2024. Vol. 83. DOI: 10.1007/s11042-023-16759-y.

25. Kadaskar M., Patil N. Image Analysis of Nuclei Histopathology Using Deep Learning: A Review of Segmentation, Detection, and Classification. *SN Computer Science*. 2023. Vol. 4. DOI: 10.1007/s42979-023-02115-2.

26. Hancer E., Traory M., Samet R. et al. An imbalance-aware nuclei segmentation methodology for H&E stained histopathology images. *Biomedical Signal Processing and Control*. 2023. Vol. 83. DOI: 10.1016/j.bspc.2023.104720.

2.2. Методи сегментації зображень різної природи для випадку...

27. Li H., Zhao X. Su A. et al. Color Space Transformation and Multi-Class Weighted Loss for Adhesive White Blood Cell Segmentation. *IEEE Access*. 2020. Vol. 8. DOI: 10.1109/ACCESS.2020.2970485.

28. Li W., Li J., Polson J. et al. High resolution histopathology image generation and segmentation through adversarial training. *Medical Image Analysis*. 2022. Vol. 75. DOI: 10.1016/j.media.2021.102251.

29. Verma R., Kumar N., Patil A. et al. MoNuSAC2020: A Multi-Organ Nuclei Segmentation and Classification Challenge. *IEEE Transactions on Medical Imaging*. 2021. Vol. 40. DOI: 10.1109/TMI.2021.3085712.

30. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. — 2017. — Vol. 39. DOI: 10.1109/TPAMI.2016.2644615.

3. 1+λ GP ENCODINGS ЕВОЛЮЦІЙНИЙ АЛГОРИТМ ДЛЯ БЕЗПЕЧНОЇ РОБОТИ З ДАНИМИ РІЗНИХ МОДАЛЬНОСТЕЙ

Олександр Яворський, аспірант
Дмитро Харь, магістр

Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

yaotianjiu@gmail.com, khar.dmytro@gmail.com

ВСТУП

Машинне навчання, зокрема з використанням нейронних мереж, активно впроваджується у великій кількості галузей, від медицини та фізики [1-4] до оптимізації показів реклами та інформаційної безпеки [5-8]. Однією з суттєвих відмінностей машинного навчання, що базується на використанні нейронних мереж, від так званих класичних алгоритмів та статистичного машинного навчання є проблема чорної скрині. Дана проблема описує ситуацію, коли зовнішній спостерігач не може дослідити кроки, які привели до отримання результату. А точніше, не може отримати їх формальне представлення, що, на практиці, унеможливує пояснення того, яким чином було отримане те чи інше значення заданим алгоритмом [9-10]. Варто зазначити, що мова йде саме про етап навчання, оскільки отримання результату від навченої моделі добре зрозумілий і часто базується на використанні тих чи інших функцій схожості.

У свою чергу ця особливість нейронних мереж призводить до можливості атак даних алгоритмів під час навчання, знижуючи таким чином як фактичну безпеку рішень, що будуються на їх основі, так і впливаючи на загальний рівень довіри до таких рішень. Разом з цим, навіть ті мережі, що вже були навчені, можна піддавати атакам. Дійсно, як показано в [11-12], нейронні мережі можуть стабільно перевершувати людей-спеціалістів у сфері медицини за якістю своєї роботи, утім через відсутність вищезазначеної «прозорості» у їх роботі, використання даних підходів є порівняно обмеженим. Це ж можна сказати і про інші сфери, де безпека є домінуючим фактором, наприклад, в інформаційній безпеці, інженерії тощо.

Зважаючи на це, постає питання про дослідження у сфері пояснення роботи алгоритмів штучного інтелекту (англ., *Explainable AI*), а також про використання альтернативних методів, які, маючи достатню точність, надають дослідникам та користувачам можливість зрозуміти те, як саме було отримано те чи інше рішення. Разом з цим алгоритми, що будуються на основі нейронних мереж, мають певні структурні особливості, що уможливають атаки на дані алгоритми без порушення базових безпекових засад їх системної реалізації. Іншими словами, зловмисник може керувати результатом певних, або впливати одразу на велику кількість, відповідей, що продукуються такими моделями. Це, у комбінації з вищезгаданою відсутністю прозорості, створює суттєві перешкоди перед ефективним та безпечним використанням даних підходів. У даному розділі будуть розглянуті альтернативні методи, що мають кращу інтерпретабельність і при цьому мають меншу вразливість до певних видів атак.

3.1. $1+\lambda$ ЕВОЛЮЦІЙНИЙ АЛГОРИТМ З GP КОДУВАННЯМ

Однією з причин активного використання нейронних мереж є те, що алгоритми на їх основі можуть бути універсальними апроксиматорами [13], що є загальновідомим. Разом з тим, той факт, що нейронні мережі не є єдиними універсальними апроксиматорами, часто оминається. Це пов'язано в першу чергу з тим, що доведення універсальності не є тривіальним завданням і гарантує, здебільшого, теоретичний результат, а не практичний. В цьому підрозділі ми розглянемо один із таких універсальних апроксиматорів $1+\lambda$ еволюційний алгоритм з GP кодуванням (« $1+\lambda$ EA»), чия «універсальність» була нещодавно доведена [14].

Формально, еволюційний алгоритм EA можна представити як четвірку $EA(P, Off, i, Sel, Mut)$, де P позначає батьків (початковий, часто випадковий, набір можливих розв'язків-індивідів), Off (англ., *offspring*) — нащадки-індивіди, Sel (англ., *selection*) — функція або алгоритм вибору, що визначає який індивід є оптимальним, здійснюючи тим самим процес навчання, Mut (англ. *mutation*), у свою чергу, позначає функцію мутації, що вносить випадкові або частково-випадкові зміни у можливі розв'язки, а i — відповідна ітерація алгоритму.

Що ж стосується GP кодування, то під ним, як і в [13], мається на увазі спеціальний тип представлення (англ., *encoding*),

суть якого полягає у використанні обмеженої кількості термінальних значень та операторів, якими може користуватись алгоритм для побудови розв'язку. Таким чином, на відміну від нейронних мереж, структурна варіативність розв'язків, що продукуються $1+\lambda$ EA з GP кодуванням є набагато меншою.

Це, в свою чергу, має специфічні наслідки для роботи алгоритму. З одного боку, глибокий контроль над можливими розв'язками дозволяє гарантувати високий рівень безпеки роботи алгоритму, з точки зору можливого “дрейфу” моделі в бік певних результатів під час донавчання та під час самої роботи, оскільки дозволяє математично оцінити “межі” розв'язків та відмінності між конкуруючими чи новоотриманими. У той же час, якщо наявна специфічна інформація про структуру розв'язку, як це буває у випадку використання фізично-інформованих нейронних мереж (англ., *PINNs*), це дозволяє отримати більш стабільний та швидкий процес навчання та мати певні “гарантії” щодо розв'язку. З іншого ж боку, така обмеженість може призводити до субоптимальних розв'язків для задач, про чиї розв'язки мало що відомо перед початком навчання.

Роботу $1+\lambda$ EA можна представити наступним чином. Першим кроком ініціалізується індивід, в нашому випадку індивідом буде дерево, у якого в якості внутрішніх вузлів виступають функції, які мають арність 2, а в якості листків — ознаки датасету або константи з набору: 1, 0, -1, e , π . Для цього індивіду розраховується фітнес-функція. Після того, як була розрахована фітнес-функція для створеного індивіду, він мутує λ разів, таким чином ми отримуємо λ нових індивідів. Мутація в даному випадку відбувається наступним чином: випадково обирається один вузол з усього індивіду і його значення замінюється на якесь інше випадкове, валідне значення (у випадку внутрішніх вузлів — значення замінюється на якусь іншу функцію, а у випадку листків на якусь іншу ознаку, або константу). Після цього розраховуються фітнес-функції для усіх новостворених індивідів і обирається індивід, який має найменше значення фітнес-функції. Далі цей індивід виступає в ролі батька на наступних ітераціях.

Еволюційні алгоритми та методи генетичного програмування є добре вивченими підходами для моделювання та побудови передбачень, вони, як і нейронні мережі, широко використовуються в різних галузях [15-19]. Алгоритм $1+\lambda$ є порівняно новим представником сімейства еволюційних підходів, але його варіації вже зарекомендували себе, наприклад, у роботі

перестановками [20-21]. Що ж стосується дослідження роботи самого алгоритму, то важливим є аналіз його ефективності для лінійних псевдо-Булевих функцій [22], особливості вибору розміру множини нащадків [23] та загальної популяції індивідів [24].

Разом з цим, більшість обчислювальних експериментів були скоріш “елементарними” [25] або технічними, як OneMinMax [26]. Це пов’язано в першу чергу з тим, що такі алгоритми мають гарну аналітичну інтерпретованість і їх швидкість сходження та низка інших важливих параметрів можуть бути оцінені у строгий спосіб. Утім, як відомо з історії, не дивлячись на формальну універсальність багат шарового перцептрона, його практичне використання не є настільки ж безхмарним, що першочергово було оцінено шляхом проведення експериментів з так званими даними з реального світу. Що і мотивує дане дослідження.

Наразі, для роботи із зображеннями та різними типами табличних даних використовуються різноманітні алгоритми на основі нейронних мереж, як було зазначено в [1-12]. Серед, мабуть, найпопулярніших підходів на даний момент варто виділити конволюційні нейронні мережі (англ., *CNN*), ResNet та AlexNet та їх варіації для роботи з зображеннями. Для роботи з даними, що мають табличний вигляд, в залежності від задачі, популярним є або використання великих мовних моделей (англ., *LLM*) в комбінації з різними методами підготовки даних, що утворюють так звані системи розширеного пошуку та генерації (англ., *Retrieval Augmented Generation, RAG*), або ж більш класичні підходи, що базуються на багат шарових перцептронах або ResNet. Разом з цим існують і змішані підходи, де алгоритм, що базується на нейронних мережах, поєднується з більш класичним, як, наприклад, у випадку алгоритмів нейронних лісів.

Як буде показано далі, $1+\lambda$ EA підхід може показувати високу ефективність, у порівнянні з багат шаровим перцептроном (англ., *MLP*). Разом з тим, такий підхід може виявитися субоптимальним, коли мова йде про порівняно складні набори даних, наприклад, під час роботи з зображеннями. Це пов’язано з тим, що базовий підхід не має методів, які б підвищували більшу стабільність алгоритму та можливість самостійного виходу з локальних мінімумів.

3.2. ПОСТАНОВКА ЗАДАЧІ ТА ЗАПРОПОНОВАНИЙ ПІДХІД

Метою даної роботи є розгляд якісних результатів двох реалізацій $1+\lambda$ еволюційного алгоритму. Фактично, задачею алгоритму буде вивчення двох наборів даних для задач бінарної класифікації на табличних даних та багатокласової класифікації зображень. Обидва набори даних мають медичне спрямування.

Як було зазначено раніше, в межах даного розділу розглядається ситуація, коли використання алгоритмів на основі нейронних мереж може мати негативні безпекові наслідки. Простим прикладом такої ситуації може слугувати наступний випадок. Вважатимемо, що державна або приватна установа має на меті розробку нового, або апробацію вже реалізованого, алгоритму, що може в автоматичному режимі визначити наявність певного захворювання. Для цього автори алгоритму надали доступ до нього в мережі Інтернет і будь-яка особа може в ручному або автоматичному режимі за допомогою API завантажити свої дані до моделі та отримати прогноз, чи має вона дане захворювання.

В такій ситуації, зловмисник може здійснити атаку на даний алгоритм та модифікувати результати його роботи. Важливим є те, що атака може бути здійснена без прямого порушення безпекових режимів установи, а лише шляхом завантаження даних, що мають певні математичні характеристики. Можливість атаки не залежить від того, чи знає зловмисник про модель, що була використана, чи ні [27-30].

Оскільки не можна гарантувати, чи був окремий запит або їх послідовність до алгоритму спланованою атакою, бажаним є або використання алгоритму, що легко інтерпретується, або складної системи запобіжників, яка не завжди зможе відрізнити “злаякісні” та “доброякісні” запити. Для цього і пропонується дослідження якості роботи $1+\lambda$ EA, як прикладу моделі, що легко інтерпретується, та зміни в якій легко відслідкувати, а отже, і запобігти небажаному чи просто підозрілому дрейфу моделі в бік певних результатів.

Наприкінці попереднього розділу було зазначено, що стандартна реалізація $1+\lambda$ EA може мати порівняно низьку якість та, як буде висвітлено в наступних розділах, занадто довгу сходимість. Для розв'язання цих проблем нами було запропоновано модифікацію цього підходу, порівняння якої зі стандартним можна представлено нижче на рис. 1.

Серед основних змін варто виділити наступні.



Рис. 1. Схеми роботи базового (а) та запропонованого (б) алгоритмів реалізації алгоритму $1+\lambda$ EA.

Додано *функцію перезапуску*, яка, у випадку стагнації швидкості навчання алгоритму використовує останнього найкращого індивіда та продукує 5λ його нащадків і таку саму кількість випадкових індивідів. Це дозволяє реініціалізувати

простір пошуку та згенерувати нових, більш оптимальних нащадків.

Зважаючи на випадковість генерації нащадків, було імплементовано *кешування індивідів*. Таким чином, якщо на i -й ітерації було створено індивід, що вже проходив оцінку, використовується попереднє її значення для аналізу якості розв'язку, що дозволило суттєво пришвидшити роботу алгоритму, зважаючи на велику кількість "копій" розв'язків, що генеруються.

Додано *функцію-кросовер*, що дозволяє комбінувати створені розв'язки-індивіди, що уможливорює створення більш різноманітних комбінацій генотипу (структури) індивідів. Це є особливо необхідним, оскільки, як зазначалося вище, алгоритм працює в доволі обмеженому просторі можливих представлень.

Крім цього, авторами було створено функцію пошуку сусідніх розв'язків, що дозволило як запобігти стагнації, так і покращити якість роботи алгоритму. Суть такого пошуку полягає в локалізованій мутації, що дозволяє швидко отримати схожі розв'язки. Для багатокласової класифікації у якості локалі розглядалися піддерева, тоді як для бінарної класифікації, мінімальним елементом слугували вершини дерева-розв'язку.

Додатково, було також використано *бетцінг* (групування) та *k-fold оцінку*. Кількість елементів в групі, параметри k -fold оцінки та інші гіперпараметри моделі було оптимізовано шляхом комбінації жадібного пошуку (*англ.* greedy search) та Байєсовської оптимізації.

3.3. НАБОРИ ДАНИХ

Для проведення експериментів нами було обрано два набори даних з різними модальностями (табличні дані та зображення) і сформовано для них задачі бінарної та мультикласової класифікації, відповідно. Нижче наведено короткий опис використаних датасетів.

Chest X-Ray Images (Pneumonia) [31] — набір даних, який використано для задач бінарної та багатокласової класифікації зображень у медичних дослідженнях. Цей датасет містить рентгенівські знімки грудної клітини пацієнтів з пневмонією (вірусною або бактеріальною) та без неї. Набір даних складається з 5 840 зображень, які віднесені до навчальної (Train) та валідаційної (Test) вибірок. Кожна категорія містить зображення, позначені як "Pneumonia" або "Normal", або якщо розглядати

задачу, як багатокласову класифікацію, то «Pneumonia» розділяється на «Virus» та «Bacteria».

Pima Indians Diabetes Database [32] — набір даних, який використано для задач бінарної класифікації табличних даних в області біомедичних досліджень. Цей набір даних був зібраний Національним інститутом діабету, шлункових і ниркових захворювань США (*англ.* National Institute of Diabetes and Digestive and Kidney Diseases). Набір даних містить інформацію про жінок з племені Піма, що проживають в Арізоні, та включає показники здоров'я, які можуть впливати на розвиток діабету. Набір даних складається з 768 зразків, кожний з яких має 8 вхідних ознак і два вихідних класи, які вказують на наявність або відсутність діабету. В наборі представлено наступні дані: Pregnancies — кількість вагітностей у жінки; Glucose — рівень глюкози у плазмі крові через 2 години після навантажувального тесту; Blood Pressure — діастолічний артеріальний тиск; Skin Thickness — товщина шкірної складки трицепса; Insulin — рівень інсуліну у сироватці крові; BMI — індекс маси тіла; Diabetes Pedigree Function — функція родоводу діабету (враховує генетичну спадковість); Age — вік пацієнта; цільова змінна: Outcome — наявність діабету (0 - відсутній, 1 — наявний). Датасет має збалансовані класи.

Для Pima Indians Diabetes Database була проведена наступна передобробка даних. Спочатку, були замінені нульові значення, які зустрічаються у деяких ознаках (Pregnancies, Glucose, BloodPressure, SkinThickness, Insulin, BMI, DiabetesPedigreeFunction, Age) на відсутні значення (NaN). Далі для кожної ознаки, у якої були відсутні значення, було обчислено медіанні значення для груп з позитивним та негативним результатом по діабету (Outcome). Відсутні значення заповнювалися відповідно до медіанної величини для відповідної групи, оскільки це дозволяє знизити вплив значень, що знаходяться в хвостах розподілів ознак. На практиці, для медичних даних табличного формату використання статистичної імпультації не завжди є гарним вибором, адже медичні показники часто не мають явних кореляцій і можуть мати, в певному сенсі, «асиметричні» значення, які і виступають маркерами належності до певного класу (напр., групи здорових пацієнтів та пацієнтів із захворюванням будуть мати певну асиметрію або декорельованість за певним списком параметрів, що й уможливорює їх віднесення до цих груп). Утім, використання більш складних і точних підходів до імпультації, зазвичай, стикається з проблемою взаємозалежних

передбачень. Іншими словами для того, щоб зробити передбачення щодо конкретного відсутнього значення в наборі даних, треба зробити загальне передбачення щодо класу (напр., здоровий чи хворий), і навпаки — значення класу залежить від окремих значень параметрів. Тому було обрано медіанний підхід, який, хоча і не дозволяє отримати ідеальні передбачення, допомагає підвищити обчислювальну стабільність на рівні алгоритму.

Після цього було проведено обробку змінної *Insulin* для видалення викидів. Викиди визначалися за допомогою методу *Interquartile Range Technique* [33]. Наступним кроком було виявлення та видалення викидів за допомогою методу *Local Outlier Factor* [34]. Цей метод використовує локальну щільність сусідів для визначення аномалій. Після розрахунку негативного фактору аномалії для кожного зразка, було визначено порогове значення, і видалено ті зразки, які мали значення нижче цього порогу.

Після видалення аномалій дані були розділені на ознаки та мітки. Вибірки було поділено на навчальний та тестовий набори даних у пропорції 80:20. Потім для навчального та тестового наборів було проведено стандартизацію ознак шляхом видалення середнього значення та масштабування до одиничної дисперсії. В результаті був отриманий оброблений датасет, який в подальшому використовуватиметься для порівняння моделей при розв'язанні задачі бінарної класифікації табличних даних.

Для *Pima Indians Diabetes Database* була проведена наступна підготовка даних. По-перше, дані були організовані у вигляді класів, де кожне зображення має відповідну мітку (0 — нормальний, 1 — бактеріальна пневмонія та 2 — вірусна пневмонія). Зображення були перетворені до розміру 224×224 пікселів і конвертовані в градації сірого для уніфікації формату. Для вилучення ознак було використано попередньо навчену модель *ResNet-50* [35] без останнього повнозв'язного шару. Модель була завантажена зі збережених ваг (які були налаштовані з використанням цього набору даних) та використана для отримання векторів ознак зображень. Далі для обробки отриманих векторів ознак було застосовано стандартизацію ознак шляхом видалення середнього значення та масштабування до одиничної дисперсії. Для зменшення розмірності та збереження 99% варіативності даних було застосовано Метод головних компонент [36]. В результаті ми отримали оброблені вектори ознак, готові до подальшого використання у навчанні.

3.4. ОСОБЛИВОСТІ НАВЧАННЯ

Як зазначалося раніше, алгоритм 1+ λ EA розглядається нами як альтернатива MLP, тому порівняльний аналіз було використано для цієї пари моделей. Алгоритм MLP було реалізовано на основі фреймворку Torch. Нижче представлено гіперпараметри для обох задач та моделей (табл. 1, табл. 2). Слід зазначити, що в табл. 2 представлені гіперпараметри для запропонованої, а не базової, варіації 1+ λ EA.

Таблиця 1 Гіперпараметри MLP для відповідних задач під час тренування

Гіперпараметри	Бінарна класифікація	Мультикласова класифікація
hidden_layer_sizes	(10, 15, 10)	(10, 10)
activation	tanh	tanh
solver	sgd	sgd
alpha	0.0009	0.0001
learning_rate_init	0.004	0.001
learning_rate	adaptive	invscaling
batch_size	32	128
tol	0.00002	0.00003

Таблиця 2 Гіперпараметри 1+ λ EA для відповідних задач під час тренування

Гіперпараметри	Бінарна класифікація	Мультикласова класифікація
lambda	2	4
restart_basic	75	75
restart_quick	15	15
restart_lambda_mult	5	5
batch_size	256	1024
tree_depth	2 or 3	2 or 3
nearest_solutions	5	10
full_batch_frequency	15	15
crossover_prob	0.5	0.5
crossover_parents	2	2

Деякі гіперпараметри алгоритму $1+\lambda$ EA має сенс розглянути більш детально. В табл. 2 *restart_basic* позначає, як часто відбувається реініціалізація простору індивідів, якщо відбувається стагнація навчання. У базовій варіації, значення *tree_depth* та *lambda* дорівнювали 3, для бінарної класифікації та *tree_depth* = 8 і *lambda* = 5 для багатокласової.

У свою чергу, *restart_quick* позначає, як швидко відбудеться перший рестарт алгоритму під час стагнації. Оскільки перша ініціалізація простору є випадковою, стагнація на порівняно високих значеннях функції втрат є не тільки ймовірною а й неоптимальною (тобто не позначає сходимість алгоритму).

Аналогічно, *restart_basic* регулює, як часто буде відбуватися перезапуск алгоритма з оновленим простором індивідів після першої стагнації.

restart_lambda_mult є множником, який використовується у функції перезапуску для підвищення різноманітності індивідів. Занадто великі значення можуть призводити до субоптимальних генерацій, в яких алгоритму важко знайти ефективні розв'язки, тоді як відсутність мультиплікатора (для невеликих значень *lambda*) означає маленьку вибірку нового простору, що теж негативно впливає на якість роботи алгоритму.

Параметр *tree_depth* приймає значення 2 або 3 випадковим чином для кожного дерева, регулюючи його максимальну глибину. Цікаво, що під час підбору оптимальних гіперпараметрів було виявлено, що більші значення глибини дерев не обов'язково призводять до швидкого перенавчання, хоча майже гарантовано негативно впливають на точність алгоритму. Це можна пояснити тим, що наявна конфігурація алгоритму не передбачає пустих значень вузлів дерев, тобто таких, які позначають відсутність перетворення (умовно, як множення на 1 чи додавання 0), у такому випадку неглибоке, оптимальне дерево пригнічується обов'язковими субоптимальними значеннями сусідніх вузлів або дерев.

Значення *nearest_solutions* впливає на те, скільки мутацій для дерева або вузла, обране під час певної ітерації, буде зроблено в якості пошуку більш оптимальної альтернативи. Великі значення цього параметра будуть призводити до перенавчання для наборів даних з великою варіативністю, але можуть бути гарним рішенням для низьковаріативних наборів.

full_batch_frequency регулює частоту оцінки розв'язку на всій множині тренувальних даних.

2.3. $1+\lambda$ GP encodings еволюційний алгоритм для безпечної роботи ...

Параметри *crossover_prob* та *crossover_parents* відповідають за ймовірність кросоверу та кількість батьків, що прийматимуть в ньому участь, тоді як *full_batch_frequency* позначає як часто відбувається оцінка індивіда-чемпіона для більшої частини тренувальної вибірки.

Для оцінки якості навчання нами для MLP алгоритму було використано BCELoss (Binary Cross Entropy) та Cross Entropy для бінарної та багатокласової задач класифікації, відповідно. BCELoss, або Критерій бінарної перехресної ентропії, визначається наступним чином для цільового значення та передбачення моделі, де останнє є певною ймовірністю значення класа для вхідного значення моделі:

$$\begin{aligned} l(x, y) &= \{l_1, \dots, l_N\}^T, \text{ де } y \in (0,1); \\ l_n &= -w_n[y_n * \log x_n + (1 - y_n) * \log(1 - x_n)]. \end{aligned} \quad (1)$$

Перехресна ентропія у свою чергу, визначається для двох розподілів у дискретному випадку як:

$$H = -\sum_{x \in X} p(x) \log q(x). \quad (2)$$

Обидві варіації $1+\lambda$ еволюційних алгоритмів поклалися на значення Log Loss (сума всіх елементів з $\{l_1, \dots, l_N\}^T$), яке обраховувалося після використання сігмоїди та softmax перетворень для бінарної та мультикласових задач в аналогічних випадках. Ми використовували класичні варіації зазначених функцій, а саме:

$$\text{sigmoid}(x) = 1/(1 + e^{-x}); \text{softmax}(x)_i = e^{x_i} / \sum_{j=1}^K e^{x_j}. \quad (3)$$

3.5. АНАЛІЗ РЕЗУЛЬТАТІВ ЕКСПЕРИМЕНТІВ

Спочатку розглянемо базову та запропоновану реалізації $1+\lambda$ еволюційного алгоритму.

Час виконання та кількість ітерацій для алгоритмів склали 50 ітерацій за 0.7326 секунд для базової варіації та 2500 ітерацій та 3146.1100 секунд для запропонованої. Як можна побачити, не дивлячись на значні зміни в логіці роботі алгоритму, базова версія має значну перевагу за часом та дещо перевершує за точністю.

Частина 2. Методи комп'ютерного зору і глибоких нейронних мереж...

Разом з цим, ми додатково проаналізували випадок використання 20 розділень для крос-валідації (замість базових 5 для всіх алгоритмів) та навчання протягом лише 100 ітерацій.

Такі результати можна пояснити тим, що невелика кількість параметрів набору даних, які необхідно вивчити алгоритмові та порівняно велика глибина базового підходу дозволяють швидко знайти гарний оптимум. У той же час оновлений підхід використовує меншу глибину дерев та більш складний процес підбору оптимальних індивідів, що вимагає більше часу, утім не має позитивного ефекту на генералізації алгоритму.

Порівнюючи MLP та базовий варіант алгоритму $1+\lambda$ EA можна побачити, що еволюційний підхід має суттєво кращу точність (як і запропонований підхід у порівнянні з MLP) і програє лише в значеннях повноти (англ., recall). В той же час отримані результати ілюструють, що для проміжної, 100-ї, ітерації значення повноти знаходиться в межах середньоквадратичної похибки, яка розрахована для даної моделі як 0.0513. Навчання такої моделі зайняло лише 89.1413 секунди (табл. 3, табл. 4).

Таблиця 3 Порівняння базового та запропонованого $1+\lambda$ алгоритмів для задачі бінарної класифікації табличних даних

Метрика / Модель	Basic $1+\lambda$ EA	Adjusted $1+\lambda$ EA 100 epochs	Adjusted $1+\lambda$ EA 2500 epochs
Accuracy	0.8882	0.8592	0.8724
Precision	0.8148	0.7580	0.8005
Recall	0.8627	0.8896	0.8552
F1-score	0.8381	0.8153	0.8232

Таблиця 4 Порівняння базового $1+\lambda$ EA та MLP для задачі бінарної класифікації табличних даних

Метрика / Модель	Basic $1+\lambda$ EA	Adjusted $1+\lambda$ EA 100 epochs	MLP
Accuracy	0.8882	0.8592	0.8421
Precision	0.8148	0.7580	0.7121
Recall	0.8627	0.8896	0.9038
F1-score	0.8381	0.8153	0.7966

Тепер порівняймо роботу базового та запропонованого алгоритмів для задачі багатокласової класифікації, де вхідними

2.3. $1+\lambda$ GP encodings еволюційний алгоритм для безпечної роботи ...

даними є зображення. Як видно з табл. 5, запропонований підхід має суттєво кращий результат за всіма метриками. Разом з цим, варто зазначити, що на роботу базової версії було витрачено 43179.4566 секунд (близько 12 годин), що є суттєвим обмеженням при практичній реалізації такого алгоритму, особливо у сферах, що вимагають щоденного або навіть щотижневого перенавчання моделей. За цей час алгоритм здійснив 2382 ітерації. Оновлений $1+\lambda$ алгоритм навчався лише 795 секунд або приблизно 13 хвилин.

Порівнюючи запропонований підхід із багатоваровим перцептроном на табл. 6, можна побачити, що MLP класифікатор впорався з поставленим завданням краще, при цьому витративши лише 2 ітерації, які тривали біля 1 секунди.

Таблиця 5 Порівняння базового та запропонованого $1+\lambda$ EA для задачі багатокласової класифікації зображень

Метрика / Модель	Basic $1+\lambda$ EA	Adjusted $1+\lambda$ EA
Accuracy	0.6955	0.7227
Precision	0.7195	0.7282
Recall	0.6634	0.7212
F1-score	0.6903	0.7167

Таблиця 6 Порівняння запропонованого алгоритму $1+\lambda$ EA та MLP для задачі багатокласової класифікації зображень

Метрика / Модель	Adjusted $1+\lambda$ EA	MLP
Accuracy	0.7227	0.7885
Precision	0.7282	0.7997
Recall	0.7212	0.7885
F1-score	0.7167	0.7847

Таку різницю в результатах можна пояснити, в першу чергу, підходами в навчанні, а саме у використанні стохастичного градієнтного спуску. Оскільки MLP оцінює «напрямок» змін, що продукуються вагами моделі, алгоритму набагато простіше підібрати коректні ваги. У той самий час, алгоритм $1+\lambda$ EA покладається виключно на жадібний пошук, що призводить до генерації вже обчислених індивідів. Наприклад, під час навчання для роботи із зображеннями, більш ніж 60% індивідів були обрховані з кешу навчання, що означає, що більш ніж половину

часу, яку алгоритм витратив на створення та підбір кандидатів, було витрачено впусу, оскільки результатом стали не нові кандидати, а копії старих.

3.6. АНАЛІЗ РЕЗУЛЬТАТІВ

В даному розділі було представлено аналіз базової реалізації $1+\lambda$ еволюційного алгоритма з GP кодуванням, його оновленої версії та MLP. Для порівняння було використано два набори даних з медичної сфери різних модальностей, а саме табличні дані та зображення.

Проведені експерименти показали, що базова реалізація $1+\lambda$ алгоритму здатна перевершувати MLP алгоритм за точністю, принципово не програючи у швидкості (0.58 та 0.60 секунд було витрачено на навчання для MLP та $1+\lambda$ алгоритмів, відповідно, для задачі бінарної класифікації табличних даних), даючи приріст в точності у 4.61%. Разом з цим, оновлений підхід впорався з бінарною класифікацією гірше, втративши 1.58% в точності, та витративши суттєво більше часу (89.14 та 3146.11 секунд для 100 та 2500 ітерацій та 20 і 5 розділень для крос-валідації, відповідно).

Залежність повноти від кількості розділень можна пояснити порівняно невеликим розміром набору даних, що може викликати небажане перенавчання та знижувати якість роботи на тестовій вибірці. Тоді як збільшення розділень допомагає отримати більш робастне узагальнення.

З іншого боку, запропонована варіація алгоритму може мати кращу точність за базовий підхід та досягати аналогічних до MLP значень повноти, що є важливим у сферах, що чутливі до типу статистичних помилок, наприклад, у медицині, де хибно-позитивний результат під час визначення чи є пацієнт хворим є кращим, ніж хибно-негативний.

Разом з цим, оновлений $1+\lambda$ алгоритм показав кращі результати на задачі багатокласової класифікації, випередивши базову реалізацію на 2.72% в абсолютних значеннях. Швидкість роботи алгоритму для цієї задачі, у порівнянні з базовою реалізацією, також підвищилась у десятки разів. Також важливо зазначити, що запропонована варіація алгоритму показала на 5.78% краще значення повноти для розв'язуваної задачі.

Утім, запропонований $1+\lambda$ алгоритм все ж виявився гіршим за підхід на основі MLP як за швидкістю, так і за точністю, що

пов'язано з використанням більш оптимального, з точки зору якості навчання, алгоритму оптимізації.

ВИСНОВКИ

В якості підсумку можна констатувати, що варіації еволюційного алгоритму типу $1+\lambda$ з GP кодуванням можуть вдало працювати з різними модальностями для задач багатокласової та бінарної класифікації.

Принциповою є можливість не тільки отримання адекватних результатів на тестових вибірках, але і можливість запропонованих алгоритмів перевершувати MLP для задачі бінарної класифікації на табличних даних.

Таким чином, можна говорити про доцільність використання даних підходів для розв'язання задач бінарної та багатокласової класифікації у сферах, де збереження «прозорості» та прямої інтерпретованості результатів є принциповим.

Важливо також зазначити, що слабкість еволюційних алгоритмів, що були розглянуті, є і їх сильною стороною, коли мова йде про безпекові аспекти використання методів машинного навчання. Це пов'язано, в першу чергу, з тим, що суттєва кількість підходів до атак на алгоритми, що базуються на нейронних мережах, такі як MLP, використовують градієнтний спуск у якості своєї цілі. Саме цей метод оптимізації (та інші суміжні методи похідних) дозволяє проводити настільки ефективно навчання, утім, залишаючи складність роз'яснення результатів дослідникам та користувачам з одного боку, а з іншого — дозволяючи використання методу Fast Gradient Sign (FSGM), який призначений саме для генерації синтетичних даних, які можуть призводити до вибіркової або невибіркової помилкової класифікації даних під час навчання, що призводить до того, що зацікавлена сторона може контролювати поведінку алгоритму під час інференсу.

Оскільки запропоновані еволюційні алгоритми не використовують даний метод оптимізації, FSGM та схожі методи не мають простору для використання. Разом з цим, можливість прослідкувати за процесом навчання та прийняття рішень алгоритмом від початку до кінця дозволяє захистити користувачів від інших методів втручання в роботу алгоритмів.

Наступними важливими кроками в розвитку цих підходів ми вбачаємо використання $1+\lambda$ EA для інших типів задач (наприклад,

замість повнозв'язних нейронних мереж в трансформерах для обробки текстів), оптимізація швидкості роботи алгоритмів та дослідження можливості їх використання замість або разом з фізично-інформованими нейронними мережами, адже обидва підходи дозволяють легку інтеграцію параметрів, що можуть обмежувати процес оптимізації, дозволяючи направити його у необхідному напрямку, що пришвидшує навчання та сприяє якійсній генералізації.

ПЕРЕЛІК ПОСИЛАНЬ

1. Belis, Vasilis, et al. "Machine learning for anomaly detection in particle physics." *Reviews in Physics*, vol. 12, 2024, 100091.
2. Guo, Shenghan, et al. "Machine learning for metal additive manufacturing: Towards a physics-informed data-driven paradigm." *Journal of Manufacturing Systems*, vol. 62, Jan. 2022, pp. 145-163.
3. Malbranke, Cyril, et al. "Machine learning for evolutionary-based and physics-inspired protein design: Current and future synergies." *Current Opinion in Structural Biology*, vol. 80, June 2023, 102571.
4. Nilius, Henning, et al. "Machine learning applications in precision medicine: Overcoming challenges and unlocking potential." *TrAC Trends in Analytical Chemistry*, vol. 179, Oct. 2024, 117872.
5. Munde, Anjali, and Jasmandeep Kaur. "Predictive Modelling of Customer Sustainable Jewelry Purchases Using Machine Learning Algorithms." *Procedia Computer Science*, vol. 235, 2024, pp. 683-700.
6. Berghout, Tarek, Mohamed Benbouzid, and S.M. Muyeen. "Machine learning for cybersecurity in smart grids: A comprehensive review-based study on methods, solutions, and prospects." *International Journal of Critical Infrastructure Protection*, vol. 38, Sept. 2022, 100547.
7. Pritee, Zinniya Taffannum, et al. "Machine learning and deep learning for user authentication and authorization in cybersecurity: A state-of-the-art review." *Computers & Security*, vol. 140, May 2024, 103747.
8. Bahassi, Hanan, et al. "Toward an exhaustive review on Machine Learning for Cybersecurity." *Procedia Computer Science*, vol. 203, 2022, pp. 583-587.
9. Burrell, J. "How the machine 'thinks': Understanding opacity in machine learning algorithms." *Big Data & Society*, vol. 3, no. 1, 2016, 205395171562251.

10. Ribeiro, M. T., S. Singh, and C. Guestrin. "“Why Should I Trust You?”: Explaining the Predictions of Any Classifier." ArXiv, 1602.04938v3, 2016.

11. Richens, Jonathan G., Ciaran M. Lee, and Saurabh Johri. "Improving the accuracy of medical diagnosis with causal machine learning." Nature Communications, vol. 11, no. 3923, 2020.

12. Artificial Intelligence and Machine Learning in Software as a Medical Device. Url: <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device>

13. Hornik, Kurt, Maxwell Stinchcombe, and Halbert White. "Multilayer feedforward networks are universal approximators." Neural Networks, vol. 2, no. 5, 1989, pp. 359-366.

14. Meyerson, Elliot, Xin Qiu, and Risto Miikkulainen. "Simple Genetic Operators are Universal Approximators of Probability Distributions (and other Advantages of Expressive Encodings)." ArXiv, 2202.09679, 2022. Url: <https://arxiv.org/pdf/2202.09679>

15. He, Chunlin, et al. "A review of surrogate-assisted evolutionary algorithms for expensive optimization problems." Expert Systems with Applications, vol. 217, 2023.

16. Gobeyn, S., et al. "Evolutionary algorithms for species distribution modelling: A review in the context of machine learning." Ecological Modelling, vol. 392, 2019, pp. 179-195.

17. Thakkar, Ankit, et al. "Applicability of genetic algorithms for stock market prediction: A systematic survey of the last decade." Computer Science Review, vol. 53, 2024.

18. Kuptamettee, Chanin, et al. "A review of efficient applications of genetic algorithms to improve particle filtering optimization problems." Measurement, vol. 224, 2024.

19. Wang, ZhenZhou, et al. "A comparative review between Genetic Algorithm use in composite optimisation and the state-of-the-art in evolutionary computation." Composite Structures, vol. 233, 2020.

20. Bassin, Anton, et al. "The $(1 + (\lambda, \lambda))$ genetic algorithm for permutations." GECCO '20: Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion, pp. 1669-1677, 2020.

21. Laessig, Joerg, and Dirk Sudholt. "Analysis of speedups in parallel evolutionary algorithms and $(1+\lambda)$ EAs for combinatorial optimization." *Theoretical Computer Science*, vol. 551, 2014, pp. 66-83.
22. Doerr, Benjamin, and Marvin Кьппemann. "Optimizing linear functions with the evolutionary $(1+\lambda)$ algorithm—Different asymptotic runtimes for different instances." *Theoretical Computer Science*, vol. 561, Part A, 2015, pp. 3-23.
23. Rowe, Jonathan E., and Dirk Sudholt. "The choice of the offspring population size in the $(1+\lambda)$ evolutionary algorithm." *Theoretical Computer Science*, vol. 545, 2014, pp. 20-38.
24. Kaufmann, Marc, et al. "Self-adjusting population sizes for the $(1,\lambda)$ -EA on monotone functions." *Theoretical Computer Science*, vol. 979, 2023.
25. Doerr, Benjamin, et al. "The $(1+\lambda)$ Evolutionary Algorithm with Self-Adjusting Mutation Rate." *ArXiv*, 1704.02191, 2018. URL: <https://arxiv.org/pdf/1704.02191>
26. Doerr, Benjamin, et al. "The $(1 + (\lambda, \lambda))$ Global SEMO Algorithm." *ArXiv*, 2210.03618, 2022. URL: <https://arxiv.org/pdf/2210.03618>
27. Liu, Jia, et al. "A comprehensive survey of robust deep learning in computer vision." *Journal of Automation and Intelligence*, vol. 2, Issue 4, 2023, pp. 175-195.
28. Xu, H., et al. "Adversarial Attacks and Defenses in Images, Graphs and Text: A Review." *International Journal of Automation and Computing*, vol. 17, 2020, pp. 151-178.
29. Dong, Huoyuan, et al. "Transferable adversarial distribution learning: Query-efficient adversarial attack against large language models." *Computers & Security*, vol. 135, 2023.
30. Qiu, Shilin, et al. "Adversarial attack and defense technologies in natural language processing: A survey." *Neurocomputing*, vol. 492, 2022, pp. 278-307.
31. Kermany, Daniel, Kang Zhang, and Michael Goldbaum. "Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification." 2018.

32. "Pima Indians Diabetes Database." Kaggle. Url: <https://www.kaggle.com/datasets/uciml/pima-indians-diabetes-database/data>.

33. Vinutha, H. P., B. Poornima, and B. Sagar. "Detection of Outliers Using Interquartile Range Technique from Intrusion Dataset." 2018, pp. 511-518.

34. Breunig, Markus, et al. "LOF: Identifying Density-Based Local Outliers." Proceedings of the ACM SIGMOD International Conference on Management of Data, vol. 29, 2000, pp. 93-104.

35. He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp. 770-778.

36. Maćkiewicz, Andrzej, and Waldemar Ratajczak. "Principal components analysis (PCA)." Computers and Geosciences, vol. 19, no. 3, 1993, pp. 303-342.

4. ЗАДАЧА РОЗМІТКИ НА ДЕРЕВАХ ДЛЯ ПОСТУПОВОГО НАДХОДЖЕННЯ ДАНИХ

Іван Кириленко, аспірант
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

kirvandr@gmail.com

ВСТУП

Задача розмітки зустрічається в багатьох галузях науки, зокрема має широке поширення у сфері комп'ютерного зору: сегментація зображень [1-3], знешумлення, стереобачення [4, 5], SGM [2, 6] тощо. Такі алгоритми, зазвичай, працюють за умови наявності повної інформації про задачу. Проте, на практиці, отримання всіх даних може бути не миттєвим процесом. В такому випадку, до часу роботи самого алгоритму додається ще й час очікування на дані. Це можна було б частково компенсувати, якби мати змогу проводити розрахунки над вже отриманими даними, тим самим зменшивши роботу необхідну для отримання результату за надходження всіх даних.

В цій праці розглянуто проблему пошуку оптимальної розмітки дерев, в умовах, коли інформація, необхідна для розв'язання задачі, частково, або повністю відсутня на момент початку обчислень, та надходить поступово, через деякі проміжки часу.

Також запропоновано підхід до вирішення задачі пошуку оптимальної розмітки дерев, який надає змогу проводити обчислення в міру надходження нових даних, при цьому поступово зменшуючи кількість операцій, що буде необхідна для розв'язання задачі по отриманню повної інформації.

4.1. ЗАДАЧА РОЗМІТКИ НА ДЕРЕВАХ

4.1.1. ПОСТАНОВКА ЗАДАЧІ

Припустимо, існує довільне дерево $\mathcal{T} = \langle \mathcal{V}, \mathcal{E} \rangle$, де \mathcal{V} – множина вузлів дерева, \mathcal{E} – множина ребер, що сполучують ці вузли. Кожному вузлу дерева $v \in \mathcal{V}$ може бути присвоєна мітка d_v із деякої множини міток D .

Розміткою дерева \mathcal{T} будемо називати послідовність $\bar{d} \in D^{\mathcal{V}}$. Кожна така розмітка \bar{d} матиме свою відповідну характеристику, яку часто називають "якістю" або "енергією", і визначають як (1) (мінімізація енергії широко використовується в задачах комп'ютерного зору, особливо після впровадження ефективних алгоритмів [6]).

$$E(d) = \sum_{v \in \mathcal{V}} h(o_v, d_v) + \sum_{v, u \in \mathcal{E}} g(d_v, d_u), \quad (1)$$

$$h: \mathcal{O} \times D \rightarrow \mathcal{R},$$

$$g: D \times D \rightarrow \mathcal{R}.$$

Тут $o_v \in \mathcal{O}$ це елемент з множини сигналів або спостережень, який відповідає вузлу v . Складова $h(o_v, d_v)$ відповідає за «консистентність» сигналу, отриманого на вузлі v , з міткою, яку ми обираємо для цього вузла. А $g(d_v, d_u)$ – складова «гладкості» розмітки, відповідає за те, щоб сусідні вузли мали схожі мітки.

Задача розмітки дерева \mathcal{T} полягає у знаходженні оптимальної розмітки \bar{d}^* , яка б мінімізувала (або максимізувала) енергію $E(\bar{d}^*)$.

$$\bar{d}^* \in \underset{\bar{d} \in D^{\mathcal{V}}}{\operatorname{argmin}} \left(\sum_{v \in \mathcal{V}} h(o_v, d_v) + \sum_{v, u \in \mathcal{E}} g(d_v, d_u) \right). \quad (2)$$

4.1.2. ЗВЕДЕННЯ ЗАДАЧІ ПОШУКУ ОПТИМАЛЬНОЇ РОЗМІТКИ ДЕРЕВА ДО ЗАДАЧІ ПОШУКУ НАЙКРАЩОГО ШЛЯХУ НА ГРАФІ СПЕЦІАЛЬНОГО ВИГЛЯДУ

Проблема пошуку найкращого шляху на графі відноситься до класичних та ретельно досліджених класів задач. На сьогодні існує багато ефективних алгоритмів вирішення таких проблем [6, 7-12], тому можливість їх використання для вирішення задачі пошуку оптимальної розмітки є доволі привабливою перспективою.

Основна ідея зведення задачі полягає у побудові відповідного оригінальній задачі графа таким чином, щоб позбутися концепту міток на вузлах, перетворивши їх на елементи самого графу.

Візьмемо для прикладу деяке дерево-ланцюжок T (рис. 1) та покладемо множину міток $D = \{d1, d2, d3\}$,



Рис. 1. Дерево T

Тоді, при зведенні задачі, новий граф матиме наступний вигляд (рис. 2):

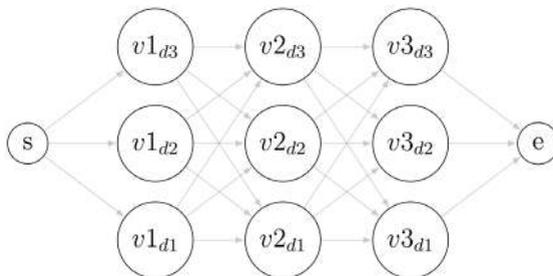


Рис. 2. Відповідний дереву T граф

Тут кожному вузлу v дерева T (окрім корення дерева) відповідає стовпчик з $|D|$ вершин, кожна з яких з'єднана з усіма відповідними вершинами, що були сусідні до v у T . Тобто, будеється новий, відповідний до оригінальної задачі, граф $G' = \langle V', E' \rangle$:

$$V' = \{\sigma_v(d) \mid v \in V \setminus \{s\}, d \in D\} \cup \{s\} \cup E^*,$$

$$E' = \{\langle \sigma_v(d), \sigma_u(d') \rangle \mid \langle v, u \rangle \in \mathcal{N}; d, d' \in D\}, \tag{3}$$

де E^* - множина кінцевих вершин, що додаються до кожного листа дерева T , а \mathcal{N} - відношення сусідства вузлів дерева T .

Введемо функцію ваги вершини:

2.4. Задача розмітки на деревах для поступового надходження даних

$$h: V' \rightarrow R, h(\sigma(v, d)) \equiv h(v, d). \quad (4)$$

Важливо зазначити, що хоч конкретний вигляд цієї функції може бути дуже різноманітним і визначається природою задачі, в більшості випадків вона буде залежати від $\sigma_v \in \mathcal{O}$ - сигналу, що надійшов на вузол v .

Функція ваги ребер, в загальному випадку, визначається як $g: \mathcal{E}' \rightarrow R$. Але нас цікавить лише "гладкість" розмітки, тож вага ребра не буде залежати від того, між якими вузлами дерева T воно проходить. А отже, можемо визначити функцію ваги ребра як:

$$g: D \times D \rightarrow \mathbb{R}. \quad (5)$$

Отримуємо такий зважений граф (рис. 3).

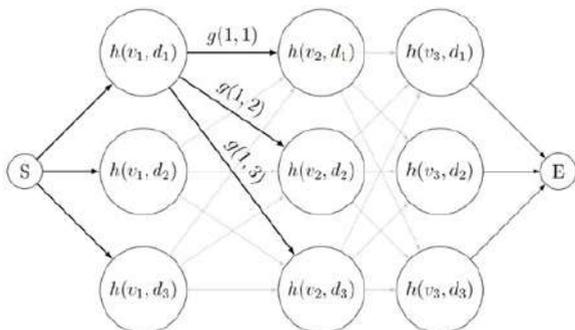


Рис. 3. Граф G

Обравши в побудованому графі G з кожного стовпчика вершин $\{\sigma_v(d), d \in D\}$ по одній вершині (кожній такій вершині відповідає певна мітка d_v), отримаємо деяку розмітку \bar{d} , та шлях від s до e , загальна вага якого визначатиметься як:

$$\sum_{v \in V'} h(v, d_v) + \sum_{v, u \in \mathcal{N}^*} g(d_v, d_u),$$

$$\mathcal{N}^* = \{(\sigma(v, d), \sigma(u, d')) \in \mathcal{E}'; d, d' \in \bar{d}\}. \quad (6)$$

Таким чином, задача пошуку таких вершин, через які можна провести оптимальний шлях на побудованому графі G , відповідає задачі розмітки дерева T (2).

4.2. ЗАДАЧА РОЗМІТКИ ДЛЯ ВИПАДКУ ПОСТУПОВОГО НАДХОДЖЕННЯ ДАНИХ

Метод, описаний в попередньому підрозділі, передбачає, що для всіх вузлів v дерева T всі відповідні їм сигнали o_v з простору спостережень \mathcal{O} , вже відомі до початку обчислень. Однак, це не завжди так.

Цілком можливі ситуації, коли надходження даних сповільнено через неякісні/перевантажені канали зв'язку, або зумовлено самою природою практичної задачі - не є ефективним. За відсутності всієї інформації, ми не зможемо розрахувати ваги деяких вершин, а отже, і не зможемо бути певними в оптимальності шуканої розмітки.

Мета цієї роботи - розглянути випадок, коли ми не маємо повної інформації про простір спостережень \mathcal{O} , а отримуємо її поступово, через певні інтервали часу. Також на меті запропонувати ефективний алгоритм вирішення проблеми пошуку оптимальної розмітки, який дав би змогу проводити певні попередні обчислення з наявними даними, прискоривши отримання фінального результату при надходженні всієї інформації.

Дещо модифікуємо постановку задачі для такого випадку. Досі маємо дерево $T = \langle \mathcal{V}, \mathcal{E} \rangle$, але тепер множина вузлів \mathcal{V} буде розбита на дві підмножини:

$$\begin{aligned} \mathcal{V} &= \mathcal{V}^\sigma \cup \mathcal{V}^c, \\ \mathcal{V}^\sigma \cap \mathcal{V}^c &= \emptyset, \end{aligned} \tag{7}$$

де \mathcal{V}^σ - підмножина «відкритих» вузлів (ті, про які ми вже маємо інформацію), і \mathcal{V}^c - підмножина «закритих» вузлів (інформація про які ще не надійшла). Так само, «закритими» або «відкритими» будуть і вершини у відповідному до дерева T графі G : $\sigma(v, d)$ - «відкрита», якщо $v \in \mathcal{V}^\sigma$, і «закрита», якщо $v \in \mathcal{V}^c$. Будемо позначати відкриті і закриті вершини білим і чорним кольором відповідно (рис. 4).

● «закрита» вершина

○ «відкрита» вершина

Рис. 4. Приклад позначення вершин

2.4. Задача розмітки на деревах для поступового надходження даних

Наприклад, нехай у деякому дереві T відкрита одна вершина \hat{v}_2 (рис. 5), тоді, у відповідному графі G , відкритими буде цілий стовпчик вершин $\sigma(v_2^*, d), d \in D$ (рис. 6).



Рис. 5. Один відкритий вузол

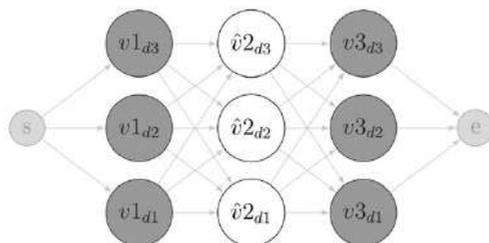


Рис. 6. Відповідний стовпчик відкритих вершин

Суть проблеми знаходження оптимальної розмітки в таких умовах полягає в тому, що обчислення можуть проводитися тільки з вагами відкритих вершин, та сусідніх їм ребер. Та, як буде показано в наступному підрозділі, навіть маючи тільки це, можна робити кроки у напрямку вирішення поставленої задачі.

4.2.1. ЗАДАЧА РОЗМІТКИ ДЛЯ ВИПАДКУ ПОСТУПОВОГО НАДХОДЖЕННЯ ДАНИХ

Ідея онлайн алгоритму пошуку оптимальної розмітки полягає у поступовій модифікації графу G , відповідно надходженню нової інформації про вузли дерева T , наступним чином: припустимо маємо інформацію про один вузол дерева T , тобто у G буде відкритий відповідний стовпчик вершин (рис. 7).

Ми можемо позбутися цих відкритих вершин таким чином, щоб зберегти сенс самої задачі. Для кожної вершини $\sigma(v', d)$, $d \in D$ нас цікавить тільки найкращий можливий шлях у кожену вершину $\sigma(v'', d')$, $d' \in D$. Обрахувавши їх, нам більше не будуть потрібні жодна з вершин $\sigma(v^*, d^*)$, $d^* \in D$, а також ребра

$\langle \sigma(v', d'), \sigma(v^*, d^*) \rangle$ та $\langle \sigma(v^*, d^*), \sigma(v'', d'') \rangle$, $d', d'', d^* \in D$. Замість них ми вводимо нові ребра (рис. 7), $\langle \sigma(v', d'), \sigma(v'', d'') \rangle$, $d', d'' \in D$.

Вага цих нових ребер буде містити у собі інформацію про видалені вершини, та визначатиметься як:

$$g_{new}(\sigma_{v'}(d'), \sigma_{v''}(d'')) = \arg \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v''}(d'')) \right), \quad (8)$$

$$d_{v^*} \in \arg \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v''}(d'')) \right).$$

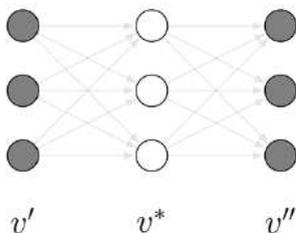


Рис. 7. До вилучення вершин

Позбувшись цього стовпчика вершин, ми зменшили загальну кількість ребер у графі G на $|D|^2$, та зменшили кількість вершин на $|D|$. При цьому ми зберегли загальну структуру задачі, а отже, для отримання фінального результату нам буде необхідно виконати меншу кількість операцій (рис. 8).

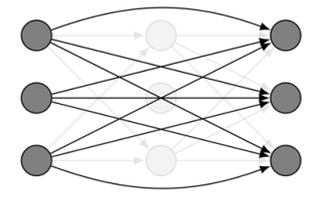


Рис. 8. Після вилучення стовпчику вершин

Для вузлів, що мають більше двох сусідів, або якщо один із сусідів є коренем, або листом дерева, алгоритм модифікації графа G буде схожим.

2.4. Задача розмітки на деревах для поступового надходження даних

Для випадку вузла, з більш ніж двома сусідами (рис. 9), та якщо потужність множини $|D| = 2$, тоді матимемо таку конфігурацію графу G , як на рисунку (рис. 10).

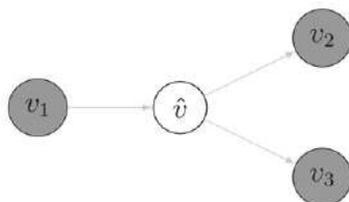


Рис. 9. Відкрита вершина з трьома сусідами

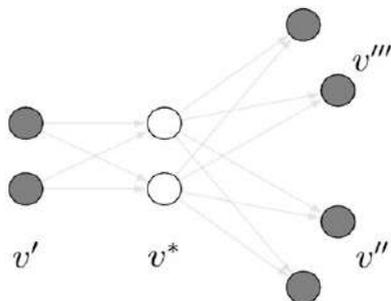


Рис. 10. До вилучення вершин

Вилучивши всі вершини $\sigma(v^*, d^*), d^* \in D$, а також ребра $\langle \sigma(v', d'), \sigma(v^*, d^*) \rangle$ та $\langle \sigma(v^*, d^*), \sigma(v'', d'') \rangle$ та $\langle \sigma(v^*, d^*), \sigma(v''', d''') \rangle$, $d', d'', d''', d^* \in D$, замінимо їх новими ребрами (рис. 11, рис. 12).

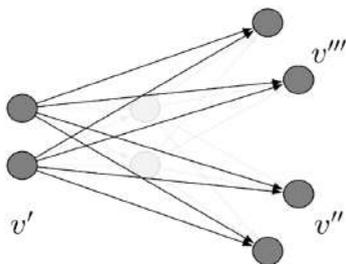


Рис. 11. Після вилучення вершин

$$g_{new}(\sigma_{v'}(d'), \sigma_{v''}(d'')) = \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v''}(d'')) \right), \quad (9)$$

$$g_{new}(\sigma_{v'}(d'), \sigma_{v'''}(d''')) = \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v'''}(d''')) \right). \quad (10)$$

$$d^{*'} \in \arg \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v''}(d'')) \right), \quad (11)$$

$$d^{*''} \in \arg \min_{d^* \in D} \left(g(\sigma_{v'}(d'), \sigma_{v^*}(d^*)) + h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v'''}(d''')) \right). \quad (12)$$

Модифікація графу G для вузлів, що є листами, або сусідами кореня дерева є найпростішим випадком. Наведемо приклад для вузла, який є сусідом кореня дерева T (рис. 13, рис. 14). Для вузлів-листіків алгоритм ідентичний.



Рис. 12. Після вилучення вершин

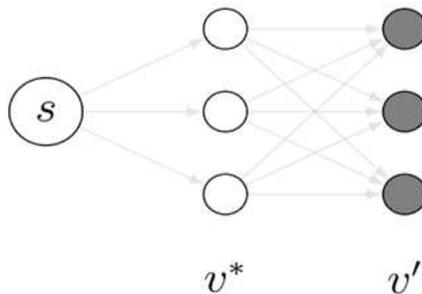


Рис. 13. До вилучення вершин

Вага нових ребер:

$$g_{new}(s, \sigma_{v'}(d')) = \min_{d^* \in D} \left(h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v'}(d')) \right), \quad (13)$$

2.4. Задача розмітки на деревах для поступового надходження даних

$$d^* \in \underset{d^* \in D}{\operatorname{argmin}} \left(h(v^*, d^*) + g(\sigma_{v^*}(d^*), \sigma_{v'}(d')) \right).$$

Описані вище дії виконуються в міру надходження інформації про сигнали $\sigma_v \in \mathcal{O}$ на вузлах дерева T . Хоч алгоритм і має ітеративний характер, проте у випадку, коли одночасно надійшли дані про спостереження на декількох, не сусідніх між собою вузлах, їх оптимізація може бути проведена паралельно.

Після того, як всі вузли дерева T (рис. 15) стануть відкритими, а відповідні їх вершини і ребра графу G (рис. 16) будуть оптимізовані, ми отримуємо просту структуру - початкову вершину s , яка з'єднана з кінцевими вершинами e_1, e_2, \dots (рис. 17).

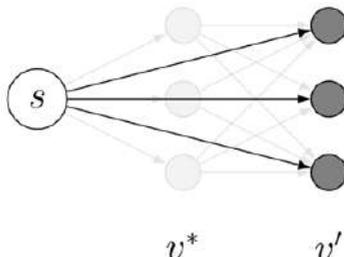


Рис. 14. Після вилучення вершин

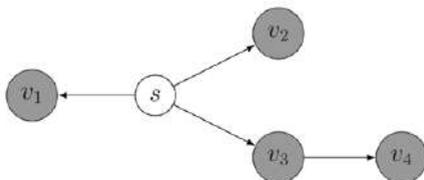


Рис. 15. Дерево T

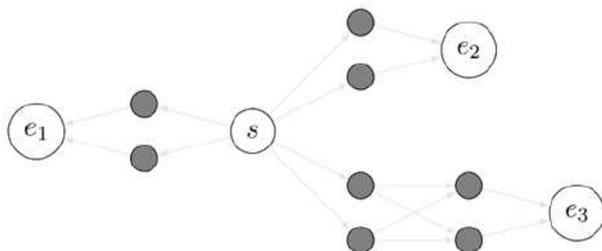


Рис. 16. Відповідний йому граф G до оптимізації (всі вузли закриті)

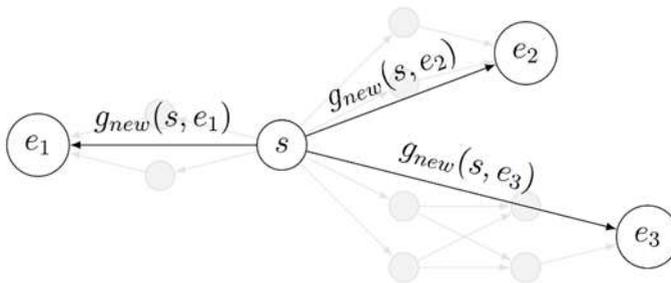


Рис. 17. Оптимізований граф G

Тоді мінімальна енергія для дерева T дорівнюватиме сумі ваг ребер в оптимізованому графі G (рис. 18), $E(\bar{d}^*) = \sum g_{new}(s, e_i)$. А сама послідовність \bar{d}^* відновлюється по збереженим на кожному кроку оптимізації міткам кращого шляху.

Таким чином, на момент отримання всієї інформації про задачу, ми вже матимемо її рішення, у вигляді оптимальної розмітки \bar{d}^* , яку ми поступово знаходили безпосередньо під час надходження даних.

4.3. ЗАСТОСУВАННЯ ЗАПРОПОНОВАНОГО МЕТОДУ НА ПРИКЛАДІ ЗАДАЧІ СТЕРЕОЗОРУ

Розглянемо одне з можливих практичних застосувань запропонованого алгоритму пошуку розмітки на деревах для поступового надходження даних на прикладі задачі стереозору.

4.3.1. ЗАДАЧА СТЕРЕОЗОРУ

Задача стереозору полягає у відновленні інформації про тривимірну структуру сцени, маючи набір зображень цієї сцени (рис. 18), отриманих з різних ракурсів.

Підходів до пошуку карти глибини сцени на одному і тому ж наборі зображень існує декілька [6, 7], та для демонстрації принципу роботи запропонованого в цьому розділі методу, ми зупинимось на одновимірному алгоритмі пошуку карти зсувів. Це означає, що кожен рядок зображення ми опрацьовуємо незалежно від інших. Такий підхід вимагає попередньої ректифікації зображення, проте є швидким (відносно інших алгоритмів пошуку

2.4. Задача розмітки на деревах для поступового надходження даних

карт глибини), простим для розуміння, та дозволяє отримати непогані результати (рис. 19).



Рис. 18. Ліве та праве зображення сцени

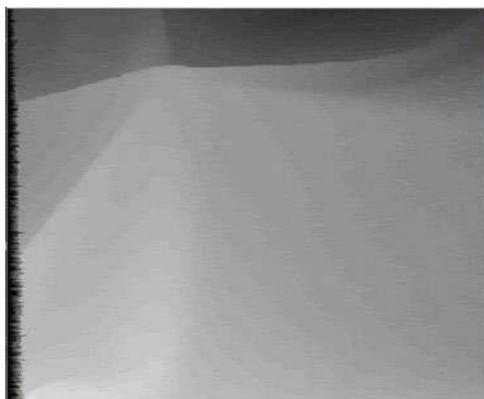


Рис. 19. Карта глибини сцени

4.3.2. ПОШУК КАРТИ ГЛИБИНИ ПРИ ПОВНИХ ДАНИХ

Далі під «зображенням» будемо розуміти деякий рядок вхідного зображення (рис. 20). Нехай n - довжина зображення, а $I = \{1, 2, \dots, n\}$ - множина координат пікселів. Ліве і праве зображення задамо як функції $\mathcal{L}: I \rightarrow R$ та $\mathcal{R}: I \rightarrow R$. Тобто $\mathcal{L}(i)$ - інтенсивність i -го пікселя на лівому зображенні, а $\mathcal{R}(i)$ - інтенсивність i -го пікселя на правому зображенні. Така постановка

природно узагальнюється на випадок кольорових зображень. Також введемо множину зсувів $D = \{0, \dots, D_{max}\}$, де D_{max} - значення максимального зсуву, та підбирається експериментально.

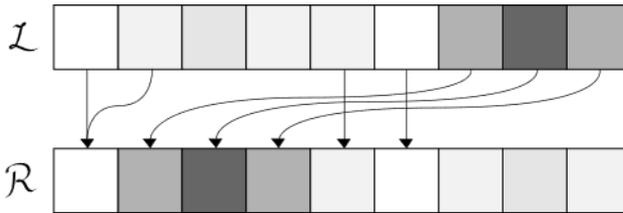


Рис. 20. Пошук відповідних пікселів між правим та лівим зображенням

Для розв'язання задачі для кожного пікселя лівого зображення потрібно знайти відповідний йому піксель на правому зображенні (рис. 20). Називатимемо пару пікселів «відповідною», якщо обидва пікселі містять інформацію про однакову область сцени.

Тобто для кожного пікселя з номером i лівого зображення знайти таке $d_i \in D$, щоб піксель правого зображення з номером $i - d_i$ відповідав йому.

Проте, не будь яка пара пікселів може знаходитися у відповідності, тобто пікселю з номером i на лівому зображенні можуть відповідати тільки ті пікселі правого зображення з номером j , для яких $i \leq j$. Переконатися в цьому можна тримаючи перед собою олівець та по черзі закриваючи то праве, то ліве око. Для правого ока олівець буде знаходитися лівіше ніж для лівого.

Тож треба знайти таку послідовність $\bar{d} \in D^n$, яка б мінімізувала наступну штрафну функцію (14).

$$\omega(\bar{d}) = \sum_{i=1}^n h(i, d_i) + \sum_{i=1}^{n-1} g(d_i, d_{i+1}), \quad (14)$$

$$h(i, d_i) = | \mathcal{L}(i) - \mathcal{R}(i - d_i) |, \quad (15)$$

$$g(d_i, d_{i+1}) = \alpha | d_i - d_{i+1} |.$$

Тут $h(i, d_i)$ відповідає за схожість кольору пікселів, $g(d_i, d_{i+1})$ - за гладкість поля зсувів (15), а α - коефіцієнт згладжування.

4.3.3. ЗВЕДЕННЯ ЗАДАЧІ ДО ПОШУКУ НАЙКОРОТШОГО ШЛЯХУ НА ГРАФІ

Представимо задачу пошуку послідовності \bar{d} , що мінімізує штрафну функцію (формула 14), як пошук найкоротшого шляху через орієнтований зважений граф $G = \langle \mathcal{V}, \mathcal{E} \rangle$ (рис. 21). Множина вершин якого:

$$\mathcal{V} = \sigma(i, d) | i \in I, d \in D \cup S, E. \quad (16)$$

Вершина $\sigma(i, d)$ має вагу $h(i, d)$, $i \in I, d \in D$.

$$\mathcal{E} = \cup_{d \in D} \langle S, \sigma(1, d) \rangle \cup \cup_{d \in D} \langle \sigma(n, d), E \rangle \cup \cup_{\substack{d \in D \\ d' \in D}} \langle \sigma(i, d), \sigma(i+1, d') \rangle. \quad (17)$$

Ваги ребер:

- $3 S$ в $\sigma(1, d) - 0, d \in D$
- $3 \sigma(n, d)$ в $E - 0, d \in D$
- $3 \sigma(i, d)$ в $\sigma(i+1, d') - g(d, d'), d, d' \in D, i \in I$

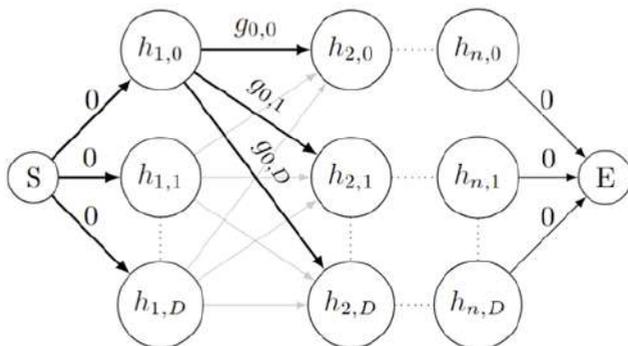


Рис. 21. Структура графу G

Тоді послідовність \bar{d} - послідовність вершин, через які проходить найкоротший шлях з S в E , і буде мінімізувати штрафну функцію $\omega(\bar{d})$ (рис. 21).

Позначимо довжину найкоротшого шляху з вершини S в вершину $\sigma(i, d)$ як $f_i(d)$. Тоді $\forall d \in D$:

$$f_1(d) = h(1, d), \quad (18)$$

$$f_2(d) = \min_{d' \in D} (f_1(d) + g(d', d)) + h(2, d),$$

...

$$f_i(d) = \min_{d' \in D} (f_{i-1}(d) + g(d', d)) + h(i, d).$$

Тоді елементи послідовності \bar{d} знаходимо за формулами:

$$d_n = \arg \min_{d' \in D} (f_n(d')), \quad (19)$$

$$d_i = \arg \min_{d' \in D} (f_i(d') + g(d', d_{i+1})), i = \overline{n-1, 1}.$$

4.3.4. ПОШУК КАРТИ ГЛИБИНИ ПРИ ПОСТУПОВОМУ НАДХОДЖЕННІ ДАНИХ

Метод, описаний в підрозділі 4.3.3, потребує наявності всіх даних до початку обчислень. В ситуації, коли дані надходять повільно, цей метод не є ефективними. Доводиться чекати надходження всіх даних і тільки потім починати обчислення, адже ми не можемо розрахувати ваги деяких вершин.

Замість цього можна проводити деякі розрахунки над частиною даних, яка вже надійшла, цим самим зменшивши час роботи алгоритму після отримання всіх даних.

Нехай на початку нам невідомі жодні пікселі (рис. 22), тож ми не можемо обчислити вагу жодної з вершин графа G .

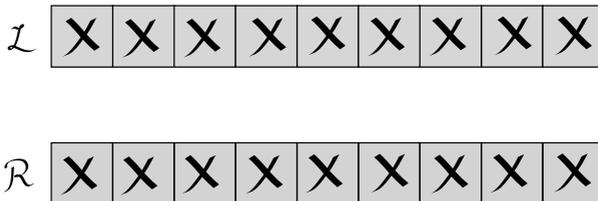


Рис. 22. Інформація відсутня. Всі вершини закриті

Будемо називати вершину “**закритою**” якщо ми не можемо обчислити вагу вершини, а якщо можемо - назвемо її “**відкритою**”.

2.4. Задача розмітки на деревах для поступового надходження даних

Тож на початку, всі вершини графу G , окрім початкової та кінцевої, будуть закритими (рис. 23).

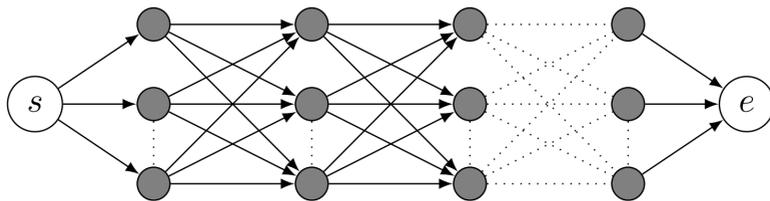


Рис. 23. Граф G

Далі, поступово, з надходженням нових частин інформації, якісь вершини будуть ставати відкритими. Ідея полягає в тому, щоб після відкриття нової вершини, перебудовувати граф G у граф G^* так, щоб цієї вершини можна було б позбутися. Таким чином, після надходження всіх даних та відкриття всіх вершин, граф G^* буде являти собою лише початкову та кінцеву вершини, що з'єднані одним ребром, вага якого і буде довжиною найкоротшого шляху через початковий граф G (рис. 24).

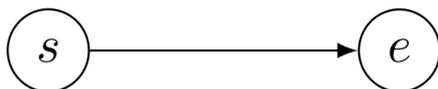


Рис. 24. Граф G^* після надходження всіх даних

Для того, щоб правильно позбавитись якоїсь вершини, нам необхідно зберегти всі шляхи що проходять через цю вершину. Тобто замість ребер які ми вилучаємо разом із вершиною, треба додати нові ребра, вага яких містила б у собі і вагу вилучених ребер, і вагу вилученої вершини (рис. 25-26).

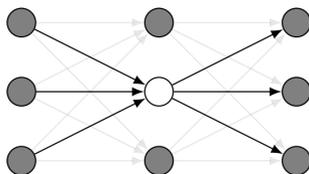


Рис. 25. До вилучення вершини

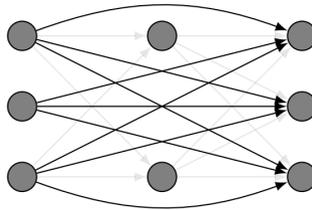


Рис. 26. Після вилучення вершини

Повертаючись до нашого конкретного прикладу: нехай нам поступово, по порядку надходить по одному пікселю кожного зображення. Коли нам відомий лише перший піксель кожного зображення то граф G матиме лише одну відкриту вершину $\sigma(1,0)$ (рис. 27).

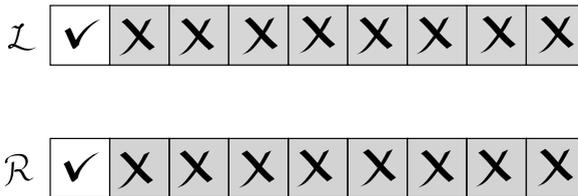


Рис. 27. Відомі перші пікселі обох зображень

Коли нам буде відомо два перші пікселі, то стануть відомі ще й вершини $\sigma(1,1)$ та $\sigma(2,0)$. Таким чином, при надходженні перших k пікселів обох зображень, в графі G будуть відкриті вершини $\sigma(i, di)$, де $i \in I, i \leq k, di \in D, 0 \leq di \leq \min(k - i, D_{max})$. І тільки коли k буде більше за D_{max} , всі вершини в першому стовпчику $\sigma(1, d) \forall d \in D$ будуть відкритими, і ми зможемо починати оптимізацію: нехай $G^0 = \langle \mathcal{V}^0, \mathcal{E}^0 \rangle \geq \mathcal{V}, \mathcal{E} \geq G$. Нехай також $T = \{1, 2, \dots, n - D_{max} - 1\}$ - множина ітерацій. А $s: T \times D \rightarrow \mathcal{R}$. $s^0(d) = 0, \forall d \in D$. Для відновлення послідовності \bar{d} введемо матрицю «попередніх оптимальних вершин» $\hat{\mathcal{P}}$ розмірності $n \times (D_{max} + 1)$.

$$p_{1,d} = 0, \forall d \in D. \tag{20}$$

Як тільки перші $D_{max} + t, (t \in T)$ стереопікселей стають нам відомі, шукаємо граф G^t :

2.4. Задача розмітки на деревах для поступового надходження даних

- $\forall d \in D$:

$$s^t(d) = \min_{d' \in D} (s^{(t-1)}(d') + h(t, d') + g(d', d)).$$

$$p_{1+t,d} = \operatorname{argmin}_{d' \in D} (s^t(d))$$
- $\mathcal{V}^t = \mathcal{V}^{t-1} \setminus \{ \sigma(t, d) \mid d \in D \}$.
- Позначимо множину $\cup_{d \in D} < S, \sigma(t, d) >$ як \mathcal{A} , множину $\cup_{d \in D} < \sigma(t, d), \sigma(t+1, d') >$ як \mathcal{B} , а множину $\cup_{d \in D} < S, \sigma(t+1, d) >$ як \mathcal{C} . Тоді $\mathcal{E}^t = (\mathcal{E}^{t-1} \setminus (\mathcal{A} \cup \mathcal{B})) \cup \mathcal{C}$. А вага ребра $< S, \sigma(t+1, d) >$ $s^t(d)$.
- $G^t = \langle \mathcal{V}^t, \mathcal{E}^t \rangle$

Кожен новий граф G^t матиме на $(D_{max})^2$ менше ребер, ніж граф G^{t-1} . Таким чином, на момент приходу останніх пікселів, нам треба буде опрацювати лише D_{max} ребер. А якщо б ми спочатку чекали приходу всіх даних, а тільки потім починали обчислення, нам треба було опрацювати $(n-1)(D_{max})^2$ ребер.

Коли ж нам стануть відомі всі n пікселів обох зображень, нам залишиться тільки знайти

$$d_n = \operatorname{argmin}_{d' \in D} (s^{(n-D_{max}-1)}(d') + h(n, d')), \quad (21)$$

та відновити послідовність \overline{d} через матрицю \hat{P} :

$$d_i = p_{i+1, d_{i+1}}, i = \overline{n-1, 1}. \quad (22)$$

4.3.5. НЕУПОРЯДКОВАНЕ НАДХОДЖЕННЯ ДАНИХ. НАЙГІРШИЙ ВИПАДОК

Розглянемо найгірший можливий випадок для запропонованого алгоритму у випадку неупорядкованого надходження даних на тому ж прикладі задачі стереозору.

Найгіршим вважатимемо випадок, при якому на етапі оптимізації t , проміжний граф G^t матиме найбільшу кількість ребер. Для заданої структури дерева, така ситуація складається у випадку, коли у кожному "стовпчику" відкрито по одній вершині (рис. 28).

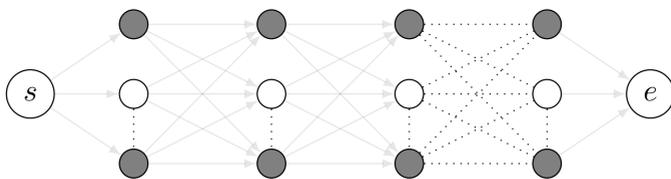


Рис. 28. Відомі перші пікселі обох зображень

Адже тоді, кожна закрита вершина матиме додаткове ребро до кожної закритої вершини у наступних стовпчиках (рис. 29).

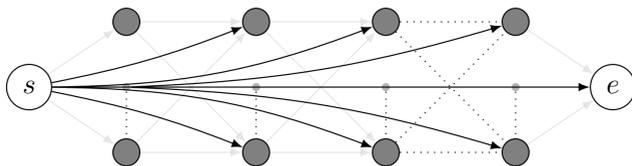


Рис. 29. Відомі перші пікселі обох зображень

У такій ситуації загальна кількість ребер не буде перевищувати $D_{max}^2 n^2$. До того ж будь-яка нова відкрита вершина буде тільки зменшувати загальну кількість ребер у графі.

4.3.6. ПРАКТИЧНИЙ АНАЛІЗ РОБОТИ ЗАПРОПОНОВАНОГО МЕТОДУ НА ПРИКЛАДІ ЗАДАЧІ СТЕРЕОЗОРУ

В цьому розділі порівнюється час отримання карти глибини сцени у результаті роботи алгоритму (наведеного у розділі 4.3.1), що є адаптацією запропонованого методу пошуку розмітки на деревах до задачі одновимірного стереозору τ_{online} , з часом роботи звичайного алгоритму $\tau_{offline}$.

Час порівнюється як з, так і без затримки між надходженням даних, для того, щоб мати уяву про вплив ітеративного процесу оптимізації графу на загальний час роботи, та оцінити доцільність такого ускладнення.

Тестування проводилось на зображеннях з Middlebury Stereo Datasets [10], з максимальним диспаратетом $D_{max} = 100$. Розмір зображення зафіксований як 1000x1000 пікселів (рис. 30).

2.4. Задача розмітки на деревах для поступового надходження даних

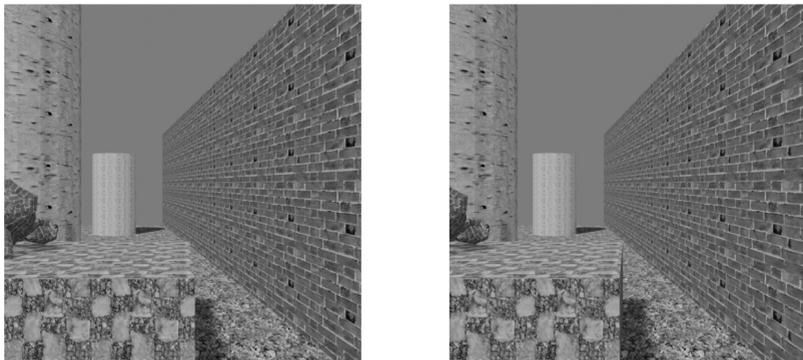


Рис. 30. Тестові зображення (ліве та праве)

На кожній ітерації $t \in \{1, \dots, 1000\}$ відкриваються пікселі лівого та правого зображення з координатою t . Результат роботи зображено на рис 31.

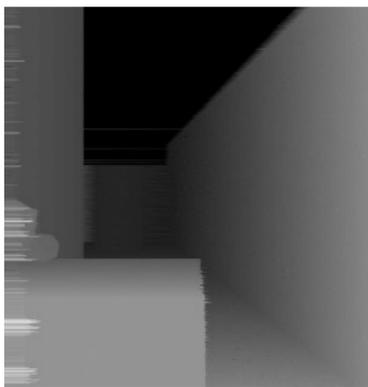


Рис. 31. Результати роботи

Таблиця 1 Порівняння часу роботи

Метод	Затримка 0с	Затримка 10^{-5} с
$\tau_{offline}$	5.6с	5.6с
τ_{online}	6.9с	0.04с

Час роботи offline алгоритму після надходження всіх даних $\tau_{offline} = 5.6$ секунд і при відсутній затримці, і при затримці в 10^{-5} секунди. Час роботи online алгоритму після надходження всіх

даних $\tau_{online} = 6.9$ секунд при відсутній затримці, і $\tau_{online} = 0.04$ при затримці в 10^{-5} секунди. Тобто запропонований алгоритм не дає жодних покращень для ситуації, коли всі дані доступні до початку обрахунків. Проте у ситуаціях, коли інформація надходить поступово, запропонований алгоритм потребує значно менше часу для отримання результату, після надходження всіх даних.

4.4. РЕЗУЛЬТАТИ

У цій праці було запропоновано модифікацію методу знаходження оптимальної розмітки на деревах для випадку поступового надходження даних. Основною перевагою запропонованого методу є відсутність необхідності наявності всіх даних для початку роботи; алгоритм дозволяє опрацьовувати вершини дерева у міру надходження інформації про них.

Ефективність і доцільність використання запропонованого алгоритму залежать від комплексу взаємопов'язаних факторів, та продиктовані і природою задачі, і такими факторами, як структура конкретного дерева та характер функцій ваги вершин h . Однак, найважливішим фактором, який визначає доцільність використання запропонованого алгоритму, є співвідношення між часом, необхідним для обробки однієї вершини, і середнім інтервалом часу між надходженням нової інформації про вершини. Якщо алгоритм встигає обробити інформацію про одну вершину до того, як надійде нова інформація про наступну вершину, то такий алгоритм вважається ефективним і його застосування є доцільним. Іншими словами, якщо час обробки однієї вершини менший або дорівнює середньому інтервалу між надходженням нової інформації, то алгоритм працює в режимі реального часу і не утворює затримки в обробці даних.

Навіть якщо запропонований метод не встигає обробити інформацію про кожну вершину до того, як надійде нова інформація (тобто час обробки вершини трохи перевищує інтервал між надходженням даних), його використання все одно може бути виправданим. Це можливо за умови, що загальний час, необхідний для обробки всіх даних за допомогою цього методу, буде меншим, ніж час, який витрачається на обробку тих самих даних за допомогою традиційних методів. Іншими словами, невелика затримка в обробці окремих вершин може бути допустимою, якщо завдяки цьому ми отримуємо прискорення обчислень в цілому.

4.5. ПОДАЛЬШІ ДОСЛІДЖЕННЯ

Запропонований алгоритм має високий потенціал для подальших досліджень та оптимізації. Для більш практичного аналізу запропонованого алгоритму, було б цікаво розглянути його застосування на конкретних задачах. Одним із перспективних напрямків є задача бінокулярного стереозору, тобто відновлення глибини сцени за двома зображеннями, отриманими з різних точок зору. Якщо ми сформулюємо задачу бінокулярного стереозору як послідовне знаходження карт диспаритету для кожного рядка зображення, то структура дерева T в нашому алгоритмі буде мати вигляд ланцюжка. Така проста структура дерева може відкрити додаткові можливості для оптимізації алгоритму.

Також можливі подальші модифікації запропонованого методу для конкретних характеристик надходження даних. Зокрема, особливий інтерес представляють сценарії, в яких характер надходження даних не хаотичний, а має певну структуру. Наприклад якщо інформація надходить упорядковано, вершина за вершиною. Або дані надходять з деякою симетрією. Також цікавий випадок, коли характер надходження інформації не має певної структури, але відомий наперед. Для кожного такого специфічного випадку можна розробити індивідуальні оптимізації алгоритму, що дозволить підвищити його ефективність та точність.

ВИСНОВКИ

У даному розділі було в загальному вигляді розглянуто задачу пошуку оптимальної розмітки на деревах, та метод зведення такої задачі, до задачі пошуку найкращого шляху на графі спеціального вигляду. Була розглянута модифікація задачі пошуку оптимальної розмітки для випадку поступового надходження даних, та запропонований алгоритм розв'язання таких проблем, для початку роботи якого не обов'язково наявність повної інформації про задачу.

Також, було наведено приклад практичного застосування запропонованого алгоритму для задачі посторокового стереозору у випадку поступового надходження даних. В рамках цього прикладу було проведено експериментальне порівняння часу роботи, необхідного для отримання результату. Ефективність запропонованого алгоритму залежить від характеру даних, а саме,

у випадку наявності повного набору даних до початку обчислень, він не приносить покращень, але в умовах, коли інформація надходить з затримкою, метод є більш ефективним.

Ефективність запропонованого алгоритму сильно залежить від природи задачі, та факторів, таких як структура конкретного дерева T , характер функцій ваги вершин h . Але найважливішим фактором, що визначить чи підійде запропонований в цій роботі алгоритм, у якості ефективного методу вирішення конкретної задачі, є відношення часу надходження частини інформації до часу, необхідного для її обрахунку.

ПЕРЕЛІК ПОСИЛАНЬ

1. Yu Chai and Fei Yang. Semi-global stereo matching algorithm based on minimum spanning tree. pages 2181–2185, 05 2018.
2. Heiko Hirschmüller. Semi-global matching: Motivation, development and applications. pages 173–184, 09 2011.
3. Dorit Hochbaum. An efficient algorithm for image segmentation, markov random fields and related problems. J. ACM, 48:686–701, 07 2001.
4. Heiko Hirschmüller and Daniel Scharstein. Evaluation of cost functions for stereo matching. IEEE Conference on Computer Vision and Pattern Recognition, CVPR'07, 06 2007.
5. Richard Szeliski, Ramin Zabih, Daniel Scharstein, Olga Veksler, Vladimir Kolmogorov, Aseem Agarwala, Marshall Tappen, and Carsten Rother. A comparative study of energy minimization methods for markov random fields. pp. 16–29, 01 1970.
6. Hirschmüller, Heiko. (2011). Semi-Global Matching: Motivation, Development and Applications. 173-184.
7. Facciolo, Gabriele & de Franchis, Carlo & Meinhardt, Enric. (2015). MGM: A Significantly More Global Matching for Stereovision. 10.5244/C.29.90.
8. D. Scharstein and R. Szeliski. A taxonomy and evaluation of dense two-frame stereo correspondence algorithms. International Journal of Computer Vision, 47(1/2/3):7-42, April-June 2002.
9. In IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2003), volume 1, pp. 195-202, Madison, WI, June 2003.

2.4. Задача розмітки на деревах для поступового надходження даних

10. Richard Szeliski, Ramin Zabih, Daniel Scharstein, Olga Veksler, Vladimir Kolmogorov, Aseem Agarwala, Marshall Tappen, and Carsten Rother. A comparative study of energy minimization methods for markov random fields, 01 1970.

11. H. Hirschmller and D. Scharstein. Evaluation of cost functions for stereo matching. In IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2007), Minneapolis, MN, June 2007.

12. Middlebury Stereo Datasets.
<http://vision.middlebury.edu/stereo/data/>.

5. ГЕНЕРАТИВНІ МЕРЕЖІ ДЛЯ ПІДВИЩЕННЯ ПРОСТОРОВОГО РОЗРІЗНЕННЯ СУПУТНИКОВИХ ДАНИХ НА ОСНОВІ ТРАНСФОРМЕРІВ З УВАГОЮ (TRANSFORMERS WITH ATTENTION)

Алла Лавренюк, доцент
Кафедра математичного моделювання та аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

alla.lavrenyuk@gmail.com

ВСТУП

Протягом останніх кількох років спостерігається стрімке зростання доступності супутникових даних середнього та високого просторового розрізнення, які можна вільно завантажувати з відкритих джерел, таких як платформи Copernicus чи USGS. Вільний доступ до цих даних відкриває нові перспективи для наукових досліджень у різних галузях — від моніторингу довкілля та змін клімату до сільського господарства і просторового планування. Супутникові зображення надають унікальну можливість для дослідження як локальних, так і глобальних змін, що відбуваються на поверхні Землі. Раніше дослідники часто стикалися з вибором: або працювати з даними високого просторового розрізнення на обмеженій території, або ж використовувати супутникові дані з глобальним охопленням, але низьким просторовим розрізненням. Однак сьогодні це протиріччя значною мірою знімається завдяки новітнім супутниковим платформам, що пропонують як високе просторове розрізнення, так і достатню просторову та спектральну деталізацію.

Однією з найпопулярніших і найбільш використовуваних науковцями платформ є супутникова місія Sentinel-2, яка входить до програми Європейського Союзу Copernicus. Sentinel-2 надає спектральні зображення з просторовим розрізненням до 10 для чотирьох каналів: синього (490 нм), зеленого (560 нм), червоного (665 нм) та ближнього інфрачервоного (842 нм). Ці канали

2.5. Генеративні мережі для підвищення просторового розрізнення...

охоплюють важливі діапазони, які дозволяють аналізувати стан рослинності, водойм та урбанізованих територій. Однак Sentinel-2 також має інші, більш специфічні спектральні канали, зокрема червоний край спектра та короткохвильові інфрачервоні канали з просторовим розрізненням 20 м. Ці канали, хоч і мають менше просторове розрізнення, є важливими для детального аналізу екосистем і здоров'я рослинності. У багатьох дослідженнях ці канали не використовуються через нижче просторове розрізнення, що обмежує точність аналізу, особливо на локальних територіях.

Інші популярні джерела супутникових даних, такі як місії Landsat-8 та Landsat-9, також відіграють важливу роль у моніторингу земної поверхні, особливо завдяки своїй довгій історії спостережень (місія Landsat триває з 1972 року). Дані Landsat мають просторове розрізнення 30 м, що є нижчим показником у порівнянні із Sentinel-2, проте вони охоплюють ширший спектральний діапазон, включаючи термальні інфрачервоні канали, що особливо корисні для аналізу температурних змін поверхні. Важливо відзначити, що спільне використання даних Sentinel-2 та Landsat може значно покращити якість моніторингу, оскільки ці платформи взаємодоповнюють одна одну, зокрема щодо часової частоти знімків і спектрального покриття.

Однак використання супутникових даних з різним просторовим розрізненням викликає певні технічні труднощі. Однією з таких проблем є гармонізація зображень з різним розрізненням для отримання єдиного продукту з високою точністю. Вирішення цієї проблеми стало одним із ключових напрямів розвитку в супутниковій індустрії та наукових дослідженнях, спрямованих на підвищення просторового розрізнення зображень. Збільшення просторового розрізнення зображень, відоме як суперрезольція, дозволяє перетворювати зображення з низькою просторовою деталізацією на зображення вищого просторового розрізнення. Це дає можливість більш точно вивчати об'єкти на поверхні Землі, включаючи моніторинг змін ландшафтів, виявлення аномалій та інші завдання.

Одним із перспективних підходів до розв'язання задачі суперрезольції є застосування методів глибокого навчання, зокрема генеративних змагальних мереж (GANs). GANs дозволяють створювати нові зображення на основі вже існуючих даних, і сьогодні активно застосовуються для покращення якості зображень у різних галузях. Сучасні дослідження показали, що GANs є ефективними не лише для суперрезольції зображень, але й для вирішення широкого спектра задач комп'ютерного зору,

таких як сегментація зображень, відновлення пошкоджених даних та інші.

В даному дослідженні пропонується методологія для підвищення просторового розрізнення супутникових зображень Sentinel-2 та Landsat на основі генеративних мереж. Однією з ключових інновацій цього підходу є використання сучасних нейронних мереж із блоками channel attention та self-attention, що дозволяє краще враховувати взаємозв'язки між різними спектральними каналами та підвищити точність генерованих зображень. Це дозволяє не лише отримати продукти високого просторового розрізнення, але й покращити аналіз рослинності та інших елементів ландшафту.

Застосування таких підходів особливо ефективно для аналізу рослинності, оскільки канали червоного краю спектра, які мають нижче просторове розрізнення, містять важливу інформацію про стан рослин та їх здоров'я. Використання методів суперрезолюції дозволяє «підтягнути» ці канали до рівня розрізнення основних каналів Sentinel-2, що значно покращує результати аналізу рослинності.

Експериментальні результати, отримані для даних Sentinel-2, підтвердили ефективність підходу, що розглядається в даному розділі. Нижче продемонстровано, що застосування глибоких нейронних мереж дозволяє значно підвищити якість зображень і створити продукти, які можуть бути використані для детального аналізу земної поверхні. Крім того, проведені експерименти показали, що цей підхід також успішно підвищує просторове розрізнення супутникових зображень Landsat-8 та Landsat-9, що відкриває нові можливості для використання даних цих місій у широкому спектрі застосувань. Особливо перспективним є використання цього підходу для досліджень в галузі екології та сільського господарства, де точність і деталізація супутникових знімків мають критичне значення.

Таким чином, запропонована методологія дозволяє значно підвищити якість супутникових зображень, що відкриває нові можливості для моніторингу природних процесів, вивчення змін у довкіллі та аналізу змін земної поверхні. Завдяки використанню передових методів глибокого навчання, це робить важливий внесок у розвиток сучасних технологій обробки супутникових даних і відкриває нові перспективи для наукових досліджень у цій сфері.

5.1. ОГЛЯД ЛІТЕРАТУРИ

Існує широкий набір супутникових даних, що дозволяють вирішувати різноманітні завдання у галузі спостереження Землі, таких як класифікація земельного покриття, прогнозування врожайності сільськогосподарських культур, виявлення вирубок лісів та контроль природних пожеж. Супутникові зображення надають безцінну інформацію про стан земної поверхні, яку можна використовувати для моніторингу змін довкілля, планування ресурсів та оцінки ризиків у реальному часі. Широкий спектр супутникових місій, доступних для наукових досліджень, включає платформи різного рівня просторового та спектрального розрізнення, що забезпечує можливість адаптації вибору даних до специфічних потреб завдань.

Залежно від мети дослідження та території, що вивчається, важливим є правильний вибір супутникових даних. Наприклад, для точного моніторингу невеликих цільових областей, таких як окремі поля, лісові ділянки або урбанізовані території, найбільш ефективними є дані високого просторового розрізнення [1]. Водночас для глобальних проєктів або національних програм моніторингу, де охоплюються великі площі, перевагу надають супутниковим зображенням середнього просторового розрізнення [2]–[4]. Зокрема, дані, отримані з платформ Sentinel-1 та Sentinel-2, що входять до програми Copernicus, є одними з найбільш популярних та затребуваних у наукових дослідженнях [5], [6]. Це зумовлено їх високим просторовим та спектральним розрізненням, що дозволяє отримати детальну інформацію про стан земної поверхні на глобальному рівні, з можливістю вивчення екосистем, оцінки змін в аграрних і лісових ресурсах, а також спостереження за урбанізованими територіями.

Одним із важливих факторів, що обмежує використання супутникових зображень у завданнях з високими вимогами до деталізації, є обмежена кількість каналів високого просторового розрізнення. Зокрема, для побудови карти класифікації земного покриття з просторовим розрізненням 10 м слід використовувати лише канали із просторовим розрізненням 10 м [7], [8]. У випадку з Sentinel-2 це чотири канали: синій, зелений, червоний та ближній інфрачервоний. Проте супутник також має спектральні канали з просторовим розрізненням 20 м, такі як червоний край спектру, які є надзвичайно корисними для аналізу стану рослинності. Втім, через нижче просторове розрізнення ці канали часто залишаються невикористаними в практичних додатках, що

знижує ефективність класифікаційних алгоритмів та моніторингових завдань.

Крім Sentinel-2, іншими поширеними джерелами супутникових даних є місії Landsat-8 та Landsat-9, які мають просторове розрізнення 30 м. Попри нижче просторове розрізнення ці дані все ж можуть суттєво покращити результати моніторингу завдяки ширшому спектральному покриттю. Проте інтеграція даних з різним просторовим розрізненням, таких як Sentinel-2 і Landsat, вимагає виконання процесу, відомого як підвищення розрізнення, або суперрезолюція. Це завдання виникає в багатьох практичних додатках і полягає в тому, щоб отримати зображення з більшим просторовим розрізненням на основі даних з низьким розрізненням [5]. Взагалі задача підвищення розрізнення виникає в багатьох прикладних завданнях для обробки зображень та відео [9]. Методи підвищення просторового розрізнення зображень можуть використовувати кілька зображень з низьким просторовим розрізненням для створення одного зображення з високим просторовим розрізненням або працювати лише з одним вхідним зображенням з низьким просторовим розрізненням. Вирішення проблеми за участю кількох вхідних зображень детально описано в [9]. Нижче розглядається розв'язання цієї проблеми у випадку, коли є лише одне вхідне зображення.

Одними з найпростіших і найвідоміших методів підвищення просторового розрізнення зображень є інтерполяційні підходи. До таких методів належать метод найближчого сусіда, білінійна інтерполяція, бікубічна інтерполяція та сплайни. Кожен з цих методів має свої особливості та використовується в різних контекстах залежно від вимог до обчислювальної потужності та точності. Метод найближчого сусіда є найпростішим і полягає у виборі значення найближчого пікселя при збільшенні зображення. Хоча цей метод виконується швидко, він створює помітні "блокові" артефакти в зображенні, які спотворюють реальну структуру об'єктів. Білінійна інтерполяція використовує лінійне усереднення значень найближчих пікселів для розрахунку нових точок, що забезпечує більш плавний перехід між пікселями, проте може призводити до розмиття деталей зображення. Бікубічна інтерполяція є вдосконаленим підходом, який враховує не лише найближчі, але й більш віддалені пікселі, що дозволяє отримати ще гладкіші результати, проте також не завжди точно відображає контури об'єктів. Сплайни, як інтерполяційний метод, забезпечують ще вищу якість згладжування, проте, як і попередні

2.5. Генеративні мережі для підвищення просторового розрізнення...

методи, не здатні точно відтворити дрібні деталі зображення та контури об'єктів.

Основною проблемою цих методів є те, що вони не враховують зміст зображення, його контекст чи структури об'єктів. Такі методи працюють виключно з інтенсивністю пікселів, не беручи до уваги форми чи межі об'єктів, що призводить до виникнення артефактів і розмитості, особливо на складних зображеннях з великою кількістю деталей. У випадках, коли важливо зберегти чіткість контурів, таких як у супутникових знімках або медичних зображеннях, ці методи є недостатньо ефективними. З розвитком глибоких методів машинного навчання та нейронних мереж з'явилися більш ефективні підходи для підвищення просторового розрізнення зображень. Завдяки здатності глибоких моделей вивчати складні патерни та враховувати контекст у зображенні, ці методи дозволяють значно покращити якість результуючих зображень, зберігаючи чіткі деталі та структури об'єктів. Нейронні мережі, зокрема згорткові нейронні мережі (CNN), стали популярними завдяки своїй здатності розпізнавати текстури, межі та інші елементи на зображеннях, що робить їх незамінними в завданнях покращення просторового просторового розрізнення.

У 2015 р. було запропоновано метод Super-Resolution Convolutional Neural Network (SRCNN) як один із перших глибоких методів для розв'язання цієї задачі [10]. Однак автори цієї роботи не пропонують рішення «від початку до кінця», а спочатку збільшують зображення до бажаного розміру за допомогою стандартного методу бікубічної інтерполяції, а лише потім застосовують запропоновану нейронну мережу для покращення якості зображення. Метод SRCNN був вдосконалений у [11] моделлю Very Deep Super Resolution (VDSR), яка складалася з 20 шарів порівняно з трьома шарами у моделі SRCNN. Крім того, VDSR намагається оцінити залишкове значення між цільовим зображенням та інтерпольованим, а не повністю здійснює перетворення від одного зображення до іншого, як це було запропоновано у випадку SRCNN. У цих обох методів є недолік використання інтерполяції на початку, що призводить до великої кількості параметрів у моделях та складнощів у навчанні для підвищення просторового розрізнення зображення. Для подолання цих проблем у [12] була представлена модель Fast Super-Resolution Convolutional Neural Networks (FSRCNN). Вона приймає на вхід зображення з низьким просторовим розрізненням без будь-якої попередньої обробки.

Інші методи із подібним підходом також були запропоновані в [13] - [15].

Альтернативним методом для підвищення просторового розрізнення зображення є використання генеративних мереж (GAN) [16], що складаються з двох нейронних мереж: генератора та дискримінатора. Такий підхід був вперше запропонований в [17] з Super Resolution Generative Adversarial Networks (SRGAN). Мережа генератора створює зображення вищого просторового розрізнення, тоді як мережа дискримінатора намагається визначити, чи зображення є реальним, чи згенерованим генератором. Навчання моделі GAN завершується, коли генератор навчився будувати зображення високого просторового розрізнення, які не відрізняються від справжніх зображень для дискримінатора. Кілька публікацій [18] - [20] пропонують використання моделей GAN для розв'язання задач збільшення просторового розрізнення зображень і показують, що ці моделі надають найточніші результати та є найефективнішими для розв'язання задачі підвищення просторового розрізнення.

Однак ці методи застосовувалися до звичайних зображень, а не до супутникових багатоспектральних даних. У публікаціях [21] і [22] було запропоновано використовувати моделі GAN для задач обробки даних спостереження Землі, таких як підвищення просторового розрізнення цифрових моделей рельєфу (DEMs) та збільшення просторового розрізнення даних метеорадару, що дозволяє отримувати більш точні прогнози погоди. Тем не менше, немає досліджень щодо підвищення просторового розрізнення каналів Sentinel-2 чи Landsat-8/9. Таким чином, основна мета даного дослідження полягає у заповненні цієї прогалини і розробці методології підвищення просторового розрізнення всіх інших доступних каналів Sentinel-2 з розрізненням 20 м до 10 м [23], а також всіх доступних каналів Landsat із 30 м до 10 м.

Водночас нейронні мережі із механізмом уваги [24], зокрема трансформери, здобули велику популярність при розв'язанні різних задач, таких як обробка зображень, обробка природної мови, системи рекомендацій, генерація зображень [25] і т.д. головним чином через те, що трансформери перевершили інші звичайні моделі глибокого навчання, які переважно базуються на використанні згорткових шарів без уваги [26]. Тому запропоновано метод для підвищення просторового розрізнення всіх доступних каналів Landsat із 30 м до 10 м на основі моделі GAN, яка складається з трансформерів із блоками уваги [27].

5.2. ПОСТАНОВКА ЗАДАЧІ

Метою цього дослідження є розробка універсального підходу та ефективної моделі до підвищення просторового розрізнення супутникових зображень, який буде ефективним для різних супутникових систем і дозволить покращити просторове розрізнення зображень з 20 або навіть 30 м до 10 м. Основний акцент зроблено на використанні генеративно-змагальних мереж (GAN), які здатні навчатися на зображеннях з високим просторовим розрізненням та застосовувати отримані знання для покращення якості зображень з нижчим просторовим розрізненням.

Задача полягає в адаптації існуючих моделей суперрезолюції до різних типів супутникових зображень, враховуючи їх особливості, такі як спектральні характеристики та наявність шумів. Також важливо забезпечити, щоб запропонований метод був універсальним, тобто міг застосовуватися до різних супутникових даних, таких як Sentinel-2 і Landsat, що мають різне просторове розрізнення.

5.3. РОЗВ'ЯЗАННЯ ЗАДАЧІ

В даному розділі для розв'язання задачі підвищення розрізнення зображень запропоновано використовувати модель GAN, зокрема, для перетворення каналів Sentinel-2 з розрізненням 20 м в зображення з розрізнення 10 м. Схема запропонованої методології показана на рис. 1. Запропонована модель складається з двох нейронних мереж — генератора та дискримінатора. В якості базової моделі була використана ідея SRGAN [17], яка використовувалася для розв'язання задач підвищення розрізнення звичайних зображень, яка була адаптована для роботи з супутниковими даними.

На першому етапі модель GAN навчалася перетворювати на канали червоного, зеленого, синього та NIR з розрізненням 20 м в трансформовані канали з розрізненням 10 м. Після цього навчена модель GAN могла б використовуватися для перетворення інших каналів з просторовим розрізненням 20 м на 10 м. На відміну від традиційних зображень супутникове зображення повинно бути розділено на квадрати.

Розмір вхідного зображення дорівнює $128 \times 128 \times 1$ пікселів, розмір вихідного зображення дорівнює $256 \times 256 \times 1$ пікселів.

Враховуючи, що краї зображення розділяють об'єкти на частини, пропонується генерувати квадрати з перекриттям у 1/4 розміру зображення з усіх сторін. В результаті відсікається центральна частина отриманого зображення (256×256×1 пікселів) розміром 128×128×1 пікселів, за винятком квадратів, які були взяті по краям супутникового зображення.

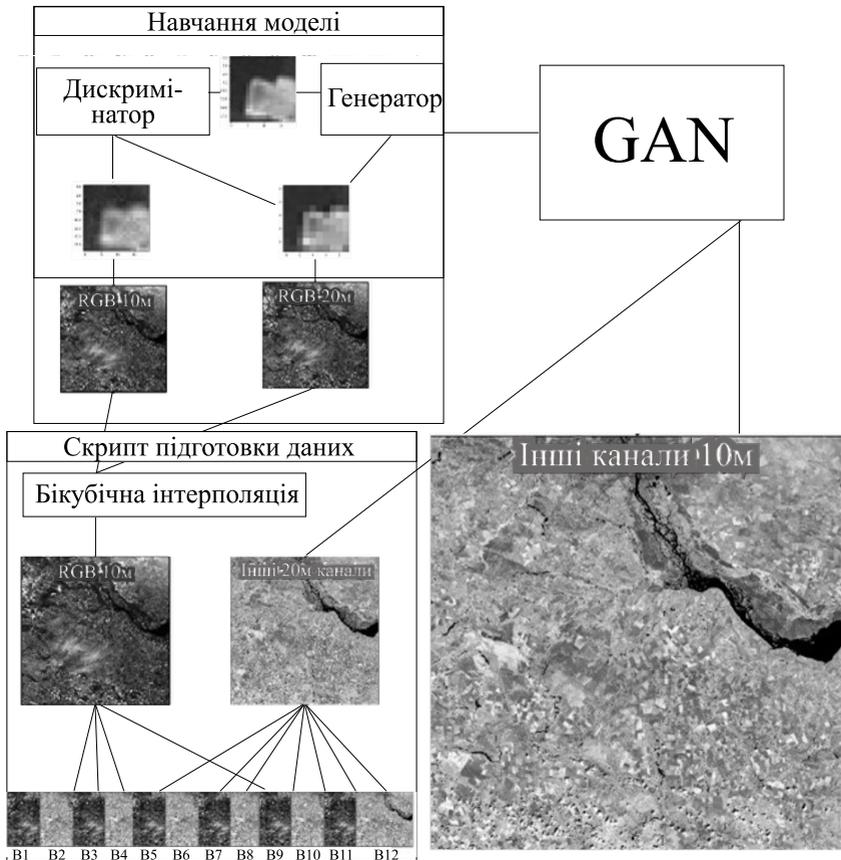


Рис. 1. Схема розв'язання задачі підвищення розрізнення зображень

Дискримінатор — це звичайна нейронна мережа для бінарної класифікації (реальне зображення 10 м чи згенероване з 20 м) з сигмоїдальним останнім шаром. Таким чином, в якості базового

2.5. Генеративні мережі для підвищення просторового розрізнення...

дискримінатора була обрана мережа ResNet, однак для цієї мети можна використовувати будь-яку іншу базову модель. ResNet легко замінити більш сучасними моделями, такими як Efficientnet, Normalizer Free Network (NFnet) або трансформерами.

В даному випадку генератор складається з 16 ідентичних блоків, з'єднаних зі зворотними з'єднаннями за допомогою операції поелементного множення. Кожен блок має два згорткових шари з ядром 3×3 і 64 ознаками, за якими слідує шар нормалізації та функція активації. Для обох наших моделей ми використовували функцію активації Leaky ReLU. Після цього є специфічний блок для підвищення просторового розрізнення карти ознак. Враховуючи, що потрібно отримати точні значення пікселів без розмиття, такі підходи як інтерполяція чи, наприклад, шар для підвищення дискретизації із зворотною згорткою, не є підходящими. Для цього було обрано ефективний субпіксельний згортковий шар, який спеціально розроблений для завдань підвищення розрізнення зображень.

Для спільного навчання дискримінатора та генератора загальна функція втрат складається з двох частин. Перша - стандартна бінарна перехресна ентропія для дискримінатора. Друга - втрата для генератора. У звичайному GAN втрата генератора обчислюється на основі виходів дискримінатора для згенерованих даних. Для завдання підвищення розрізнення зображень основною метою генератора є не тільки вивчення того, як генерувати зображення, схожі на реальні, але й зберігати значення пікселів та форми об'єктів. Таким чином, ми додали втрату вмісту, яка обчислюється на картах ознак моделі Resnet, як в [17], що є більш інваріантною до змін у піксельному просторі, на відміну від втрати MSE, що зазвичай використовується [13]. Отже, якщо X - це вхідне зображення, Y_{pred} - згенероване зображення, (Y_{pred}) - вихід дискримінатора для згенерованого зображення, Y - оригінальне зображення високого просторового розрізнення, втрата GAN може бути оцінена за формулою (5) на основі втрати дискримінатора ($loss1$) та втрати генератора ($loss2$), де α та β - це коефіцієнти ваги.

$$Y_{pred} = generator(X), \quad (1)$$

$$\hat{Y}_{pred} = discriminator(Y_{pred}), \quad (2)$$

$$loss1 = \frac{1}{n} \sum_{i=1}^n Y_{pred_i} \log \hat{Y}_{pred_i} + (1 - Y_{pred_i}) \log (1 - \log \hat{Y}_{pred_i}), \quad (3)$$

$$loss2 = MSE(Y - Y_{pred}), \quad (4)$$

$$loss = \alpha * loss1 + \beta * loss2. \quad (5)$$

Для розв'язання задачі підвищення просторового розрізнення супутникових зображень Landsat з 30 м до 10 м пропонується використовувати дещо іншу модель GAN. Дана модель також складається з двох нейронних мереж: генератора та дискримінатора. Обидві моделі є трансформерами з блоками уваги. Наш підхід базується на моделі Hybrid Attention Transformer (HAT) [28], яка є сучасною та ефективною при розв'язанні задач підвищення розрізнення для звичайних зображень.

Спочатку модель GAN навчається перетворювати трансформовані канали червоного, зеленого та синього кольору з просторовим розрізненням 30 м на оригінальне розрізнення в 10 м. Після цього навчена модель може бути використана для перетворення каналів Landsat з просторовим розрізненням 30 м на розрізнення 10 м. На відміну від традиційних зображень супутникові зображення потрібно розділити на менші квадрати для обробки. Розмір вхідного зображення становить $128 \times 128 \times 1$ пікселів, тоді як розмір вихідного зображення - $384 \times 384 \times 1$ пікселів. Щоб уникнути відсікання об'єктів на краях зображення, генеруються квадрати з перекриттям з усіх сторін, рівним $1/4$ розміру зображення, так само як і у випадку з даними Sentinel-2.

Мережа дискримінатора - це нейронна мережа, яка зазвичай використовується для бінарної класифікації з останнім сигмоїдальним шаром. Найбільш поширеними виборами для дискримінатора є архітектура ResNet, але можна використовувати будь-яку іншу основу, таку як EfficientNet чи Normalizer Free Network. Проте, враховуючи, що трансформери є більш ефективними порівняно з загальноновживаними згортковими мережами, ми зосередились саме на них. Трансформери, такі як ViT, DEiT чи ViLo, мають квадратичну залежність від розміру вхідного зображення, а SWIN [26] має лінійну залежність, тому саме ця архітектура була обрана в якості дискримінатора для розв'язанні поставленої задачі.

Для генератора ми використовуємо мережу трансформера з блоками уваги. SWIN трансформер вже продемонстрував відмінні

2.5. Генеративні мережі для підвищення просторового розрізнення...

результати у завданнях підвищення розрізнення зображень, але, як заявлено в [28], механізм зсуву вікна (основна ідея SWIN) є неефективним для побудови міжвіконного з'єднання. Таким чином, ми покращили його, додавши додаткові блоки уваги, зокрема, увагу перехресного каналу, як у моделі HAT. Загальна архітектура мережі генератора складається з трьох частин: виділення поверхневих ознак, виділення глибоких ознак та відновлення зображення (рис. 2).

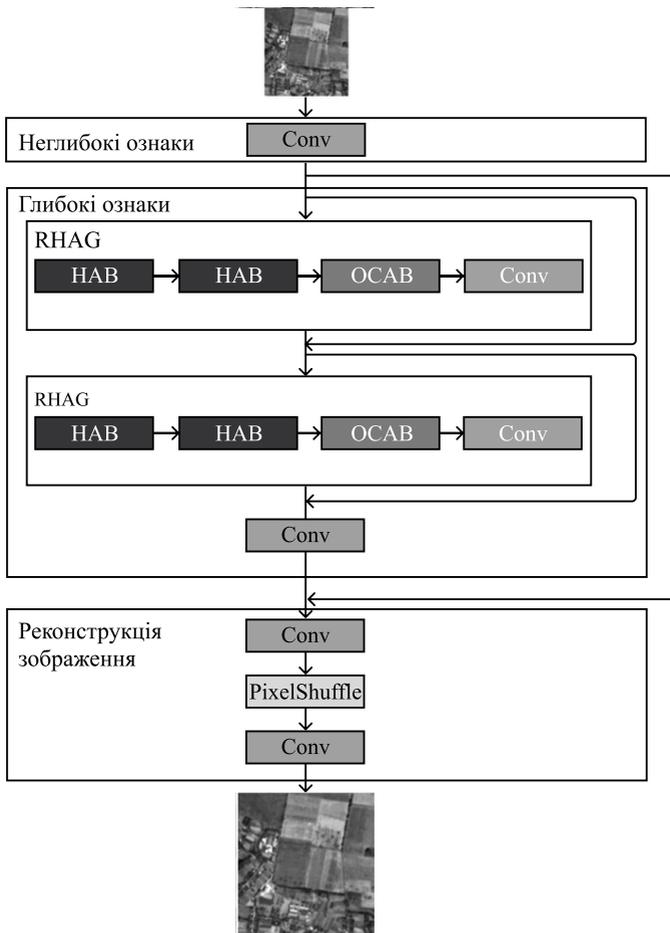


Рис. 2. Загальна архітектура моделі генератора

Для заданого зображення низького просторового розрізнення спочатку використовується один згортковий шар для виділення поверхневих ознак. Вхід перетворюється з простору низької розмірності в простір високої розмірності, створюючи високорозмірне вбудовування (high-dimensional embedding). Глибокі ознаки виділяються за допомогою N послідовних груп гібридної уваги залишкового типу (RHAG) та згорткового шару 3×3 . Після виділення глибоких ознак використовується глобальне залишкове з'єднання для поєднання поверхневих і глибоких ознак. Схожа до SRGAN техніка pixel-shuffle [17] використовується для збільшення просторового розрізнення об'єднаних ознак. В результаті отримуємо зображення більшого просторового розрізнення.

Основним інноваційним блоком генератора є RHAG, який складається з M послідовних гібридних блоків уваги (HAB), блока уваги перехресного перекриття (OCAB) та згорткового шару 3×3 . Блок HUB інтегрує блок згортки на основі каналної уваги в стандартний блок трансформера для подальшого покращення можливостей представлення моделі. Якщо бути більш точним, блок каналної уваги додається до стандартного блоку SWIN трансформера після першого рівня нормалізації та працює паралельно з віконним модулем самоуваги з кількома головами.

5.4. АНАЛІЗ РЕЗУЛЬТАТІВ

Для перевірки ефективності запропонованого підходу було проведено декілька експериментів, які більш детально описані нижче.

Експеримент 1. Підвищення просторового розрізнення всіх доступних каналів Sentinel-2 з просторовим розрізненням 20 м до 10 м.

Для проведення експерименту була завантажена смуга Sentinel-2 (35UQR), що охоплює територію Київської області України за 1 червня 2021 року. Ця смуга була обрана через свою репрезентативність, оскільки вона містить різноманітні типи земельного покриття, такі як сільськогосподарські угіддя, водойми, лісові масиви, штучні об'єкти (міста і дороги), а також необроблювані території.

Така різноманітність ландшафтів дозволяє охопити всі основні категорії земельного покриття, що є важливим для перевірки ефективності запропонованої методології. Крім того,

2.5. Генеративні мережі для підвищення просторового розрізнення...

знімок мав хмарність на рівні 11%, що є прийнятним для аналізу супутникових даних, оскільки хмарність незначно впливає на якість інформації, особливо в спектральних діапазонах, які використовуються для навчання моделі.

Попередня обробка даних здійснювалася за допомогою програмного забезпечення Sen2Core, що є стандартним інструментом для обробки зображень Sentinel-2. Процес обробки включав атмосферну та радіометричну корекцію, що дозволяє враховувати вплив атмосфери на відбивання світла та коригувати похибки, спричинені різницею в умовах освітлення або наявністю аерозолів в атмосфері. Ці кроки є важливими для покращення точності зображень та забезпечення їх придатності для подальшого аналізу, оскільки вони забезпечують реалістичне відображення спектральних характеристик об'єктів на землі.

У процесі навчання моделі використовувалися зелений, синій та ближній інфрачервоний (NIR) канали з просторовим розрізненням 10 м, оскільки вони мають високий рівень деталізації та є важливими для класифікації рослинного покриву, водних об'єктів і штучних структур. Червоний канал, також з просторовим розрізненням 10 м, був використаний для тестування результатів моделі. Для проведення експерименту було створено зображення з нижчим просторовим розрізненням 20 м, трансформували вихідні дані за допомогою кубічної інтерполяції. Це дозволило сформувати навчальний набір, де кожний канал мав свою низькороздільну версію, на якій тренувалася модель, а також використовувалася для подальшого порівняння з оригінальними високороздільними даними.

Навчальні дані були розділені на невеликі квадрати розміром 256×256 пікселів для каналів з просторовим розрізненням 10 м та 128×128 для каналів з розрізненням 20 м. Це дозволило збільшити кількість зразків для тренування моделі та полегшити її навчання на різних ділянках зображення.

Модель була проініціалізована випадковими ваговими коефіцієнтами для всіх шарів. Вхідний шар містив 64 згорткових шари з розміром ядра 9 і активаційною функцією PReLU. Потім сигнал проходить через 16 послідовних блоків залишкового типу з 64 згортковими шарами з розміром ядра 9 та активаційною функцією PReLU, а також 64 згортковими шарами з тим самим розміром ядра та нормалізацією. Після цього слідує ще один блок із 64 згортковими шарами з розміром ядра 3 та нормалізацією. Останнім кроком є передача інформації через транспонований фільтр для збільшення розрізнення та вихідний згортковий фільтр,

який генерує результуюче зображення. Для оцінки втрат генератора використовуються вагові коефіцієнти: 1 для MSE генератора та 0.1 для бінарної крос-ентропії дискримінатора.

Після 10 епох навчання з 10 ітераціями в кожній та розміром порції 32, модель досягла MSE, рівного 2075, для Sentinel-2 нормалізованих пікселів із значеннями від 0 до 10 000. Тестування проводилося розрахунком MSE між згенерованим зображенням GAN з 20 м трансформованого червоного каналу та оригінальним 10 м червоним каналом. На рис. 3 продемонстровано вихід моделі GAN для вхідного зразка.

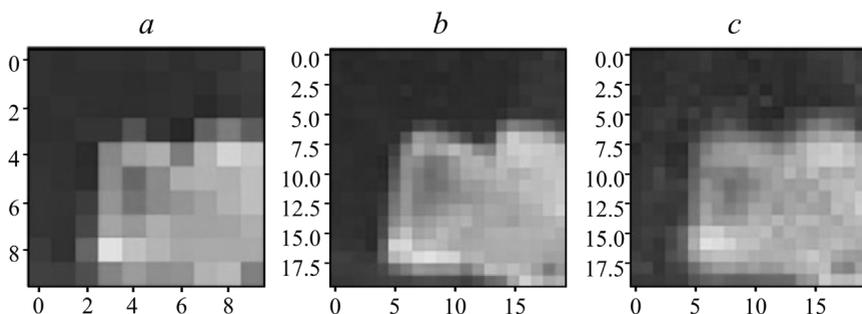


Рис. 3. Підвищення просторового розрізнення на одному зразку: а – трансформоване зображення 20 м, б – оригінальне зображення 10 м, с – вихід GAN

Зазвичай при використанні транспонованих фільтрів результат обирається в центрі вхідного зразка (коли обчислення значень транспонованих значень виконується максимальну кількість разів), а не на кутах, де фільтрацію проводили тільки 1 або кілька разів. Отже, у результуючому зображенні береться лише центральна частина вхідного зразка розміром 128×128 та ковзне вікно для моделювання з розміром кроку 64 пікселі. На рис. 4 продемонстровано результат для повного зображення.

Таким чином, запропоновано методологію для збільшення просторового розрізнення супутникових зображень на основі моделі GAN. Ця модель була успішно навчена на червоних, зелених, синіх та NIR каналах зображень супутників Sentinel-2 і дозволяє збільшити просторове розрізнення всіх інших доступних каналів з розрізненням 20 м до 10 м. Такі канали із збільшеним просторовим розрізненням можуть бути використані для розв'язання різних прикладних задач, особливо крайні червоні

2.5. Генеративні мережі для підвищення просторового розрізнення...

канали для більш точного аналізу рослинності, наприклад, для прогнозу врожаю [29] або визначення глибини по фото [30]–[32]. Обмеження запропонованої методології на основі моделі GAN полягає в можливості збільшення просторового розрізнення із масштабним коефіцієнтом лише 2 або 4. Якщо необхідно збільшити просторове розрізнення із масштабним коефіцієнтом більше 4, потрібно використовувати іншу додаткову інформацію високого просторового розрізнення, наприклад, NDVI, карту земного покриву і т. д.

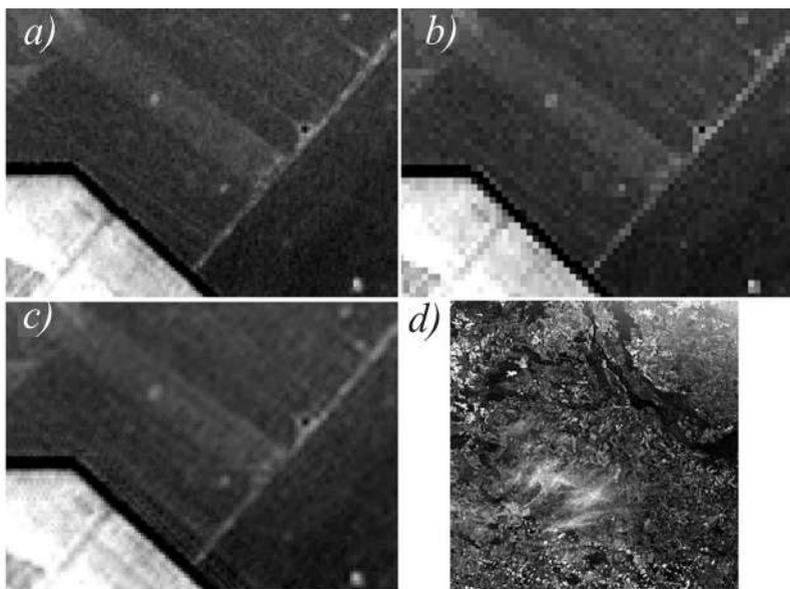


Рис. 4. Результат застосування методу підвищення просторового розрізнення GAN на зображенні: а – оригінальне зображення червоного каналу 10 м, б – трансформоване до 20 м, с – результат моделі, д – результат моделі для повного зображення

Експеримент 2. Підвищення просторового розрізнення всіх доступних каналів Landsat із 30 м до 10 м.

Для проведення експерименту було використано дані супутників Sentinel-2 та Landsat-9 за період з 1 червня 2022 р. до 30 червня 2022 р., експеримент проводився на частині Київської області України. Для забезпечення чітких спостережень для цього

конкретного періоду використані безхмарні композити даних Sentinel-2 та Landsat-9. Набір даних охоплював повне представлення основних типів земельного покриття, включаючи орні землі, водойми, штучні об'єкти, ліси та необроблювані землі. Для підготовки даних використовувалася платформа Google Earth Engine. Червоний, зелений та синій канали використовувалися як для навчання, так і для тестування. Для створення зображення з просторовим розрізненням 30 м із початкових каналів з просторовим розрізненням 10 м було застосовано кубічну інтерполяцію для трансформації зображення. Згодом навчальні дані були розділені на невеликі фрагменти розміром 384×384 пікселів для каналів з розрізненням 10 м і 128×128 пікселів для каналів з розрізненням 30 м.

Попередні дослідження показали, що попереднє навчання є важливим для розв'язання багатьох прикладних задач. Тому що моделі на основі трансформерів потребують більшої кількості даних та ітерацій навчання для отримання базової інформації. Тому моделі генератора та дискримінатора були ініціалізовані з використанням ваг, попередньо отриманих при навчання на наборі даних ImageNet. Для експерименту була встановлено 6 RNAGs та NABs, кількість каналів усієї мережі була 180.

Для оцінки якості отриманої моделі було обрано три стратегії. Перша стратегія полягала в оцінці на основі даних Sentinel-2. Для цього вимірювалася середня похибка (MAE) для спектральних каналів згенерованого зображення (на основі зменшеного зображення Sentinel-2) та оригінальних спектральних каналів із просторовим розрізненням 10 м.

Друга стратегія використовує зменшені зображення Sentinel-2 до 30 м та дані Landsat до 90 м. У цьому випадку модель навчається створювати 30-метровий багатоспектральний канал Landsat на основі 90-метрового каналу. Третя стратегія полягала в аналізі кореляції між згенерованими багатоспектральними каналами та оригінальними даними Sentinel-2. Побудована модель досягла кращих результатів за всіма 3 стратегіями порівняно із класичним підходом GAN, піксельно-орієнтованим підходом глибокої нейронної мережі та методом білінійної регресії, які традиційно використовуються для збільшення розрізнення супутникових даних. Метрика MAE для червоного каналу склала 0,0844, для зеленого каналу - 0,0437, для синього каналу - 0,0507, для всіх каналів - 0,05965. На рис. 5 наведено приклади оригінальних даних Sentinel-2 та Landsat-9 на двох рівнях

2.5. Генеративні мережі для підвищення просторового розрізнення...

масштабування, а також результати підвищення розрізнення, отримані з Landsat-9.

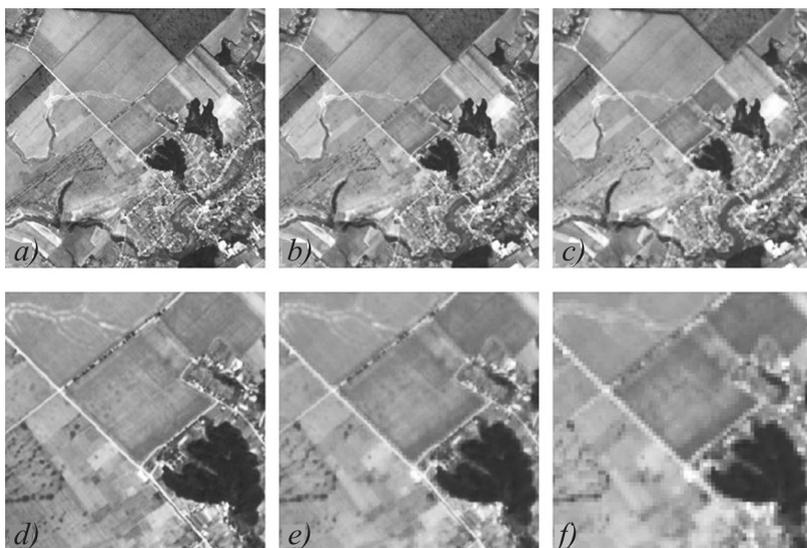


Рис. 5. Результати збільшення розрізнення GAN на зображенні на основі запропонованого піходу: а) - оригінальне RGB-зображення Sentinel-2 (10 м), б) - результат моделі, с) - оригінальне RGB-зображення Landsat-9 (30 м), д) - збільшене оригінальне RGB-зображення Sentinel-2 (10 м), е) - збільшений результат моделі, ф) - збільшене оригінальне RGB-зображення Landsat-9 (30 м)

Набір даних супутникової місії Landsat є одним із найбільших і важливих наукових джерел інформації, яке може бути використано для моніторингу земель, а також аналізу змін земного покриву на багаторічних рядах даних. Однак багато досліджень підтверджують, що просторове розрізнення має важливе значення, тому багато дослідників віддають перевагу даним Sentinel-2. Водночас, найкращі результати моніторингу земель можна досягти лише за умови комбінування даних з різних джерел. Основною перешкодою в гармонізації наборів даних Sentinel і Landsat є їх просторове розрізнення. Це може бути досягнуто з використанням запропонованого нового методу підвищення просторового розрізнення супутникових даних на основі GAN зі згортковими

шарами та блоками уваги, а також з блоками RHAG, які дозволяють вивчати залежності між багатоспектральними та текстурними характеристиками та точно генерувати зображення з просторовим розрізненням 10 м на основі даних Landsat дозволяє отримати.

ВИСНОВКИ

Запропонована методологія показала високу ефективність у підвищенні просторового розрізнення супутникових зображень Sentinel-2 і Landsat-9, що підтверджується результатами проведених експериментів. Використані GAN-моделі забезпечують генерацію зображень з високою точністю, що дозволяє значно покращити деталізацію та якість відображення різних типів земельного покриття.

Одним із ключових аспектів запропонованого підходу є можливість підвищення просторового розрізнення каналів з 20 м до 10 м у Sentinel-2 та з 30 м до 10 м у Landsat-9. Такий підхід є особливо корисним у випадках, коли висока деталізація є критично важливою, наприклад, для моніторингу стану сільськогосподарських угідь, аналізу лісового покриття або вивчення змін у міських середовищах.

З іншого боку, слід зазначити, що в процесі генерації зображень міських районів виникають певні труднощі. Міські ландшафти відрізняються високим рівнем деталізації, складними структурами та значною неоднорідністю, що може створювати проблеми при застосуванні GAN-моделей. Незважаючи на те, що наш підхід дозволяє досягти покращення якості зображень для природних ландшафтів, для міських середовищ потрібні додаткові дослідження та подальша модифікація методики.

Запропонований підхід до підвищення просторового розрізнення на основі GAN значно перевершує традиційні методи, такі як білінійна регресія та піксельно-орієнтовані підходи глибокого навчання. Використання генеративних моделей забезпечує більш точну передачу деталей і текстур зображень, що є критично важливим для аналізу супутникових даних.

Особливо варто відзначити переваги використання блоків уваги (Attention Blocks) та адаптивних блоків залишкової мережі (Residual High Attention Blocks, RHAGs), які дозволяють покращити здатність моделі до навчання на складних зображеннях. Ці блоки забезпечують краще розпізнавання

2.5. Генеративні мережі для підвищення просторового розрізнення...

ключових характеристик зображень, таких як структура ландшафту, різниця в спектральних властивостях різних типів покриву та інші текстурні особливості.

Незважаючи на переваги, запропонований підхід має деякі обмеження. Як було зазначено раніше, труднощі виникають при обробці зображень міського середовища, що може бути пов'язано з недостатньою складністю моделі для адекватного врахування всієї різноманітності текстур та деталей у цих районах. Відповідно, подальші дослідження повинні бути спрямовані на вдосконалення моделі шляхом додавання нових блоків, збільшення кількості шарів або залучення додаткових даних.

Окремої уваги заслуговує аналіз ефективності підходу для різних типів земельного покриву. Наші експерименти охоплювали кілька основних типів ландшафтів, включаючи сільськогосподарські угіддя, водойми, ліси, необроблювані землі та штучні об'єкти. Зображення кожного типу ландшафту мають свої особливості, що впливають на результати генерації.

Для природних ландшафтів, таких як ліси та сільськогосподарські угіддя, модель показала відмінні результати. Це пов'язано з відносно однорідною текстурою та меншою кількістю складних структур у порівнянні з міськими районами. Наприклад, для лісових масивів модель змогла точно відтворити текстуру дерев, зберігаючи високу деталізацію та коректно передаючи зміни у спектральних характеристиках різних ділянок.

Складнішим виявилось завдання генерації зображень водойм. Це пояснюється специфічністю водних поверхонь, які можуть сильно варіюватися залежно від наявності рослинності, глибини, ступеню прозорості води та інших характеристик. У деяких випадках модель не справлялась з точним відтворенням дрібних деталей, наприклад, берегових ліній або окремих елементів, що знаходяться на поверхні води. Проте, загалом, результати генерації для водойм були достатньо точними для використання у практичних завданнях, таких як моніторинг водних ресурсів.

Щодо необроблюваних земель, розроблена модель також показала високу ефективність, що, ймовірно, пов'язано з відносно низькою складністю текстур цього типу ландшафту. Необроблювані землі часто мають менш виражену структуру, що полегшує завдання генерації. Крім того, для цього типу ландшафту модель виявила високу точність у відтворенні спектральних характеристик, що може бути корисним для аналізу змін в умовах посухи або інших природних явищ.

Гармонізація даних з різних супутникових місій є важливим аспектом для забезпечення більш точного аналізу та моніторингу змін земного покриття. Наш підхід дозволяє інтегрувати дані з Sentinel-2 і Landsat-9, що створює умови для комбінованого використання інформації з різних джерел. Це особливо важливо для довгострокового моніторингу, де необхідна висока сумісність даних для проведення ретроспективного аналізу.

Запропонований метод підвищення просторового розрізнення Landsat-9 до рівня Sentinel-2 дозволяє зменшити розбіжності між даними, що полегшує їх інтеграцію та спільне використання в різних дослідницьких задачах. Наприклад, покращена гармонізація даних може бути використана для моніторингу змін у землекористуванні, оцінки впливу кліматичних змін або аналізу екологічних процесів на глобальному рівні.

Однак, як вже було зазначено вище, гармонізація даних супутників з різним просторовим розрізненням потребує врахування додаткових факторів. Наприклад, для досягнення ще кращої сумісності даних може бути корисним використання додаткових показників, таких як NDVI або інші індекси рослинності. Це дозволить підвищити точність аналізу, особливо в умовах, коли різні супутники мають відмінності не лише в просторовому розрізненні, але й у спектральних характеристиках.

Запропонований метод підвищення просторового розрізнення супутникових даних на основі GAN демонструє вагомі переваги в порівнянні з традиційними методами. Результати наших експериментів свідчать, що використання генеративно-змагальних мереж у поєднанні зі згортковими шарами та блоками уваги дозволяє ефективно підвищувати просторове розрізнення супутникових зображень, зокрема, для каналів з розрізненням здатністю 20 м у Sentinel-2 та 30 м у Landsat-9.

Значущим аспектом результатів другого експерименту є підтвердження ефективності комбінування даних різних супутникових місій. Гармонізація даних Sentinel і Landsat, яка досягається завдяки підвищенню просторового розрізнення, відкриває нові можливості для інтеграції даних із різних джерел та забезпечення більш точного аналізу змін на поверхні Землі. Це особливо важливо для задач довгострокового моніторингу, де необхідна максимальна сумісність даних різних супутників.

В цілому проведені дослідження показують, що використання генеративно-змагальних мереж для підвищення просторового розрізнення супутникових зображень є перспективним напрямком, що дозволяє значно покращити якість даних.

2.5. Генеративні мережі для підвищення просторового розрізнення...

Незважаючи на очевидні переваги запропонованого методу, існують деякі обмеження, які необхідно враховувати. Одним із основних обмежень є здатність моделі підвищувати просторове розрізнення лише з масштабним коефіцієнтом до 4. При спробах досягти ще більш високого просторового розрізнення (наприклад, з 30 м до 5 м) модель може не мати достатньої кількості інформації для точного відтворення дрібних деталей, що особливо помітно в складних міських умовах.

Ще одне важливе обмеження стосується впливу спектральної неоднорідності в міських районах. Міські території мають складні структури, що включають різні типи будівель, дороги, зелені насадження, водні об'єкти тощо. Для більш точного відтворення таких середовищ може знадобитися вдосконалення моделі, наприклад, через додавання додаткових шарів або використання інших підходів до обробки зображень, таких як мультиспектральний аналіз.

Таким чином, подальші дослідження можуть бути спрямовані на кілька ключових напрямків.

- **Вдосконалення моделей для міських умов.** Необхідно розробити більш складні архітектури, які могли б краще відтворювати різноманітність текстур і деталей у міських районах. Це може включати використання гібридних підходів, що комбінують генеративні моделі з іншими типами нейронних мереж, такими як рекурентні мережі або мережі зі згортковими блоками.

- **Розширення масштабних можливостей.** Варто дослідити можливість підвищення просторового розрізнення зображень з більшим масштабним коефіцієнтом, що може вимагати залучення додаткових даних або використання інших моделей. Це дозволить розширити область застосування методу, зробивши його ще більш універсальним.

- **Інтеграція з іншими показниками.** Включення додаткових спектральних індексів або карт земельного покриття може підвищити точність генерації зображень, особливо в умовах складних ландшафтів або там, де спектральна неоднорідність є суттєвим фактором.

У цій праці було запропоновано та випробувано новий підхід до підвищення просторового розрізнення супутникових зображень на основі генеративно-змагальних мереж (GAN). До основних висновків слід віднести наступні положення.

1. **Висока ефективність методу.** Використання GAN для підвищення просторового розрізнення супутникових зображень Sentinel-2 і Landsat-9 показало значне покращення якості зображень, що дозволяє отримувати детальніші дані для аналізу різних типів земельного покриття.
2. **Обмеження в міських умовах.** Незважаючи на успіхи в природних ландшафтах, модель стикається з труднощами при генерації зображень міських територій. Це підкреслює необхідність подальших досліджень і вдосконалення архітектури для точного відтворення складних структур і текстур.
3. **Гармонізація даних різних супутників.** Запропонований підхід сприяє ефективній інтеграції даних з різних супутників, що дозволяє використовувати їх спільно для більш точного і всебічного аналізу змін на земній поверхні.

Таким чином, запропонований метод має потенціал для значного покращення якості супутникових зображень і відкриває нові можливості для їх використання у дослідженнях та практичних застосуваннях, пов'язаних з моніторингом земного покриття, оцінкою впливу кліматичних змін та іншими важливими завданнями. Подальші дослідження в цьому напрямку можуть ще більше розширити можливості цього підходу.

ПЕРЕЛІК ПОСИЛАНЬ

1. Kislov, Dmitry E., et al. "Extending deep learning approaches for forest disturbance segmentation on very high-resolution satellite images." *Remote Sensing in Ecology and Conservation*, vol. 7, no. 3, pp. 355-368, 2021.
2. Hansen, M. C., et al. "High-resolution global maps of 21st-century forest cover change." *Science*, 342(6160), 850-853, 2013.
3. Waldner F., Schucknecht A., Lesiv M. et al., "Conflation of expert and crowd reference data to validate global binary thematic maps," *Remote sensing of environment*, vol. 221, pp. 235-246, 2019.
4. Shelestov A., Lavreniuk M., Kussul N. et. al., "Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping," *Frontiers in Earth Science*, vol. 5, 2017.

2.5. Генеративні мережі для підвищення просторового розрізнення...

5. d'Andrimont, Raphaël, et al. "From parcel to continental scale-A first European crop type map based on Sentinel-1 and LUCAS Copernicus in-situ observations," arXiv preprint arXiv:2105.09261, 2021.

6. Yi Zhiwei, Li Jia, and Qiting Chen, "Crop classification using multi-temporal Sentinel-2 data in the Shiyang River Basin of China," *Remote Sensing*, 12.24, pp 1-21, 2020.

7. Shelestov A., Lavreniuk M., Vasiliev V., et. al., "Cloud Approach to Automated Crop Classification Using Sentinel-1 Imagery," *IEEE Transactions on Big Data*, 6(3), pp. 572-582, 2019.

8. Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.

9. Yang, Jianchao, and Thomas Huang. "Image super-resolution: Historical overview and future challenges." *Super-resolution imaging*, pp. 20-34, 2010.

10. Dong, Chao, et al. "Image super-resolution using deep convolutional networks." *IEEE transactions on pattern analysis and machine intelligence* 38.2 (2015): 295-307.

11. Kim, Jiwon, Jung Kwon Lee, and Kyoung Mu Lee. "Accurate image super-resolution using very deep convolutional networks." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

12. Dong, Chao, Chen Change Loy, and Xiaoou Tang. "Accelerating the super-resolution convolutional neural network." *European conference on computer vision*. Springer, Cham, 2016.

13. Shi, Wenzhe, et al. "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

14. Lim, Bee, et al. "Enhanced deep residual networks for single image super-resolution." *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2017.

15. Tai, Ying, Jian Yang, and Xiaoming Liu. "Image super-resolution via deep recursive residual network." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.

16. Ian, Goodfellow, et al. "Generative adversarial nets." In *Advances in neural information processing systems*. (2014): 2672-2680.

17. Ledig, Christian, et al. "Photo-realistic single image super-resolution using a generative adversarial network." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.

18. Yuan, Yuan, et al. "Unsupervised image super-resolution using cycle-in-cycle generative adversarial networks." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2018.

19. Wang, Xintao, et al. "Esrgan: Enhanced super-resolution generative adversarial networks." *Proceedings of the European conference on computer vision (ECCV) workshops*. 2018.

20. Johnson, Justin, Alexandre Alahi, and Li Fei-Fei. "Perceptual losses for real-time style transfer and super-resolution." *European conference on computer vision*. Springer, Cham, 2016.

21. Demiray, Bekir Z., Muhammed Sit, and Ibrahim Demir. "D-SRGAN: DEM super-resolution with generative adversarial networks." *SN Computer Science* 2.1 (2021): 1-11.

22. Chen, Hongguang, et al. "Generative adversarial networks capabilities for super-resolution reconstruction of weather radar echo images." *Atmosphere* 10.9 (2019): 555.

23. Lavreniuk, Mykola, et al. "Super Resolution Approach for the Satellite Data Based on the Generative Adversarial Networks." *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2022, pp. 1095-1098.

24. Vaswani, Ashish, et al. "Attention is all you need." *Advances in neural information processing systems*, 30 (2017).

25. Zhao, Long, et al. "Improved transformer for high-resolution GANs." *Advances in Neural Information Processing Systems*, 34, pp. 18367-18380, 2021.

26. Liu, Ze, et al. "Swin transformer: Hierarchical vision transformer using shifted windows." *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021.

27. Lavreniuk, M., Shumilo, L., & Lavreniuk, A. "Generative Adversarial Networks for the Satellite Data Super Resolution Based on

2.5. Генеративні мережі для підвищення просторового розрізнення...

the Transformers with Attention,” IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2023, pp. 6294-6297.

28. Chen, Xiangyu, et al. "Activating More Pixels in Image Super-Resolution Transformer." arXiv preprint arXiv:2205.04437, 2022.

29. Kolotii, A., Kussul, N., Shelestov, A., Skakun, S., Yailymov, B., Basarab, R., ..., Ostapenko, V. "Comparison of biophysical and satellite predictors for wheat yield forecasting in Ukraine." *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(7W3), 2015, pp. 39-44.

30. Lavreniuk, M., Bhat, S. F., МӀller, M., & Wonka, P. (2023). EVP: Enhanced Visual Perception using Inverse Multi-Attentive Feature Refinement and Regularized Image-Text Alignment. arXiv preprint arXiv:2312.08548.

31. Spencer, J., Tosi, F., Poggi, M., Arora, R. S., Russell, C., Hadfield, S., ... & Elder, J. H. (2024). The third monocular depth estimation challenge. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 1-14).

32. Lavreniuk, M. (2024). SPIdepth: Strengthened Pose Information for Self-supervised Monocular Depth Estimation. arXiv preprint arXiv:2404.12501.

ПРИКЛАДНІ ЗАДАЧІ СУПУТНИКОВОГО ІНТЕЛЕКТУ НА МУЛЬТИМОДАЛЬНИХ ДАНИХ

1. ВИЗНАЧЕННЯ ОПТИМАЛЬНИХ МІСЦЬ ДЛЯ РОЗМІЩЕННЯ СОНЯЧНИХ ЕЛЕКТРОСТАНЦІЙ НА ТЕРИТОРІЇ УКРАЇНИ

Софія Дрозд, магістр
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

sofi.drozd.13@gmail.com

ВСТУП

Війна в Україні призвела до серйозних руйнівних наслідків, особливо в енергетичному секторі, через прямі бомбардування та обстріли інфраструктурних об'єктів у різних частинах країни. За даними Національної енергетичної компанії «Укренерго», станом на травень 2023 року Україна втратила близько 27 ГВт існуючих потужностей генерації. Найбільших збитків зазнали енергетичні об'єкти на сході та півдні України. Зокрема, Запорізька атомна електростанція опинилася під окупацією, а Каховська гідроелектростанція була зруйнована. Альтернативні джерела енергії також зазнали значних втрат, зокрема, приблизно половина сонячних електростанцій вийшла з ладу.

Відновлення енергетичної інфраструктури є критично важливим для відновлення добробуту та розвитку країни. В умовах євроінтеграції України особливо важливо не лише відновити енергетичні потужності, але й орієнтуватися на виконання принципів Європейського зеленого курсу (European Green Deal).

3.1. Визначення оптимальних місць для розміщення сонячних...

Цей амбітний план Європейського Союзу спрямований на перехід до кліматично нейтральної економіки до 2050 року, що передбачає поступову відмову від викопних видів палива на користь відновлюваних джерел енергії.

Україна, як країна-кандидат на вступ до ЄС, активно прагне відповідати цим стандартам, що накладає додаткові вимоги до відновлення енергетичної інфраструктури. Відповідно, пріоритетним стає розвиток відновлюваних джерел енергії, зокрема сонячної енергетики, яка має значний потенціал. Будівництво сонячних електростанцій є швидким та відносно доступним рішенням, особливо в контексті сучасних технологій та стандартизованих компонентів. Проте для ефективного використання сонячної енергії важливим є правильний вибір місць для встановлення станцій, що дозволить максимізувати виробництво електроенергії та забезпечити оптимальну ефективність системи.

1.1. ОГЛЯД ЛІТЕРАТУРИ

Оптимальне розташування сонячних панелей дозволяє максимізувати виробництво електроенергії та забезпечити оптимальну ефективність системи. Неправильний вибір місця може призвести до зниження продуктивності та недовикористання потенціалу сонячної енергії.

Для визначення оптимальних територій для встановлення сонячних електростанцій цінним ресурсом є дані спостереження Землі [1]. Використання супутникових даних дозволяє швидко та ефективно аналізувати велику кількість інформації щодо потенційних місць встановлення сонячних електростанцій. Супутникові дані можуть надати інформацію про кліматичні умови, рельєф, землекористування та інші параметри, що впливають на продуктивність сонячних панелей.

Низка досліджень присвячена аналізу потенціалу та викликам встановлення великих сонячних електростанцій у різних країнах. Так, у роботі [2] оцінили потенціал використання сонячної радіації в різних регіонах Ірану, вказавши на значний потенціал у центральних та південних частинах країни. Подібним чином, у [3] показано, що сонячні фотогальванічні та вітрові електростанції в двох провінціях Афганістану можуть досягти рівня проникнення 65%–70% без значного скорочення виробництва. У дослідженні [4] запропонована модель системи підтримки прийняття рішень для

Індонезії для розвитку великомасштабних сонячних електростанцій у тропічних країнах. У [5] обговорювались питання економічної життєздатності концентрованої сонячної енергії для Іспанії, наголошуючи на її обмеженнях через високі капітальні та експлуатаційні витрати. В праці [6] оцінено десять провінцій Канади для будівництва сонячних електростанцій. В роботі [7] надали рекомендації щодо вибору місця для сонячних електростанцій у багатьох країнах, включаючи В'єтнам. У [8] наведені результати геопросторового та часового порівняння сонячних технологій у Європі та США, висвітливши значні регіональні відмінності в річній продуктивності.

Дослідження [9] визначає критерії вибору оптимального місця для дуже великих фотогальванічних сонячних електростанцій у глобальному контексті. У [10] підкреслили потенціал сонячної енергії для чистішого виробництва в Пакистані, тоді як у [11] демонструють технічний потенціал певних локацій на південному сході Ірану для забезпечення значних обсягів сонячної електроенергії. У [12] визначають та ранжують драйвери та бар'єри для розгортання концентрованої сонячної енергії в ЄС. У [13] обговорюють можливості для ширшого інвестування у впровадження сонячної енергії.

Незважаючи на значний потенціал, можливості використання сонячної енергії в Україні залишаються переважно невивченими, і в літературі немає ґрунтовних публікацій, що безпосередньо стосуються цієї теми для країни.

Для визначення найважливіших критеріїв придатності земель часто використовується метод багатокритеріального аналізу. Цей метод часто поєднується з методом аналізу ієрархій (МАІ, англ. Analytic Hierarchy Process - АНР) для визначення важливості кожного критерію відносно інших [14].

Для прямого розрахунку придатності земель використовуються булева логіка, модель зважених сум (МЗС, англ. Weighted Sum Model -WSM) або нечітке накладання. Як метод булевої логіки, так і МЗС використовують дискретні порогові значення для визначення придатності. Коефіцієнти та ваги в моделях зазвичай визначаються групою експертів. Обидва методи передбачають припущення та певний ступінь невизначеності.

Натомість нечітка логіка пропонує більш адаптивний підхід, який не обмежується жорсткими межами. Замість чітких категорій із визначеними межами, вона дозволяє використовувати кілька градацій. Наприклад, для оцінки інтенсивності глобальної горизонтальної сонячної радіації можуть бути встановлені нечіткі

3.1. Визначення оптимальних місць для розміщення сонячних...

межі для розмежування таких категорій, як «дуже інтенсивна», «помірно інтенсивна» тощо, що дає результати, які точніше відображають реальність.

Так, у [15] вдалося виконати завдання з вибору місць для сонячних електростанцій, поєднавши нечітку та булеву логіку, враховуючи економічні, технічні та екологічні показники. Однак у цій роботі всі критерії мають однакову вагу, що може спотворювати результати.

У [16] показали, що комбінація нечіткої логіки, МЗС та багатокритеріального аналізу прийняття рішень характеризується високою точністю та продемонстрували успішне застосування нечіткої логіки для оцінки оптимальних місць для сонячних електростанцій.

Попри існуючі досягнення в цій сфері, потенціал для використання сонячної енергії в Україні залишається переважно невивченим. Немає значних публікацій, які б всебічно досліджували можливості встановлення сонячних електростанцій у цій країні. Хоча деякі дослідження були проведені [17], вони не враховують усіх факторів і не пропонують комплексного методу для визначення придатності територій по всій країні для розміщення сонячних ферм.

1.2. ПОСТАНОВКА ЗАДАЧІ

Метою цього дослідження є розробка та впровадження методології для визначення оптимальних територій в Україні для встановлення сонячних електростанцій з урахуванням специфічних географічних і кліматичних умов країни. Використовуючи мультимодальні джерела геопросторових даних, створюється комплексна модель, яка інтегрує кліматичні дані, інформацію про рельєф, землекористування та інші критично важливі фактори. Ця модель дозволяє ідентифікувати території, де сонячні електростанції можуть забезпечити максимальну продуктивність і ефективність.

Ключовим завданням є застосування сучасних методів багатокритеріального аналізу, зокрема поєднання методу аналізу ієрархій (МАІ) з нечіткою логікою та моделлю зважених сум (МЗС). Такий підхід забезпечує точнішу оцінку придатності земель для розміщення сонячних станцій, враховуючи широкий спектр факторів та їх взаємодію.

Крім визначення нових потенційних зон для сонячних електростанцій, дослідження передбачає оцінку ефективності вже існуючих об'єктів. Планується проведення детального аналізу поточного розташування сонячних електростанцій в Україні, щоб визначити їх оптимальність з точки зору енергетичного потенціалу. Це дозволить виявити можливі недоліки в наявній інфраструктурі та запропонувати рекомендації для її покращення.

В даному розділі запропоновано модель аналізу придатності територій України для ефективного встановлення сонячних електростанцій з використанням підходу на основі мультимодальних джерел геопросторових даних, таких як супутникові спостереження за кліматом, характеристики рельєфу та землекористуванням.

1.3. ВИКОРИСТАНІ ДАНІ

Ефективність сонячних електростанцій залежить від різних критеріїв, включаючи кліматичні, топографічні, економічні та інші параметри. У рамках цього дослідження основні зусилля були зосереджені на ключових критеріях, що впливають на оптимальний вибір розташування сонячних електростанцій. Зокрема, до цих факторів належать наступні.

- **Кліматичні умови:** глобальна горизонтальне сонячне випромінювання (англ. Global Horizontal Irradiance - GHI), температура, опади, швидкість вітру.

- **Топографічні ознаки:** висота та нахил місцевості.

- Грунтовий покрив і землекористування.

Для аналізу ґрунтового покриву та землекористування було використано карту класифікації земного покриву за 2022 рік, створену на основі даних Sentinel-1 і Sentinel-2.

Кліматичні та топографічні параметри території України були отримані з використанням кліматичних і топографічних карт, побудованих на платформі Google Earth Engine на основі відкритих супутникових даних.

Кліматичні умови. Для аналізу клімату на території України було використано погодинні дані з набору ERA5-Land з просторовим розрізненням 9 км, надані Copernicus Climate Data Store. Цей набір даних містить усі необхідні в рамках даного дослідження параметри для аналізу клімату, доступні з 1950 року, а саме:

- Глобальне горизонтальне сонячне випромінювання (GHI);

3.1. Визначення оптимальних місць для розміщення сонячних...

- Температура на висоті 2 метри над рівнем землі;
- U та V компоненти вітру на висоті 10 метрів над рівнем землі;
- Кількість опадів, включаючи дощ і сніг.

Щоб забезпечити точність оцінки кліматичних умов і врахувати часові зміни, використовувалися дані за 2015-2022 роки, що дозволило побудувати усереднені кліматичні карти за п'ятирічний період, забезпечуючи релевантність результатів дослідження. Побудовані кліматичні та топографічні карти представлені на рис. 1.

Топографічні особливості. Для побудови карт рельєфу території України було використано набір даних Shuttle Radar Topography Mission (SRTM) Digital Elevation Model (DEM) з просторовим розрізненням 90 м. Отримані карти висот та схилів зображено на рис. 2.

Земний покрив і землекористування. Сонячні електростанції не можна встановлювати в місцях з невідповідним ґрунтовим покривом, таких як болота, річки або густі ліси. Крім того, вибір місця розташування сонячних електростанцій має бути узгоджений з іншими потребами землекористування для забезпечення найбільш ефективного використання території. Тому сонячні електростанції заборонено встановлювати в заповідниках, національних парках і подібних територіях.

Найбільш придатними зонами для розміщення сонячних електростанцій є вільні та необроблювані земельні ділянки. Менше придатні також сільськогосподарські поля і рідколісся.

Карта класифікації земного покриву для 2022 року, використана у даному дослідженні, показана на рис. 3. Вона включає 16 класів, серед яких 8 класів відповідають сільськогосподарським культурам. Карта містить інформацію про необроблені поля, ліси, парки та інші типи земель, які впливають на вибір місць для сонячних батарей [18].

Як видно з рис. 3, найбільші площі необроблених земель розташовані у південній частині України. Північні та західні райони країни багаті на ліси. На решті території України сільськогосподарські поля розподілені рівномірно.

Частина 3. Прикладні задачі супутникового інтелекту на ...

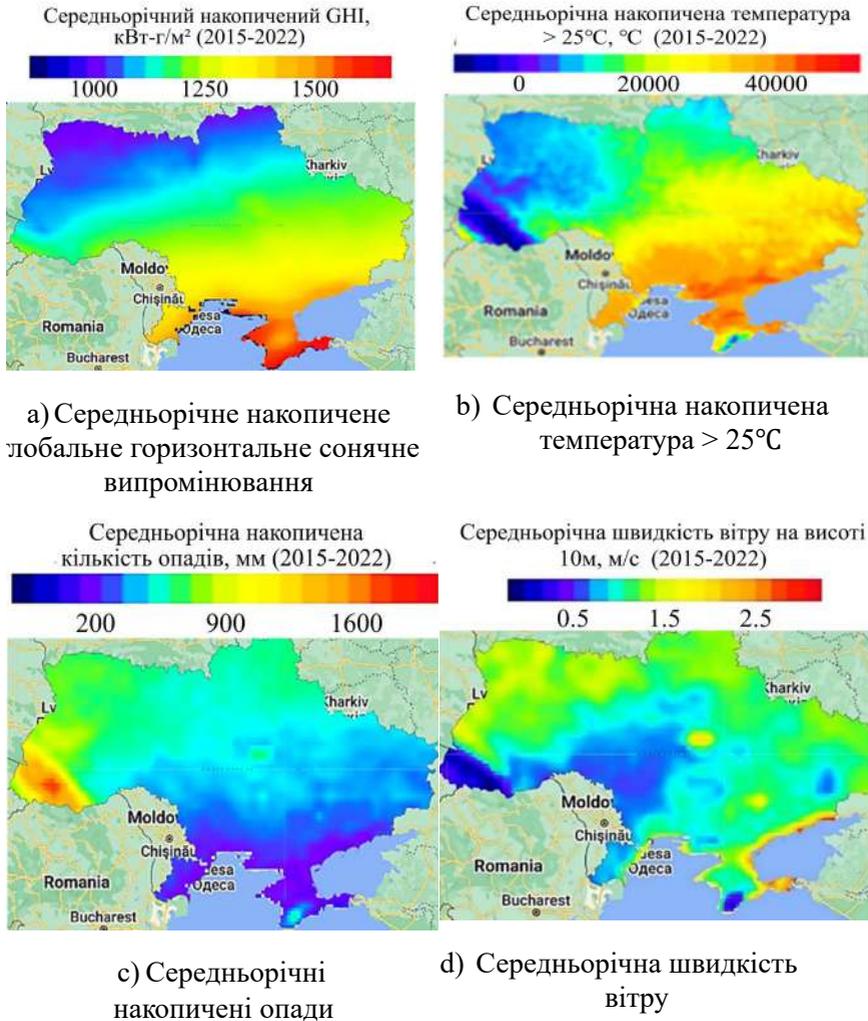


Рис. 1. Кліматичні карти України (усереднені дані за 2015–2022 рр.)

3.1. Визначення оптимальних місць для розміщення сонячних...

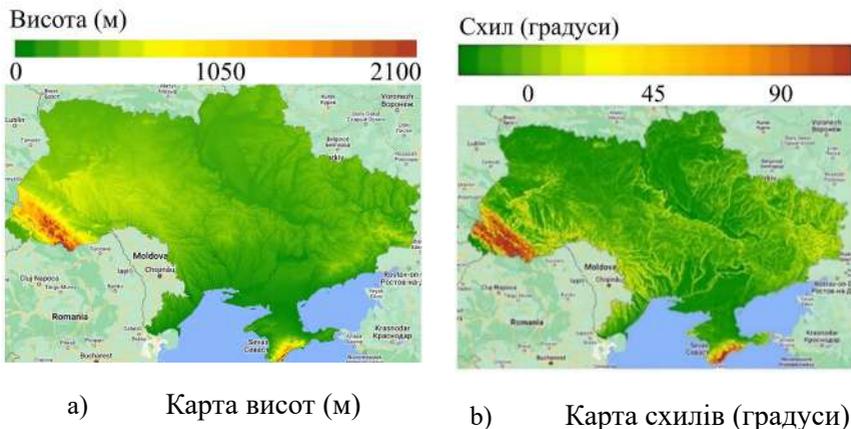


Рис. 2. Карти рельєфу України



Рис. 3. Карта класифікації земного покриття для 2022 року

Збір даних про найбільші сонячні електростанції в Україні. На основі кліматичних, топографічних та класифікаційних карт можна оцінити не лише потенціал території України для побудови нових ефективних сонячних електростанцій, а також оптимальність розташування існуючих найбільших об'єктів сонячної енергетики в Україні.

Для отримання даних про розташування найбільших сонячних електростанцій в Україні було використано відкриті карти платформи Wikimapia (<https://wikimapia.org/>). Для проведення досліджень було завантажено векторні дані для 298 основних сонячних електростанцій України (рис. 4).

Ці полігони містять інформацію про географічні координати сонячних електростанцій, назви та тип (сонячна електростанція, сонячні батареї тощо). За допомогою цього набору даних можна провести геопросторовий аналіз і оцінити адекватність розміщення найбільших сонячних електростанцій в Україні та визначити території, потенціал яких ще не повністю використано.

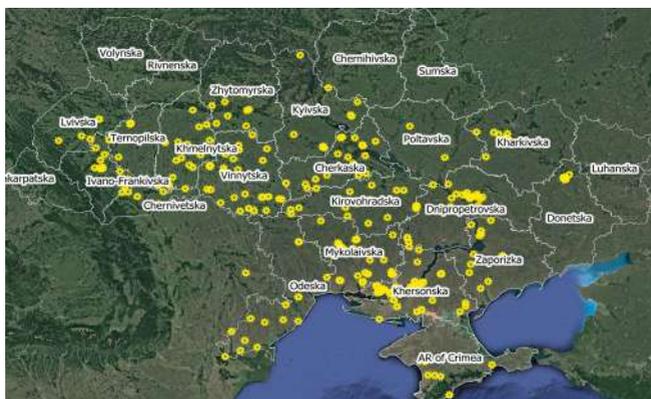


Рис. 4. Сонячні електростанції України

1.4. ОПИС МЕТОДОЛОГІЇ

Для визначення найбільш оптимальних місць для розміщення сонячних електростанцій на території України використано комплексну методику. Цей підхід поєднує метод зваженої лінійної комбінації, метод парного порівняння (похідний від МАІ), який допомагає визначати вагові коефіцієнти для кліматичних та топографічних параметрів, а також землекористування, і застосування нечіткої логіки для нормалізації цих параметрів.

На рис. 5 представлено процес побудови карти придатності для встановлення сонячних електростанцій.

3.1. Визначення оптимальних місць для розміщення сонячних...

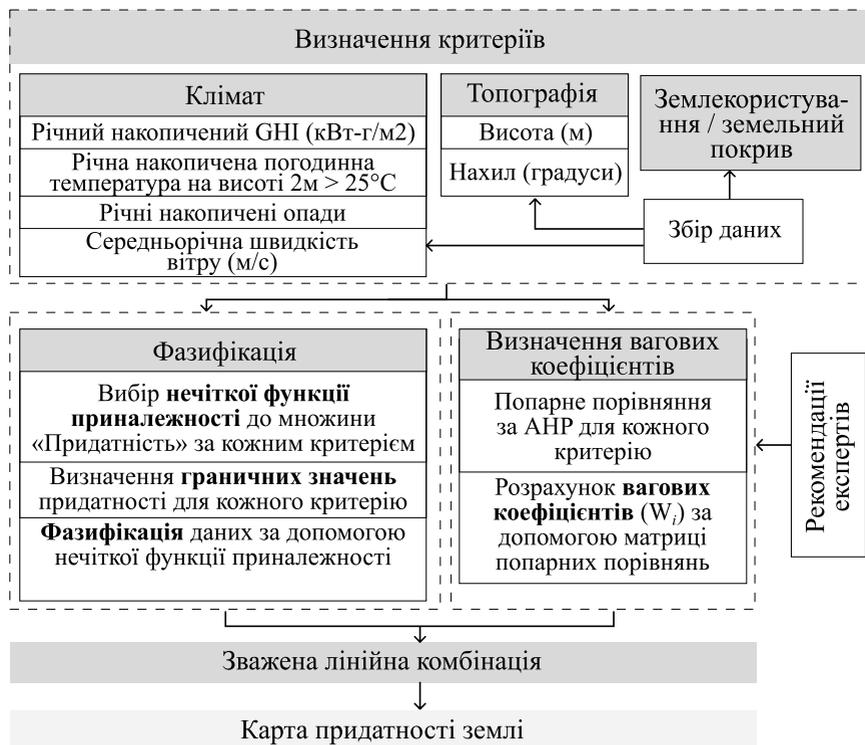


Рис. 5. Алгоритм побудови карти придатності територій для встановлення сонячних електростанцій

На першому етапі визначаються кліматичні, топографічні параметри, що впливають на ефективність сонячної електростанції, а також землекористування. В результаті отримуються растрові дані, які відповідають цим критеріям, як було описано в попередньому підрозділі.

На наступному етапі дані нормалізуються за допомогою нечіткої логіки, тобто *фазифікуються*, в діапазоні від 0 до 1. Нульове значення відповідає абсолютній непридатності критерію для встановлення сонячної електростанції, тоді як 1 є ідеальним значенням критерію. У результаті буде отримано нечіткі карти придатності для кожного критерію.

Для точного врахування впливу кожного критерію на придатність землі для встановлення сонячної електростанції визначаються вагові коефіцієнти на основі думок експертів – експертних рекомендацій.

Після отримання карт придатності та відповідних вагових коефіцієнтів для кожного критерію використовується зважена лінійна комбінація. В результаті може бути сформована карта придатності землі для встановлення сонячних електростанцій. Більш детальний опис кожного кроку алгоритму наведено нижче.

1.5. НЕЧІТКА ЛОГІКА ДЛЯ НОРМАЛІЗАЦІЇ ВХІДНИХ ГЕОПРОСТОРОВИХ ДАНИХ

Хоча модель зважених сум зазвичай використовується для аналізу придатності без використання нечіткої логіки, у даному дослідженні розподіл кліматичних і топографічних параметрів на чіткі класи придатності для встановлення сонячних панелей неможливий. Це пов'язано з труднощами в остаточному присвоєнні конкретних числових діапазонів високопридатним, помірно придатним або непридатним класам.

Включення нечіткої логіки дозволяє більш гнучко розглядати неоднозначності та невизначеності в даних, які можуть виникнути під час територіального аналізу. Це допомагає отримати більш реалістичне та адаптоване до різних умов рішення. Тому для розділення території України на придатні чи невідповідні зони для кожного з вхідних кліматичних і топографічних параметрів, ми використовуємо нечітку логіку, зокрема метод *фазифікації*. Фазифікація — це процес перетворення чіткого набору вхідних даних у нечіткий набір, у нашому випадку із присвоєнням ступенів належності значень вхідних параметрів до нечіткої множини в діапазоні від 0 до 1. Це перетворення досягається шляхом застосування ретельно відібраної функції належності, яка визначає рівень приналежності кожної точки даних до нечіткої множини.

Для створення нечіткого набору для кожного вхідного критерію, який розглядається під час аналізу придатності території для встановлення сонячних панелей, необхідно виконати наступні кроки.

Вибір нечітких функцій належності. На цьому кроці визначається математична функція $\mu(x)$, яка визначає ступінь приналежності елемента до певного набору або категорії. Ця функція приналежності може приймати різні форми, такі як трикутники, трапеції, Гаусса (нормальний розподіл) та інші. В даному випадку, для кожного критерію буде визначено функції приналежності до нечіткої множини «Придатність», трикутної або

3.1. Визначення оптимальних місць для розміщення сонячних...

трапецієподібної форми, що найкраще представляють природу вхідних даних.

Визначення граничних точок. Для визначення функції приналежності в певному числовому діапазоні, необхідно встановити крайні граничні значення для кожного критерію. Ці значення визначають повну приналежність до множини «Придатність» (ймовірність 1) або повну неприналежність (ймовірність 0). Значення, після якого ймовірність стає нульовою, називають «порогом придатності».

Розрахунок ймовірності членства. Після визначення функції приналежності, області визначення та граничних точок для кожного вхідного параметра будуються відповідні набори термів і обчислюється ймовірність приналежності до нечіткої множини «Придатність». Ця ймовірність коливається від 0 до 1 для проміжних значень між крайніми точками «повністю придатний» і «повністю непридатний». Для цього використано інструмент Fuzzify із модуля Saga в програмному забезпеченні QGIS. Граничні точки, визначені на попередньому кроці, є вхідними параметрами для запуску алгоритму Fuzzify, який безпосередньо створює функцію належності та призначає нечіткі значення кожному критерію.

Процес фазифікації для кліматичних і топографічних критеріїв описано в табл. 1.

Таблиця 1 Фазифікація кліматичних та топографічних параметрів

Параметр	Поріг придатності	Функція приналежності	Графік функції приналежності
GHI	< 1100 kWh/m ²	$\mu(x) = \begin{cases} 0, & x < 1100 \\ 1 - \frac{1500 - x}{400}, & 1100 \leq x < 1500 \\ 1, & x \geq 1500 \end{cases}$	

Частина 3. Прикладні задачі супутникового інтелекту на ...

Темп.	≥ 35000 °C	$\mu(x) = \begin{cases} 1, & x < 5000 \\ \frac{35000 - x}{30000}, & 5000 \leq x < 35000 \\ 0, & x \geq 35000 \end{cases}$	
Швид. вітру	< 0.5 м/м і ≥ 3 м/с	$\mu(x) = \begin{cases} 0, & x < 0,5 \\ \frac{1,5 - x}{1}, & 0,5 \leq x < 1,5 \\ 1, & x = 1,5 \\ \frac{3 - x}{1,5}, & 1,5 < x < 3 \\ 0, & x \geq 3 \end{cases}$	
Опади	< 200 мм і ≥ 1500 мм	$\mu(x) = \begin{cases} 0, & x < 200 \\ 1 - \frac{500 - x}{300}, & 200 \leq x < 500 \\ 1, & 500 \leq x < 700 \\ \frac{1500 - x}{800}, & 700 \leq x < 1500 \\ 0, & x \geq 1500 \end{cases}$	
Нахил	$\geq 15^\circ$	$\mu(x) = \begin{cases} 1, & x < 1 \\ \frac{15 - x}{11}, & 1 \leq x < 15 \\ 0, & x \geq 15 \end{cases}$	
Висота	< 0 м і ≥ 2200 м	$\mu(x) = \begin{cases} 0, & x < 0 \\ 1 - \frac{500 - x}{500}, & 0 \leq x < 500 \\ 1, & 500 \leq x < 1500 \\ \frac{2200 - x}{700}, & 1500 \leq x < 2200 \\ 0, & x \geq 2200 \end{cases}$	

3.1. Визначення оптимальних місць для розміщення сонячних...

Оскільки використовувана вихідна карта землекористування представлена у вигляді дискретних цілочисельних значень, що просто ідентифікують кожен клас і не повинні сприйматися як безпосередні порівнювані числа, для фазифікації цієї карти довелося здійснити кілька додаткових операцій. Основне завдання полягало в тому, щоб перевести цілочисельні ідентифікатори кожного класу у числа, що вказували б на ступінь придатності земного покриття для встановлення сонячних електростанцій. Для цього кожен клас було оцінено за шкалою від 1 до 5, де 1 означає абсолютну непридатність території, а 5 — повну придатність (табл. 2).

Таблиця 2 Перекласифікація карти земного покриття

Id класу	Назва класу	Оцінка
1	Штучні об'єкти	3
2	Пшениця	4
3	Ріпак	4
5	Кукурудза	4
7	Соняшник	4
8	Соя	4
9	Інші культури	4
10	Ліс	1
11	Луки	5
12	Гола земля	5
13	Вода	1
14	Болота	1
15	Ячмінь	4
18	Сади, парки	2
19	Гречка	4
22	Не оброблені поля	5

Території, непридатні для встановлення сонячних панелей з огляду на специфічні характеристики земельного покриття, такі як річки, болота та ліси, отримали оцінку 1. Сади, парки мають менше обмежень, але все ще помірно непридатні через законодавчі обмеження (заборона встановлення сонячних панелей у заповідниках чи національних парках) або з точки зору міркування щодо використання. Тому вони були оцінені як 2.

Невеликі сонячні станції для побутових або промислових потреб можна встановити на дахах будівель. Сільськогосподарські

поля, особливо завдяки ефективності сучасних агрофотоелектричних систем, які поєднують сільське господарство та виробництво сонячної енергії, добре підходять для установки сонячних ферм і отримали оцінку 4. Однак найбільш придатними територіями для сонячних електростанцій, особливо для великих сонячних електростанцій, є необроблені поля, голі землі та луки, оцінені як 5.

Після перекласифікації карта землекористування була фазифікована, подібно до підходу до карт кліматичних і топографічних компонентів. Фазифікація проводилася лінійною функцією з крайніми точками 1 (абсолютно непридатна земля) і 5 (повністю придатна земля) для визначення ступеня придатності.

Нечітка множина «придатності», отримана в результаті фазифікації, була розділена на 5 рівних діапазонів, кожен з яких описується відповідною лінгвістичною змінною (табл. 3).

Таблиця 3 Нечіткі лінгвістичні змінні для множини "Придатність"

Інтервал	Лінгвістична змінна
<0.2	Дуже низька придатність
0.2-0.4	Низька придатність
0.4-0.6	Середня придатність
0.6-0.8	Висока придатність
>0.8	Дуже висока придатність

Таким чином, для кожного кліматичного та топографічного параметра, а також карти землекористування були побудовані нові карти, умовно розділені на 5 нечітких діапазонів (рис. 6). На цих картах кожен піксель описує ймовірність належності відповідного параметра до нечіткого набору «Придатність» для встановлення сонячних панелей.

Оскільки початкові дані про клімат, рельєф і землекористування були отримані з різних джерел, карти мали різне просторове розрізнення, що могло призвести до неточностей. Для вирішення цієї проблеми та забезпечення належного використання даних, всі карти були перепроєктовані до загального просторового розрізнення 100 м.

3.1. Визначення оптимальних місць для розміщення сонячних...

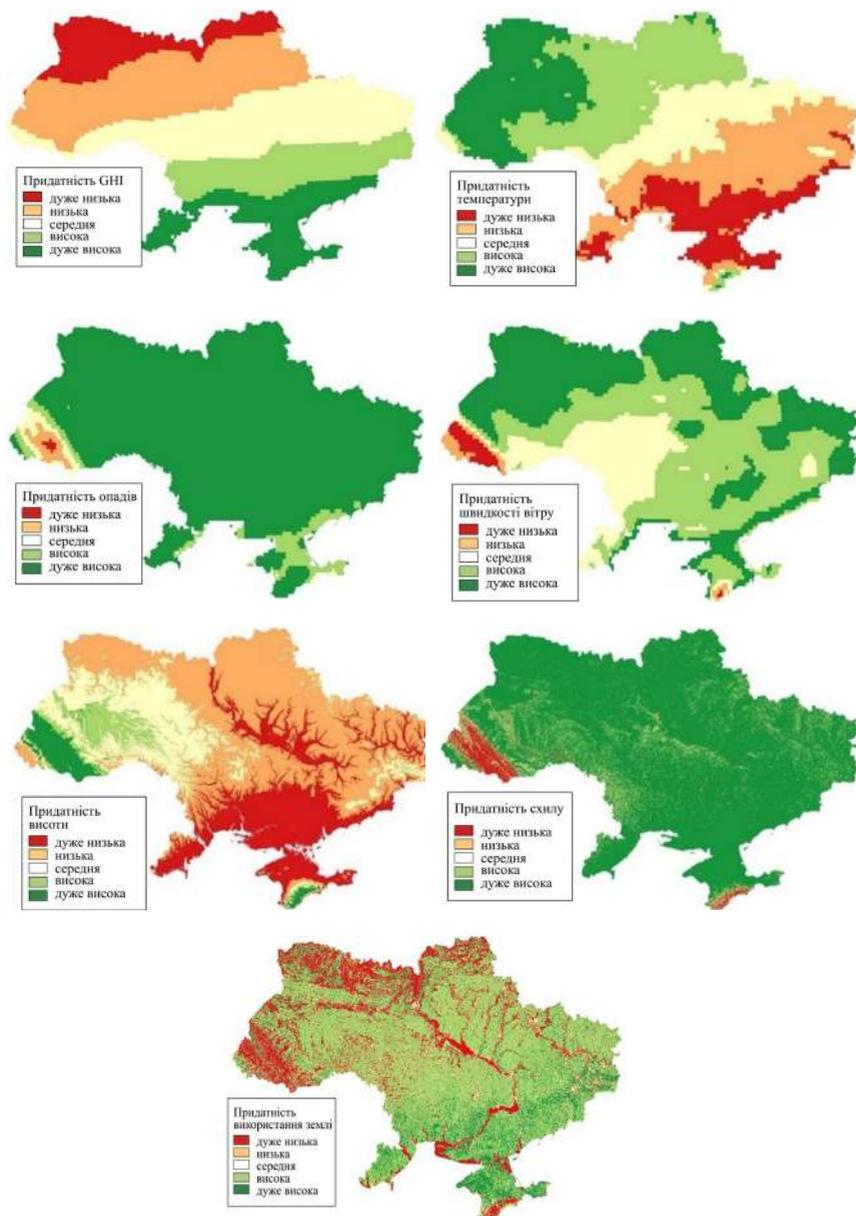


Рис. 6. Фазифіковані карти

1.6. ВИЗНАЧЕННЯ ВАГОВИХ КОЕФІЦІЄНТІВ ЗА ДОПОМОГОЮ МЕТОДУ ПОПАРНИХ ПОРІВНЯНЬ

Опис методу. Оскільки клімат, топографічні фактори та землекористування мають різний ступінь важливості для визначення придатності районів для сонячних електростанцій, необхідно встановити вагові коефіцієнти для кожного з цих параметрів. Для визначення цих вагових коефіцієнтів використано метод попарного порівняння на основі методу аналізу ієрархій (МАІ).

Метод МАІ, розроблений Томасом Сааті [19], заснований на використанні матриць попарних порівнянь для визначення відносної важливості різних змінних. Дев'ятибальна шкала, описана в табл. 4, використовується для спрощення порівняння цих змінних.

Таблиця 4 Шкала матриці порівнянь

Рівень переваги	Визначення	Опис
1	Відсутність переваги	Дві альтернативи мають однакову важливість у досягненні цілі.
3	Слабка перевага	Досвід та судження слабо віддають перевагу одній альтернативі перед іншою.
5	Сильна перевага	Досвід та судження міцно віддають перевагу одній альтернативі перед іншою.
7	Дуже сильна перевага	Віддача переваги одній альтернативі над іншою дуже виражена. Її перевага практично очевидна.
9	Екстремальна перевага	Докази на користь переваги однієї альтернативи перед іншою надзвичайно сильні та очевидні.
2, 4, 6, 8	Проміжні значення між сусідніми оцінками	Ситуація, де потрібно прийняти компромісне рішення між сусідніми значеннями.

3.1. Визначення оптимальних місць для розміщення сонячних...

Значення на цій шкалі коливаються від 1 до 9, де 1 означає однакову важливість змінних, а 9 вказує на надзвичайно сильну перевагу однієї змінної над іншою. У результаті порівняння кожного з критеріїв між собою отримуємо матрицю попарних порівнянь, яка описується такою формулою:

$$A = \begin{bmatrix} 1 & a_{12} & \dots & a_{1n} & 1/a_{12} & 1 & \dots & a_{2n} & \dots & \dots & \dots \\ \dots & 1/a_{1n} & 1/a_{2n} & \dots & 1 & \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix}, \quad (1)$$

де A — матриця попарних порівнянь; a_i — рівень важливості; n — кількість критеріїв.

Для визначення вагового коефіцієнта для кожного критерію за допомогою матриці попарних порівнянь спочатку необхідно обчислити середнє геометричне для кожної змінної (середнє геометричне у рядках) за формулою:

$$GM_i = \sqrt[n]{\prod_{j=1}^n a_{ij}}, \quad (2)$$

де GM_i — середнє геометричне для i -ї змінної (критерію); a_{ij} — елементи матриці попарного порівняння; n — це число критеріїв.

Потім отримані значення нормалізуються за допомогою формули:

$$W_i = \frac{GM_i}{\sum_1^n GM_i}. \quad (3)$$

Нормовані значення середнього геометричного є ваговими коефіцієнтами для кожного критерію. Для заповнення матриці попарних порівнянь залучено експертів з досвідом у відповідній галузі. У контексті цього дослідження експертами були професіонали, які спеціалізуються на встановленні сонячних електростанцій.

Навіть за наявності висококваліфікованих експертів врахування їхніх оцінок може призвести до неправильних результатів через людські помилки. Для виявлення потенційних неточностей та забезпечення об'єктивності експертних порівнянь, можна скористатися методом перевірки рівня невідповідності, широко відомий як коефіцієнт узгодженості (CR) [20], який дозволяє контролювати якість експертних оцінок і виявляти

випадки, коли експерти дають суперечливі або неправильні відповіді.

CR розраховується за такими формулами:

$$CI = \frac{\lambda_{max} - n}{n - 1}, \quad (4)$$

$$CR = \frac{CI}{RI}, \quad (5)$$

де CI — індекс узгодженості; n — кількість критеріїв; λ_{max} — визначає найбільше власне значення матриці; RI — табличне значення на основі кількості критеріїв, так званий випадковий індекс; CR — значення коефіцієнта консистенції.

Значення CR порівнюється з певним порогом узгодженості. Саати припускає [18], що значення CR має бути менше або дорівнювати 0.1. Якщо CR перевищує це порогове значення, матриця вважається неузгодженою, і необхідно переглянути або відкоригувати значення в матриці попарного порівняння.

Розрахунок вагових коефіцієнтів. Для заповнення матриці попарних порівнянь використано опитування експертів у сфері сонячної енергетики [18, 21, 22]. Результати наведені у табл. 5.

Таблиця 5 Матриця попарних порівнянь, отримана з оцінок авторів публікацій та експертів.

	ГНІ	Темп.	Опади	Вітер	Висота	Нахил	Землекор.	GMi	Wi
ГНІ	1,00	2,00	5,00	6,00	5,00	2,00	4,00	3,04	0,33
Темп.	0,50	1,00	4,00	4,00	3,00	2,00	2,00	1,92	0,21
Опади	0,20	0,25	1,00	2,00	2,00	0,33	0,50	0,62	0,07
Вітер	0,17	0,25	0,50	1,00	0,33	0,20	0,33	0,33	0,04
Висота	0,20	0,33	0,50	3,00	1,00	0,25	0,25	0,48	0,05
Нахил	0,50	0,50	3,00	5,00	4,00	1,00	2,00	1,63	0,18
Землекор.	0,25	0,50	2,00	3,00	4,00	0,50	1,00	1,06	0,12
Сума	2,82	4,83	16,00	24,00	19,33	6,28	10,1	9,08	1,00

Після аналізу матриці попарних порівнянь встановлено, що ГНІ, температура та нахил є найвпливовішими критеріями для вибору місця розташування сонячних електростанцій, оскільки вони мають вищі ваги порівняно з іншими параметрами. Опади, швидкість вітру та висота мають менші ваги в цьому контексті, а землекористування — помірну вагу.

3.1. Визначення оптимальних місць для розміщення сонячних...

Для перевірки узгодженості отриманої матриці було обчислено CR з використанням формул (4)-(5). Як зазначено в табл. 6, CR дорівнює 0.0335.

Таблиця 6 Розрахунок CR отриманої матриці попарних порівнянь

λ_{max}	CI	RI	CR
7.2657	0.0443	1.3200	0.0335

Це значення свідчить про узгодженість отриманої матриці, що дозволяє використовувати отримані вагові коефіцієнти для проведення наступних розрахунків.

1.7. МОДЕЛЬ ЗВАЖЕНОЇ СУМИ

Після фазифікації значень вхідних параметрів та визначення вагових коефіцієнтів для кожного параметра шляхом попарних порівнянь, наступним і завершальним кроком у методології процесу вибору оптимального місця розташування сонячних електростанцій є застосування моделі зваженої суми (МЗС).

МЗС — це сума зважених фазифікованих критеріїв в аналізі придатності, яка описується формулою:

$$S_i = \sum_{i=1}^n Criteria_i * W_i, \quad (6)$$

де *Criteria* — фазифіковане значення параметра, який використовується для вибору місця розташування сонячних електростанцій у даному дослідженні; *W* — ваговий коефіцієнт, присвоєний критерію методом попарних порівнянь; *n* — кількість критеріїв; *S_i* — індекс придатності.

Таким чином, буде отримано карту придатності територій для встановлення сонячних електростанцій, значення пікселів на якій будуть варіюватися в діапазоні 0-1, де 1 означає ідеальну придатність, а 0 — абсолютно непридатну територію.

Враховуючи, що водно-болотні угіддя, річки та густі ліси за своєю природою є непридатними для встановлення сонячних електростанцій з огляду на їх специфічні характеристики та екологічну важливість, повністю ці території були виключені з результуючої карти, використовуючи наступну формулу:

$$S_i = Land_{restriction} * \sum_{i=1}^n Criteria_i * W_i, \quad (7)$$

де $Land_{restriction}$ — бінарна карта класифікації ґрунтового покриття, на якій водно-болотні угіддя, річки та ліси мають значення 0, а всі інші класи — 1.

Тому остаточною картою придатності відображає лише ті місця, які справді придатні для встановлення сонячної електростанції.

1.8. ОЦІНКА ПРИДАТНОСТІ ЗЕМЕЛЬ УКРАЇНИ ДЛЯ ВСТАНОВЛЕННЯ СОНЯЧНИХ ЕЛЕКТРОСТАНЦІЙ

В результаті проведених досліджень було побудовано карту придатності території України для встановлення сонячних електростанцій (рис. 7). Для забезпечення більш детального уявлення про придатність землі для встановлення сонячних електростанцій, ця карта була розділена на нерівні інтервали, що дозволило чітко окреслити різні зони придатності.

Як видно з цієї карти, майже вся територія України має індекс придатності землі для встановлення сонячних електростанцій вище 0.55, що вказує на високий енергетичний потенціал країни. Винятком є зона Карпат, де вплив сонячного світла для ефективної роботи сонячних панелей обмежений через складний крутий рельєф та значні опади. Крім того, слід відзначити, що в зоні Карпат та на Поліссі є багато територій, які через особливості ґрунтового покриття є непридатними для розміщення сонячних електростанцій. В цьому регіоні переважають ліси та болота.

Індекс придатності земель для розміщення сонячних електростанцій зростає з півночі на південь і досягає найвищих значень (понад 0.75) на Кримському півострові, частково в Одеській, Миколаївській, Херсонській та Запорізькій областях. У центральній частині України придатність територій для розміщення сонячних електростанцій переважно знаходиться в межах 0.65-0.7. Цікаво, що в центрально-західних областях показник придатності вищий. Зокрема, у Чернівецькій, Вінницькій, Хмельницькій та Тернопільській областях він підвищується до 0.7-0.75. Натомість у східних регіонах є території з придатністю в межах 0.55-0.65. Це можна пояснити тим, що на заході України температури нижчі, ніж на сході при майже однаковій інтенсивності ГНІ.

3.1. Визначення оптимальних місць для розміщення сонячних...

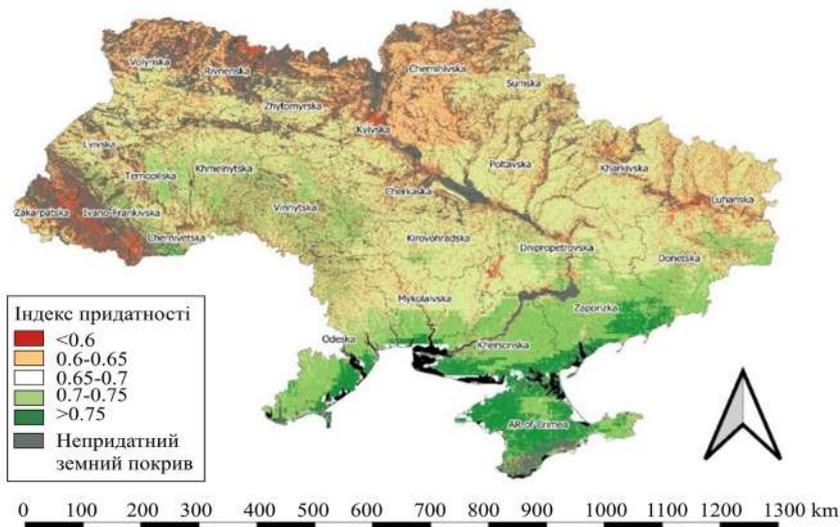


Рис. 7. Карта придатності територій України для встановлення сонячних електростанцій

В північній частині країни показник придатності ще нижчий, але не опускається нижче 0.55, що свідчить про помірний рівень придатності для ефективної роботи сонячної електростанції.

Для кращого розуміння розподілу індексу придатності по країні в числовому діапазоні, було побудовано графік щільності (рис. 8). З цього графіка видно, що придатність землі для встановлення сонячних панелей коливається приблизно від 0.45 до 0.85, з піком близько 0.65.

На основі отриманого розподілу було виділено 5 основних інтервалів, в яких знаходиться індекс придатності. На основі цих значень були створені відповідні лінгвістичні змінні для нечіткого набору придатності землі з параметрами, як показано в табл. 7.

Як видно з рис. 9, є певний відсоток земель із дуже низьким (10.68%) та низьким (16.68%) індексом придатності, а також повністю непридатних ділянок (18.18%) через наявність водойм та лісу. Водночас більше третини (35.65%) земель України має перспективний середній показник придатності. На зони високої та дуже високої придатності припадає 14.4% та 4.78% території відповідно, що забезпечує можливість розвитку та ефективного використання сонячної енергетики на території України.

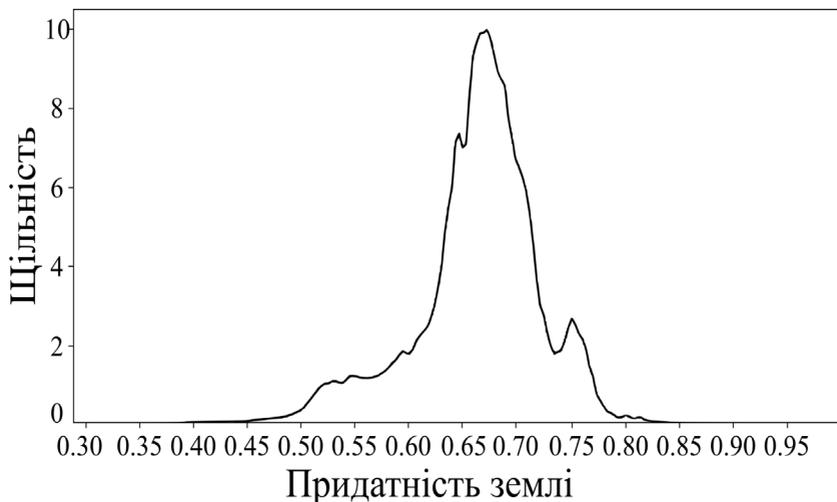


Рис. 8. Розподіл індексу придатності території України для встановлення сонячних електростанцій

Таблиця 7 Розподіл зон у відповідному інтервалі індексу придатності на нечіткі лінгвістичні змінні

Індекс придатності	Лінгвістична змінна	Розподіл зон за лінгвістичними змінними
<0.6	Дуже низька придатність	
0.6-0.65	Низька придатність	
0.65-0.7	Середня придатність	
0.7-0.75	Висока придатність	
>0.75	Дуже висока придатність	

3.1. Визначення оптимальних місць для розміщення сонячних...

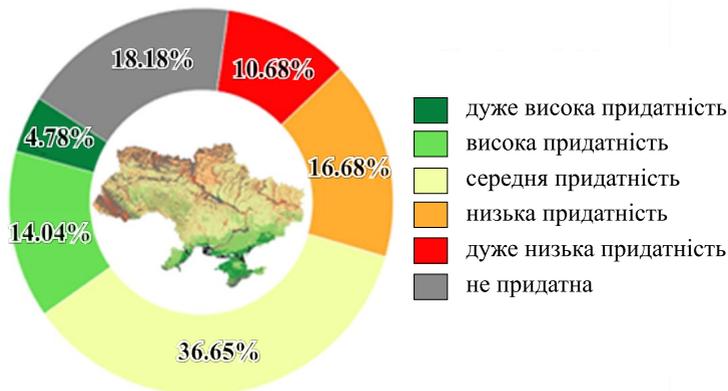


Рис. 9. Розподіл території України за показником придатності земель для встановлення сонячних електростанцій.

ВИСНОВКИ

Проведений у даному розділі аналіз підтверджує значний потенціал використання сонячної енергії на території України. Використання комплексної методології, що включає супутникові спостереження, багатокритеріальний аналіз, нечітку логіку та зважену лінійну комбінацію, дозволило ефективно виділити оптимальні зони для будівництва сонячних електростанцій.

Отримана карта придатності вказує на те, що південні регіони, особливо Кримський півострів, мають найбільший потенціал для розміщення сонячних електростанцій, зі значенням індексу придатності, що перевищує 0,75. Водночас навіть у північних регіонах цей індекс залишається досить високим, не опускаючись нижче 0,55. Загалом, понад 50% території України демонструють помірну або високу придатність для розвитку сонячної енергетики.

Аналізуючи розташування існуючих великих сонячних електростанцій, було встановлено, що багато з них знаходяться в оптимальних регіонах. Проте деякі території, такі як Полтавська та Донецька області, наразі використовуються недостатньо, незважаючи на їх придатність для будівництва сонячних ферм. Виявлені території з високим індексом придатності та ідеальними характеристиками земельного покриття, зокрема в Одеській, Миколаївській та Запорізькій областях, можуть бути ефективно використані для розвитку сонячної енергетики.

Запропонована методологія та результати дослідження сприяють вибору оптимальних ділянок по всій Україні для встановлення сонячних електростанцій, що забезпечить максимальну продуктивність. Розроблений підхід може стати цінним інструментом для підтримки розширення використання сонячної енергії та зміцнення енергосистеми України. Використання значного потенціалу сонячної енергії країни є критично важливим для досягнення енергетичної незалежності, відповідності цілям Європейської Зеленої Угоди та забезпечення сталого розвитку України.

У майбутньому планується розширити дослідження та, на основі отриманої карти придатності, застосувати регресійний аналіз для визначення потенційного обсягу електроенергії, яку можуть генерувати майбутні сонячні електростанції. Це дозволить провести більш детальну оцінку територій і визначити оптимальні місця для створення потужних та ефективних сонячних електростанцій.

ПЕРЕЛІК ПОСИЛАНЬ

1. Mahtta R., Joshi P. K., Jindal A. K. Solar power potential mapping in India using remote sensing inputs and environmental parameters. *Renewable Energy*. 2014. Vol. 71. P. 255–262. DOI: <https://doi.org/10.1016/j.renene.2014.05.037>
2. The potential of harnessing solar radiation in Iran: Generating solar maps and viability study of PV power plants / S. M. Besarati et al. *Renewable Energy*. 2013. Vol. 53. P. 193–199. DOI: <https://doi.org/10.1016/j.renene.2012.11.012>
3. Ershad A. M., Brecha R. J., Hallinan K. Analysis of solar photovoltaic and wind power potential in Afghanistan. *Renewable Energy*. 2016. Vol. 85. P. 445–453. DOI: <https://doi.org/10.1016/j.renene.2015.06.067>
4. GIS-AHP Multi Criteria Decision Analysis for the optimal location of solar energy plants at Indonesia / H. S. Ruiz et al. *Energy Reports*. 2020. Vol. 6. P. 3249–3263. DOI: <https://doi.org/10.1016/j.egy.2020.11.198>
5. San Miguel G., Corona B. Economic viability of concentrated solar power under different regulatory frameworks in Spain. *Renewable and Sustainable Energy Reviews*. 2018. Vol. 91. P. 205–218. DOI: <https://doi.org/10.1016/j.rser.2018.03.017>

3.1. Визначення оптимальних місць для розміщення сонячних...

6. A novel integrated approach for ranking solar energy location planning: a case study / A. Mostafaeipour et al. *Journal of Engineering, Design and Technology*. 2020. Ahead-of-print, ahead-of-print. DOI: <https://doi.org/10.1108/jedt-04-2020-0123>

7. Multi-Criteria Decision Making (MCDM) Approaches for Solar Power Plant Location Selection in Viet Nam / C.-N. Wang et al. *Energies*. 2018. Vol. 11, no. 6. P. 1504. DOI: <https://doi.org/10.3390/en11061504>

8. A Geospatial Comparison of Distributed Solar Heat and Power in Europe and the US / Z. Norwood et al. *PLoS ONE*. 2014. Vol. 9, no. 12. P. e112442. DOI: <https://doi.org/10.1371/journal.pone.0112442>

9. A framework for selecting the location of very large photovoltaic solar power plants on a global/supergrid / B. O. Saracoglu et al. *Energy Reports*. 2018. Vol. 4. P. 586–602. DOI: <https://doi.org/10.1016/j.egy.2018.09.002>

10. Rafique M. M., Rehman S., Alhems L. M. Assessment of solar energy potential and its deployment for cleaner production in Pakistan. *Journal of Mechanical Science and Technology*. 2020. Vol. 34, no. 8. P. 3437–3443. DOI: <https://doi.org/10.1007/s12206-020-0736-9>

11. Theoretical and technical potential evaluation of solar power generation in Iran / G. Ghasemi et al. *Renewable Energy*. 2019. Vol. 138. P. 1250–1261. DOI: <https://doi.org/10.1016/j.renene.2019.02.068>

12. Kiefer C. P., del Rıo P. Analysing the barriers and drivers to concentrating solar power in the European Union. Policy implications. *Journal of Cleaner Production*. 2020. Vol. 251. P. 119400. DOI: <https://doi.org/10.1016/j.jclepro.2019.119400>

13. Stevović I., Mirjanić D., Stevović S. Possibilities for wider investment in solar energy implementation. *Energy*. 2019. Vol. 180. P. 495–510. DOI: <https://doi.org/10.1016/j.energy.2019.04.194>

14. Al Garni H. Z., Awasthi A. Solar PV power plant site selection using a GIS-AHP based approach with application in Saudi Arabia. *Applied Energy*. 2017. Vol. 206. P. 1225–1240. DOI: <https://doi.org/10.1016/j.apenergy.2017.10.024>

15. Yousefi H., Hafeznia H., Yousefi-Sahzabi A. Spatial Site Selection for Solar Power Plants Using a GIS-Based Boolean-Fuzzy Logic Model: A Case Study of Markazi Province, Iran. *Energies*. 2018. Vol. 11, no. 7. P. 1648. DOI: <https://doi.org/10.3390/en11071648>

16. Optimization solar site selection by fuzzy logic model and weighted linear combination method in arid and semi-arid region: A case study Isfahan-IRAN / M. Zoghi et al. *Renewable and Sustainable Energy Reviews*. 2017. Vol. 68. P. 986–996. DOI: <https://doi.org/10.1016/j.rser.2015.07.014>

17. Оптимізація процесу вибору місця розташування сонячних електростанцій з використанням ГІС-аналізу / О. Butenko та ін. Системи управління, навігації та зв'язку. Збірник наукових праць. 2019. Т. 1, № 53. С. 17–21. DOI: <https://doi.org/10.26906/sunz.2019.1.017>

18. Prieto-Amparobn J.A., Pinedo-Blvarez A., Morales-Nieto C.R., Valles-Aragyn M.C., Blvarez-Holgunn A., Villarreal-Guerrero F. A regional GIS-Assisted Multi-Criteria evaluation of Site-Suitability for the development of solar farms. *Land*. 2021. Vol. 10, no. 2. pp. 217. DOI: 10.3390/land10020217.

19. Saaty T.L. *The analytic hierarchy process: Planning, Priority Setting, Resource Allocation*. McGraw-Hill International Book Co. 1980. Vol. 287.

20. A framework for selecting the location of very large photovoltaic solar power plants on a global/supergrid / B. O. Saracoglu et al. *Energy Reports*. 2018. Vol. 4. P. 586–602. DOI: <https://doi.org/10.1016/j.egy.2018.09.002>

21. Tafula J.E., Justo C.D., Moura P., Mendes J., Soares A. Multicriteria Decision-Making approach for optimum site selection for Off-Grid solar photovoltaic microgrids in Mozambique. *Energies*. 2023. Vol. 16, no. 6. pp. 2894. DOI: 10.3390/en16062894.

22. Taoufik M., Meriem L., Fekri A. Land suitability analysis for solar farms exploitation using the GIS and Analytic Hierarchy Process (AHP) – a case study of Morocco. *Polityka Energetyczna – Energy Policy Journal*. 2021. Vol. 24, no. 2. pp. 79–96. DOI: 10.33223/epj/133474.

2. МОДЕЛЮВАННЯ РОЗВИТКУ ІНФРАСТРУКТУРИ СІЛ НА ОСНОВІ ГРАФОВИХ ДАНИХ

Єлизавета Волкова, аспірант
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

yelvol-ipt22@iit.kpi.ua

ВСТУП

Розвиток сільської інфраструктури залишається одним із ключових завдань як для України, так і для багатьох інших країн світу. Нерівномірний розподіл ресурсів та відмінності у рівні розвитку інфраструктури між міськими і сільськими районами посилюють соціальні та економічні нерівності, що гальмують загальний розвиток країни. Це питання особливо актуальне для України, де значна частина населення проживає у сільських регіонах із недостатньо розвинутою інфраструктурою. Нерівномірний доступ до базових послуг, таких як охорона здоров'я, освіта, транспорт і зв'язок обмежує можливості цих територій та знижує якість життя населення.

Традиційні підходи до оцінки інфраструктурних потреб сільських громад виявляються недостатніми, оскільки вони часто не враховують специфічні відмінності між селами. Це призводить до узагальнених рішень, які не здатні ефективно адресувати локальні проблеми.

Інтеграція методів геопросторового аналізу з методами машинного навчання пропонує можливість створення більш точних та адаптованих до контексту моделей для оцінки інфраструктурних потреб сільських громад.

2.1. СУЧАСНІ ПІДХОДИ ДО ОЦІНКИ РОЗВИТКУ СІЛЬСЬКИХ ГРОМАД

Геопросторовий аналіз відіграє важливу роль у вивченні розвитку сільських територій, забезпечуючи аналітичні

інструменти для оцінки інфраструктури та соціально-економічних умов. Сучасні дослідження демонструють, як різні методи геоінформаційних технологій можуть сприяти більш ефективному управлінню сільськими територіями.

В якості прикладу можна навести працю [1], яка фокусується на дослідженні просторових характеристик сільських поселень у провінції Цзянсі (Китай). В цьому дослідженні застосовуються методи просторового аналізу, такі як індекс Морена (*англ.* Moran's I) та ядерна щільність [1], що дозволяє виявити нерівномірний розподіл поселень за схемою «щільно на півночі, рідко на півдні».

Важливим внеском цього дослідження є введення індексу соціально-екологічної оцінки SEI (*англ.* socio-environmental evaluation index), який допомагає ідентифікувати пріоритетні території для інфраструктурного втручання. Наведені індекси дозволяють зконцентрувати увагу на соціально-економічних та природних факторах, що впливають на розташування сільських поселень, і пропонують нові підходи до планування розвитку сільських територій на основі геоінформаційних технологій.

В [2] оцінка якості життя у сільських районах України здійснюється на основі геопросторового аналізу. Авторами запропоновано алгоритм оцінки доступу до об'єктів інфраструктури, таких як лікарні, школи та магазини, в якому також врахована ступінь близькості до природних ресурсів та зони конфліктів. Це дозволило виявити значні регіональні відмінності в якості життя сільських громад, зокрема, найгірші умови спостерігаються на сході та півдні України. Отримані результати [2] також підкреслюють важливість використання методів кластеризації для аналізу інфраструктури та розробки стратегій її покращення.

В праці [3] досліджувалось застосування геопросторових технологій для картографування та аналізу соціальних та інфраструктурних об'єктів у селі Чиннапенд'яла (Індія). Дані дослідження ілюструють, як геоінформаційні системи можуть використовуватись для створення детальних баз даних на місцевому рівні, що допомагає краще розуміти потреби громади і покращувати планування їх розвитку в цілому. Особлива увага приділяється методам картографування та аналізу доступності об'єктів, таких як школи, лікарні та транспортні маршрути. Дослідження демонструє важливість індивідуального підходу до планування на рівні сіл та їх специфічних потреб.

Всі ці дослідження підкреслюють універсальність і важливість геопросторового аналізу для оцінки інфраструктури сільських

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

районів у різних географічних та соціально-економічних контекстах, демонструючи, як відкриті дані та сучасні технології можуть сприяти рівномірному розвитку сільських територій.

Практичне значення оглянутих досліджень полягає у формуванні ефективних інструментів для прийняття управлінських рішень, що дозволяє визначати пріоритетні напрямки інфраструктурних втручань у сільських районах. Завдяки використанню геоінформаційних технологій та аналізу соціально-економічних даних, ці дослідження надають можливість оптимізувати процеси планування, спрямовані на забезпечення збалансованого розвитку сільських територій.

2.1.1. ГЕОПРОСТОРОВА ХАРАКТЕРИСТИКА СІЛЬСЬКИХ ПОСЕЛЕНЬ У ПРОВІНЦІЇ ЦЗЯНСІ

Розглянемо детальніше застосування геопросторового аналізу для вивчення сільських поселень на прикладі провінції Цзянсі (Китай) [1]. Це дослідження підкреслює важливість інтеграції геоінформаційних технологій та соціально-економічних даних для розробки ефективних стратегій відновлення та покращення умов життя на сільських територіях.

Метою дослідження є виявлення просторових закономірностей розподілу сільських поселень та визначення факторів, що впливають на цей процес. Окрім цього, ставиться завдання розробки індексу соціально-екологічної оцінки SEI, який може використовуватись для оцінювання нерівномірності розвитку сільських територій та виявлення цільових зон для покращення інфраструктури.

Для досягнення зазначених цілей застосовуються наступні методи геопросторового аналізу:

1. *Аналіз ядерної щільності* (англ., Kernel Density Estimation, KDE). Цей метод дозволяє оцінити щільність сільських поселень у визначеному радіусі. Формула ядерної щільності виглядає наступним чином:

$$f(x, y) = \frac{1}{nh^2} \sum_{i=1}^n K\left(\frac{d_i}{h}\right), \quad (1)$$

де $f(x, y)$ — оцінка щільності в точці (x, y) , n — кількість поселень, h — ширина ядерного вікна, K — ядерна функція, d_i — відстань від i -го поселення до точки (x, y) .

2. *Просторова автокореляція* (англ., Spatial Autocorrelation). Для визначення ступеня взаємозв'язку між об'єктами в просторі застосовується індекс Морена, який має наступний вигляд:

$$I = \frac{n}{W} \frac{\sum_i \sum_j w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2}, \quad (2)$$

де I — індекс Морена, n — кількість поселень, W — сума всіх вагових коефіцієнтів w_{ij} , x_i і x_j — значення змінної для поселень i та j , \bar{x} — середнє значення змінної.

3. *Регресійний аналіз* (англ., Regression Analysis). Для визначення факторів, що впливають на географічний розподіл сільських поселень, використовуються прості та множинні лінійні регресійні моделі. Множинна лінійна регресія описується наступним чином:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon, \quad (3)$$

де Y — залежна змінна (розподіл поселень), X_1, X_2, \dots, X_n — незалежні змінні (соціально-економічні та екологічні фактори), β_0 — вільний член, $\beta_1, \beta_2, \dots, \beta_n$ — коефіцієнти регресії, ϵ — похибка моделі.

4. *Найближча відстань сусіда* (англ., Nearest Neighbor Distance, NND). Метод найближчої відстані сусіда обчислює індекс найближчого сусіда (англ., Nearest Neighbor Ratio, NNR):

$$r_E = \frac{1}{2} \sqrt{\frac{\bar{n}}{S}} = \frac{1}{2} \sqrt{\omega}, \quad (4)$$
$$\text{NNR} = \frac{r_i}{r_E},$$

де r_E — це теоретично очікувана (середня) відстань до найближчого сусіда, n — кількість сільських поселень, S — площа досліджуваної території, ω — густина точок, r_i — це середня фактична відстань до найближчого сусіда, а NNR — індекс найближчого сусіда.

Результати [1] вказують на значну різницю у щільності поселень між північними та південними районами провінції Цзянсі. Одним з ключових внесків даного дослідження є розробка індексу соціально-екологічної оцінки (англ., Socio-Ecological Index, SEI), який може стати основою для стратегій відновлення

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

сільських територій. Індекс SEI можна представити наступним чином:

$$SEI = \frac{1}{1 + e^{-(a+bX_1+cX_2+dX_3+eX_4)}} \quad (5)$$

де SEI — індекс соціально-екологічної оцінки, X_1 — дохід на душу населення, X_2 — ресурси орних земель, X_3 — середня висота, X_4 — середній нахил, a, b, c, d, e — коефіцієнти моделі.

Результати дослідження [1] підтверджують, що сільські поселення провінції Цзянсі мають чітко виражену тенденцію розподілу за принципом «щільні на півночі – рідкі на півдні». Поселення здебільшого розташовані на низьких висотах, рівнинних територіях, в районах з високою щільністю річок та доріг, а також у регіонах, багатих на орні землі. Це пояснюється комплексом фізичних та соціально-економічних факторів.

Запропонований індекс SEI демонструє значний методологічний прогрес у геопросторовому аналізі, надаючи детальніший підхід до вивчення проблем та можливостей розвитку сільських територій.

2.1.2. ГЕОПРОСТОРОВИЙ АНАЛІЗ ЯКОСТІ ЖИТТЯ У СІЛЬСЬКИХ РАЙОНАХ УКРАЇНИ

На кафедрі математичного моделювання та аналізу даних запропоновано алгоритм оцінки якості життя у сільських районах України з використанням агрегації геопросторової інформації з різних джерел [2].

Підхід полягає у комплексній оцінці віддаленості села від життєво важливих інфраструктурних об'єктів (лікарні, навчальні заклади, банки, бібліотеки, магазини, дороги, лінії електропередач тощо), до природних екосистем (водойми, ліси або парки), а також до окупованих територій.

Результати проведених досліджень показали, що найбільша кількість сіл з депресивною якістю життя розташована у східних та південних регіонах країни, тоді як позитивна якість переважає у західній та центральній Україні. Це, безумовно, частково пов'язано з активними бойовими діями.

Для визначення якості життя у селах було використано 16 показників. Для кожного села були розраховані найкоротші

відстані по кожному з показників. Також, для кожного показника було визначено інтервали для трьох класів: 0 – позитивне розташування, 1 – середнє розташування, 2 – депресивне розташування. Для кожного села та кожного показника відстані були розраховані за допомогою геоінформаційних систем.

Градація якості життя для кожного показника i в інтервалі $[0, up_val]$ було поділено на три рівні частини, а градація якості життя для села j та показника i визначалась наступним чином:

$$Gradation_{j,i} = \begin{cases} 0, & \text{якщо } dist_{j,i} \in \left[0, \frac{up_val}{3}\right], \\ 1, & \text{якщо } dist_{j,i} \in \left(\frac{up_val}{3}, 2 \cdot \frac{up_val}{3}\right], \\ 2, & \text{якщо } dist_{j,i} > 2 \cdot \frac{up_val}{3}, \end{cases} \quad (6)$$

де $dist_{j,i}$ – відстань для села j та показника i , up_val – верхня межа інтервалу, визначена за правилом 3 сигм.

Наступним кроком було об'єднання отриманих градацій для різних показників в один загальний показник, що відображає загальну картину життя в кожному селі окремо. В якості такого показника було обрано суму отриманих градацій для кожного i :

$$Life_level_j = \sum_{i=1}^N Gradation_{j,i}. \quad (7)$$

Вважалось, що села, які сумарно набрали до 3 балів для всіх показників, мають позитивне розташування, від 3 до 10 – середнє, понад 10 – депресивне:

$$Life_quality_j = \begin{cases} \text{позитивне, якщо } Life_level_j \in [0,3], \\ \text{середнє, якщо } Life_level_j \in (3,10], \\ \text{депресивне, якщо } Life_level_j > 10. \end{cases} \quad (8)$$

На основі розрахованих градацій показників було визначено рівень якості життя для сіл України.

Проведені експерименти демонструють застосовність запропонованої методології оцінки якості життя у сільських поселеннях України за допомогою геопросторового аналізу. Запропонований підхід дозволяє агрегувати дані про віддаленість сіл від життєво важливих об'єктів i , таким чином, кількісно

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

оцінити їх рівень доступності. Результати показують значні регіональні відмінності, причому депресивні умови найбільш виражені у східних та південних областях. Градаційний підхід класифікує села за позитивними, середніми та депресивними категоріями на основі накопиченого балу. Це забезпечує відносний рейтинг і дозволяє визначити пріоритетні області для інтервенцій у розвиток. Не зважаючи на те, що в методі використовуються різноманітні показники, алгоритм може бути вдосконалений шляхом включення додаткових шарів даних.

2.1.3. ГЕОПРОСТОРОВІ ТЕХНОЛОГІЇ ДЛЯ КАРТОГРАФУВАННЯ ТА АНАЛІЗУ ПОСЕЛЕНЬ В ІНДІЇ

В [3] представлено детальне дослідження застосовності геопросторових технологій для картографування та аналізу соціальних та інфраструктурних об'єктів на рівні села, зокрема, на прикладі села Чиннапенд'яла в Індії. Дослідження демонструє, як геопросторові технології і, зокрема, геоінформаційні системи, дозволяють ефективно інтегрувати просторові та непросторові дані для побудови детальної геопросторової бази даних. Ця база є важливим інструментом для місцевих органів влади, що дозволяє краще розуміти та задовольняти потреби сільських громад на мікрорівні.

У [3] застосовуються кілька цікавих методів геопросторового аналізу, які спрямовані на покращення картографування та аналізу соціальних та інфраструктурних об'єктів у сільських районах.

Основні методи, що використовуються, включають наступні:

1. *Геоінформаційні системи (ГІС)*. Цей метод дозволяє поєднувати просторові та непросторові дані для побудови детальної геопросторової бази даних. ГІС-технології допомагають виявити прогалини в інфраструктурі та точніше відображати наявні соціальні об'єкти, такі як школи, медичні установи, дороги тощо.

2. *Картографування та просторовий аналіз*. За допомогою ГІС виконано картографування інфраструктурних об'єктів для оцінки доступності різних послуг.

3. *Аналіз даних на мікрорівні*. Дослідження використовує інструменти геопросторового аналізу для збору та вивчення даних на рівні окремих сіл, що дає можливість детальніше зрозуміти потреби місцевих громад і точніше планувати розвиток сільських територій.

4. *Інтеграція просторових та непросторових даних.* Цей підхід дозволяє враховувати як географічні, так і соціально-економічні аспекти для прийняття більш обґрунтованих рішень щодо розвитку інфраструктури.

Ці методи допомагають створювати більш ефективну систему оцінки та подальшого розвитку інфраструктурних об'єктів на місцевому рівні.

2.1.4. ПРОСТОРОВО-ЧАСОВИЙ АНАЛІЗ ГЛОБАЛЬНИХ ДАНИХ ПРО МІСЬКІ БУДІВЛІ В OSM

За допомогою даних OpenStreetMap (OSM) аналіз повноти даних про міські будівлі можна проводити на основі наявних в них геопросторових характеристик сільських поселень. Дані OSM дозволяють оцінити масштаб та розподіл міських забудов, вивчаючи відмінності у наявності та якості даних, які можуть вплинути на комплексний аналіз та формування політик.

В [4] описується нерівномірність та неповнота даних про інфраструктуру в глобальній базі OSM. Основна увага зосереджена на аналізі даних для 13 189 урбанізованих територій по всьому світу. Автори використовують машинне навчання для оцінки повноти даних і констатують, що лише для 16% урбанізованих центрів OSM-дані про будівлі мають понад 80% повноти. Натомість для багатьох міст, особливо в країнах із середнім та високим індексом людського розвитку (*англ.* Human Development Index, HDI), дані є недостатньо повними, особливо в Латинській Америці, Південній і Південно-Східній Азії. Водночас в Африці, завдяки гуманітарним проектам, в яких для розв'язання задач картографування беруть активну участь волонтери, дані є більш повними. β

Формально, запропоновану в [4] модель можна представити наступним чином:

$$\hat{A}_{building} = f(X) + \epsilon, \quad (9)$$

де $\hat{A}_{building}$ — прогнозована площа будівель, X — набір предикторів, що включає дані дистанційного зондування, субнаціональний індекс людського розвитку (*англ.* Sub-national Human Development Index, SHDI), щільність дорожньої мережі та інші змінні, а ϵ — стохастична складова (залишкова похибка).

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

Для кількісного оцінювання повноти даних про забудову OSM використовується наступна формула:

$$C_{OSM} = \frac{A_{OSM}}{A_{total}}, \quad (10)$$

де C_{OSM} — повнота даних OSM, A_{OSM} — площа будівельних слідів, зафіксованих в OSM, A_{total} — загальна прогнозована площа будівель.

Оцінка прогалин у даних OSM є критично важливою, оскільки вона безпосередньо впливає на ефективність використання геопросторової інформації в міському плануванні і може сприяти досягненню цілей сталого розвитку (*англ.* Sustainable Development Goals, SDG). Автори запропонували систему підходів для оцінки повноти даних OSM про будівлі, враховуючи такі фактори, як індекс людського розвитку, кількість населення та географічне розташування для побудови складних моделей просторової неоднорідності в покритті даних. Важливою частиною аналізу є використання коефіцієнта Джині (G):

$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n |x_i - x_j|}{2n \sum_{i=1}^n x_i}, \quad (11)$$

де x_i і x_j — значення повноти даних у двох різних урбаністичних центрах, n — загальна кількість центрів, та коефіцієнта Морана (I):

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{(\sum_{i=1}^n (x_i - \bar{x})^2) \sum_{i=1}^n \sum_{j=1}^n w_{ij}}, \quad (12)$$

де w_{ij} — просторові ваги між об'єктами i та j , \bar{x} — середнє значення повноти даних, для вимірювання рівномірності та просторової автокореляції відповідно.

Таким чином в [4] проілюстрована необхідність інтеграції різних джерел даних та аналітичних методів для всебічного розуміння як сільської, так і міської інфраструктури. Це не лише доповнює сільський фокус попередніх розділів, але й розширює перспективу застосування відкритих геопросторових даних для аналізу інфраструктури на різних масштабах.

Дослідження [4] даних OSM про будівлі надає критичну оцінку поточного стану повноти геопросторових даних, закликаючи до більш справедливого розподілу зусиль по збору

даних. Автори підкреслюють важливість якісних даних для моніторингу розвитку міст і досягнення цілей сталого розвитку, що стосується безпечних та інклюзивних міст. Автори пропонують методи подолання прогалів у даних і покращення якості картографічних даних шляхом залучення місцевих спільнот та гуманітарних ініціатив. Ця праця надає важливу інформацію для дослідників та гуманітарних організацій щодо покращення оцінок та використання даних OSM у своїй роботі.

2.1.5. КЛАСТЕРИЗАЦІЯ ГРАФОВИХ ДАНИХ

Важливим аспектом у вищезазначених публікаціях є використання графових даних. Для прикладу, розглянемо працю [5], в якій були проаналізовані методи побудови графів, такі як граф ϵ -околу та граф k -найближчих сусідів. Автори встановили, що ці методи дозволяють суттєво зменшити чутливість до параметрів і покращити точність кластеризації. Зокрема, використання графу ϵ -околу дозволяє отримати більш надійні кластери, мінімізуючи вплив шуму у великих масивах даних. Цей метод допомагає виявити чіткі межі між кластерами навіть в умовах нерівномірного розподілу даних.

Ще однією важливою перевагою дослідження [5] є застосування методу k -найближчих сусідів, який дозволяє адаптуватися до локальних змін у структурі даних. Це робить його особливо корисним для аналізу складних графових структур у великих мережах, де традиційні методи кластеризації можуть виявитися неефективними. Завдяки цьому підходу вдалося досягти більшої точності в ідентифікації кластерів у багаторівневих мережах.

У [5] автори також підкреслюють важливість багаторівневого аналізу кластерів, яке дозволяє ефективно ідентифікувати структури на різних рівнях складності. Це надає дослідникам інструменти для детальнішого аналізу графів, що охоплюють різні типи взаємодій та зв'язків у мережах - від соціальних мереж до біологічних систем.

У публікації [6] описується використання теорії графів та геопросторового аналізу для планування електрифікації сільських районів. Результати показують, що інструмент GISEle (https://github.com/Energy4Growing/gisele_v01), який використовує кластеризацію на основі густини та теорію графів, оптимізує мережеву топологію для більш ефективного розвитку

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

інфраструктури. Зокрема, було встановлено, що використання цього інструменту дозволяє знизити вартість електрифікації на 15% завдяки оптимальному розташуванню електричних підстанцій та прокладенню ліній електропередач. Аналіз також виявив, що використання геопросторових даних сприяє більш точному визначенню потреб в електрифікації в різних регіонах, що дозволяє більш ефективно розподіляти ресурси.

У дослідженні [7] аналізуються сільські райони Індії за допомогою кластеризації на основі соціально-економічних характеристик. Вони встановили значні нерівності в розвитку та виявили тенденції, що можуть бути адаптовані для аналізу українських сіл. В [7] для групування сіл на основі 150 різних змінних, зібраних з урядових джерел, використовуються потужні методи кластеризації. В результаті було запропоновано чотирикластерну стратегію, яка дозволяє детальніше зрозуміти різноманітність сільських регіонів Індії та їхні специфічні потреби. Ця стратегія підкреслює важливість індивідуального підходу до планування та розвитку сільських територій, що дозволяє більш точно визначати пріоритети політики та розподілу ресурсів. Ці дослідження демонструють різноманітність підходів до кластеризації графових даних та їх успішне застосування в різних контекстах, що підкреслює їхню користь для аналізу та планування. Всі ці підходи базуються на використанні сучасних методів аналізу даних, що дозволяє досягати більш точних і надійних результатів у вивченні складних соціально-економічних систем.

Огляд сучасних підходів до оцінки розвитку сільських територій показав, що застосування вищезазначених методів є ефективним як на міжнародному рівні, так і в українських реаліях. У наступних підрозділах буде розглянуто методологію, що дозволяє адаптувати та розвинути ці підходи для розв'язання конкретних задач оцінки ступеня розвитку інфраструктури сільських громад в Україні.

2.2. ПОСТАНОВКА ЗАДАЧІ ОЦІНКИ РОЗВИТКУ СІЛЬСЬКОЇ ІНФРАСТРУКТУРИ

В даному розділі запропонована методологія для вирішення задачі оцінки поточного стану та покращення ступеня розвитку сільської інфраструктури в Україні на основі геопросторових даних і методів кластеризації за допомогою побудови системи

класифікації сільських громад за рівнем розвитку їх інфраструктури, що дозволить ідентифікувати розриви в доступності важливих об'єктів інфраструктури та визначити пріоритетні зони для інвестицій і планування подальшого розвитку.

Для цього пропонується використати нові оцінки доступності, отримані з відкритих джерел, таких як OpenStreetMap (OSM) та Humanitarian Data Exchange (HDX). До таких оцінок перш за все слід віднести відстані до ключових об'єктів, таких як дороги, медичні заклади, освітні установи та інші об'єкти інфраструктури.

Ключовим питанням є також застосування методів машинного навчання, таких як KMeans і DBSCAN, для сегментації сіл за рівнем розвитку інфраструктури, а також розробка інструментів візуалізації, що забезпечать легкий доступ до результатів аналізу. Це дослідження спрямоване на формування бази для стратегічного планування розвитку сільських районів, а також на створення інструментів для прийняття рішень стейкхолдерами та спеціалістами по розвитку інфраструктури.

2.3. ВИКОРИСТАНІ ДАНІ

Для досягнення поставленої мети було використано різноманітні геопросторові шари даних, вилучені з OpenStreetMap (OSM) та оброблені у форматі GeoDataFrame (GDF). Дані OSM, отримані на основі роботи волонтерів (citizen science), даних аерофотозйомки, GPS-пристроїв та польових обстежень, є відкритими для використання і містять інформацію про дороги, будівлі, природні об'єкти, що робить цей ресурс цінним для подальшого геопросторового аналізу.

У цьому підрозділі використано шари даних, що охоплюють різні типи доріг (основні, вторинні та сільські), типи земельного покриття, а також розташування об'єктів соціальної інфраструктури, таких як школи, університети, лікарні, аптеки, торгові центри, банки, церкви, бібліотеки та парки різного рівня (місцеві, національні, регіональні).

Додаткові дані про розташування населених пунктів було отримано з платформи Humanitarian Data Exchange (HDX) (<https://data.humdata.org/group/ukr>) в Україні, що були актуальними на середину 2021 року програми Copernicus (<https://www.copernicus.eu>). HDX є відкритою платформою для

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

обміну даними, що стосується гуманітарних криз та стану країн, і керується Офісом ООН з координації гуманітарних питань (*англ.*, Office for the Coordination of Humanitarian Affairs, ОСНА). Для цього дослідження використовувалися дані про розташування сіл та міст.

Використаний набір даних містить 28381 записи, кожен з яких відповідає унікальному географічному місцю в сільській Україні. Ці записи ретельно деталізовані по 41 інформативним колонкам, пропонуючи панорамний огляд ландшафту сільської інфраструктури через призму геопросторової аналітики. Однак у цьому дослідженні використано лише 17 параметрів типу «відстань до найближчого об'єкта» та 13 графових описів. Усі ці дані були зібрані в результаті обробки великого обсягу геопросторових даних з баз даних OSM, HDX, інформаційних ресурсів з інформацією про зернові елеватори [9], поштові провайдери [10, 11], а також дані про стільниковий зв'язок [12].

Міри близькості інфраструктури. Значна частина набору даних містить оцінку міри близькості, яка кількісно оцінює близькість кожної сільської громади до різних критичних елементів інфраструктури, і тим самим є фундаментальною складовою для подальшого просторового аналізу. Усі ці об'єкти інфраструктури згруповані за типами та описані в табл. 1. Частково дані міри були сформовані в [2], а також в інших дослідженнях, зокрема [8].

Таблиця 1 Дані про близькість інфраструктури

Тип	Об'єкти	Опис
Дороги	RD_m1_NEAR, RD_m2_NEAR, RD_m3_NEAR	Відстань до основних, регіональних та сільських доріг відповідно.
Міста	CITY2_NEAR, Kyiv_NEAR_	Відстань до найближчого міста та столиці України відповідно.
Парки	LokPark_NE, NatPark_NE, regPark_NE	Відстань до найближчого місцевого, національного та регіонального парку відповідно.

Частина 3. Прикладні задачі супутникового інтелекту на ...

Елеватори	Elevators_	Відстань до найближчого елеватора.
Дитячий садок	Kinder_NEAR	Відстань до найближчого дитячого садка.
Банк	Bank_NEAR_	Відстань до найближчого банку.
Церква	Cerkva_NEA	Відстань до найближчої церкви.
Освіта	Education_	Відстань до найближчого навчального закладу.
Готелі	Hotels_NEA	Відстань до найближчого готелю.
Бібліотека	Library_NE	Відстань до найближчої бібліотеки.
Лікарня	Likarni_NE	Відстань до найближчої лікарні.
Магазин	Magaz_NEAR	Відстань до найближчого магазину.
Пошта	NP_Min_Dist, UP_Min_Dist	Відстань до найближчого відділення Укрпошти та Нова пошти відповідно.
Мобільний зв'язок	kyivstar-4g, kyivstar-3g, vodafone-4g, vodafone-3g, lifecell-4g, lifecell-3g, trimob	Наявність мобільного оператора з певними технологіями.

Графові представлення. У сформованому наборі даних частина параметрів містить елементи опису графових структур, запропонованих в [8, 17]. Наприклад графові колонки (graph_city, graph_local_park тощо) містять дані у форматі JSON у вигляді масиву, що пропонує детальний погляд на найближчі об'єкти різних типів. Це детальне представлення дозволяє проводити розширений аналіз інфраструктурної мережі, включаючи дослідження зв'язності та просторового розподілу основних послуг. Більш детальний опис параметру кожного типу та приклад опису об'єкта наведено в табл. 2.

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

Таблиця 2 Графові дані

Тип	Приклад Об'єкта та його JSON-представлення	Опис
Graph_city	{ «id_type»: «admin4Pcod», «id»: «UA5323810100», «distance»: 15874.531539053276, «pos_x»: 814898.792138855, «pos_y»: 5565562.434442552 }	Стандартний опис міста, яке знаходиться поблизу села, з усіма основними характеристиками .
Graph_local_park	{ «id_type»: «KodPZF», «id»: «0253UA0708041», «distance»: 3695.6829331930207, «KatObPZF»: «Reserve», «AreaPZF»: 120, «pos_x»: 807527.095508027, «pos_y»: 5577813.50041332 }	Опис місцевого парку, крім стандартного, містить площу та категорію об'єкта KatObPZF.
Graph_national_park, graph_regional_park	{ «id_type»: «KodPZF», «id»: «0153UA0200001», «distance»: 10908.01990446648, «AreaPZF»: 12028.42, «pos_x»: 813282.7981963563, «pos_y»: 5570259.240116742 }	Опис національного та регіонального парків, містить площу об'єкта.
Graph_bank, graph_kindergarten, graph_library	{ «id_type»: «osm_id», «id»: «668736377», «distance»: 24589.561415524415, «pos_x»: 830942.7863028484, «pos_y»: 5593380.706043951 }	Опис банку, дитячих садків та бібліотек.

Graph_church, graph_edu, graph_hotel, graph_medicine , graph_shop	{ «id_type»: «osm_id», «id»: «298759370», «distance»: 6992.808427912616, «fclass»: «class», «pos_x»: 816907.4829874948, «pos_y»: 5580679.407344543 }	Опис церков, навчальних закладів, готелів, медичних установ та магазинів, де у полі «fclass» буде описано клас об'єкта.
Graph_elevator	{ «id_type»: «id», «id»: 746, «distance»: 2657.6559562758794, «pos_x»: 807667.363751653, «pos_y»: 5579215.811847648 }	Опис елеватора.

До кожного об'єкту прив'язаний ідентифікатор `id_type`. Це пов'язано з тим, що сформований набір даних представляє собою складну структуру, що базується на використанні різних пов'язаних окремих піднаборів даних. Це дозволяє формувати різні представлення без необхідності перебудови загальної структури даних.

2.4. МЕТОДОЛОГІЯ РОЗВ'ЯЗАННЯ ЗАДАЧІ КЛАСТЕРИЗАЦІЇ

В даному підрозділі розглядаються методи, які можуть бути застосовані для виконання дослідження. Вище вже було розглянуто метод KDE як один з можливих підходів. Однак, подальший аналіз показав, що методи кластеризації можуть бути більш придатними для розв'язання поставленої задачі оцінки та планування розвитку сільської інфраструктури.

Кластеризація — це метод машинного навчання, що дозволяє об'єднати схожі об'єкти в окремі групи або кластери. Це дуже важлива частина аналізу даних, оскільки вона допомагає виявити природні структури в даних без їх попереднього маркування. Метою кластеризації є мінімізація внутрішньогрупової варіації та максимізація міжгрупової варіації. Методи кластеризації більш детально розглянуті нижче.

- **KMeans.** Метод KMeans є одним із найпоширеніших алгоритмів кластеризації, метою якого є поділ n об'єктів на k

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

кластерів таким чином, щоб мінімізувати різницю між об'єктами в межах одного кластера та максимально збільшити відстань між кластерами. Кожен кластер має свій центроїд, і метод намагається мінімізувати відстані між об'єктами та їх центроїдами.

Для оцінки цієї відстані та якості розподілу використовується функція вартості, яка показує сумарну відстань між об'єктами та їхніми центроїдами. Чим менше значення цієї функції, тим краще розподіл об'єктів по кластерах.

Функція вартості, яку необхідно мінімізувати, визначається наступним чином:

$$J = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2, \quad (13)$$

де J — функція вартості, k — кількість кластерів, C_i — набір об'єктів у кластері i , μ_i — центроїд кластера i , x_j — об'єкт, що належить до кластера i .

Алгоритм реалізації методу KMeans можна визначити наступним чином:

- 1) Вибрати початкові центроїди випадковим чином.
- 2) Кожен об'єкт призначається до найближчого центроїда μ . Відстань до центроїда обчислюється за формулою:

$$\mu_i = \frac{1}{|C_i|} \sum_{x_j \in C_i} x_j. \quad (14)$$

- 3) Оновити центроїди μ як середнє значення об'єктів у кожному кластері.

- 4) Повторювати кроки 2 і 3 до досягнення збіжності, тобто поки центроїди не перестануть змінюватися.

Переваги методу кластеризації KMeans полягають в простоті його реалізації та високій ефективності для обробки великих наборів даних. До недоліків слід віднести чутливість до початкової ініціалізації центроїдів, необхідності попереднього визначення кількості кластерів та можливість роботи лише з числовими даними.

• **Ієрархічна кластеризація.** Ієрархічна кластеризація дозволяє побудувати ієрархію кластерів, яка може бути представлена у вигляді дендрограми. Існують два основні підходи: агломеративна (знизу вгору) та дивізійна (зверху вниз) кластеризація [14].

Алгоритм агломеративної ієрархічної кластеризації має наступний вигляд:

- 1) Розглянути кожен об'єкт як окремий кластер.
- 2) Знайти два найближчі кластери C_i та C_j та об'єднати їх у новий кластер C_{ij} , де відстань між кластерами визначається формулою:

$$d(C_i, C_j) = \frac{1}{|C_i||C_j|} \sum_{x \in C_i} \sum_{y \in C_j} \|x - y\|. \quad (15)$$

- 3) Повторювати крок 2, поки всі об'єкти не будуть об'єднані в один кластер.

Переваги методу ієрархічної кластеризації полягають в відсутності необхідності вказувати кількість кластерів заздалегідь та можливості працювати з будь-яким типом даних.

До недоліків слід віднести високі обчислювальні витрати для великих наборів даних та чутливість до шуму та викидів.

• **DBSCAN** (Density-Based Spatial Clustering of Applications with Noise) — алгоритм кластеризації, що базується на густині даних. Він дозволяє виявити кластери довільної форми та не враховувати шуми [2].

Для кожної точки P в наборі даних D визначаються ϵ -околиці:

$$N_\epsilon(P) = \{q \in D \mid \text{dist}(P, q) \leq \epsilon\}, \quad (16)$$

де $N_\epsilon(P)$ — множина точок в радіусі ϵ від точки P .

Алгоритм **DBSCAN** має наступний вигляд:

- 1) Обрати точку P та знайти всі точки в радіусі ϵ від P (ϵ -околиці).
- 2) Якщо ϵ -околиця містить щонайменше MP точок, створити кластер з P .
- 3) Повторити процес для всіх точок у кластері шляхом його розширення.
- 4) Повторити кроки 1–3 для всіх наступних точок.

Переваги методу **DBSCAN** полягає в відсутності необхідності вказувати кількість кластерів заздалегідь, можливості виявляти кластери довільної форми та в стійкості до шуму та викидів.

З недоліків – можлива складність вибору параметрів ϵ та MP та високі обчислювальні витрати для великих наборів даних.

Для вибору найкращого методу для розв'язання поставленої задачі розглянемо наявні дані більш детально, та підберемо метод,

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

який дозволить розв'язати задачу розподілу на кластери найкращим чином. Задача розподілу на кластери полягає в групуванні об'єктів, що знаходяться в схожому віддаленні від нульової координати.

Для цього введемо вираз (17) для аналізу відмінності відстаней між об'єктами одного кластера та оглянемо кластери, побудовані за допомогою методів графічного представлення, розфарбованих за належністю до кластерів (рис. 1).

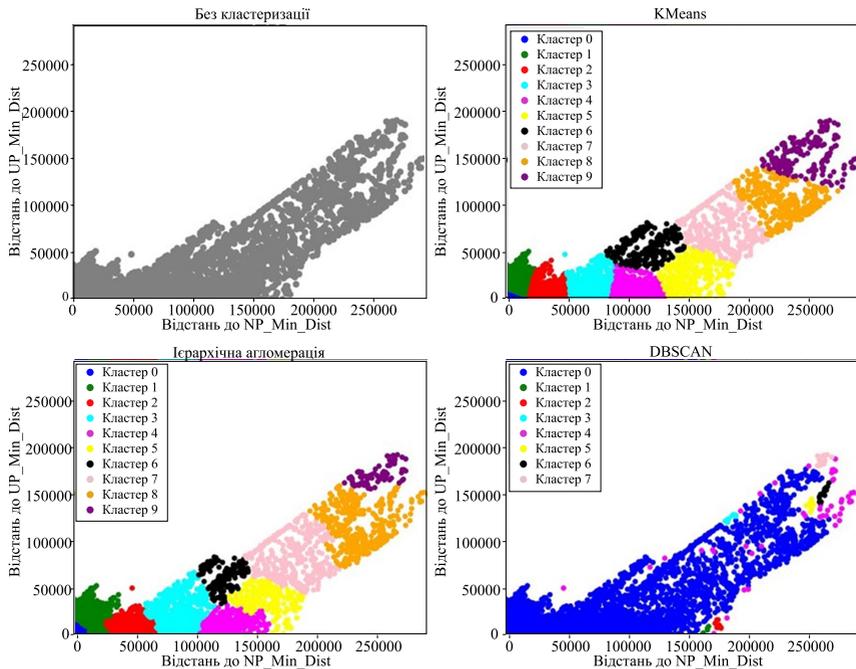


Рис. 1. Порівняння методів кластеризації: (а) без кластеризації, (б) KMeans, (в) ієрархічна агломерація, (г) DBSCAN

На рис. 1 представлені результати застосування методів кластеризації до сформованого набору даних відносно поштових відділень. З наведеного рисунку бачимо, що дані рівномірно розташовані на графіку та фактично є однією групою. Тому можна зробити висновок, що метод DBSCAN проявляє себе значно гірше порівняно з KMeans та ієрархічною агломерацією, які не зважаючи на те, що дані відносяться до одної групи, змогли виокремити окремі кластери.

Введемо наступні позначення:

- \bar{D}_k : середнє значення суми абсолютних відхилень для кластера k .
- N_k : кількість об'єктів у кластері k .
- d_i : відстань i -го об'єкта у кластері k від початку координат $(0, 0)$.
- \bar{d}_k : середнє значення відстаней всіх об'єктів у кластері k від початку координат $(0, 0)$.
- K : загальна кількість кластерів.
- \bar{D} : загальне середнє значення суми абсолютних відхилень для всіх кластерів.

Для оцінки різниці відстаней між об'єктами одного кластера використаємо (17), де \bar{D}_k обчислюється як середнє значення суми абсолютних відхилень відстаней кожного об'єкта в кластері k від середньої відстані всіх об'єктів цього кластера від початку координат.

$$\bar{D}_k = \frac{1}{N_k} \sum_{i=1}^{N_k} |d_i - \bar{d}_k|. \quad (17)$$

Узагальнюючи це для всіх кластерів, \bar{D} обчислюється як середнє значення всіх \bar{D}_k для кожного кластера, що дозволяє отримати загальне уявлення про відхилення в усіх кластерах.

$$\bar{D} = \frac{1}{K} \sum_{k=1}^K \bar{D}_k. \quad (18)$$

Таким чином можна зробити висновок, що для розв'язання поставленої задачі кластеризації краще підходять методи KMeans та ієрархічна агломерація. Проте продовжимо аналіз.

Результати застосування формули (18):

- \bar{D} для KMeans: 10487.38
- \bar{D} для Ієрархічної агломерації: 10579.64
- \bar{D} для DBSCAN: 11127.80

На рис. 2 представлені розподіли відстаней для кожного кластера. Порівнюючи значення на цих графіках, можна побачити,

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

що в середньому відстані від початку координат для кожного кластера виявилися найбільш щільними для KMeans, середньо щільними для ієрархічної агломерації та найменш щільними для DBSCAN. Також це підтверджується, значеннями, отриманими на основі (18). Таким чином, можна стверджувати, що для подальших досліджень найкраще підходить метод KMeans.

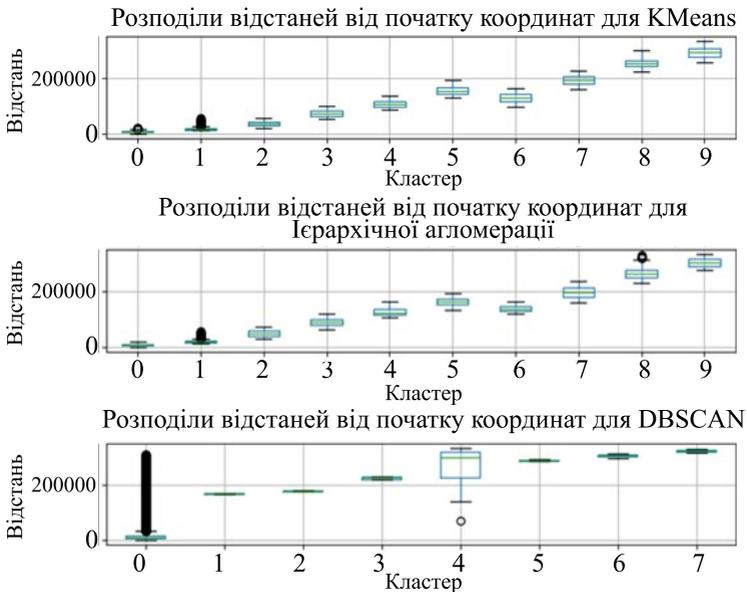


Рис. 2. Розподіли відстаней від початку координат для KMeans, ієрархічної агломерації, DBSCAN

Оптимізація кластеризованих даних. Завдяки алгоритму та природі функцій кластеризації номери кластерів не завжди відображають наближеність даного кластера до нульової координати. Оскільки, як було розглянуто вище, дані містять відстані до різних об'єктів, було б корисним відсортувати дані за віддаленістю від нульової координати, оскільки наближеність до неї означає, що інфраструктура знаходиться ближче до сіл, що в свою чергу означає, що вона є більш доступною, а отже, дане село є більш інфраструктурно розвиненим. Такий підхід також дозволяє виявити найбільш ізольовані села, які потребують пріоритетного розвитку. Врахування цих факторів сприяє більш точному аналізу та плануванню інфраструктурних проєктів.

Допоміжна кластеризація. Для вдосконалення розглянутого методу кластеризації введемо крок, який дозволяє реорганізувати кластери після їх формування. Цей крок ранжує кластери за якістю їх інфраструктури, від найменш до найбільш потребуєчої покращення, використовуючи дані точок (центроїдів) з поточних результатів кластеризації. Цей метод не тільки полегшує розуміння стану інфраструктури кожного окремого кластера, а й дозволяє автоматично призначити кластери та отримати їх оцінки.

Введемо наступні позначення:

- \bar{d}_k — середнє значення відстаней всіх об'єктів у кластері k від початку координат (0, 0).
- C_k : номер кластера k до допоміжної кластеризації.
- R_k : номер кластера k після допоміжної кластеризації (ранжування). Процес допоміжної кластеризації включає наступні кроки:

1) Обчислення середньої відстані до початку координат для кожного кластера:

$$\bar{d}_k = \frac{1}{N_k} \sum_{i=1}^{N_k} d_i, \quad (19)$$

де N_k - кількість об'єктів у кластері k , d_i - відстань i -го об'єкта до початку координат.

2) Сортування кластерів за зростанням \bar{d}_k та їх перенумерація:

$$R_k = \text{rank}(\bar{d}_k), \quad (20)$$

де $\text{rank}(\bar{d}_k)$ - ранг кластера після сортування.

На рис. 3 зліва показана нумерація та розфарбовка кластерів відразу після кластеризації, а справа після раніше введеного кроку допоміжної кластеризації.

Приклад коду для порівняння допоміжної кластеризації та звичайного підходу:

```
# Function to plot pre-sorted and sorted clusters
def plot_pre_and_post_sorted_clusters(data):
    max_x_y = max(data[:, 0].max(), data[:, 1].max())
    # Determine the limits for the plots
    xlim = (0, max_x_y)
```

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

```
ylim = (0, max_x_y)
fig, axes = plt.subplots(1, 2, figsize=(12, 6))
# Pre-sorted clustering using simple KMeans
kmeans = KMeans(n_clusters=10, random_state=0)
presorted_labels = kmeans.fit_predict(data)
plot_2d_post_clusters(data, presorted_labels, 'Перед
сортуванням', axes[0], xlim, ylim)
# Post-sorted clustering using apply_clustering
sorted_labels, _ = apply_clustering(data, method='kmeans',
params={'n_clusters': 10})
plot_2d_post_clusters(data, sorted_labels, 'Після сортування',
axes[1], xlim, ylim)
plt.tight_layout()
plt.savefig("pre_and_post_sorted_clustering.png",
bbox_inches='tight')
plt.show()
# Generate the plots
plot_pre_and_post_sorted_clusters(post_data_scaled)
```

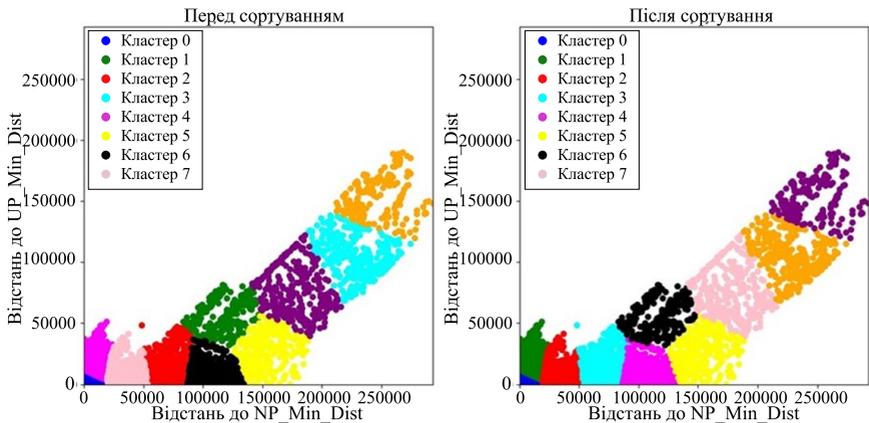


Рис. 3. Порівняння кластерів до та після кроку допоміжної кластеризації

Визначення методу ефективного аналізу інфраструктури для її подальшого покращення. Одним із ключових завдань цього дослідження є вибір методів, які були б ефективними для аналізу інфраструктури в різних сільських населених пунктах. Як вище

зазначено в табл. 1, пропонується додати кластер, що буде створюватися на основі результатів кластеризації відносно кожного типу інфраструктури. В комбінації з раніше розглянутими методами кластеризації та допоміжної кластеризації, можна визначити оптимальні кроки для покращення інфраструктури певного села за допомогою наступного алгоритму:

1) *Ідентифікація сусідніх сіл.* Визначити всі інші села в наборі даних, які були віднесені до різних кластерів на основі їх характеристик інфраструктури.

2) *Аналіз сусідніх кластерів.* Виявити села, що знаходяться в кластерах з вищим рівнем інфраструктурного розвитку. Це можна зробити шляхом порівняння значень кластерів, де вищі значення вказують на кращу інфраструктуру.

3) *Визначення найближчих сіл.* Для кожного кластера з вищим рівнем інфраструктури знайти найближче село до обраного села за характеристиками інфраструктури. Це здійснюється шляхом обчислення відстаней між векторами характеристик інфраструктури обраного села та сіл у вищих кластерах.

4) *Аналіз відмінностей.* Провести порівняльний аналіз між характеристиками інфраструктури обраного села та найближчих сіл з вищих кластерів. Це дозволить виявити конкретні елементи інфраструктури, які потребують покращення.

5) *Визначення дефіциту.* На основі аналізу відмінностей визначити конкретні аспекти інфраструктури, яких не вистачає обраному селу для його віднесення до вищого кластера.

В результаті застосування цього підходу зможемо отримати детальний опис типів інфраструктури, яких не вистачає певному селу для підвищення його кластерної класифікації. В комбінації з використанням додаткових експертних оцінок це дозволить досягнути високої ефективності в покращенні інфраструктури.

Оцінювання загальної якості інфраструктури. Для оцінки загальної якості інфраструктури кожного села пропонується інтегральний підхід, який дозволяє поєднати оцінки різних типів інфраструктури та рейтинг кластера після додаткової кластеризації. Формулу для обчислення інтегральної оцінки якості інфраструктури можна представити наступним чином:

$$\text{ОЯ} = a \times \left(\frac{1}{n} \sum_{i=1}^n \text{ОI}_i \right) + b \times \text{РК}, \quad (21)$$

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

де ОЯ – оцінка якості, ОІ – оцінка інфраструктури, РК – рейтинг кластера a , b – параметри, які визначають вагу кожного показника, n – кількість типів інфраструктури, Оцінка інфраструктури i – оцінка якості інфраструктури для кожного типу, рейтинг кластера – рейтинг кластера, який визначається після додаткової кластеризації.

Ці параметри обираються таким чином, щоб вони мали нормальний, логнормальний, чи гамма-розподіл, що дозволило б виокремити села, що є нормальними, та села, що є аномальними. Такий підхід дозволяє не лише оцінити поточний стан інфраструктури, а й виявити потенційні точки для покращення, що є важливим кроком для стратегічного планування розвитку регіону.

2.5. МЕТОДИ ВІЗУАЛІЗАЦІЇ ГЕОПРОСТОРОВИХ ДАНИХ

Для проведення комплексної оцінки геопросторових наборів даних, що стосуються сільської інфраструктури в Україні, застосовуються різні числові та графічні статистичні методи. Комбінація кількох підходів дозволяє отримати комплексне уявлення про розподіл даних та їх особливості.

Значну роль в аналітичному процесі відіграють гістограми, які забезпечують візуалізацію частотних розподілів відстаней до інфраструктурних об'єктів серед сільських поселень. Вони дозволяють швидко виявити характер розподілу — чи є він нормальним, чи має зміщення в напрямку більших або менших значень. Гістограми дозволяють також ефективно виявляти аномалії в даних, такі як викиди. Наприклад, завдяки такій візуалізації сільське поселення, яке знаходиться на аномально великій відстані від найближчої медичної установи, легко ідентифікується.

З технічної точки зору, гістограма — це графічне представлення, яке відображає розподіл частотних значень в наборі даних, надаючи зручний спосіб аналізу ключових характеристик розподілу. Таке представлення будується наступним чином:

$$H(x) = \frac{1}{n} \sum_{i=1}^n I(x_i \in [x_j, x_{j+1})), \quad (22)$$

де $H(x)$ — висота стовпчика гистограми для інтервалу $[x_j, x_{j+1})$, n — загальна кількість даних, I — індикаторна функція, яка дорівнює 1, якщо значення x_i потрапляє у відповідний інтервал, і 0 в іншому випадку.

Коробкові діаграми (англ., box plot) дозволяють лаконічно і наочно відобразити внутрішню структуру розподілу даних, включаючи основні квартилі, викиди та діапазон екстремальних значень. Порівняння коробкових діаграм дозволяє швидко визначити схожості та відмінності медіанних значень, які відповідають різним категоріям інфраструктури. Наприклад, можна легко оцінити, яка частина сільських населених пунктів України знаходиться в межах 10 км від найближчої школи, або яка середня відстань до найближчого великого міста.

Коробкові діаграми показують п'ять наступних основних характеристик розподілу:

1. Нижній квартиль (Q_1),
2. Медіана (Q_2),
3. Верхній квартиль (Q_3),
4. Мінімальне значення (нижній ус),
5. Максимальне значення (верхній ус).

Коробкові діаграми також використовуються для візуалізації міжквартильного розмаху (англ., Interquartile Range, IQR), який розраховується за формулою:

$$IQR = Q_3 - Q_1, \quad (23)$$

де IQR представляє центральну частину розподілу даних, вказуючи на діапазон значень, які охоплюють середні 50% сукупності. Цей інструмент є ефективним для швидкої оцінки варіацій даних та виявлення викидів, що сприяє глибшому розумінню розподілу досліджуваних даних.

У той час як графічні підходи вказують на властивості розподілу, кореляційні матриці дозволяють оцінити безпосередні зв'язки між доступністю лікарень, шкіл, доріг та інших об'єктів. Кореляційні коефіцієнти дозволяють ідентифікувати аспекти сільської інфраструктури з найтіснішими зв'язками, спрямовуючи глибші дослідження на найбільш цікаві параметри.

Кореляція між двома змінними X та Y визначається наступним чином:

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y}, \quad (24)$$

де $\text{cov}(X, Y)$ — коваріація між X та Y , σ_X та σ_Y — стандартні відхилення X та Y .

На додаток до навчання на основі візуалізації даних, використовуються дві фундаментальні статистичні функції.

Основні описові статистики можна формально визначити наступним чином:

– Середнє значення:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i. \quad (25)$$

– Медіана — значення, яке розділяє набір даних на дві рівні частини

– Стандартне відхилення:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}. \quad (26)$$

Ці статистичні характеристики надають важливу інформацію про розподіл даних у наборі. Наприклад, середнє значення вказує на типове значення в наборі даних, тоді як медіана дає уявлення про центральну точку розподілу. Стандартне відхилення описує, наскільки значення в наборі даних відхиляються від середнього, що важливо для оцінки варіацій рівня доступності інфраструктури.

Підсумкові статистичні дані, такі як середні значення, медіани та стандартні відхилення, підкреслюють центральні тенденції та варіації для відстаней до інфраструктури та додаткових особливостей. Була використана бібліотека Pandas для Python, яка пропонує зручні вбудовані функції для обчислення описової статистики через синтаксис на кшталт `dataframe.describe()`.

Методи обробки геопросторових даних. Найпростішим є пошук відстані між селом та різноманітними точками інфраструктури. Даний підхід був розглянутий в [2]. Проте, наразі є прагнення розширити даний опис, імплементувавши нові оцінки даних.

Основна суть даного нововведення полягає в отриманні інформації про 5 найближчих об'єктів в певному радіусі від села.

Для цього недостатньо просто використати вбудовані методи мови програмування Python, оскільки методи, наприклад, реалізовані в бібліотеці Pandas, не дозволяють реалізувати ефективний пошук, а роблять повний перебір, що при 28000 тисяч сіл та 50000 об'єктів інфраструктури означає розрахунок 1.4 мільярдів відстаней, що потребує 388 годин обробки при обрахунку 1000 відстаней в секунду.

Підвищити ефективність обчислень можна за рахунок реалізації власного методу обробки даних, що дозволить отримати результати за адекватний час.

Методи створення розширеного набору даних з новими оцінками. Для розробки більш комплексного набору даних з додатковими параметрами оцінки сільських громад України пропонується використати систематичний процес виявлення та інтеграції точок інтересу (point of interest — POI) з вихідних геопросторових шарів даних у групи для кожного села, представлені у графовій формі.

Для кожного типу POI всі об'єкти спочатку сегментуються на буферні зони однакового заздалегідь визначеного розміру, що відповідає максимальній відстані, визначеній для кожного типу у вхідних даних. Після створення цих буферних зон можна перейти до виявлення найближчих об'єктів для кожного села. Це включає визначення, у якому буфері розташоване село, та визначення набору з восьми сусідніх зон.

Процес буферизації POI та визначення буферів пошуку представлено на рис. 4, а процес обчислення відстаней до POI та визначення найближчих — на рис. 5.

Цей підхід дозволяє створити всеосяжний набір POI поблизу кожного села, охоплюючи як різноманітність найближчих об'єктів (включаючи міста, парки тощо), так і визначення їхнього розташування на доступній відстані. Систематично каталогізуючи найближчі POI різних типів до кожного сільського поселення, можна отримати оцінки додаткових параметрів, що охоплюють доступність і наявність ключової інфраструктури та послуг.

Кінцевим результатом є набір даних у графовій структурі, що об'єднує села з їх найближчими POI по визначених категоріях разом з метриками відстані. Цей вихідний набір даних надає детальну інформацію щодо доступу до важливих сервісів на національному рівні. Структура графу, яка з'єднує сільські поселення з найближчими POI різних типів через зв'язки на

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

основі відстані, формує основу розширених геопросторових оцінок для аналізу сільської інфраструктури.

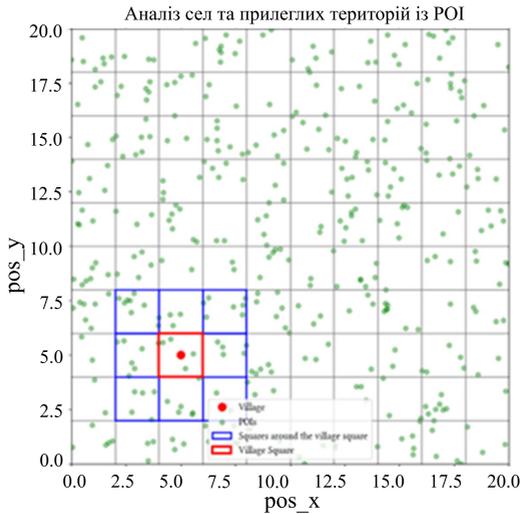


Рис. 4. Запропонований підхід для визначення регіонів для просторового аналізу

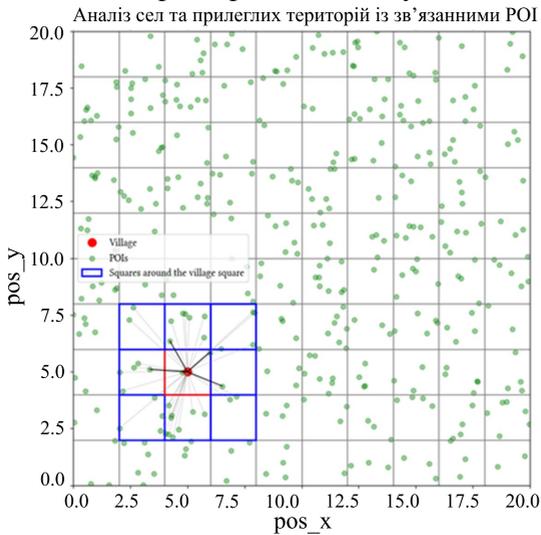


Рис. 5. Обчислення відстаней у визначених регіонах відповідно до запропонованої методології

Основні кроки побудови розширеного набору даних включають наступні:

Розбиття даних POI на окремі блоки. Кожний блок має розмір, що відповідає максимальній відстані, визначеній для кожного типу POI.

Визначення найближчих об'єктів для кожної сільської громади. Це включає визначення, у якому блоці розташоване село, та аналіз восьми сусідніх блоків.

Обмеження кількості об'єктів до задалегідь визначеної кількості найближчих об'єктів для кожного села. Формула для обчислення евклідової відстані між селом і точкою інтересу (POI) виглядає наступним чином:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}, \quad (27)$$

де d — відстань між селом і POI, (x_1, y_1) — координати сільської громади, а (x_2, y_2) — координати POI.

Цей підхід дозволяє значно скоротити час обчислень і забезпечує точність результатів. Важливо зазначити, що для побудови таких графів використано ефективні алгоритми пошуку найближчих сусідів, такі як KD-дерева (k - d trees) та Ball-дерева, які забезпечують пошук за логарифмічний час:

$$O(n \log n), \quad (28)$$

де n - кількість об'єктів у наборі даних.

При такому підході кількість об'єктів для аналізу зменшилась до 500 об'єктів (в середньому) для кожної сільської громади, що покращило швидкість обчислення в 100 разів. За допомогою паралельних обчислень на 8 ядрах процесора отримано додаткове прискорення в 5 разів. Після оптимізації загального підходу всі обчислення займають близько 0.75 години, що є прийнятним часом для такого обсягу даних.

2.5.1. ВІЗУАЛІЗАЦІЯ РЕЗУЛЬТАТІВ КЛАСТЕРНОГО АНАЛІЗУ

Створення векторів для типів POI дозволяє отримати структуроване представлення просторових характеристик об'єктів, розташованих поблизу кожного села. У процесі проведення експерименту було сформовано вектори, що представляють різні

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

категорії POI (дороги, міста, парки) та складаються з набору значень, які вказують на відстані до критичних інфраструктурних об'єктів і графові дані.

Наприклад, вектор для доріг включає відстані до кількох найближчих доріг різного типу (RD_m1_NEAR, RD_m2_NEAR тощо), як показано в табл. 3. Такі вектори описують наявну інфраструктуру навколо кожної громади, що дає змогу аналізувати доступність інфраструктури та порівнювати громади між собою.

Таблиця 3 Формат вектора типу POI

Тип	Вектор
Дороги	(RD_m1_NEAR, RD_m2_NEAR, RD_m3_NEAR)
Міста	(Kyiv_NEAR_, CITY2_NEAR, obj_1, obj_2, obj_3, obj_4, obj_5)
Місцеві парки	(LokPark_NE, obj_1, obj_2, obj_3, obj_4, obj_5)
Національні парки	(NatPark_NE, obj_1, obj_2, obj_3, obj_4, obj_5)
Регіональні парки	(regPark_NE, obj_1, obj_2, obj_3, obj_4, obj_5)
Об'єднані парки	(значення кластера місцевих парків, значення кластера регіональних парків, значення кластера національних парків)
Банки	(bank_NEAR_, obj_1, obj_2, obj_3, obj_4, obj_5)
Церква	(cerkva_NEA, obj_1, obj_2, obj_3, obj_4, obj_5)
Освіта	(education_, obj_1, obj_2, obj_3, obj_4, obj_5)
Елеватори	(elevators_, obj_1, obj_2, obj_3, obj_4, obj_5)
Готелі	(hotels_NEA, obj_1, obj_2, obj_3, obj_4, obj_5)
Дитячі садки	(kinder_NEA, obj_1, obj_2, obj_3, obj_4, obj_5)
Бібліотеки	(library_NE, obj_1, obj_2, obj_3, obj_4, obj_5)
Медицина	(likarni_NE, obj_1, obj_2, obj_3, obj_4, obj_5)
Магазини	(magaz_NEAR, obj_1, obj_2, obj_3, obj_4, obj_5)
Загальний	(дороги, міста, парки, банки, церкви, освіта, елеватори, готелі, дитячі садки, бібліотеки, медицина, магазини)

Для відсутніх даних використовувалися значення-заповнювачі, що дозволило зберегти цілісність даних та полегшило подальший аналіз.

Одним із завдань, яке виникає при аналізі кластерів, є проблема візуального представлення даних, коли кількість вимірів

перевищує 2 чи 3. Для двовимірних і тривимірних даних можливе створення 2D та 3D візуалізацій, які забезпечують наочно відображення отриманих результатів. Однак для даних, що мають більшу кількість вимірів, доцільним є застосування теплових карт, які дозволяють ефективно візуалізувати результати кластеризації. Для цього використовуються нормалізовані дані, що дозволяє адекватно порівнювати кластери між собою.

Такий підхід спрощує представлення складних багатовимірних даних, підкреслюючи подібності та відмінності між кластерами. Нормалізація даних забезпечує справедливі порівняння, а використання теплових карт виступає ефективним інструментом для швидкого виявлення ключових тенденцій та відхилень у кластеризації.

Процес нормалізації даних включає наступні кроки:

1) Вибір показників, що будуть використовуватись для візуалізації.

2) Нормалізація цих показників з використанням формули:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (29)$$

де x — значення показника, x_{min} та x_{max} — мінімальне та максимальне значення цього показника відповідно.

3) Використання нормалізованих даних для візуалізації.

Генерація теплової карти. Після виконання кластеризації використаємо теплові карти як інструмент візуалізації нормалізованих даних для кожного кластера. Це допомагає наочно відобразити, наскільки подібні чи різні кластери між собою з врахуванням різних інфраструктурних показників. За допомогою додаткових описів, таких як кількість об'єктів у кластері, можна також зробити висновок про загальний стан розвитку певного типу інфраструктури. Приклад теплової карти наведено на рис. 6.

Приклад коду для створення функції відображення теплової карти нормалізованих даних для кластера:

```
def heatmap_clusters(series, cluster_labels,
                    custom_row_labels=None, custom_column_labels=None,
                    file_name="Name"):
    data = np.stack(series.values)
    scaler = MinMaxScaler()
    data_normalized = scaler.fit_transform(data)
```

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

```
unique_clusters = np.unique(cluster_labels)
centroids_normalized = np.array([data_normalized[cluster_labels ==
k].mean(axis=0) for k in unique_clusters])
if custom_row_labels is None:
    row_labels = [f"Cluster {k}" for k in unique_clusters]
else:
    row_labels = custom_row_labels
if custom_column_labels is None:
    column_labels = [f"Feature {j}" for j in range(data.shape[1])]
else:
    column_labels = custom_column_labels
centroids_df = pd.DataFrame(centroids_normalized,
index=row_labels, columns=column_labels)
plt.figure(figsize=(12, 8))
sns.heatmap(centroids_df, annot=True, fmt=".2f", cmap='viridis')
plt.title("Heatmap of Normalized Cluster Centroids")
plt.xlabel("Features")
plt.ylabel("Clusters")
plt.xticks(rotation=30)
timestamp = datetime.now().strftime("%Y-%m-%d_%H-%M-%S")
filename =
f"Clustering_of_{file_name}_{custom_column_labels[0]}.png"
save_path = f"{filename}"
plt.savefig(save_path, bbox_inches='tight')
plt.show()
```

Застосування запропонованих методів до отриманих векторів та аналіз результатів. Нижче наведено аналіз отриманих результатів, які демонструють створення кластерів та їх відповідність очікуваним результатам. Важливим спостереженням є виявлення менш поширених POI, таких як місцеві парки, церкви, освітні заклади, готелі, дитячі садки та медичні установи, що відображено на кількох рисунках.

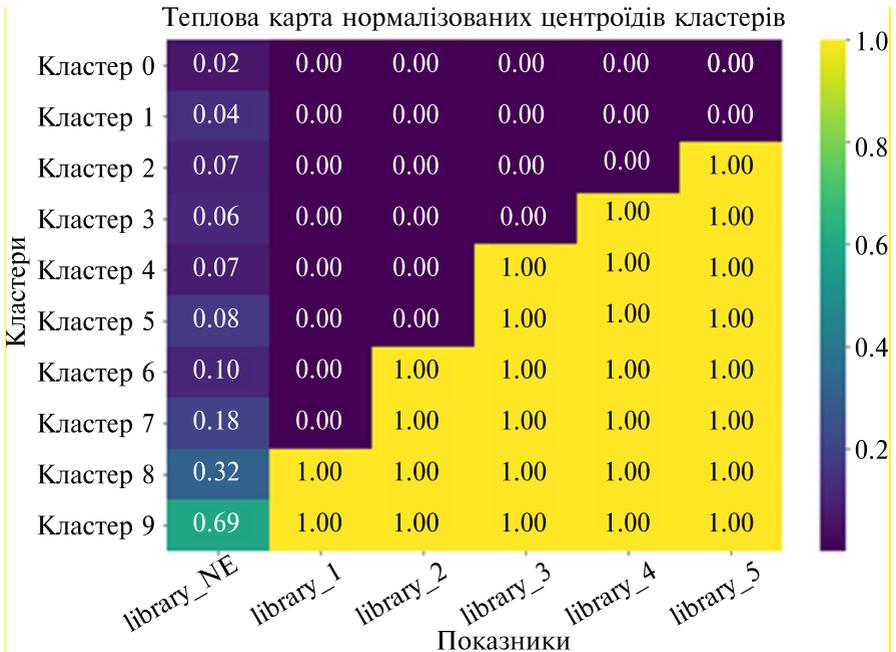


Рис. 6. Приклад теплової карти нормалізованих даних для кожного кластера, інфраструктура типу «бібліотека»

Приклад коду для кластеризації доріг (рис. 7).

```
def road_vector_series(df):
    road_columns = ['RD_m1_NEAR', 'RD_m2_NEAR',
'RD_m3_NEAR']
    if not all(col in df.columns for col in road_columns):
        raise ValueError("Required columns are missing from the
dataframe")
    roads_vec_series = df.apply(lambda row: np.array([row[col] for col
in road_columns]), axis=1)
    return roads_vec_series
def road_clustering(roads_series, n_clusters=10):
    data = np.stack(roads_series.values)
    kmeans = KMeans(n_clusters=n_clusters,
random_state=0).fit(data)
```

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

```
cluster_labels = pd.Series(kmeans.labels_,
index=roads_series.index)
return cluster_labels
def plot_3d_road_clusters(roads_series, cluster_labels):
data = np.stack(roads_series.values)
fig = plt.figure(figsize=(10, 8))
ax = fig.add_subplot(111, projection='3d')
colors = ['blue', 'green', 'red', 'cyan', 'magenta', 'yellow', 'black',
'pink', 'orange', 'purple']
62
for i in np.unique(cluster_labels):
cluster = data[cluster_labels == i]
ax.scatter(cluster[:, 0], cluster[:, 1], cluster[:, 2], s=50, c=colors[i],
label=f'Cluster {i}')
ax.set_title('3D Clustering of Roads Data')
ax.set_xlabel('Distance to Road Type 1')
ax.set_ylabel('Distance to Road Type 2')
ax.set_zlabel('Distance to Road Type 3')
ax.legend()
plt.savefig("roads_clustered.png", bbox_inches='tight')
plt.show()
###
# Clustering
precategorized_df["roads"] = road_vector_series(df)
print(precategorized_df["roads"])
categorized_df["roads"] =
categorize_distances(precategorized_df["roads"], n_clusters=10)
# Visualization
plot_3d_road_clusters(precategorized_df["roads"],
categorized_df["roads"])
```

З огляду на рис. 8, більшість сільських громад мають схожий доступ до регіональних та сільських доріг (типи 2 та 3, відповідно). Можна чітко визначити набір сільських громад у кластері 3, які потребують кращого зв'язку з регіональними дорогами.

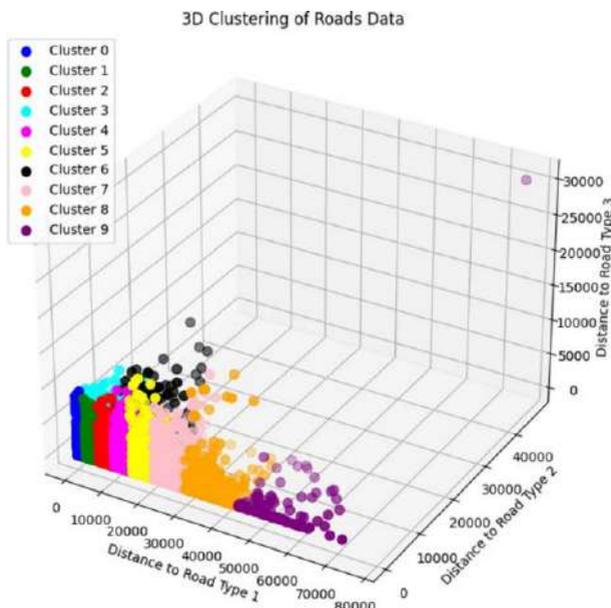


Рис. 7. Кластери типів доріг, де кожен колір представляє різний кластер

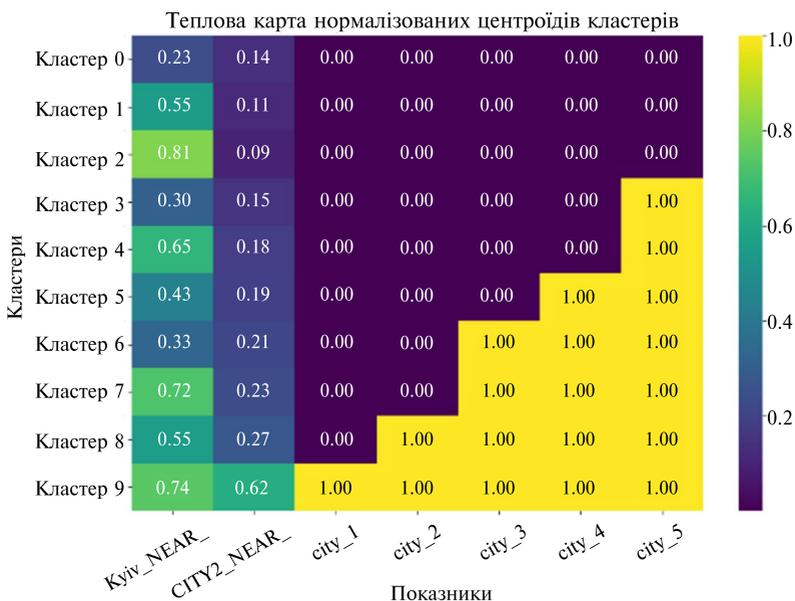


Рис. 8. Теплокорта кластерів міст

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

Приклад коду для створення карти кластерів міст:

```
def create_city_distance_vector(df, city_column='graph_city'):
def process_row(row):
    cities = json.loads(row[city_column]) if
pd.notnull(row[city_column]) else []
    city_distances = [city["distance"] for city in cities]
    city_distances = sorted(city_distances)[:5]
    city_distances.extend([2147483647] * (5 - len(city_distances)))
    return np.array([row['Kiyv_NEAR_'], row['CITY2_NEAR']] +
city_distances)
    df['city_distance_vector'] = df.apply(process_row, axis=1)
    return df['city_distance_vector']
# Clustering
precategorized_df["cities"] = create_city_distance_vector(df, graph_city")
print(precategorized_df["cities"])
categorized_df["cities"] =
categorize_distances(precategorized_df["cities"])
# Visualization
labels = ["Kiyv_NEAR_", "CITY2_NEAR", "city_1", "city_2", "city_3",
"city_4", "city_5"]
heatmap_clusters(precategorized_df["cities"], categorized_df["cities"],
custom_column_labels = labels)
```

На основі аналізу рис. 8 бачимо, що існує три кластери сільських громад, які розташовані поблизу п'яти міст, два кластери з чотирма найближчими містами, один кластер з трьома та два кластери з двома містами поблизу. Такий розподіл свідчить, що значна частина сіл може отримати переваги від близького розташування до кількох міст, що спрощує реалізацію майбутніх інфраструктурних проєктів. Наявність міст у безпосередній близькості свідчить про вищий рівень інфраструктурного розвитку, що, згідно з [6], підвищує загальний добробут мешканців. Окрім того, теплові карти показують, що кластери 0, 3 та 6 мають високу доступність до столиці (K_NEAR), що додатково підтверджує вищий рівень інфраструктурного забезпечення порівняно з іншими сільськими громадами.

Розглядаючи характеристики кластерів національних та регіональних парків на рис. 9, можна побачити, що більшість сіл не мають швидкого доступу до них. Хоча близькість розташування до таких об'єктів може не бути життєво важливою для повсякденного життя мешканців, знаходження поблизу цих зон

безсумнівно сприяє загальному розвитку навколишнього регіону. Це підвищує рівень туризму, що, в свою чергу, стимулює будівництво готелів та магазинів, підтримуючи місцеву економіку.

Приклад коду кластеризації національних парків. Теплові карти для парків наведено на рис. 9.

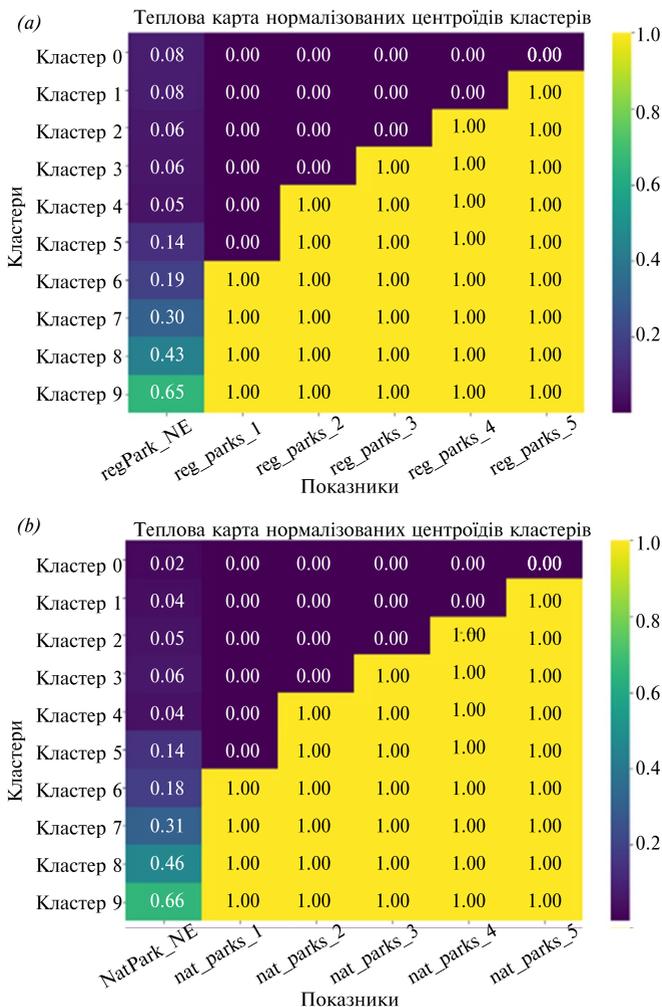


Рис. 9. Теплокarti кластерів: (а) регіональних парків, (б) національних парків

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

Діаграми на рис. 10-12 ілюструють різні аспекти соціального життя у селах і можуть бути розділені на дві групи: ті, що представляють розвинені та легкодоступні об'єкти (включаючи церкви, як показано на рис. 10e, освітні центри на рис. 10f, елеватори на рис. 10a, готелі на рис. 10b, дитячі садки на рис. 10c, медичні заклади на рис. 10d та магазини на рис. 12), і ті, що є більш складними для доступу, такі як банки та бібліотеки (показані на рис. 11b та рис. 11a відповідно).

```
def create_national_park_distance_vector(df,
park_column='graph_national_park'):
    def process_row(row):
        parks = json.loads(row[park_column]) if
pd.notnull(row[park_column]) else []
        park_distances = [park["distance"] for park in parks]
        park_distances = sorted(park_distances)[:5]
        park_distances.extend([2147483647] * (5 -
len(park_distances)))
        return np.array([row["NatPark_NE"] + park_distances)
df['national_park_distance_vector'] = df.apply(process_row, axis=1)
return df['national_park_distance_vector']
```

```
#%%
```

```
precategorized_df["nat_parks"] =
create_national_park_distance_vector(df)
print(precategorized_df["nat_parks"])
labels = ["NatPark_NE", "nat_parks_1", "nat_parks_2", "nat_parks_3",
"nat_parks_4", "nat_parks_5"]
categorized_df["nat_parks"] =
categorize_distances(precategorized_df["nat_parks"])
heatmap_clusters(precategorized_df["nat_parks"],
categorized_df["nat_parks"], custom_column_labels = labels
```

Приклад коду кластеризації регіональних парків:

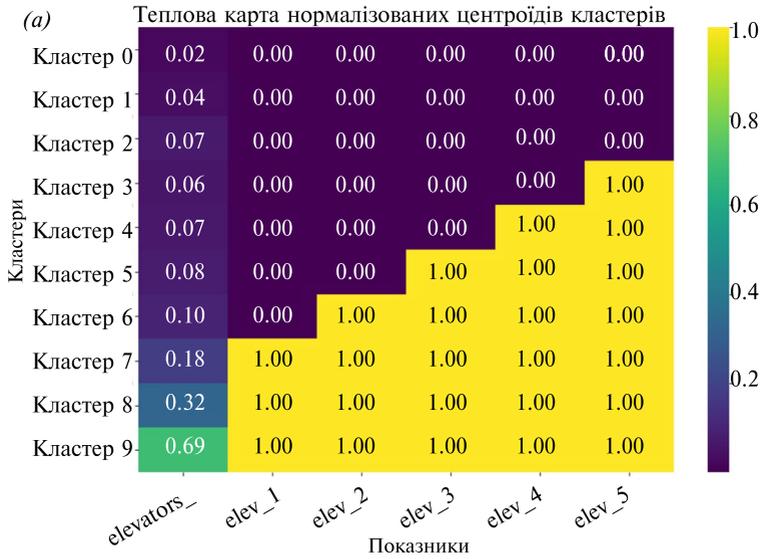
```
def create_regional_park_distance_vector(df,
park_column='graph_regional_park'):
    def process_row(row):
        parks = json.loads(row[park_column]) if
pd.notnull(row[park_column]) else []
        park_distances = [park["distance"] for park in parks]
```

```
park_distances = sorted(park_distances)[:5]
park_distances.extend([2147483647] * (5 -
len(park_distances)))
return np.array([row['regPark_NE']] + park_distances)
df['regional_park_distance_vector'] = df.apply(process_row, axis=1)
return df['regional_park_distance_vector']
#%%
precategorized_df["reg_parks"] =
create_regional_park_distance_vector(df)
print(precategorized_df["reg_parks"])
labels = ["regPark_NE", "reg_parks_1", "reg_parks_2", "reg_parks_3",
"reg_parks_4", "reg_parks_5"]
categorized_df["reg_parks"] =
categorize_distances(precategorized_df["reg_parks"], 10)
heatmap_clusters(precategorized_df["reg_parks"],
categorized_df["reg_parks"], custom_column_labels = labels)
```

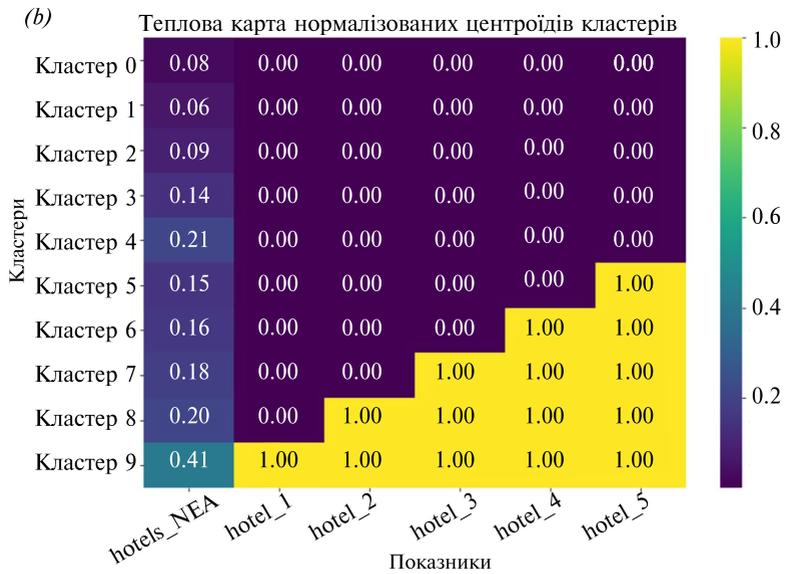
Сільські громади першої групи мають швидкий доступ до важливих об'єктів інфраструктури, таких як освіта, медичні послуги та дитячі садки, що є вирішальним для загального добробуту мешканців. Готелі та магазини, хоч і не є критично важливими, в цілому також сприяють розвитку малого бізнесу та забезпечують доступ до товарів, що підтримує економічну активність регіону. Окрім того, наявність готелів підвищує можливості для прийому туристів, що є важливим чинником для сталого розвитку сільських територій.

Друга група підкреслює, що хоча роль бібліотек змінюється через поширення Інтернету та мобільних технологій, вони продовжують виконувати важливу соціальну та культурну функцію. Це підкреслює необхідність покращення громадських просторів, таких як місцеві парки, для підтримки соціальної згуртованості. Крім того, розширення банківських послуг, таких як мережа банкоматів та фінансових установ, сприятиме економічній активності, полегшуючи доступ до кредитних та фінансових продуктів для місцевого бізнесу.

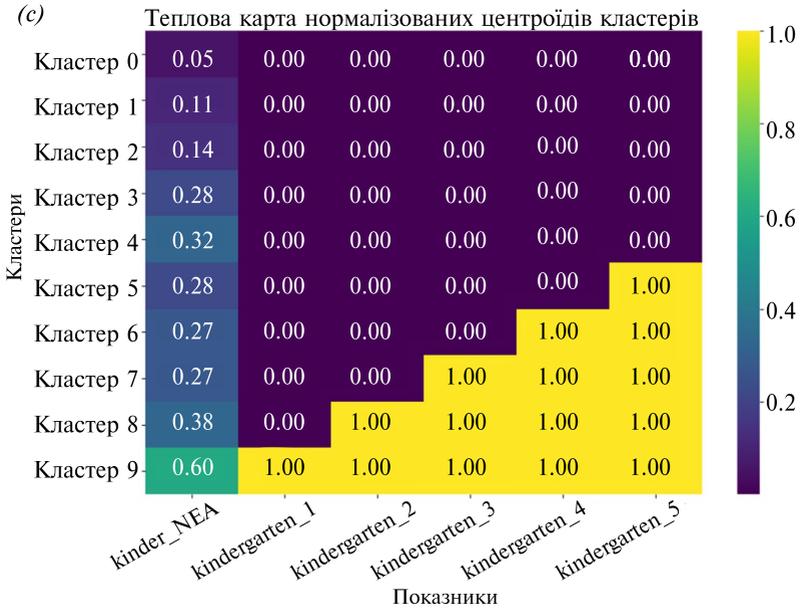
3.2. Моделювання розвитку інфраструктури сіл на основі графових даних



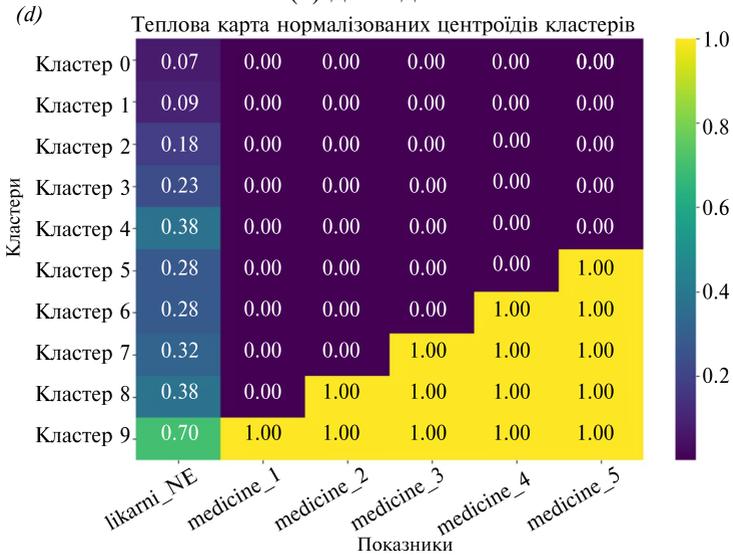
(a) елеватори



(b) готелі

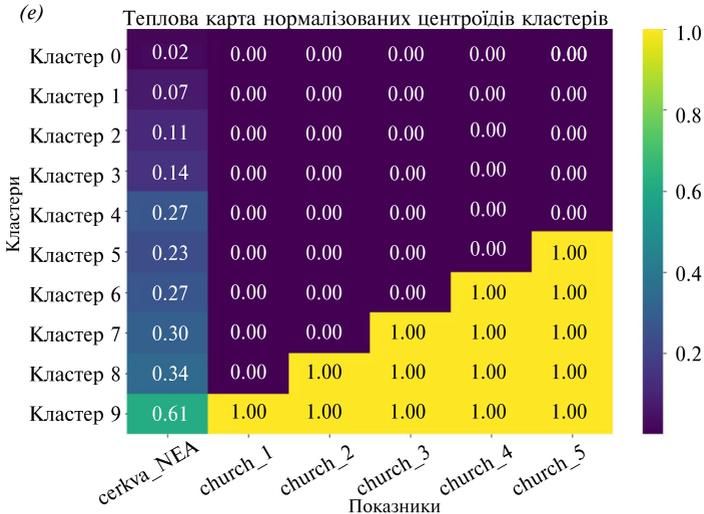


(c) ДИТСАДКИ

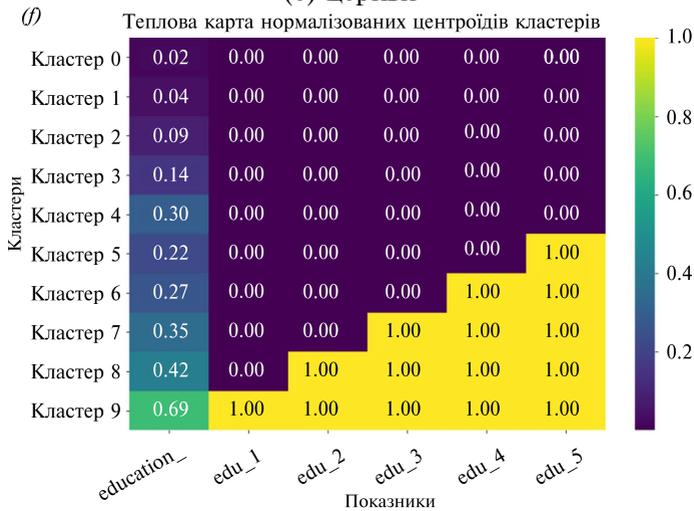


(d) мед. заклади

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних



(e) церкви



(f) об'єкти освіти.

Рис. 10. Теплокарти кластерів різних об'єктів

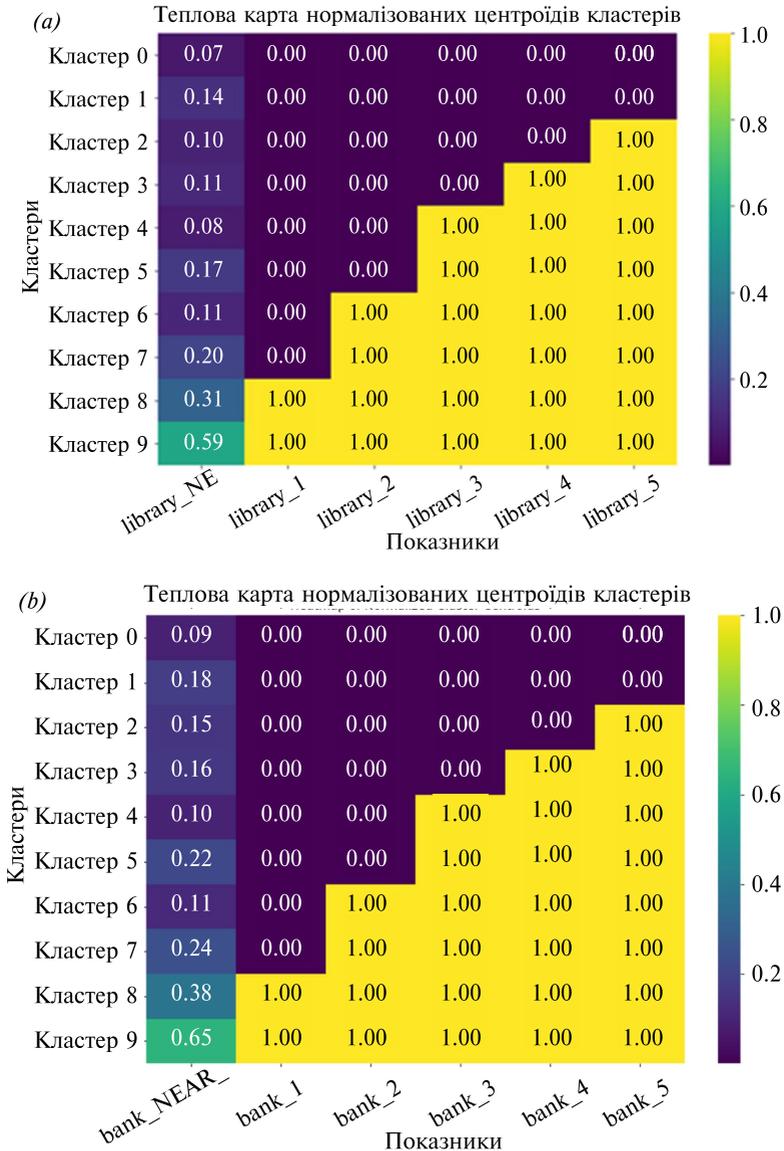


Рис. 11. Теплокарти кластерів: (а) бібліотек, (б) банків

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

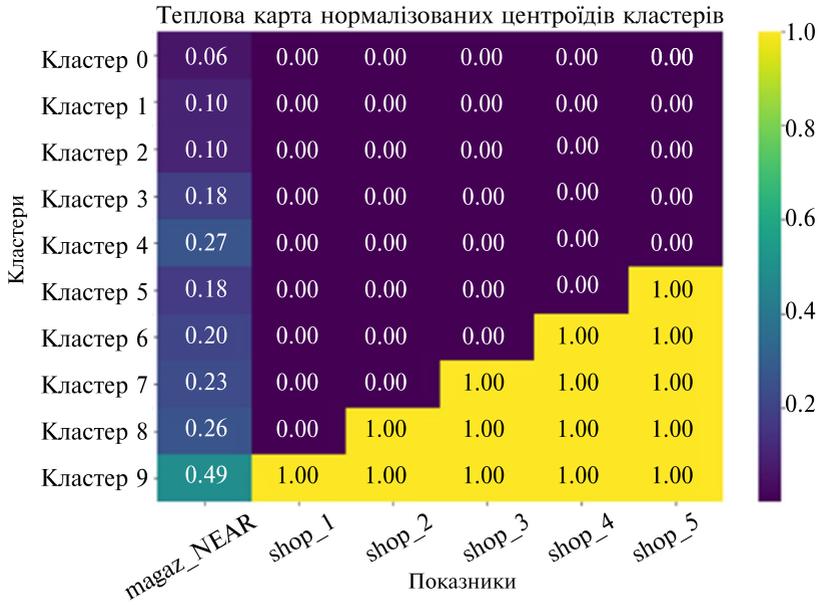


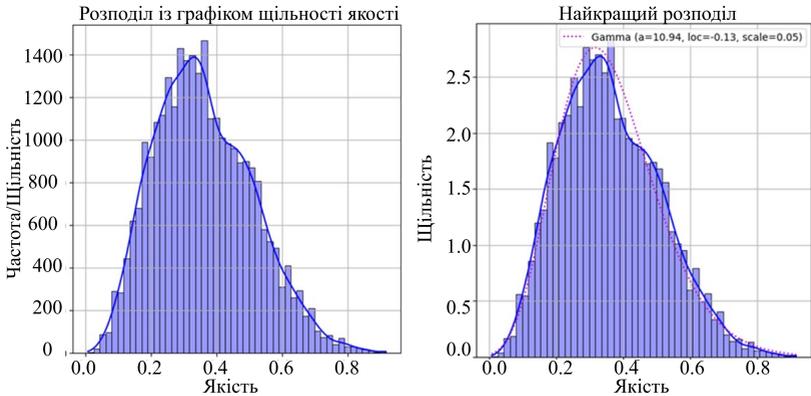
Рис. 12. Теплокарта кластерів магазинів

Важливим аспектом залишається забезпечення зручного доступу до банківських послуг. Незважаючи на розвиток електронного банкінгу в Україні, фізична присутність банків залишається важливою, особливо для літніх людей та туристів, які можуть потребувати особистої взаємодії або допомоги. Тому покращення фізичної банківської інфраструктури може зробити регіони більш привабливими та комфортними для вирішення фінансових питань.

Загальний аналіз кластерів вказує на певні розбіжності, наприклад, в описі бібліотек у кластері 2 та доріг у кластері 1. Це підтверджує, що застосований підхід забезпечив ефективний та детальний аналіз даних.

Аналіз розподілу та обчислення оцінки якості. Перейдемо до більш детального аналізу розподілу якості інфраструктури в селах, представлений на рис. 13а.

Спробуємо визначити, чи задовольняє цей розподіл хоч якусь з статистичних моделей, як оговорювалось раніше. Для цього підберемо найкращу статистику та візуалізуємо її, так на рис. 13б.



(а) Загальна якість всіх сіл (б) Найкраща статистична модель

Рис.13. Гістограми якості інфраструктури в селах та найкраща статистична модель

Не зважаючи на досить низьке значення у тесті Колмогорова-Смірнова, можна побачити, що розподіл досить добре повторює гамма-розподіл з наведеними на рисунку параметрами, а отже, мету досягнуто за допомогою формули (21), де $a = 1.0555$ та $b = 0.0555$.

Таким чином отримано важливий результат експерименту, а саме сформульовано оцінку якості для кожного села, що розрахована наступним чином:

$$\text{ОЯ} = 1.0555 \times \left(\frac{1}{n} \sum_{i=1}^n \text{Оі}_i \right) + 0.0555 \times \text{РК}. \quad (30)$$

Ця формула інтегрує середню оцінку категорії інфраструктури з рейтингом кластера, надаючи детальну міру якості інфраструктури. Ця комплексна оцінка охоплює як різноманітність наявної інфраструктури в сільській громаді, так і її порівняльний стан серед інших сіл.

Для ілюстрації роботи запропонованих раніше методів було розроблено пілотний дашборд, який можна побачити на рис. 14 або ж за відкритим посиланням [15].

На рис. 14 представлено загальний вигляд даного дашборду - мапи України, де відмічені всі сільські громади за допомогою кольорової шкали, що відображає якість інфраструктури, починаючи від зеленого, що означає кращу якість розвитку

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

інфраструктури, до гіршої якості, що відображається червоним кольором.

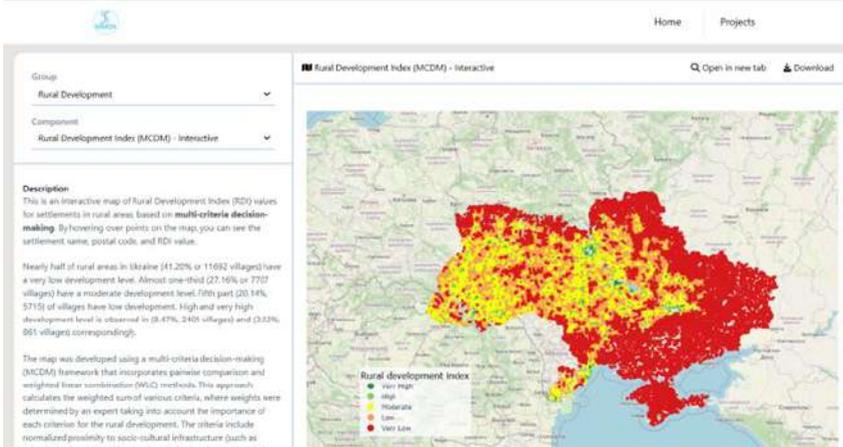


Рис. 14. Дашборд з візуалізацією отриманих результатів дослідження

Однією з важливих функцій цього дашборду є можливість отримання інформації по кожній сільській громаді (рис. 15), наприклад *id*, значення кожного типу інфраструктури, а також загальний рейтинг якості інфраструктури і фінальну оцінку якості.

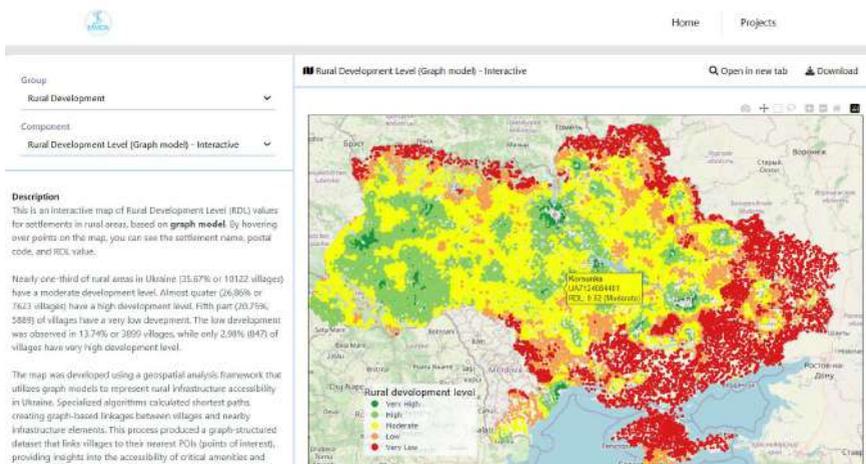


Рис. 15. Детальна інформація про кожне село

Даний дашборд дозволяє як візуалізувати отримані результати, так і детально ознайомитися з кожним селом окремо, що може бути корисним для подальшого аналізу та планування розвитку інфраструктури, при чому важливим є те, що ознайомлення з даним дашбордом має низький рівень входу, що дозволяє використовувати його широкому колу користувачів та стейкхолдерів.

2.5.2. ОПТИМІЗАЦІЯ ОЦІНОК ДОСТУПНОСТІ НА ОСНОВІ ГРАФОВИХ ДАНИХ

Основною метою експерименту є розробка розширеного набору геопросторових оцінок для представлення доступності критичної інфраструктури для сільських громад на основі графової моделі. Для досягнення цієї мети проведемо багатofазний аналіз, що включає наступні кроки.

1) Побудова статистичного профіля базових геопросторових наборів даних про сільські території України для перевірки цілісності та узгодженості з пріоритетами розвитку.

2) Експериментальна реалізація спеціалізованих алгоритмів для побудови графових зв'язків між сільськими поселеннями та навколишніми багатокатегорійними точками інтересу POI, що представляють доступну інфраструктуру.

3) Кількісний та графічний статистичний аналіз для оцінки, чи зберігає графова трансформація якісні властивості попередніх розподілів доступності сільських територій.

Вихідним результатом є вдосконалений графовий набір даних, що кількісно оцінює доступність на рівні сіл до ключових сервісів у межах критичних порогів відстані. Це закладає фундамент для майбутньої аналітики для визначення прогалів у сільській інфраструктурі, що обмежують розвиток.

Перевірка базових геопросторових даних. Спочатку перевіримо повноту та адекватність зібраних геопросторових шарів даних про сільську інфраструктуру в Україні. Для цього було обрано використання GeoDataFrames (GDF) (рис. 16).

GeoDataFrames є основною структурою даних для роботи з геопросторовими даними в бібліотеці geopandas, яка розширює можливості pandas.

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

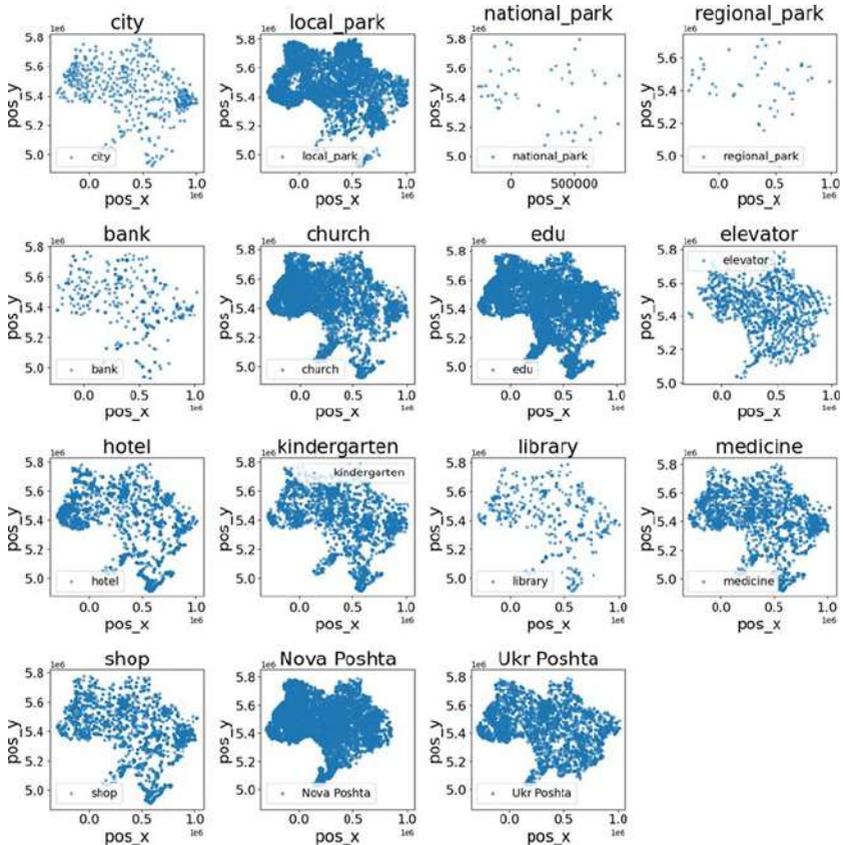


Рис. 16. Графічне представлення груп точок інтересу POI. Кожен рисунок представляє один тип POI як в табл. 3.

Основні характеристики GeoDataFrame:

Колонка геометрії: У GeoDataFrame є спеціальна колонка *geometry*, яка містить геометричні об'єкти (точки, лінії або полігони), що представляють просторові дані. Це дозволяє прив'язати кожен рядок до певної географічної форми.

Аналіз і візуалізація: GeoDataFrames підтримують просторові операції, такі як об'єднання, перетини та буферизація, а також дозволяють візуалізувати дані на карті, що спрощує роботу з геопросторовою інформацією.

Сумісність із GIS: GeoDataFrames можуть зберігатися у форматах, сумісних із геоінформаційними системами (наприклад,

Shapefile та GeoJSON), що дозволяє обмінюватися даними з іншими ГІС-додатками.

Після аналізу графічного представлення на рис. 16 стає очевидним, що більшість цих графіків демонструють більш-менш нормальний розподіл по Україні.

«Нормальний» у цьому контексті означає, що немає значних прогалів, смуг або будь-яких інших відсутніх областей у даних, окрім даних поштових операторів, в зв'язку з закриттям своїх відділень через війну на сході України.

Оцінка доступності сільських територій на основі графових даних. Маючи чисті базові дані, реалізуємо запропоновану методологію сегментації зони обслуговування сільських територій, вилучення та відбору POI, розрахунку відстаней та побудови графової бази даних для перетворення попередніх наборів даних у розширені оцінки доступності. Як було описано в підрозділі 2, процес створення графової бази даних включає декілька ключових етапів. Спочатку визначаються всі можливі точки інтересу (POI) в заданому радіусі навколо кожного села. Далі використовуються алгоритми просторового аналізу для розрахунку евклідових відстаней між селами та кожною POI, забезпечуючи тим самим точні географічні зв'язки. Ці відстані конвертуються в атрибути графових вершин і ребер, що дозволяє створити деталізовану мережу доступності. Ця мережа відображає реальні шляхи доступу до різних об'єктів інфраструктури і забезпечує глибоке розуміння просторових структур та можливих прогалів у наявності критичних ресурсів. Експеримент передбачає використання таблиці, яка описує, які дані були включені у новостворені оцінки. Для кожного фрейму визначено конкретні значення, що визначають, які параметри (стовпці) повинні бути включено у вихідні дані.

Таблиця 4 Опис даних, включених в новостворені оцінки POI

Дані	Опис у вихідному графі	Максимальна відстань	Максимальна кількість в кластері
Міста	Id, pos_x, pos_y, distance	50 км	5
Місцеві парки	Id, type, distance, area, pos_x,	30 км	5

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

	pos_y		
Національні парки	Id, area, pos_x, pos_y, distance	50 км	5
Регіональні парки	Id, area, pos_x, pos_y, distance	50 км	5
Банк	Id, pos_x, pos_y, distance	30 км	5
Церква	Id, type, pos_x, pos_y, distance	30 км	5
Освіта	Id, type, pos_x, pos_y, distance	30 км	5
Елеватори	Id, pos_x, pos_y, distance	30 км	5
Готелі	Id, type, pos_x, pos_y, distance	30 км	5
Дитячі садки	Id, pos_x, pos_y, distance	30 км	5
Бібліотеки	Id, pos_x, pos_y, distance	30 км	5
Медицина	Id, type, pos_x, pos_y, distance	30 км	5
Магазини	Id, type, pos_x, pos_y, distance	30 км	5

Кількісна оцінка відстані в початкових даних. Даний тип оцінки сільських громад [2] включає різні атрибути інфраструктури, детальний опис яких наведено у табл. 3.

Збір та обробка цих даних дозволили створити детальну картину доступності сільських територій до критичної інфраструктури, такої як дороги, міста, елеватори, освітні та медичні заклади, а також інші важливі об'єкти. За допомогою найпростішого типу опису, що дозволяє закласти певний найпростіший опис доступності інфраструктури, розкриваються основні характеристики та значення кореляції, які можна використати в наступних підрозділах при аналізі новостворених оцінок доступності.

Графові оцінки доступності. В результаті виконання експерименту, описаного вище, було отримано графові оцінки доступності для сільських територій. В результаті трансформації

початкових оцінок відстаней у детальне графове з'єднання між сільськими селами та навколишніми багатокатегорійними POI, успішно сконструйовано розширені оцінки доступності. В результаті розроблено наступну структуру, де `id_type` це назва ключа села, `id` – це його ідентифікатор, `distance` - це відстань в метрах до села та `pos_x`, `pos_y` - це координати села в EPSG:32636.

```
{
  "id_type": "admin4Pcod",
  "id": "UA2111000000",
  "distance": 3111.931012554032,
  "pos_x": 52060.12938924221,
  "pos_y": 5420926.907282681 },
{"id_type": "admin4Pcod",
 "id": "UA2110100000",
 "distance": 23160.7396750182,
 "pos_x": 60818.384628206666,
 "pos_y": 5441084.188000026 },
{"id_type": "admin4Pcod",
 "id": "UA2123210100",
 "distance": 41187.70115749954,
 "pos_x": 76317.64176459657,
 "pos_y": 5451978.68918336},
{"id_type": "admin4Pcod",
 "id": "UA2110400000",
 "distance": 41376.3746009097,
 "pos_x": 90058.87699085698,
 "pos_y": 5416411.645983889},
{"id_type": "admin4Pcod",
 "id": "UA2110200000",
 "distance": 43577.79427222703,
 "pos_x": 80594.92931475205,
 "pos_y": 5391219.696301765}
```

Статистичний аналіз. Досліджуючи вторинні та сільські дороги (`RD_m2_NEAR` та `RD_m3_NEAR`), видно, що майже всі села мають задовільний доступ до доріг будь-якого типу, як ілюструє рис. 17.

Однак, є значний простір для покращення в основних дорогах `RD_m1_NEAR`, який демонструє розподіл, зміщений вправо. `Kyiv_NEAR` показує трикутний розподіл, що вказує на те, що більшість сіл розташовані на відстані 150–500 км, що сприятливо, оскільки це свідчить про рівномірний доступ до столиці та,

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

відповідно, до можливостей бізнесу з компаніями, які там базуються.

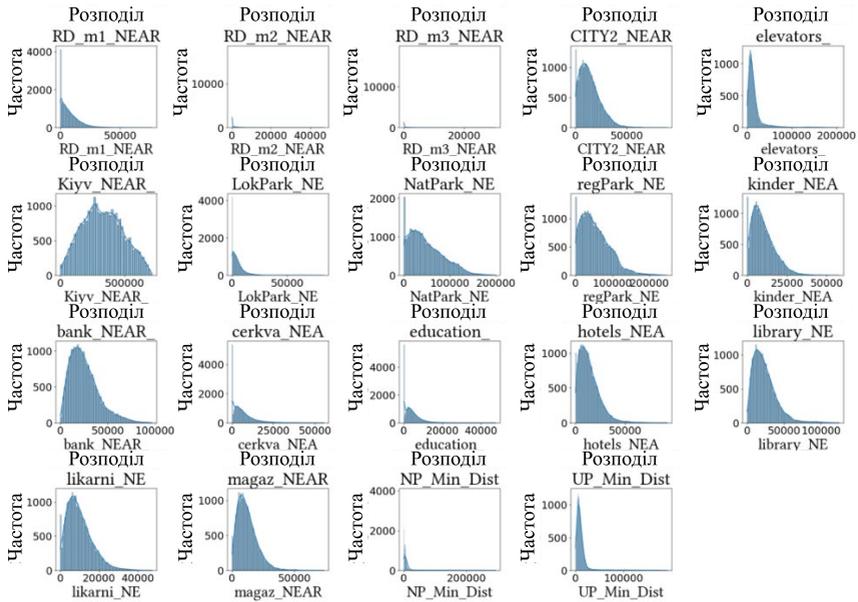


Рис. 17. Гістограма відстані для кожного типу інфраструктури

Розподіли інших змінних ілюструють певну схожість з логнормальним розподілом, що вказує на те, що хоча деякі сільські громади розташовані близько до POI, багато інших мають простір для покращення в плані розташування та доступу до різних елементів інфраструктури. *Слід зазначити, що «схожість» в даному контексті була отримана, як результат проведення тесту по підбору параметрів для нормального, логнормального гамма- та експоненціального розподілів.* Після підбору параметрів і проведення тесту Колмогорова-Смірнова, було визначено, що навіть для найкращого підходу значення p (рівень значущості, який вказує на ймовірність того, що отримані результати могли виникнути випадково, якби нульова гіпотеза була вірною) досить низьке (0.05 – 0.1), що не дозволяє стверджувати, що дані розподіли повторюють обрані розподіли точно, проте можна говорити про їх схожість.

Додатковий аналіз (рис. 18) підтверджує відносну коректність використаних відстаней при побудові графових оцінок, а саме в табл. 4 для параметру «максимальної відстані».

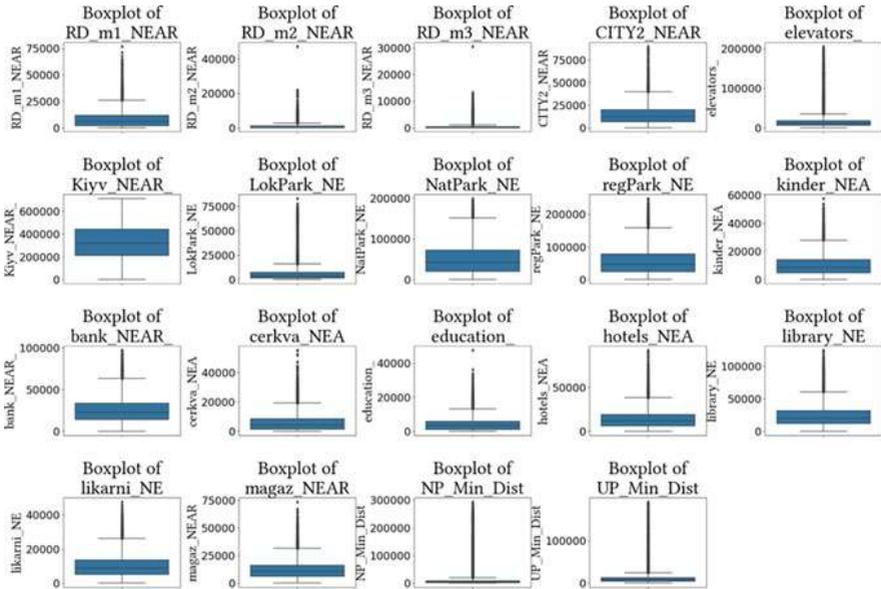


Рис. 18. Коробкові діаграми досліджуваних колонок

Розглянемо кореляції між оцінками відстаней, що зображені на рис. 19, більш детально. Важливим спостереженням є кореляція розташування таких об'єктів, як дитячі садки, банки, церкви та місця надавання освітніх послуг, з близькістю до найближчого міста, оскільки міста зазвичай пропонують більше можливостей та кращі сервіси, ніж села.

Додатковий статистичний аналіз показав, що інші категорії інфраструктури, такі як лікарні та магазини, також демонструють високий рівень кореляції з відстаннями до міст. Це свідчить про те, що сільські райони, які мають кращий доступ до міської інфраструктури, мають значні переваги в доступі до ключових послуг.

Крім того, результати показують, що сервіси, які вважаються менш критичними, такі як місцеві парки та готелі, також демонструють значну кореляцію з ступенем близькості до міста. Це підкреслює важливість комплексного підходу до розвитку сільської інфраструктури, включаючи як критичні, так і

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

некритичні послуги, для забезпечення високої якості життя в сільських громадах.

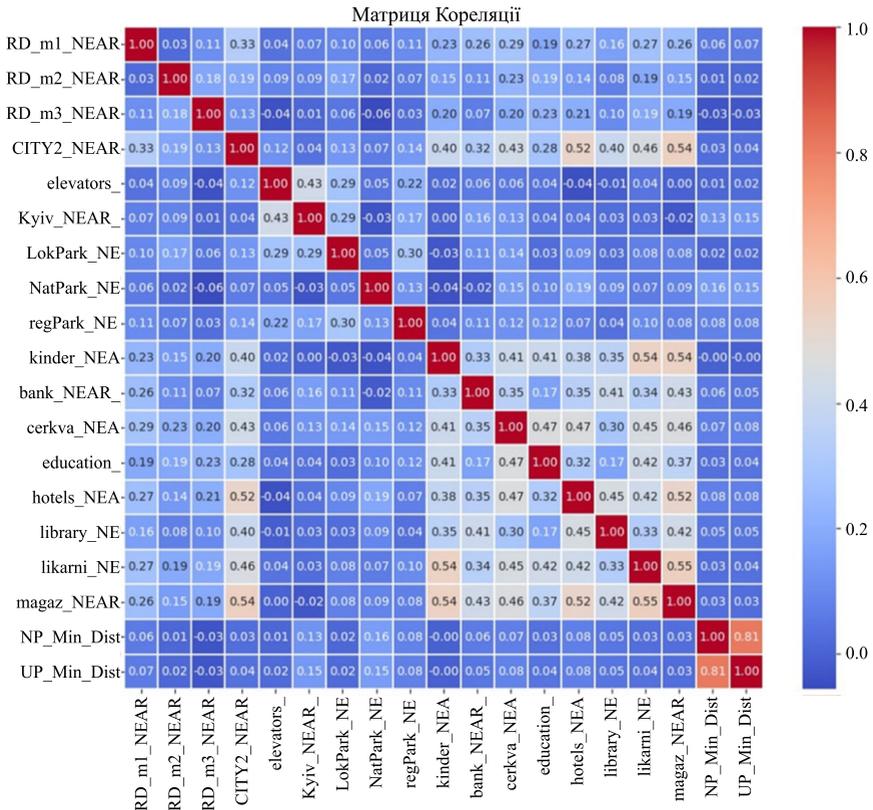


Рис. 19. Кореляційна матриця досліджуваних колонок

Важливо, щоб розширені набори даних не втрачали цілісність або не демонстрували широко варіативні розподіли. Рис. 19 підтверджує актуальність загальної доступності соціальних зручностей. Далі потрібно перевірити, чи залишаються розподіли даних стабільними, або майже такими, створюючи графіки розподілу, як показано на рис. 20. Хоча ці діаграми містять багато даних та містять розбіжності, все ж можна спостерігати, що загальний розподіл не змінився суттєво в розширеному наборі даних.

Це свідчить про те, що запропонований підхід забезпечує стабільність і надійність отриманих результатів, зберігаючи ключові характеристики початкових даних.

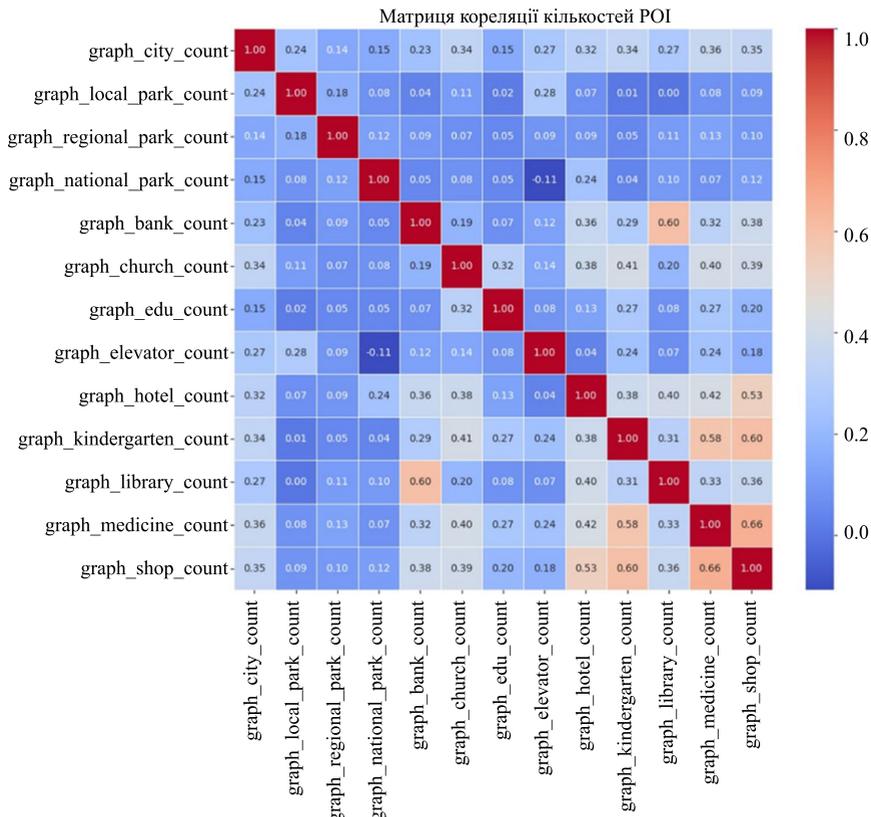


Рис. 20. Кореляційна матриця розширеного набору даних

Також необхідно оцінити, чи зберігається структура в розподілах в графових структурах, а саме чи підтверджується факт того, що сільські громади з більшою кількістю наближених POI серед однієї групи будуть мати перший об'єкт ближче, ніж села з меншою кількістю POI. Та чи підтверджується факт того, що для сіл з декількома наближеними POI, з переходом від першого до останнього об'єкту будуть віддалятися. Для цього було використано коробкові діаграми (рис. 21). Як можна побачити, дані правила виконуються.

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

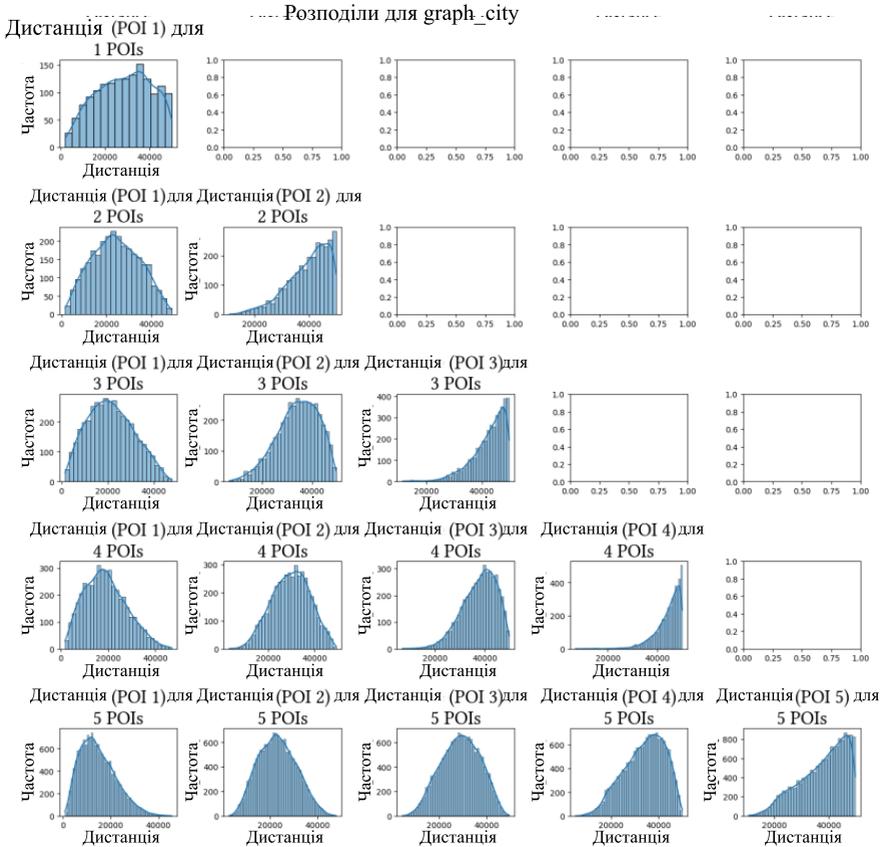


Рис. 21. Матриця розподілу об'єктів для «graph_city» на основі кількості POI на певній відстані для кожного конкретного порядку точки з цього масиву

2.6. ОБГОВОРЕННЯ

У цьому дослідженні проаналізовано доступність інфраструктури для сільських громад, що дозволило краще зрозуміти розподіл об'єктів поблизу сільських територій. Введення нових оцінок інфраструктури на основі даних про POI, зокрема щодо близькості до доріг, міст та соціальних об'єктів, дало змогу створити багатогранний опис інфраструктурних умов. Використання графових дескрипторів із детальними координатами

та відстанями до об'єктів дозволяє оцінити доступність основних ресурсів і виявити, де необхідні покращення.

Статистичний аналіз показав кілька важливих тенденцій, зокрема щодо підключення сільських громад до доріг. Наприклад, відстань до основних доріг має право-зміщений розподіл (RD_m1_NEAR), що вказує на обмеження у сполученні для значної кількості сіл, незважаючи на те, що більшість з них мають доступ до вторинних доріг, як бачимо з гістограми (рис. 17).

Аналіз показує також диспропорцію в доступності важливих послуг, таких як освіта, охорона здоров'я та роздрібна торгівля. Це вказує на необхідність покращень у наданні цих послуг. Рівномірний розподіл доступності до Києва (Kyiv_NEAR) свідчить про можливість для економічного розвитку завдяки кращому доступу до столиці, що може сприяти залученню інвестицій та розвитку місцевого бізнесу.

Коробкова діаграма на рис. 18 показує, що відстань до основних зручностей, як правило, становить менше 50 км, що вказує на відносну доступність послуг, важливих для соціального розвитку, за винятком регіональних та національних парків і відстані до столиці.

Це дозволяє зробити висновок про важливість забезпечення доступності соціальних послуг для громад.

Кореляційний аналіз підкреслює взаємозв'язок між відстанню до міських центрів та доступністю зручностей, підтверджуючи, що міські центри часто забезпечують більше послуг та об'єктів інфраструктури. Оригінальні та нові графові оцінки вказують на те, що введені метрики не змінюють характер розподілу даних, що дозволяє забезпечити достовірність рекомендацій для політики на їх основі.

Крім того, аналіз показав значну кореляцію між кількістю магазинів, медичних закладів, дитячих садків та готелів, що може вказувати на потенційні напрямки для розширення інфраструктури. Оскільки комерційні об'єкти, як магазини та готелі, в Україні здебільшого приватні, це дозволяє побачити, які державні покращення (медицина, дитячі садки, церкви) можуть залучити інвестиції та посилити розвиток.

На основі результатів було створено дашборд з градуванням ROI, що дозволяє виділити найбільш нерозвинені райони для подальших досліджень (рис. 14). Використання цих результатів у майбутньому сприятиме детальному аналізу інфраструктурних потреб у регіонах [15].

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

Аналіз розвитку сільської інфраструктури, представлений у цьому дослідженні, вимагає обробки великих обсягів даних, що включають геопросторові шари, графові структури та інші параметри, описані вище .

Для ефективного оброблення таких масивів даних необхідно використовувати високопродуктивні обчислювальні системи, такі як GRID або хмарні середовища [16]. Зокрема, системи Google Earth Engine або хмарне середовище CREODIAS дозволяють забезпечити масштабованість та продуктивність при аналізі геоданих великого обсягу.

Використання таких обчислювальних платформ сприяє ефективному плануванню інфраструктурних проєктів, зокрема шляхом ідентифікації пріоритетних регіонів, що потребують розвитку. Особливості застосування таких хмарних платформ будуть детально описані в частині 4 даної монографії.

Використання супутникових даних у поєднанні з розробленими моделями [17] дозволяє проводити соціо-економічний аналіз та оцінювати ризики і вплив надзвичайних ситуацій природного та антропогенного характеру на сільські території.

Зокрема, дані спостереження Землі забезпечують можливість моніторингу змін у землекористуванні, доступності ресурсів та стану інфраструктури в умовах, коли традиційні методи збору інформації є обмеженими або недоступними. Наприклад, у випадках природних катастроф, таких як посухи або повені, можна оцінювати втрати врожаю, зміну водних ресурсів та їх вплив на економіку сільських громад [18, 19].

У контексті антропогенного впливу, наприклад, війни, супутникові дані дозволяють аналізувати руйнування інфраструктури, переміщення населення та зміни у використанні земель [20-22]. Такий підхід сприяє ідентифікації найбільш вразливих регіонів, розробці стратегій пом'якшення наслідків та плануванню заходів для відновлення і сталого розвитку постраждалих територій.

ВИСНОВКИ

Проведені дослідження демонструють важливість використання методів геопросторового аналізу та методів кластеризації для оцінки та планування розвитку сільської інфраструктури, особливо в умовах України, що стикається з

унікальними соціально-економічними та інфраструктурними викликами. Основні отримані результати свідчать про ефективність запропонованих підходів у різних аспектах аналізу даних та класифікації сільських громад.

В даному розділі було запропоновано нові оцінки доступності на основі геопросторових даних, отриманих з джерел OpenStreetMap (OSM) та Humanitarian Data Exchange (HDX). Ці оцінки дозволили більш точно описати відстані до ключових об'єктів інфраструктури, таких як дороги, міста та соціальні об'єкти.

Це створило основу для більш комплексного аналізу доступності та розподілу інфраструктури у сільських районах, що є критично важливим для формування ефективних стратегій подальшого розвитку та відновлення.

Отримані результати кластеризації сільських громад показали, що запропонований підхід, що базується на поєднанні геопросторових даних та технік машинного навчання, є дієвим інструментом для визначення основних типів сільських громад за рівнем інфраструктурного розвитку. Це дозволило виявити ключові прогалини у розвитку інфраструктури та встановити пріоритетні напрями для подальших робіт.

Проведений кількісний та графічний аналіз продемонстрував узгодженість нових оцінок з початковими метриками, підтверджуючи надійність запропонованих методів.

Запропонований підхід до здійснення кластеризації, яка була застосована на реальних даних, показав можливість його використання для стратегічного планування розвитку сільських районів. Побудовані карти інфраструктурних зв'язків допомагають визначити області, які потребують першочергових інфраструктурних інвестицій, і сприяють кращому розумінню просторових нерівностей у доступності ключових послуг.

Подальші дослідження можуть бути спрямовані на подальше розширення набору даних для включення додаткових соціально-економічних показників, таких як рівень доходів та зайнятості, що дозволить отримати більш точну картину розвитку сільських громад. Важливо також інтегрувати дані в реальному часі для оперативного аналізу та моніторингу змін у інфраструктурі сільських територій.

ПЕРЕЛІК ПОСИЛАНЬ

1. Y. Liu та ін. «Geospatial characterization of rural settlements and potential targets for revitalization by geoinformation technology». Англ. В: Scientific Reports 12 (2022), с. 8399. url: <https://doi.org/10.1038/s41598-022-12294-2>.

2. Hanna Yailymova та ін. «Geospatial Analysis of Life Quality in Ukrainian Rural Areas». В: 2023 13th International Conference on Dependable Systems, Services and Technologies (DESSERT). 2023, с. 1—5. doi: 10.1109/DESSERT61349.2023.10416517.

3. A. Maryada та V. L. Thatiparthi. «Geospatial technology for mapping and analysis of social and infrastructural facilities at village level: a case study of Chinnapendyala village». Англ. В: Modeling Earth Systems and Environment 6 (2020), с. 1763—1781. url: <https://doi.org/10.1007/s40808-020-00788-9>.

4. B. Herfort та ін. «A spatio-temporal analysis investigating completeness and inequalities of global urban building data in OpenStreetMap». Англ. В: Nature Communications 14 (2023), с. 3985. url: <https://doi.org/10.1038/s41467-023-39698-6>.

5. Zijing Liu та Mauricio Barahona. «Graph-based data clustering via multiscale community detection». В: Applied Network Science 5.1 (2020), с. 3. issn: 2364-8228. doi: 10.1007/s41109-019-0248-7. url: <https://doi.org/10.1007/s41109-019-0248-7>.

6. Gadelha T. Filho Vinicius та ін. «Rural electrification planning based on graph theory and geospatial data: A realistic topology oriented approach». В: Sustainable Energy, Grids and Networks 28 (2021), с. 100525. issn: 2352-4677. doi: <https://doi.org/10.1016/j.segan.2021.100525>. url: <https://www.sciencedirect.com/science/article/pii/S2352467721000965>.

7. Akhbar Sha та ін. «Data-Driven Clustering and Insights for Rural Development in India». В: Procedia Computer Science 233 (2024). 5th International Conference on Innovative Data Communication Technologies and Application (ICIDCA 2024), с. 336—342. issn: 1877-0509. doi: 10.1016/j.procs.2024.03.223. url: <https://www.sciencedirect.com/science/article/pii/S1877050924005829>.

8. Kussul, N., Svirsh, V., Potuzhnyi, B. Integrated Geospatial Analysis for Rural Development Metrics. CEUR Workshop

ProceedingsVolume 3664, Pages 141 - 160. 2024. Machine Learning Workshop of the 8th International Conference on Computational Linguistics and Intelligent Systems, MLW-CoLIInS 2024. url: <http://ceur-ws.org/Vol-3664/paper11.pdf>.

9. Elevatorist. Elevators in Ukraine. <https://elevatorist.com/karta-elevatorov-ukrainy>. 2022.

10. Нова Пошта. Національний оператор експрес-доставки України. 2023. Режим доступу: <https://novaposhta.ua/>.

11. Укрпошта. Національний оператор поштового зв'язку України. 2023. Режим доступу: <https://www.ukrposhta.ua/>.

12. Mobua.net. Інформаційний портал мобільного зв'язку України. 2023. Режим доступу: <https://mobua.net/>.

13. James MacQueen. «Some Methods for Classification and Analysis of Multivariate Observations». В: Proceedings of the fifth Berkeley symposium on mathematical statistics and probability 1.14 (1967), с. 281—297.

14. Brian S Everitt. Cluster Analysis. Heinemann Educational Books, 1974.

15. Сайт кафедри ММАД НТУУ “КПІ”. Режим доступу: https://mmda.ipt.kpi.ua/portal/MON/Products.html?group=rural_development&infra=rdi-interactive.

16. Куссуль Н. Н. Grid-системи для задач дослідження Землі. Архітектура, моделі і технології / Н. Н. Куссуль, А. Ю. Шелестов. — К. : Наукова думка, 2008. — 452 с.

17. Kussul, N. , Potuzhnyi, B., Svirsh, V. Clustering Techniques for Modeling Village Infrastructure Development. CEUR Workshop Proceedings, 2024, 3668, pp. 98–119.

18. Ghazaryan, G., Dubovyk, O., Graw, V., Kussul, N., & Schellberg, J. (2020). Local-scale agricultural drought monitoring with satellite-based multi-sensor time-series. GIScience & Remote Sensing, 57(5), 704-718.

19. Kussul, N., Shelestov, A., Skakun, S., & Kravchenko, O. (2008). Data assimilation technique for flood monitoring and prediction. International Journal Information Theories & Applications, 15, 76-83.

3.2. Моделювання розвитку інфраструктури сіл на основі графових даних

20. Skakun, S., Justice, C. O., Kussul, N., Shelestov, A., & Lavreniuk, M. (2019). Satellite data reveal cropland losses in South-Eastern Ukraine under military conflict. *Frontiers in Earth Science*, 7, 305.

21. Kussul, N., Drozd, S., Yailymova, H., Shelestov, A., Lemoine, G., & Deininger, K. (2023). Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103562.

22. S. Skakun et al., "High-Impact Hot Spots of Land Cover Land Use Change in Ukraine" 2022 12th International Conference on Dependable Systems, Services and Technologies (DESSERT), Athens, Greece, 2022, pp. 1-5, doi: 10.1109/DESSERT58054.2022.10018657.

3. АНАЛІЗ ІНДИКАТОРІВ ЕКОНОМІЧНОЇ ДІЯЛЬНОСТІ НА ОСНОВІ РІЗНОРІДНИХ ДАНИХ

Наталія Куссульт, професор¹

Андрій Шелестов, професор¹

Богдан Яйлимов, завідувач відділу²

Ганна Яйлимова, доцент¹

Андрій Колотій, старший викладач¹, старший науковий
співробітник²

Олександр Пархомчук, асистент¹

¹ Кафедра математичного моделювання та аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України "Київський
політехнічний інститут імені Ігоря Сікорського"

² Відділ космічних інформаційних технологій і систем
Інститут космічних досліджень НАН України та ДКА
України

nataliia.kussul@lll.kpi.ua, andrii.shelestov@gmail.com,
yailymov@gmail.com, annayailymova@gmail.com,
andrew.k.911@gmail.com, omparkhomchuk@gmail.com

ВСТУП

У сучасних умовах стрімкого розвитку технологій та глобальних викликів економічна діяльність набуває нового значення, вимагаючи від науковців і практиків більш глибокого та різностороннього аналізу. Економіка вже не обмежується класичними підходами до оцінки показників і потребує інтеграції нових джерел даних, що дозволяють побудувати більш об'єктивні та комплексні моделі розвитку, які можуть оперативного відображати зміни економічних процесів. Особливої актуальності цей підхід набуває в умовах кризових ситуацій, зокрема, у контексті військових дій, які кардинально впливають на різні сектори економіки, змінюючи структури регіональних економік, динаміку виробничих процесів і доступність трудових ресурсів.

В цьому розділі розглядаються приклади аналізу непрямих індикаторів економічної діяльності (нічне освітлення, показники якості повітря та рівні використання земель сільськогосподарського призначення, отримані за допомогою супутникових даних), які використовують новітні методи збору та

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

обробки даних. Серед них ключову роль відіграють супутникові дані, оскільки їх використання дає змогу в умовах недостатності традиційних статистичних даних робити висновки про динаміку економічної активності на регіональному рівні. Особливо важливим є застосування цих технологій для моніторингу сільськогосподарських угідь та визначення збитків, спричинених військовими діями.

Зокрема, супутникові дані допомагають виявляти найбільш постраждалі регіони, що дозволяє уряду і міжнародним організаціям приймати обґрунтовані рішення щодо підтримки аграрного сектору. Іншим важливим напрямом є кореляція між рівнем нічного освітлення та економічною активністю, що дозволяє оцінити вплив воєнних дій на міські агломерації та економічну інфраструктуру країни. Тому дослідження на основі непрямих індикаторів є не лише актуальними, а й надзвичайно важливими для прогнозування відновлення та розвитку економіки України в умовах сучасних викликів.

В цьому розділі міститься огляд напрямків аналізу взаємозв'язків між непрямыми індикаторами економічної активності та економічними показниками регіонів у вигляді конкретних прикладних задач. Використовуючи супутникові дані високого просторового розрізнення та новітні методи геопросторового аналізу, запропоновано комплексний підхід до моніторингу економічної активності та відстеження динаміки змін в умовах кризи.

3.1. ВИЯВЛЕННЯ ОЗНАК ЕКОНОМІЧНОЇ ДІЯЛЬНОСТІ В РЕГІОНАХ ЗА ДАНИМИ РІЗНОЇ ПРИРОДИ

3.1.1. ОЦІНКА ДИНАМІКИ ЕКОНОМІЧНОЇ ДІЯЛЬНОСТІ ЗА ЯКІСТЮ ПОВІТРЯ

Дані про якість повітря надають важливу інформацію про вплив промисловості та інших економічних факторів на навколишнє середовище та здоров'я населення.

Сервіс моніторингу атмосфери програми Copernicus (CAMS) [1] розроблений для обміну даними та обробки інформації про поверхню Землі, аерозолі, озон та інші хімічно активні гази з метою підтримки процесів прийняття рішень, підприємств та громадян розширеною інформацією про стан атмосфери. Зокрема, цей сервіс надає щоденні погодинні дані про $PM_{2.5}$ та PM_{10} у вигляді близького до реального часу аналізу для Європи та України

з просторовим розрізненням 11 км. У цьому підрозділі досліджується взаємозв'язок між якістю повітря та рівнем економічної активності в функціональних міських зонах (ФМЗ) та областях України за 2019-2022 рр. [2, 3]. Як основу для отримання ФМЗ для найбільших міст України було обрано методіку Європейської комісії [4], [5]. ФМЗ для України визначено у чотири етапи, що детально описано в [6].

В результаті проведеного аналізу, для основних ФМЗ рівні середнього акумульованого за рік показнику $PM_{2.5}$ для 2018-2021 рр. на 18-28% вищі порівняно зі значеннями для 2022 року (рис. 1). Основний спад припав на регіони України, які постраждали від вторгнення Росії [7].

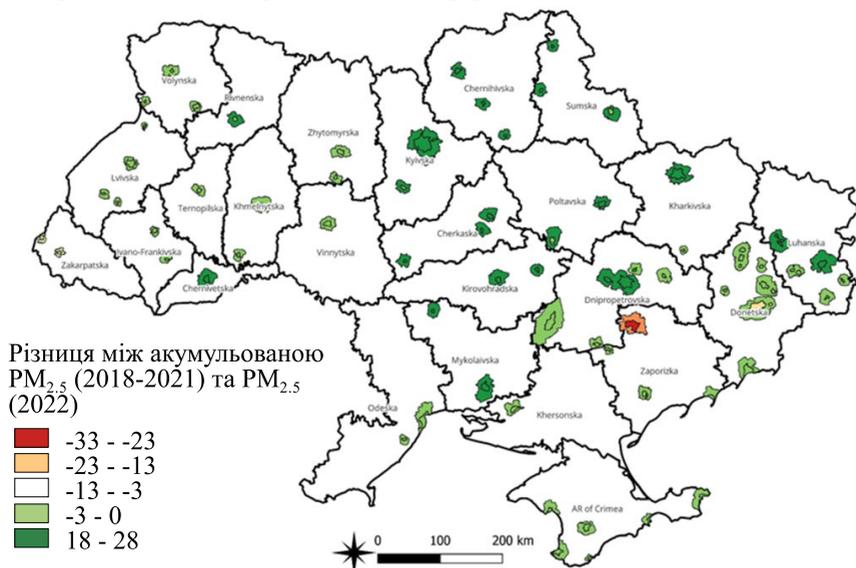


Рис. 1. Порівняння рівнів $PM_{2.5}$ для основних ФМЗ за 2018-2021 рр. проти 2022 р.

Станом на 1 лютого 2022 р. загальна кількість громадян України за переписом [8] становила близько 41 мільйон осіб. Після початку війни близько 8 мільйонів українців зареєстровано у Європейському Союзі та близько 3 мільйонів мігрували до Білорусі та Росії [9]. Кумулятивні значення РМ для ФМЗ показують досить близьке відсоткове зниження в порівнянні з динамікою чисельності населення (тобто існує кореляція між

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

кумулятивними значеннями РМ та населенням великих міст). З отриманих результатів можна припустити, що кумулятивні річні концентрації твердих частинок над ФМЗ можуть бути використані як приблизний показник для оцінки міграційних процесів [10].

Таблиця 1 Структура валової доданої вартості в Україні у 2020 р.

Вид економічної діяльності	Обсяг ВВП, млн грн	Частка
Оптова та роздрібна торгівля, ремонт автотранспортних засобів і мотоциклів	585 344	13.96 %
Переробна промисловість	425 067	10.13 %
Сільське господарство, лісове господарство та рибне господарство	388 726	9.27 %
Державне управління й оборона, обов'язкове соціальне страхування	303 059	7.23 %
Операції з нерухомим майном	267 661	6.38 %
Транспорт, складське господарство, поштова та кур'єрська діяльність	262 408	6.26 %
Інформація та телекомунікації	208 427	4.97 %
Добувна промисловість і розроблення кар'єрів	190 343	4,54 %
Освіта	180 980	4.32 %
Професійна, наукова та технічна діяльність	136 832	3.26 %

Ліси відіграють важливу роль у зниженні рівня дрібнодисперсних твердих часток РМ (particulate matter), зокрема РМ_{2.5} і РМ₁₀, у повітрі [11]. Зокрема лісові насадження забезпечують фільтрацію та поглинання часток РМ (листя дерев діє як природний фільтр для часток РМ, оскільки тверді частки осідають на поверхні листя і поглинаються або утримуються рослинами), крім цього крони дерев знижують концентрацію пилу та інших аерозолів у повітрі, сповільнюючи їхній рух.

Інтенсифікація вирубок [12] має негативний вплив на рівні якості повітря. Так, аналізуючи взаємозв'язок валового річного продукту (ВРП) по областях України з річним прибутком у сфері діяльності лісівництва (згідно даних з служби державної статистики України https://www.ukrstat.gov.ua/operativ/operativ2021/fin/pdsg/orpsg_ved_15-20.xlsx), можна спостерігати позитивну кореляцію (рис. 2 – помаранчевий стовпець). Дані наведено не для всіх областей, оскільки для деяких з них статистична інформація є конфіденційною та не надається державною службою статистики. У свою чергу взаємозв'язок річного прибутку у сфері діяльності лісівництва з якістю повітря є негативним (тобто при збільшенні прибутку від лісівництва показник $PM_{2.5}$ зменшується або якість повітря покращується (рис. 2, зелений стовпець)).

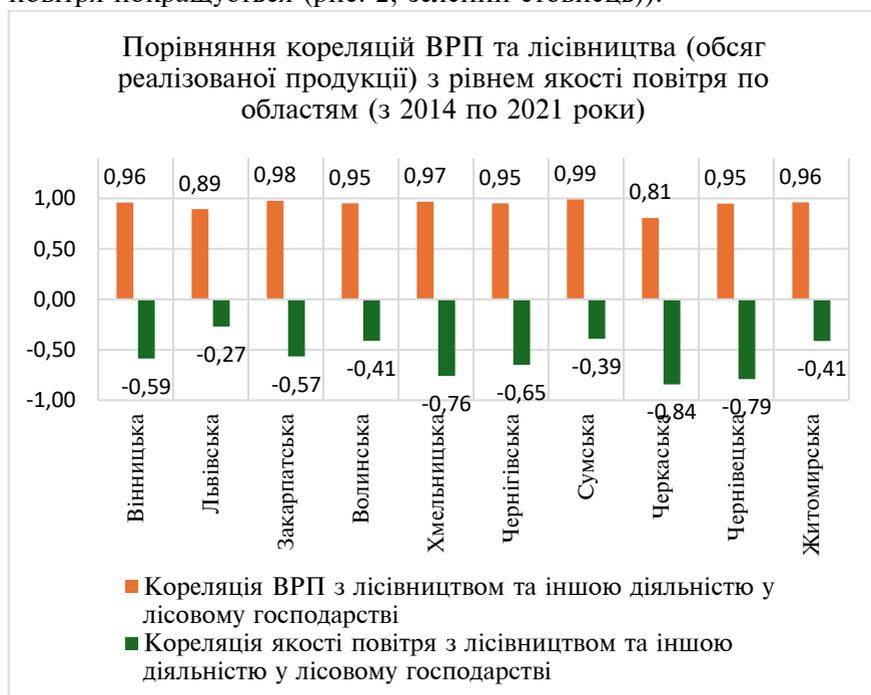


Рис. 2. Порівняння кореляцій ВРП та лісівництва (обсяг реалізованої продукції) з рівнем якості повітря по областям (з 2014 по 2021 роки)

Отриманий результат має логічне пояснення, оскільки діяльність та прибуток лісівництва залежить від загальної площі

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

лісових господарств в області. А ліси в свою чергу покращують якість повітря. Тому кумулятивні річні концентрації твердих частинок по областям (чи в інших адміністративних розрізах) можуть бути використані як приблизний показник економічної діяльності (зокрема і лісової).

3.1.2. ОЦІНКА ДИНАМІКИ ЕКОНОМІЧНОЇ ДІЯЛЬНОСТІ ЗА НІЧНИМ ОСВІТЛЕННЯМ

Випромінювання нічного світла у видимому діапазоні дає унікальну можливість безпосередньо спостерігати за діяльністю людини з космосу. Ці дані можна використовувати в різноманітних задачах, включаючи картографування міських територій, оцінку населення та ВВП, моніторинг катастроф і конфліктів. Зовсім недавно супутникові дані нічних вогнів знайшли застосування для розуміння впливу випромінювання світла на навколишнє середовище (світлового забруднення), включно з їх впливом на здоров'я людини [13].

В запропонованому підході використовується продукт VIIRS Stray Light Corrected Nighttime Day/Night Band Composites, наявний у хмарній платформі Google Earth Engine [14]. Цей набір даних надає інформацію про нічну освітленість поверхні Землі, отриману за допомогою супутникового зондування інструментом Visible Infrared Imaging Radiometer Suite (VIIRS) National Oceanic and Atmospheric Administration (NOAA). Значення вимірюються в нановатах на стерадіан на квадратний сантиметр (nanoWatts/sr/cm^2), де нановат — це одиниця вимірювання потужності, яка дорівнює одній мільярдній частині вату, а стерадіан — це одиниця вимірювання просторового кута, що відповідає площі сферичної поверхні, на яку вона проєктується. Цей продукт може бути корисним для виявлення ознак економічної діяльності з різних причин. Зокрема, чим більшою є нічна освітленість у певному регіоні, тим ймовірніше, що там розташовані великі міста або промислові об'єкти. Це може служити показником рівня розвитку та економічної активності в цьому районі. За допомогою цих даних можна виявити промислові області та комплекси, які відрізняються високим рівнем нічної освітленості, що може бути ознакою великих виробничих потужностей. Аналізуючи зміни в нічній освітленості протягом часу, можна виявити тенденції розвитку економічних зон та торговельних шляхів. Спостереження за нічним освітленням також

може допомогти виявити зміни в економічній активності під час природних катастроф, гуманітарних криз, епідемій чи війни.

Нижче (рис. 3 - 5) наведені усереднені значення показників нічного освітлення для території України за 2013, 2021 та 2022 роки.

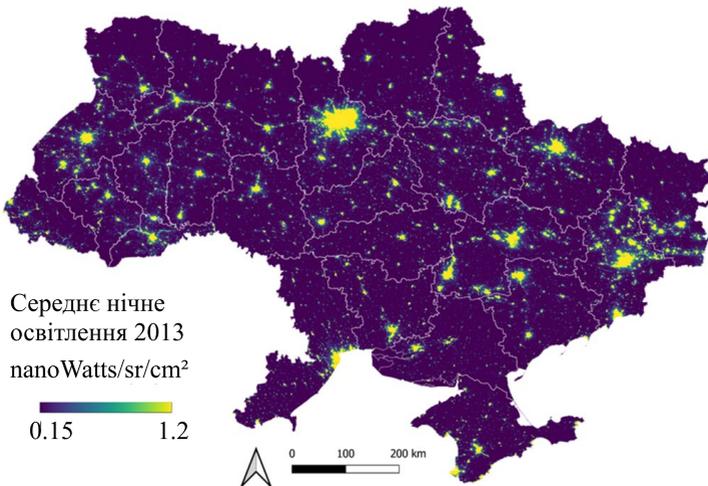


Рис. 3. Річні усереднені значення нічного освітлення у 2013 році

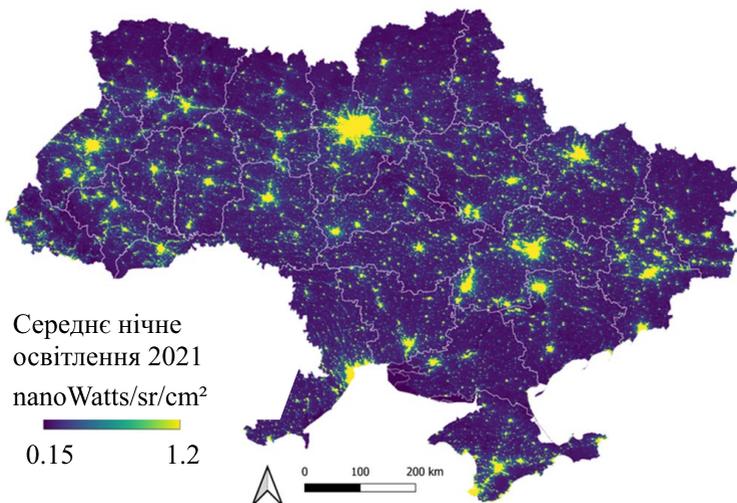


Рис. 4. Річні усереднені значення нічного освітлення у 2021 році

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

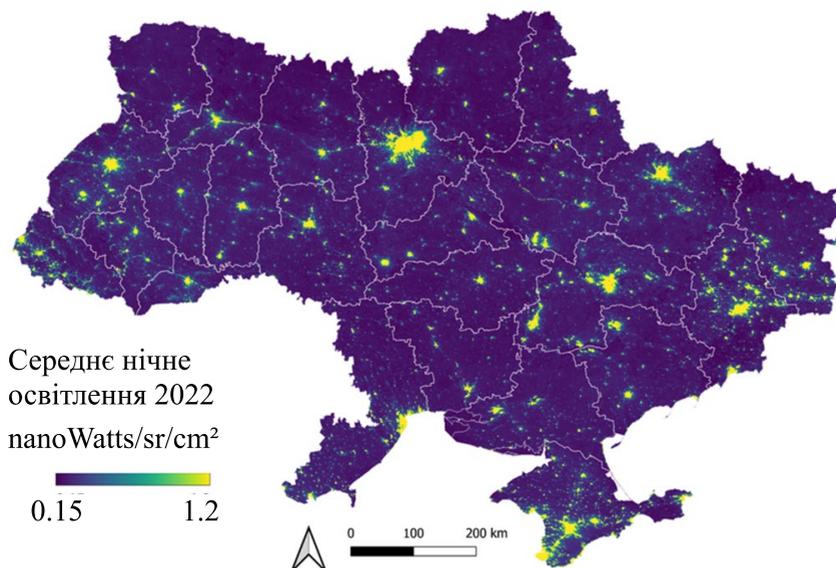


Рис. 5. Усереднені значення нічного освітлення у 2022 році

Із рис. 3 - 5 бачимо, що освітленість всіх регіонів України збільшилась за період від 2013 до 2021 року, що свідчить про підвищення економічної активності. Водночас в 2022 році спостерігається явне зниження економічної активності по всій території країни.

На рис. 6 представлено зміну освітлення в функціональних міських зонах України до повномасштабного вторгнення і після початку великої війни [10]. На діаграмі зліва порівняно рівень освітлення функціональних міських зонах України у 2013 р. та 2021 р. З наведеної діаграми бачимо, що практично в усіх функціональних міських зонах рівень освітлення в 2021 р. значно перевищує аналогічні показники 2013 р. На діаграмі справа порівняно рівень освітленості у функціональних міських зонах у 2021 та 2022 роках. Тут явно прослідковується зменшення освітленості практично в усіх міських функціональних зонах. Особливо відчутна різниця спостерігається в південних та східних областях України, що пояснюється впливом військових дій.

Як бачимо із рис. 7 в період з 2013 по 2021 р. економічна активність зростала на всій території України за винятком тимчасово окупованих частин Луганської та Донецької областей.

На основній території України спостерігається збільшення нічного освітлення на 20–100 відсотків, що свідчить про зростання економічної активності в цей період.

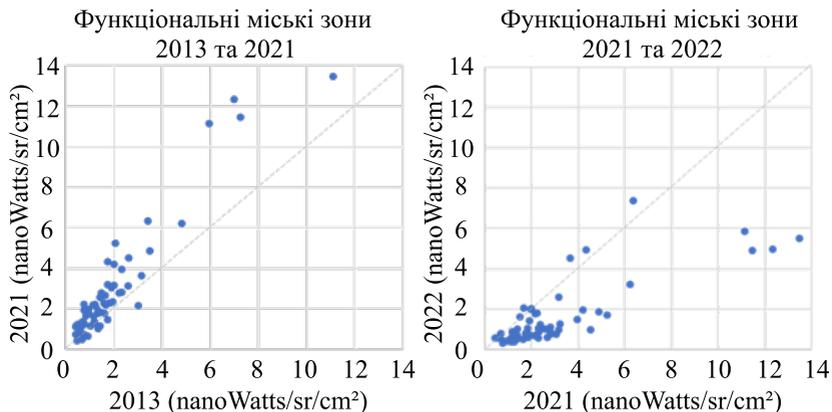


Рис. 6. Зміна освітлення в функціональних міських зонах України (2013 та 2021; 2021 та 2022)

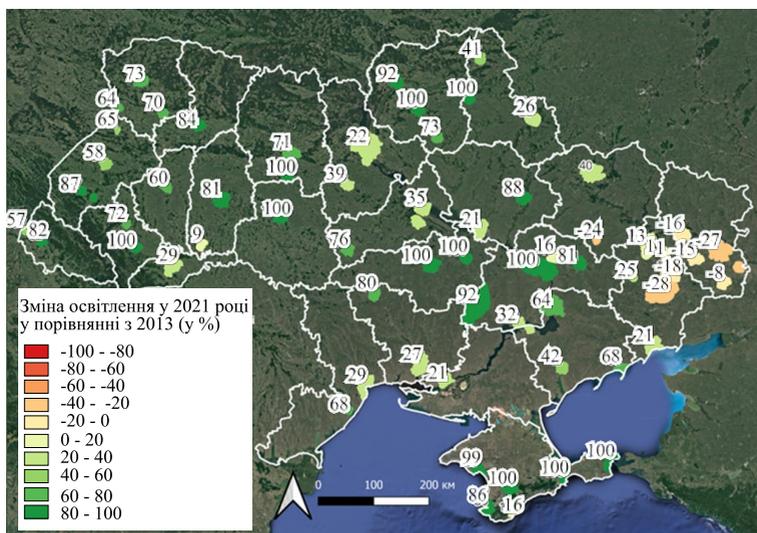


Рис. 7. Зміна освітленості у функціональних міських зонах у 2021 році у порівнянні з 2013 роком у відсотках

На тимчасово окупованих територіях спостерігається зменшення нічного освітлення функціональних міських зонах до

Для прикладу візьмемо переробну промисловість, що становить 10,13 % частини ВВП, та визначимо на скільки від неї залежить ВВП, а також для яких областей України ця залежність є вищою, а для яких нижчою. Для цього обрано валовий регіональний продукт (ВРП) з державної статистики України [17], а також статистичні показники переробної промисловості (за кількістю підприємств в регіонах [18] та за обсягом переробної продукції [19]).

Для обраних показників пораховано кореляцію Пірсона для 2014–2021 р. для кожної області окремо. Отриманий результат наведено у помаранчевому стовпчику на рис. 9 (за кількістю підприємств в регіонах). Цифри над стовпчиковою діаграмою відповідають кількості підприємств в регіонах. Як бачимо з рис. 9, майже всі області мають високу кореляцію ВРП з переробною промисловістю за кількістю підприємств в регіонах, окрім Івано-Франківської, Тернопільської, а для Донецької та Луганської областей спостерігається від’ємна залежність.

Така сама кореляція була обчислена і між показником освітленості в областях та кількістю підприємств переробної промисловості (рис. 9 зелений стовпець). Як бачимо з отриманої діаграми, майже в усіх областях рівень двох обчислених кореляцій майже однаковий.

Аналогічні показники кореляцій були отримані і для обсягу переробної продукції та представлені на рис. 9. Як бачимо з наведеного рисунку, для Луганської та Донецької області зникли від’ємні кореляції, що ймовірно свідчить про наявність підприємств, які не працюють з певних причин.

Отже, порівнявши динаміку рівня освітлення по областям України з 2013 по 2022 роки (табл. 2) з переробною промисловістю, і, в свою чергу, переробну промисловість з ВРП, можна зробити висновок, що ВРП опосередковано залежить від середньорічного рівня освітленості (рис. 10).

Таким чином можна зробити висновок, що використання світлового випромінювання може виступати індикатором економічної діяльності. Зокрема, на рис. 11 наведено приклад залежності ВРП від рівня освітленості для Дніпропетровської області, що демонструє можливість будувати моделі для прогнозування річного ВРП та ВВП на рівні областей та цілої країни.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

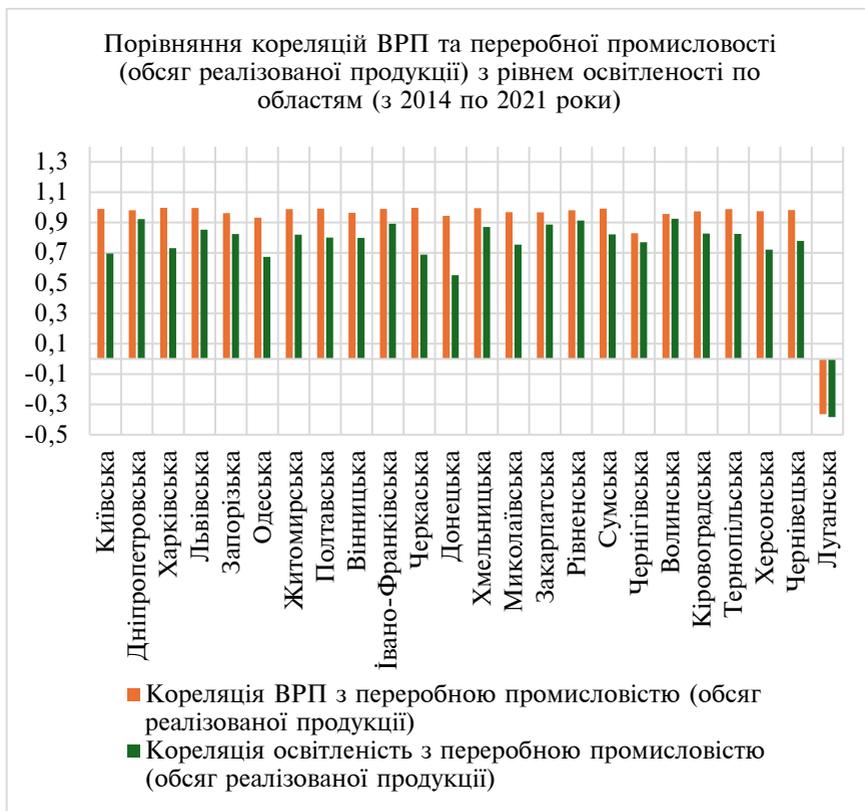


Рис. 9. Порівняння кореляцій ВРП та переробної промисловості (обсяг реалізованої продукції) з рівнем освітленості по областях (з 2014 по 2021 роки)

Таблиця 2 Зміна середньорічного показнику освітленості в розрізі областей

Освітленість (області)	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
Черкаська	0,33	0,40	0,35	0,45	0,55	0,56	0,58	0,41	0,63	0,38
Чернігівська	0,16	0,16	0,15	0,13	0,26	0,23	0,27	0,21	0,31	0,24
Чернівецька	0,37	0,35	0,21	0,30	0,36	0,44	0,43	0,37	0,53	0,32
Дніпропетровська	0,41	0,51	0,38	0,47	0,66	0,67	0,68	0,61	0,83	0,41
Донецька	0,64	0,60	0,32	0,47	0,62	0,59	0,60	0,52	0,62	0,47

Частина 3. Прикладні задачі супутникового інтелекту на ...

Івано-Франківська	0,27	0,27	0,19	0,23	0,32	0,33	0,36	0,32	0,51	0,33
Харківська	0,34	0,38	0,33	0,36	0,47	0,48	0,43	0,37	0,53	0,35
Херсонська	0,19	0,20	0,14	0,14	0,30	0,24	0,30	0,29	0,33	0,31
Хмельницька	0,24	0,25	0,17	0,19	0,29	0,29	0,31	0,29	0,43	0,30
Кіровоградська	0,18	0,21	0,17	0,19	0,31	0,31	0,30	0,26	0,40	0,27
Київська	1,12	1,00	0,89	1,02	1,15	1,15	1,24	0,89	1,46	0,69
Луганська	0,31	0,29	0,17	0,21	0,35	0,31	0,32	0,27	0,34	0,36
Львівська	0,44	0,43	0,32	0,43	0,54	0,57	0,64	0,49	0,84	0,48
Миколаївська	0,23	0,27	0,19	0,21	0,36	0,32	0,37	0,32	0,42	0,27
Одеська	0,32	0,36	0,28	0,29	0,45	0,42	0,46	0,43	0,51	0,37
Полтавська	0,35	0,35	0,30	0,36	0,46	0,42	0,45	0,35	0,53	0,32
Рівненська	0,22	0,20	0,16	0,16	0,27	0,27	0,30	0,25	0,39	0,29
Сумська	0,24	0,23	0,22	0,22	0,33	0,33	0,33	0,27	0,39	0,27
Тернопільська	0,31	0,26	0,16	0,19	0,28	0,28	0,31	0,28	0,42	0,29
Вінницька	0,21	0,24	0,17	0,21	0,31	0,30	0,33	0,27	0,43	0,30
Волинська	0,20	0,17	0,15	0,14	0,25	0,24	0,27	0,23	0,36	0,28
Закарпатська	0,25	0,24	0,19	0,24	0,35	0,32	0,37	0,33	0,45	0,41
Запорізька	0,27	0,30	0,22	0,24	0,38	0,34	0,39	0,35	0,44	0,32
Житомирська	0,20	0,20	0,16	0,17	0,29	0,28	0,30	0,22	0,40	0,26

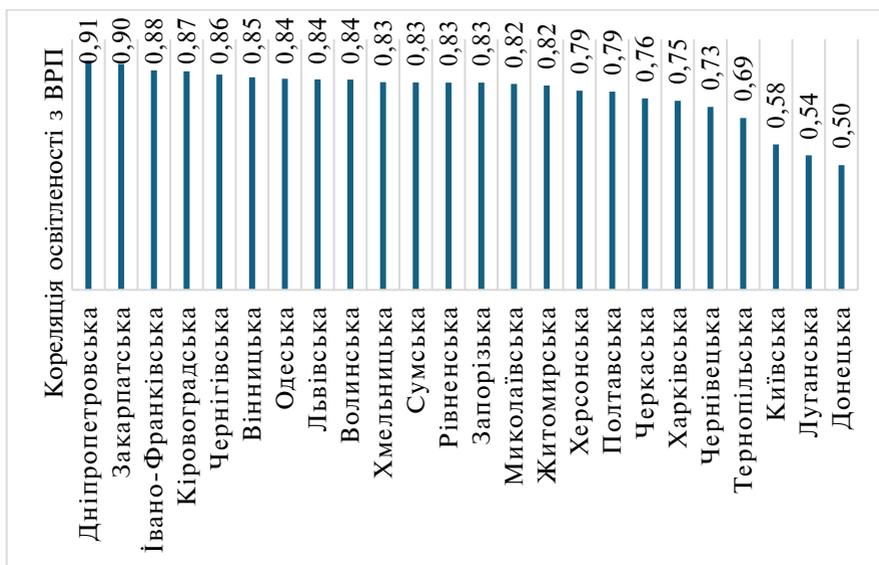


Рис. 10. Кореляція ВРП та рівня освітленості по областям України

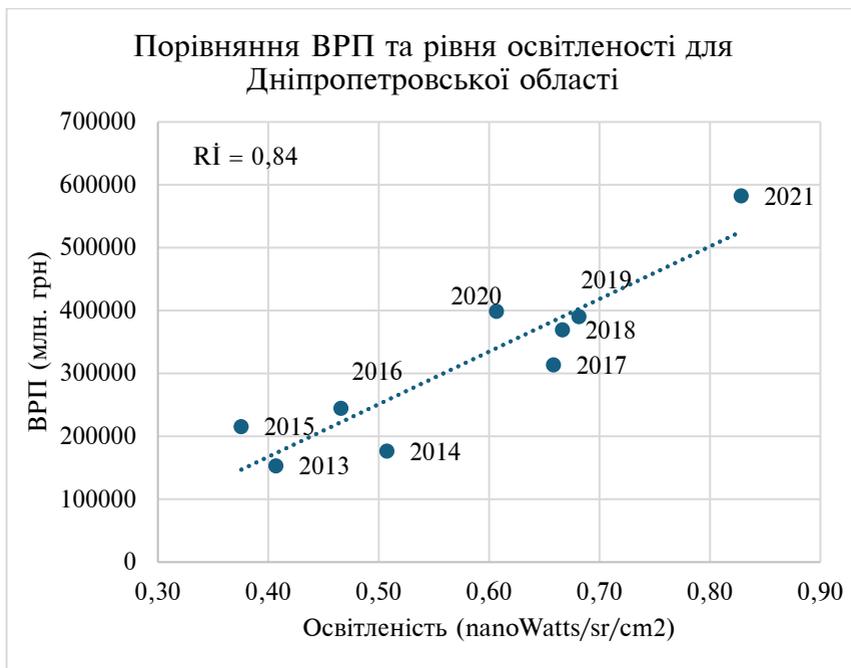


Рис. 11. Порівняння ВРП та рівня освітленості для Дніпропетровської області за 2014 – 2021

Аналогічний експеримент проведено з добувної промисловістю (рис. 12), що становить 4,54 % від ВВП України. Із рис. 12 бачимо, що в усіх областях України, де розвинена добувна промисловість, спостерігається сильна кореляція з ВРП області та рівнем освітленості. Від’ємну кореляцію спостерігаємо лише в тих областях, де видобувної промисловості практично немає.

3.1.3. МОНІТОРИНГ ЕКОНОМІЧНОЇ ДІЯЛЬНОСТІ З ВИКОРИСТАННЯМ РІЗНОМІРНИХ ГЕОПРОСТОРОВИХ ДАНИХ ТА СУПУТНИКОВИХ ДАНИХ ПІДВИЩЕНОГО РОЗРІЗНЕННЯ В УМОВАХ ВІЙНИ

В 2022 р. економіка України зазнала значного впливу повномасштабного вторгнення Росії, розпочато 24 лютого 2022 р. Проте, незважаючи на воєнні дії на частині території країни, основні галузі економіки продовжують функціонувати.

Вагомим сегментом економіки залишається аграрний сектор, оскільки вирощування зернових, технічних культур [20] та виробництво м'ясо-молочної продукції триває навіть в умовах війни. В цьому підрозділі наведено аналіз деяких індикаторів розвитку агросектору в умовах війни.

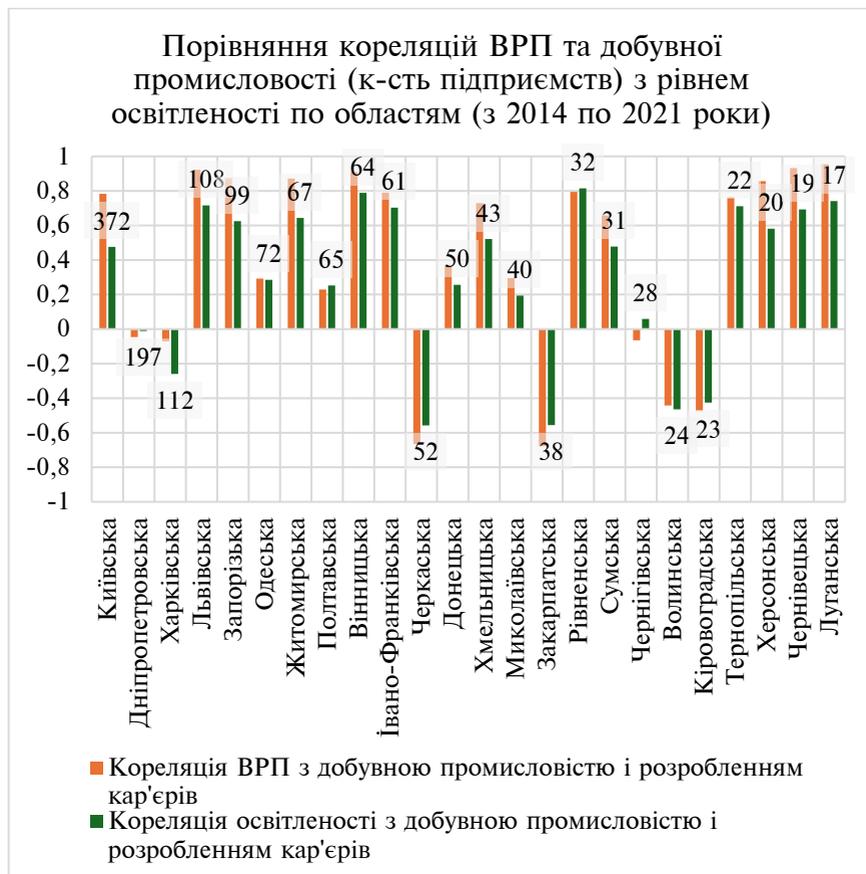


Рис. 12. Порівняння кореляцій ВРП та добувної промисловості (кількість підприємств) з рівнем освітленості по областях (з 2014 по 2021 р.)

В умовах війни зростає роль моніторингу економічної діяльності та аграрного сектору за допомогою непрямих ознак з використанням геопросторових та супутникових даних. Через активні бойові дії на частині території України та загальноу

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

дезорганізацію роботи установ традиційні методи збору та аналізу статистичних даних є ускладненими. В таких умовах вкрай необхідним є використання альтернативних джерел інформації, зокрема супутникових даних.

Завдяки супутниковим знімкам Sentinel можна отримати цінні непрямі індикатори стану аграрного виробництва – площі посівів, стан рослинності тощо. Інтеграція цих даних з іншою геопросторовою інформацією дозволяє оперативно оцінювати вплив війни на сільське господарство регіонів та аграрний сектор в цілому [21]. Супутниковий моніторинг дозволяє забезпечити своєчасне та точне відстеження змін в економічних паттернах, особливо в умовах, коли традиційні методи можуть бути обмежені через недоступність територій чи військові дії [22, 23]. Це допомагає уряду та міжнародним організаціям виявляти і відстежувати тенденції економічного розвитку, оцінювати вплив природних чи антропогенних подій на аграрний сектор та оперативно реагувати на надзвичайні ситуації. Інтеграція таких даних дозволяє підвищити прозорість та забезпечити більш ефективне планування та використання ресурсів [24].

В даному підрозділі проаналізовано вплив війни в Україні, розпочатої Росією у лютому 2022 р., на сільськогосподарське виробництво в Україні. Основні результати моніторингу економічної діяльності в аграрному секторі за супутниковими даними описано в праці [25]. Використовуючи дані за 2019-2022 р. по 10 125 сільських радах України, оцінено вплив війни на площі та очікувані врожаї озимих культур (пшениця, ячмінь, жито і ріпак) на рівні окремих полів та агреговано результати на рівні сільрад. Для виявлення пошкоджень полів внаслідок бойових дій використано супутникові знімки Sentinel-2 та Planet, класифікація типів сільськогосподарських культур здійснюється за допомогою методів машинного навчання [26, 27, 28, 29] у хмарних платформах [30, 31], а в якості предиктора врожайності використовується вегетаційний індекс NDVI [32].

За отриманими оцінками площа полів, що зазнали прямих пошкоджень внаслідок бойових дій в 2022-2023 рр., становить близько 1,5 млн га. Зменшення площі посівів в 2022 р. становить близько 10% від посівних площ 2021 р., а в 2023 – близько 15% чи 4.5 млн га (рис. 13).

Частина 3. Прикладні задачі супутникового інтелекту на ...

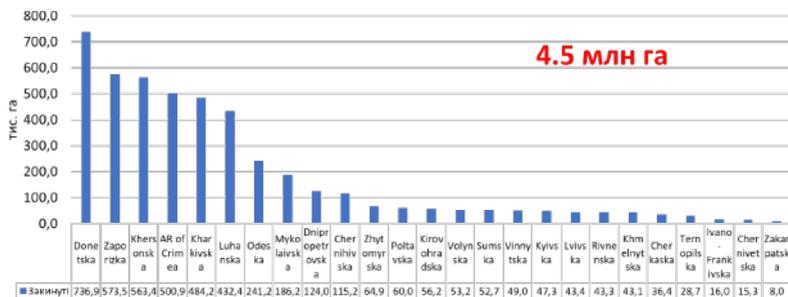


Рис. 13. Площі закинутих сільськогосподарських земель у 2023 р. (в порівнянні з 2021 р.)

Зменшення площі посівів призводить до зменшення обсягів виробництва сільськогосподарської продукції. Це може вплинути на доступність продуктів харчування на внутрішньому ринку, призводячи до зростання цін та зменшення конкурентоспроможності сільськогосподарських виробників. Сільськогосподарські підприємства, які втратили свої поля через бойові дії, можуть зазнати серйозних фінансових втрат. Вони можуть стикатися із зниженням доходів, збитками віднесеними до знищених посівів і взагалі зменшенням економічної стійкості.

Використання супутникових даних для картографування земного покриття та моніторингу сільськогосподарських посівів може значно полегшити вивчення економічної ситуації країни в умовах воєнного конфлікту, а також сприяти розробці ефективних стратегій для відновлення та розвитку сільського господарства [33].

Окрім супутникових даних важливим елементом є дані наземних досліджень, які використовуються для навчання та валідації моделі. З врахуванням обставин в Україні варто зазначити, що маршрути збору наземних даних поступово скорочуються та охоплюють менші території країни. Наприклад, якщо у 2021 р. довжина маршруту становила приблизно 6500 км, то у 2023 р. ця величина скоротилась до близько 4018 км (рис. 14).

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних



Рис. 14. Маршрути збору наземних даних у 2021 та 2023 р.

Таким чином, набуває важливості постійне вдосконалення методів та моделей для їх навчання та успішного застосування на різних територіях при умові обмеженості навчальних даних.

У 2023 р. карта класифікації земного покриття забезпечує можливість відстеження не лише земель сільськогосподарського призначення, але й територій, які стали закинутими і перестали

оброблятися на сході та півдні України (рис. 15), що у свою чергу має вплив на економічну діяльність країни.

Зазвичай для валідації карт класифікації посівів культур використовуються дані офіційної статистики. Проте в сучасних умовах, у деяких областях такі дані відсутні. Тому супутникові дані стають єдиним можливим джерелом для оцінки посівних площ в умовах відсутності повноцінної статистики (рис. 16).

В ситуаціях, коли офіційна статистика виявляється недостатньою або відсутньою, супутникові дані стають невід'ємним інструментом для оцінки та моніторингу площ, що має важливе значення для економічної діяльності.

Створені карти озимих зернових для сільських рад на основі вегетаційних індексів вказують на найбільші концентрації озимих зернових на півдні та сході країни, а також на зменшення їхніх площ у 2022 році та, в певній мірі, у 2020 році, порівняно із 2021 та 2019 рр. (рис. 17).

Оцінений на основі даних NDVI спад врожаю пшениці в 2022 р. становить 1,9 млн. тон. В цілому втрати виробництва озимої пшениці через прямі та непрямі наслідки війни в 2022 р. становлять до 4,84 млн тон або 17% потенційного врожаю [25].

На рис. 18 проілюстрований розподіл агрегованих в межах сільських громад значень NDVI для різних періодів років. Для всіх років, крім 2021, пікові значення NDVI досягаються в перші 10 днів червня (синій: 1 - 11 травня ; червоний: 12-21 травня; зелений: травень 22 - 31; помаранчевий: 1 - 11 червня). Щоб порівняти NDVI за роками на різних стадіях росту, на рис. 19 представлені NDVI на полях з озимими зерновими 11 травня, 21 травня, 31 травня та 11 червня, що дозволяє зробити аналогічний висновок.

Отримані результати демонструють, що NDVI у 2022 році був нижчим, ніж у попередні роки (синій - 2019; червоний - 2020; зелений - 2021; помаранчевий - 2022).

Найбільше постраждали дрібні фермерські господарства. Для цього були виділені субсидії для фермерів. Із використанням побудованих карт та меж полігонів із кадастру можна визначити, чи були оброблені фермерські землі (рис. 20). Таким чином можна контролювати ефективність використання виділених коштів на субсидіювання.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

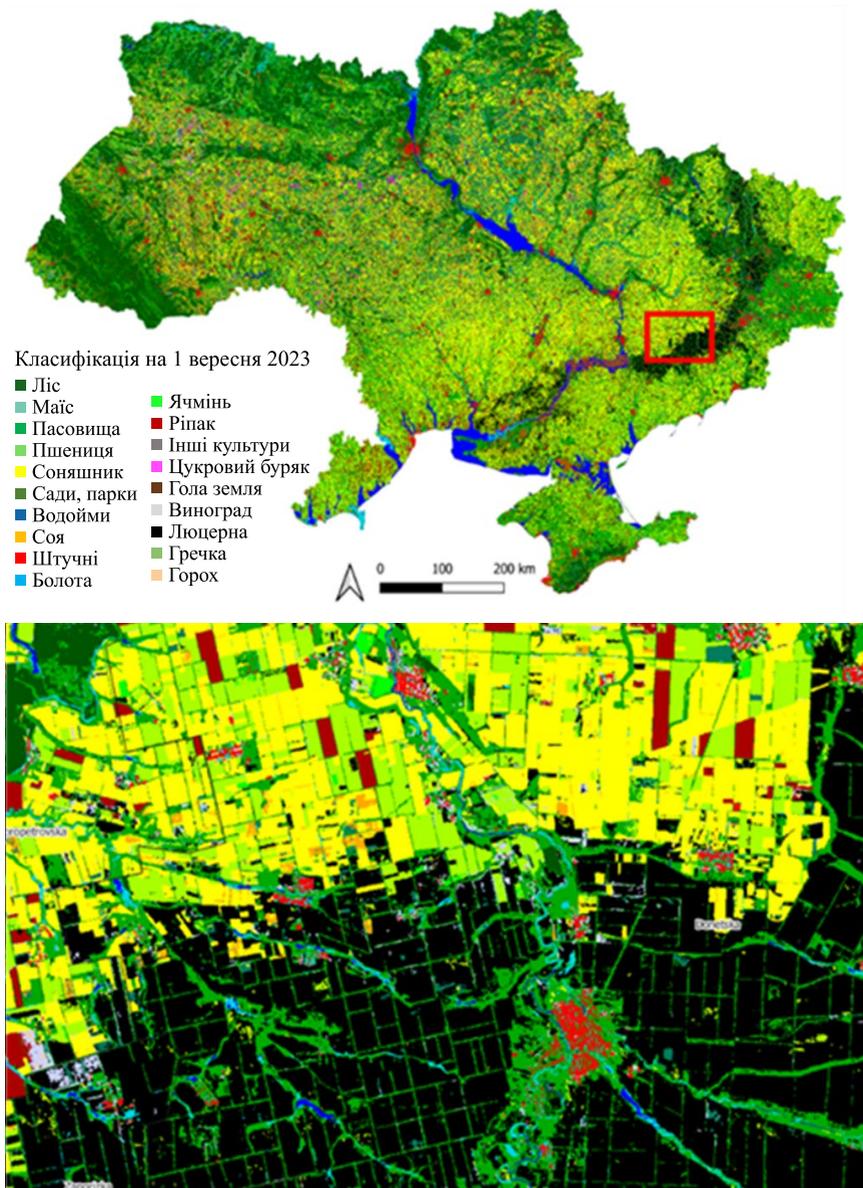


Рис. 15. Карта класифікації земного покриття для території України в 2023 р.

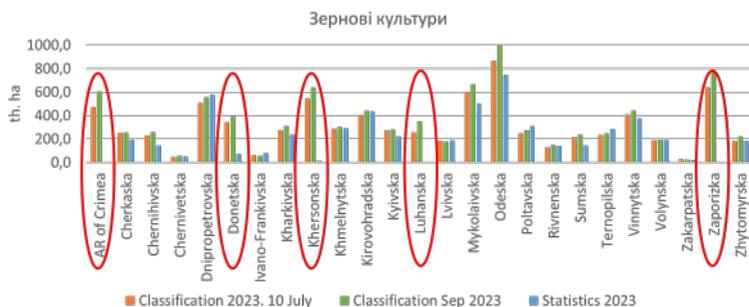


Рис. 16. Оцінка посівних площ за супутниковими даними в умовах відсутності повноцінної статистики (2023)

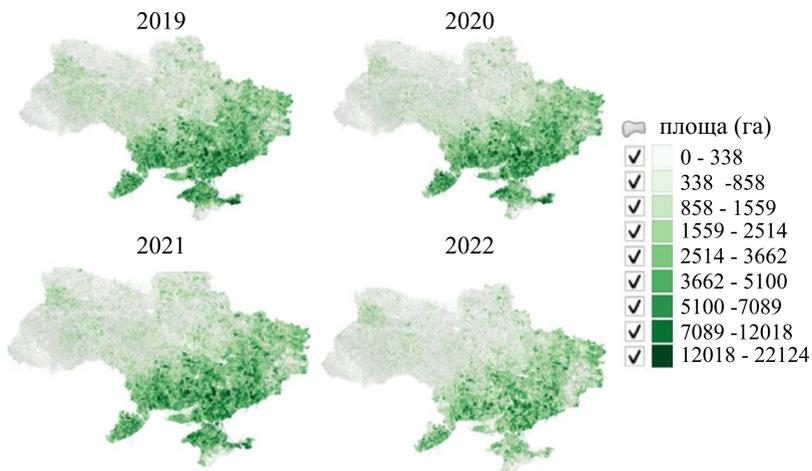


Рис. 17. Карта озимих культур за вегетаційні періоди 2019–2022 рр.

Отже, використання супутникових даних дозволило кількісно оцінити вплив війни на сільське господарство України. Це важливо для прийняття обґрунтованих рішень з підтримки аграрного сектору та забезпечення продовольчої безпеки, оскільки супутникова інформація часто є єдиним достовірним джерелом даних про пошкоджені землі сільськогосподарського призначення (рис. 21) і про площі окупованих сільськогосподарських земель.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

Площа окупованих сільськогосподарських земель у 2022 р. становила 5.7 млн га (табл. 3).

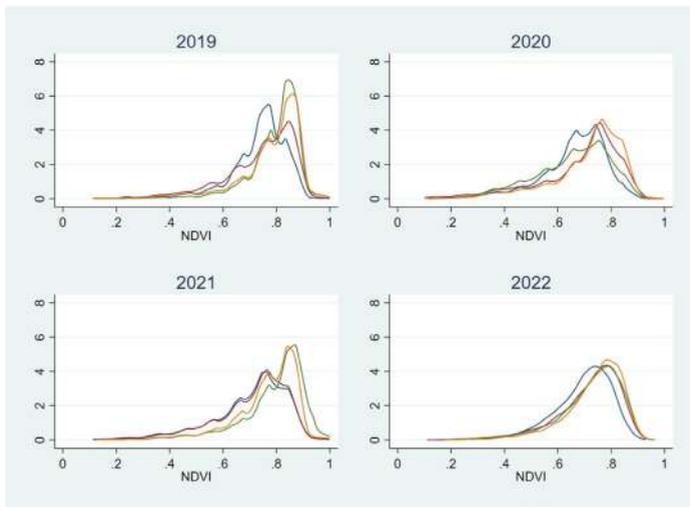


Рис. 18. Розподіл NDVI для полів озимих зернових за різні часові періоди, 2019 - 2022 рр.

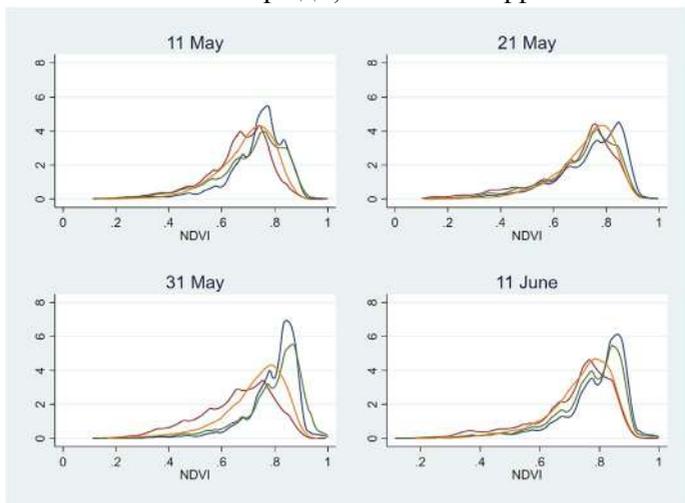


Рис. 19. Розподіл NDVI для полів озимих, вирощених під озими зернові культури в різні дати протягом вегетаційного періоду, 2019 – 2022рр.

Частина 3. Прикладні задачі супутникового інтелекту на ...



Рис. 20. Моніторинг земель окремих фермерів

Загальна площа безпосередньо пошкодженої території становить 1,4 млн га (станом на 10 вересня 2023 р.).

Розроблені інформаційні технології [34] дозволяють обчислювати такі економічні індикатори розвитку аграрного сектору щорічно.

Ці результати передаються в Світовий банк та Мінагрополітики, де використовуються для аналізу ефективності державних та міжнародних програм.

Таблиця 3 Площі окупованих сільськогосподарських земель в 2022 році

млн. га	Окуповані з 2014	Окуповані з 24 лют. 2022	Не окуповані	Загалом млн га
С.г.	1,73 (5.6%)	5,70 (18.3%)	23,58 (76.1%)	31,00
Озимі 2022	0,59 (6.6%)	2,05 (22.9%)	6,33 (70.5%)	8,97

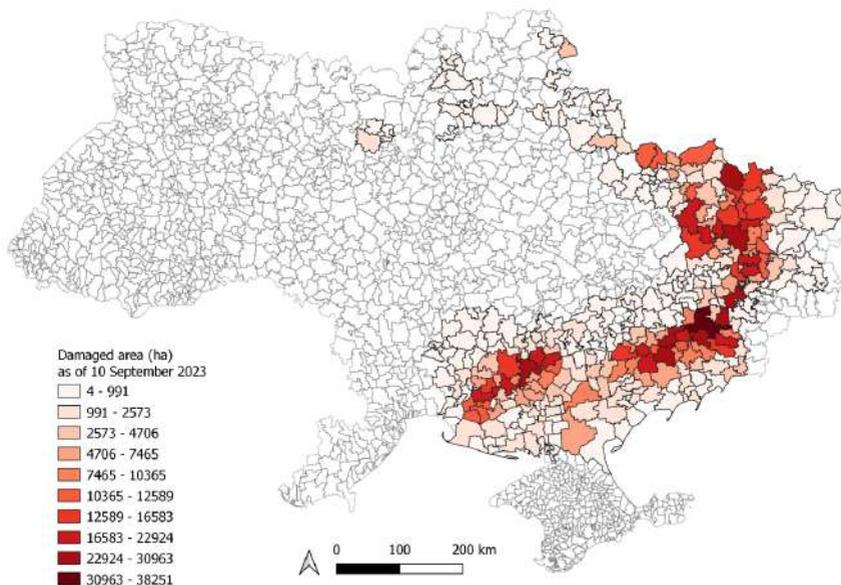


Рис. 21. Пошкоджені землі сільського призначення протягом війни станом на 10 вересня 2023 р.

3.1.4. МОНІТОРИНГ ПОШКОДЖЕНЬ ПОЛІВ З ВИКОРИСТАННЯМ РІЗНОМІРНИХ ГЕОПРОСТОРОВИХ ДАНИХ ТА СУПУТНИКОВИХ ДАНИХ ПІДВИЩЕНОГО РОЗРІЗНЕННЯ В УМОВАХ ВІЙНИ

Збройна агресія в Україні має глибокий негативний вплив на сільське господарство, суттєво погіршивши ситуацію в аграрному секторі. Внаслідок військових дій пошкоджено тисячі гектарів сільськогосподарських полів, що призвело до зниження врожайності озимої пшениці у 2022 р. на 17% [35]. Це величезна втрата для української економіки, враховуючи, що до війни Україна була одним із найбільших у світі експортерів зерна та іншої рослинницької та сільськогосподарської продукції. Для відновлення благополуччя в аграрному секторі важливим завданням є пошук і відстеження динаміки розвитку пошкоджень на полях. Супутникові дані, особливо з дуже високим просторовим розрізненням (VHR), корисні для цього завдання. Таким чином, завдяки аналізу супутникових даних можна визначити

пошкодження посівів через град, мороз [36] або посуху [37], інші стихійні лиха [38] і т.д.

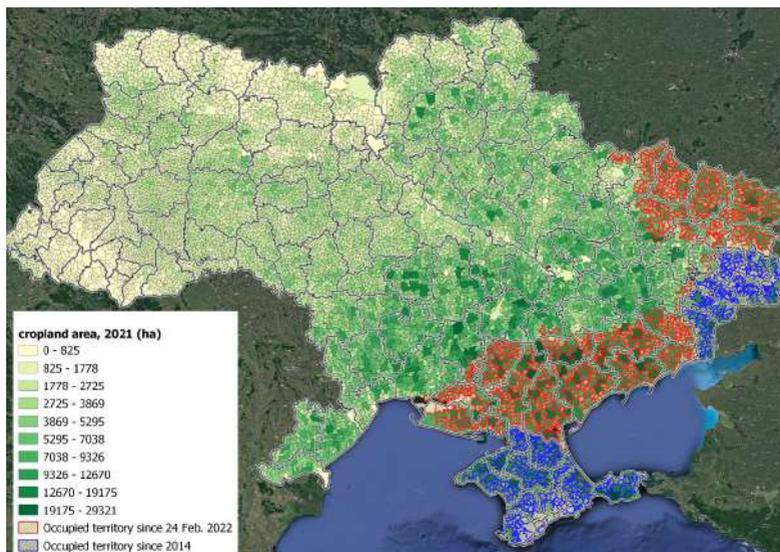


Рис. 22. Площі окупованих сільськогосподарських земель в 2022 р.

В [39] супутникові дані VHR використано для виявлення та картографування пошкоджень сільськогосподарських полів через наявність кратерів від артилерійських снарядів. Автори використали супутникові зображення високого просторового розрізнення WorldView-2 і глибоке машинне навчання, щоб визначити пошкодження в районі Донецької області площею близько 858 км², яка є зоною активного конфлікту з 2014 р. У процесі досліджень було виявлено понад 22 000 кратерів, утворених на сільськогосподарських полях на цій території. Однак супутникові дані VHR зазвичай знаходяться в комерційному доступі та рідко публікуються відкрито, часто обмежуючись невеликими зразками для зон обмеженого доступу. Це створює проблему для вивчення великих територій і тривалих періодів. Тим не менш, дослідницькі організації та університети можуть отримати певні супутникові зображення VHR для своїх досліджень безкоштовно. Наприклад, Planet Labs пропонує університетським дослідникам безкоштовний доступ до даних супутника PlanetScore

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

із просторовим розрізненням 3 м, хоча й з деякими обмеженнями щодо кількості завантажень зображень на місяць.

З іншого боку, для дослідження завданої війною шкоди сільськогосподарським полям також можна використовувати безкоштовні дані з нижчим просторовим розрізненням [21]. Наприклад, на основі аналізу нормалізованого вегетаційного індексу (NDVI) або виявлення аномалій у спектральних каналах із супутникових знімків Sentinel-2 із розрізненням 10 м можна ідентифікувати великі воронки, сліди руху військової техніки і пожежі на полях [40], [41].

Для досягнення синергетичного ефекту можна поєднати характеристики просторового розрізнення VHR і тимчасового просторового розрізнення з супутникових даних середнього розрізнення. Такий підхід дозволяє розширити територію для пошуку пошкоджень та дослідити історію їх виникнення. Використовуючи дані на вищих часових частотах, наприклад Sentinel-2 (3-5 днів) або щоденний PlanetScope, можна визначити приблизну дату появи кратера. Відстежуючи подальші зміни пошкоджень, можна оцінити довгостроковий вплив кратерів або вигорілих ділянок і те, як швидко поля відновлюються після пошкоджень. Крім того, важливо визначити, які пошкодження залишаються видимими навіть через тривалий період.

Запропонований підхід полягає в поєднанні комерційних супутникових даних SkySat і PlanetScope з безкоштовними даними Sentinel-2 для реконструкції історії збитків і аналізу їх динаміки. Крім того, порівнюються результати виявлення кратерів, отримані за допомогою машинного навчання та аналізу зображень SkySat, з результатами виявлення аномалій на даних Sentinel-2 і PlanetScope. За допомогою цього підходу ми прагнемо перевірити релевантність результатів виявлення кратерів на полях, використовуючи дані з нижчим просторовим розрізненням (3- і 10-м), порівнюючи їх з результатами, отриманими з даних з вищим просторовим розрізненням (<1 м). Це дозволить оцінити застосовність даних з нижчим просторовим розрізненням для виявлення пошкоджень на сільськогосподарських полях. Крім того, таким чином можна оцінити можливість розширення зони пошуку збитків та збільшення площі земель, що входять до аналізу. Це дозволить краще зрозуміти масштаб збитків та їх

наслідки, а також спрямувати зусилля на ефективне відновлення сільського господарства після військових дій.

3.1.5. ВИКОРИСТАНІ ДАНІ

Для проведення дослідження можливості поєднання даних із дуже високим просторовим розрізненням та вільно доступних супутникових даних для виявлення пошкоджень на сільськогосподарських полях були використали зображення з трьох різних джерел супутникових даних з різним просторовим та часовим розрізненням, а саме:

1. SkySat — група з 21 супутника спостереження Землі, що належить Planet Labs, забезпечує високе просторове розрізнення (0.5 м) [42].

2. PlanetScope: група з приблизно 130 супутників, здатних щоденно знімати всю поверхню Землі (щоденне покриття 200 мільйонів км²) з просторовим розрізненням приблизно 3 м, також керується компанією Planet [43].

3. Sentinel-2: місія Copernicus, що складається з двох ідентичних супутників, оснащених 13 спектральними каналами, що забезпечують просторове розрізнення до 10 м і часове розрізнення 3-5 днів [44].

Незважаючи на дуже високе просторове розрізнення і щоденне оновлення даних SkySat і PlanetScope, їх основним обмеженням є вартість, яка обмежує охоплення великих територій і можливість аналізу довгострокових часових рядів. Однак, незважаючи на нижче просторове розрізнення і менш часте оновлення, супутникові дані Sentinel-2 мають значну перевагу — вони відкриті та безкоштовні. Це дозволяє проводити дослідження на величезних територіях і відстежувати довгострокові часові ряди.

Для дослідження була обрана територія на межі Донецької та Луганської областей, де тривають активні бойові дії (рис. 23).

Для досліджень були використані зображення SkySat за 2 липня 2022 р., яке охоплює вказану область (рис. 24-б). Зображення охоплює площу 8836 га і включає близько 370 сільськогосподарських полів, які були ідентифіковані за допомогою ділянок, наданих компанією Sinergise в рамках ініціативи EO4UA [45] (рис. 24-а). Що стосується супутника Sentinel-2, то для цього регіону також доступне зображення за цю

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

ж дату (2 липня 2022 р.) (рис. 24). Зображення PlanetScore були відсутні через велику хмарність. Тому для проведення експерименту було використано найближче доступне безхмарне зображення PlanetScore за 6 липня 2022 р. (рис. 24).

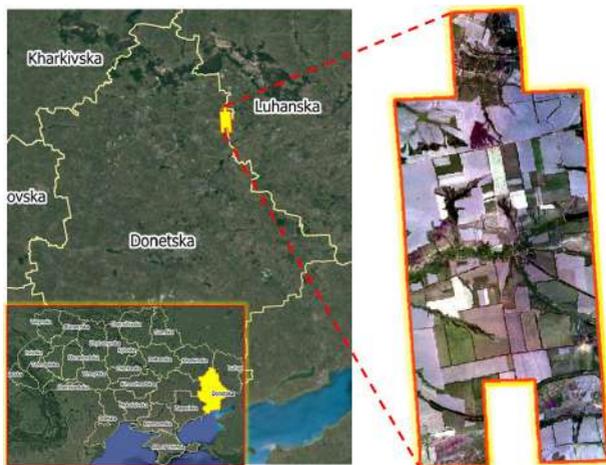


Рис. 23. Досліджувана територія

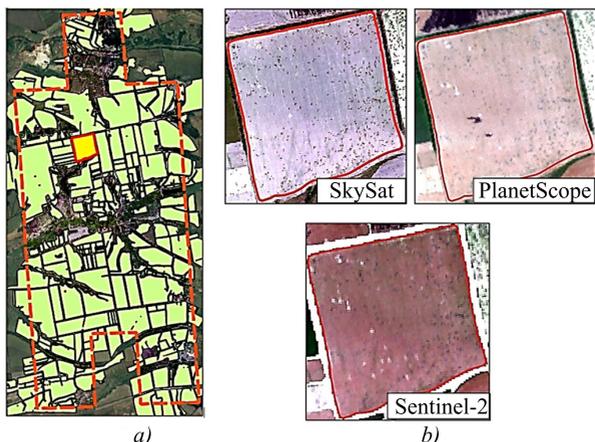


Рис. 24. а) Польові ділянки, розташовані на території інтересу. б) огляд одного з полів на зображеннях із трьох супутників у комбінації натуральних кольорів (RGB)

Крім самого супутникового зображення SkySat були також використані векторні дані з раніше визначеними векторними межами 18 888 кратерів на сільськогосподарських полях (рис. 25) [38].

Були завантажені щоденні дані PlanetScore та 5-денні дані Sentinel-2 за період з березня по липень 2022 р. Використовуючи ці набори даних із меншим просторовим розрізненням, але вищим у часі, можна визначити дати появи кратерів, які добре бачимо на супутникових знімках SkySat високого просторового розрізнення. Крім того, цей підхід дозволяє нам відстежувати зміни в часі цих кратерів.

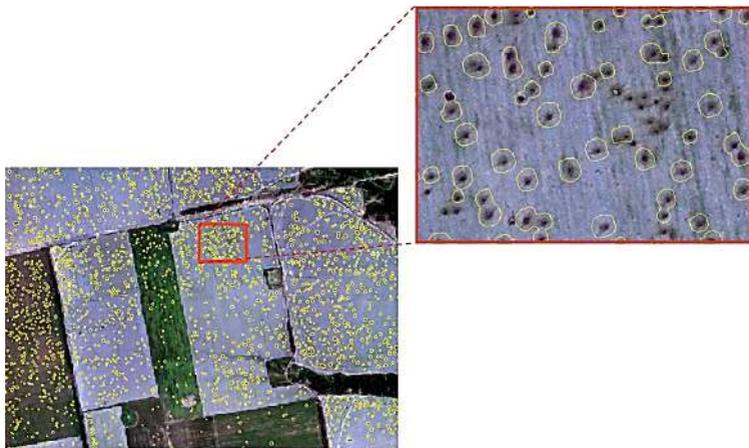


Рис. 25. Виявлені кратери за допомогою даних SkySat

3.1.6. МЕТОДОЛОГІЯ ПОРІВНЯННЯ ВИКОРИСТАННЯ ДАНИХ РІЗНОГО ПРОСТОРОВОГО РОЗРІЗНЕННЯ

Для визначення збитків за допомогою відкритих даних Sentinel-2 і комерційних даних PlanetScore була застосована методологія [39, 40] заснована на виявленні аномалій на основі комбінації синього та зеленого спектральних каналів. Для виявлення аномалій до розгляду був також включений нормалізований індекс води NDWI. Він пов'язаний із вмістом вологи та базується на відносних відмінностях між зеленим (Green) і ближнім інфрачервоним (NIR) каналами (1).

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

$$NDWI = \frac{Green - NIR}{Green + NIR}. \quad (1)$$

Індекс NDWI дозволяє визначити наявність заболочених і посушливих територій. Було зроблено припущення, що у разі пошкодження рельєфу місцевості, спричиненого вибухом або снарядом, рівень вологи може змінюватися або вгору (через руйнування ґрунту, що призводить до висхідного руху вологого ґрунту), або вниз (у разі пожеж і висохлих воронки) в залежності від виду пошкодження. Індекс NDWI чутливий до таких змін.

Для ідентифікації пошкоджень за допомогою спектральних каналів були використані зелений канал (2) для ідентифікації кратерів чорного кольору (що вказує на потенційно щойно пошкоджений ґрунт через вибух), а синій канал (3) – для білих кратерів (вказують на потенційно сухий ґрунт):

$$Green_{dam} = \begin{cases} 1, & \text{if } Green_{mean} - Green > 0.5 * Green_{stdDev}, \\ 0, & \text{otherwise} \end{cases}, \quad (2)$$

де $Green_{dam}$ — це виявлені пошкоджені пікселі, $Green_{mean}$ — середні значення зеленого каналу в межах поля, $Green_{stdDev}$ — стандартне відхилення в межах поля

$$Blue_{dam} = \begin{cases} 1, & \text{if } Blue_{mean} - Blue < -1.5 * Blue_{stdDev}, \\ 0, & \text{otherwise} \end{cases}, \quad (3)$$

де $Blue_{dam}$ — виявлені пошкоджені пікселі, $Blue_{mean}$ — середні значення синьої смуги в полі, $Blue_{stdDev}$ — стандартне відхилення в межах поля.

При пошуку аномалій за допомогою вегетаційного індексу NDWI використано підхід, заснований на застосуванні фільтра усереднення. Цей фільтр збирає значення пікселів у невеликих прямокутних областях, як правило, розміром 5×5 пікселів, і замінює їх середнім значенням, яке вважається еталонним або «неушкодженим полем» ($NDWI_{filter}$). Цей процес фільтрації дозволяє ефективно згладити значення індексу рослинності, навіть якщо поле зазнало пошкоджень, таких як воронки від бомб або сліди від військових машин. У результаті ми створюємо модель

$NDWI_{filter}$, яка слугує еталоном для порівняння з реальними значеннями NDWI поля для виявлення пошкоджень.

Ми обчислюємо різницю між відфільтрованими та реальними значеннями пікселів NDWI (4). Потім, на основі відфільтрованих значень NDWI, обчислюється порогове значення як суму середнього значення та коефіцієнта k , помноженого на стандартне відхилення в межах поля (5). Коефіцієнт k було обрано вручну та встановлено на 0,5, що представляє половину стандартного відхилення.

$$NDWI_{diff} = NDWI_{filter} - NDWI, \quad (4)$$

$$threshhold = NDWI_{diffmean} + 0.5 * NDWI_{diffstdDev}. \quad (5)$$

Тут $NDWI_{filter}$ — відфільтроване значення NDWI, $NDWI$ — фактичне значення NDWI, $NDWI_{diff}$ — різниця між відфільтрованим і фактичним значеннями NDWI, $NDWI_{diffmean}$ — середнє значення відфільтрованого NDWI в межах поля, $NDWI_{diffstdDev}$ — стандартне відхилення відфільтрованого NDWI в межах поля.

Потім для виявлення темних кратерів і пожеж використано (6), а для виявлення білих кратерів — (7).

$$NDWI_{black} = \begin{cases} 1, & \text{if } NDWI_{diff} + threshhold < 0 \\ 0, & \text{otherwise} \end{cases}, \quad (6)$$

$$NDWI_{white} = \begin{cases} 1, & \text{if } NDWI_{diff} - threshhold > 0. \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

У результаті будуть об'єднані аномалії, виявлені за допомогою каналів, і аномалії, виявлені за допомогою аналізу індексу NDWI (8).

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

$$Damage = \begin{cases} Green_{dam} * NDWI_{black}, \\ Blue_{dam} * NDWI_{white}. \end{cases} \quad (8)$$

Для ідентифікації кратерів за допомогою даних SkySat було застосовано раніше розроблена модель керованого глибокого навчання [39]. По-перше, кратери були вручну ідентифіковані на супутникових знімках. Потім отримані результати були використані для навчання нейронної мережі U-Net, яка після навчання дозволила автоматично визначати пошкоджені ділянки. Цей алгоритм шукає кратери як на сільськогосподарських полях, так і в інших областях. Для дослідження кратерів лише на сільськогосподарських полях векторні межі всіх кратерів, виявлених за допомогою даних SkySat, були перетнуті з векторними межами сільськогосподарських полів із ділянками, наданими Synergize.

Як вже зазначалося раніше, при розв'язанні задачі ми прагнемо оцінити можливості даних Sentinel-2 (10 м) і PlanetScope (3 м) у визначенні пошкоджених областей, які раніше були визначені як пошкоджені за допомогою даних VHR SkySat (0,5 м). Для досягнення поставленої мети ми обчислимо площу кратерів, виявлених за допомогою даних Sentinel-2 і PlanetScope, і порівняємо її з площею кратерів, виявлених за допомогою даних SkySat. Важливо зрозуміти рівень узгодженості та розбіжності між різними наборами даних. Крім того, буде застосована візуальна інтерпретація зображень Sentinel-2 і PlanetScope, для відстеження динаміки розвитку кратерів з часом. Цей візуальний аналіз надасть додаткове уявлення про зміни пошкоджених областей, чого неможливо досягти за допомогою методології, яка базується виключно на даних SkySat за одну дату.

3.1.7. РЕЗУЛЬТАТ ВИКОРИСТАННЯ ДАНИХ РІЗНОГО РОЗРІЗНЕННЯ

Використовуючи зображення SkySat, в праці [45] було встановлено, що в зоні інтересу 259 із 370 полів, або 70%, містять кратери через військові дії. Поля, на яких не було виявлено кратерів, насправді мають дуже малу площу або лише частково охоплені супутниковими знімками (рис. 26). Використовуючи дані Sentinel-2 і PlanetScope, було виявлено 7889 кратерів (або 42%) на

10-метровому зображенні Sentinel-2 і 10 143 кратери (54%) — на 3-метрових зображеннях PlanetScore.



Рис. 26. Поля з виявленими кратерами (помаранчеві) і поля, де не виявлено кратерів (жовті) за даними SkySat

Для визначення зв'язку між виявленими кратерами та їх площами було побудовано також графік щільності. Виявлення кратерів за допомогою Sentinel-2 стає складним для кратерів, площа яких менше 100 м^2 , що дорівнює площі одного пікселя Sentinel-2 (рис. 27). Максимальна щільність виявлених кратерів спостерігається на площі приблизно 150 м^2 .

В процесі аналізу щільності виявлених кратерів на зображеннях PlanetScore (рис. 28) було виявлено, що дані PlanetScore більш ефективні для виявлення кратерів меншого розміру. Однак за допомогою даних PlanetScore неможливо виявити кратери площею менше 50 м^2 . Для аналізу великих кратерів (площею понад 250 м^2) дані PlanetScore та Sentinel-2 демонструють майже однакову корисність.

Для оцінки загальної пошкодженої площі була розрахована загальна площа кратерів, виявлених за допомогою Sentinel-2 і окремо за допомогою PlanetScore (рис. 29). За допомогою даних супутника Sentinel-2 виявлено кратери загальною площею 165 га, що становить 51,42% від загальної площі кратерів, визначених за даними SkySat. Крім того, використовуючи дані PlanetScore, були ідентифіковані кратери загальною площею 202 га (62,89%).

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

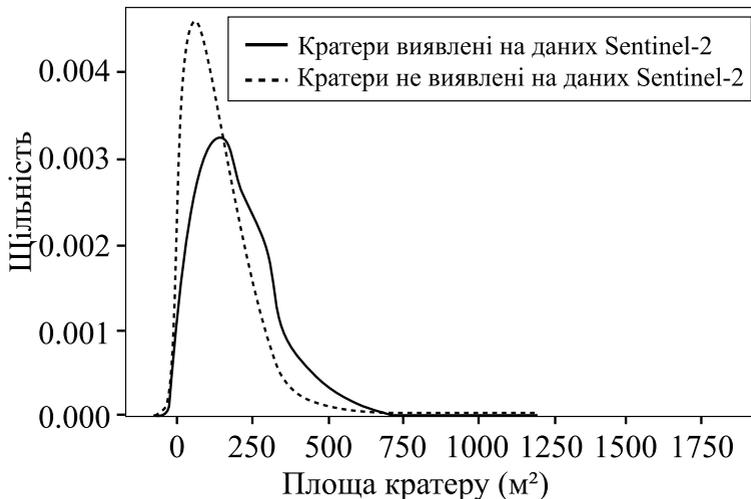


Рис. 27. Діаграма щільності виявлених і невиявлених кратерів залежно від їх площі за даними Sentinel-2

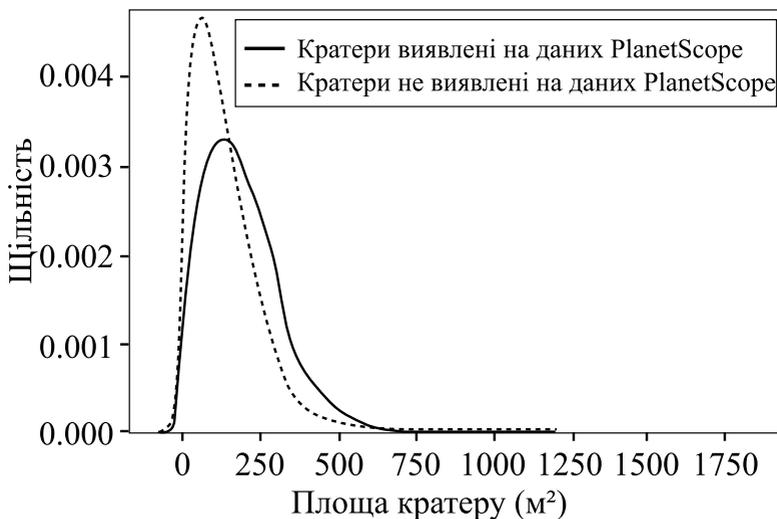


Рис. 28. Діаграма щільності виявлених і невиявлених кратерів залежно від їх площі за даними PlanetScope

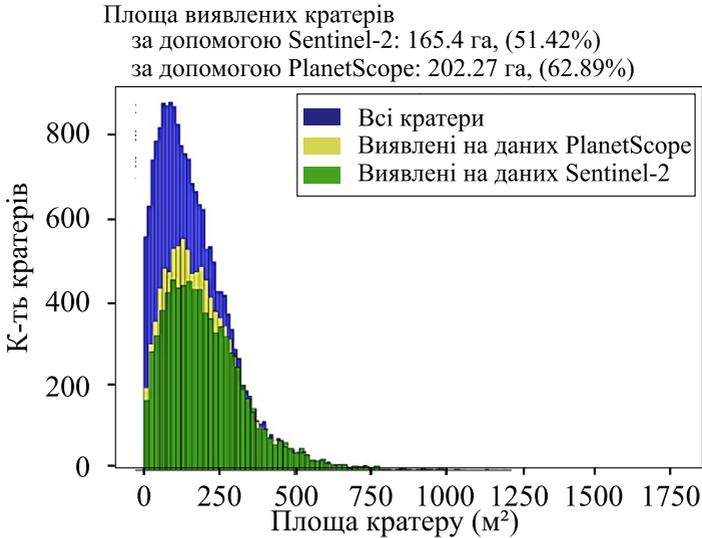


Рис. 29. Площа виявлених кратерів

Варто зазначити, що виявлені за допомогою супутника SkySat зони пошкоджень також не ідеальні. Під час аналізу були ідентифіковані деякі кратери, які не були розпізнані за допомогою SkySat і методології на основі глибокого навчання, але були ідентифіковані за допомогою супутників Sentinel-2 і PlanetScore на основі виявлення аномалій.

На рис. 30-а можна побачити, що кратери, ідентифіковані на основі машинного навчання на зображеннях SkySat, представлені фіолетовими векторними контурами і не охоплюють усі пошкоджені ділянки в регіоні. Однак за допомогою методології виявлення аномалій на основі спектральних смуг і NDWI на даних PlanetScore (рис. 30-б) і Sentinel-2 (рис. 30-с) ці пошкодження було виявлено (показано пікселями червоного кольору).

Крім того, за допомогою аналізу аномалій, навіть на безкоштовних даних можна виявити згорілі ділянки, сліди військової техніки тощо. Тому, хоча багато кратерів, виявлені на даних SkySat з використанням машинного навчання, були пропущені, метод пошуку аномалій на основі на супутникових знімках Sentinel-2 або PlanetScore не можна назвати неефективними. Тому для досягнення хорошого результату слід поєднувати комерційні та безкоштовні дані та обидві методології.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

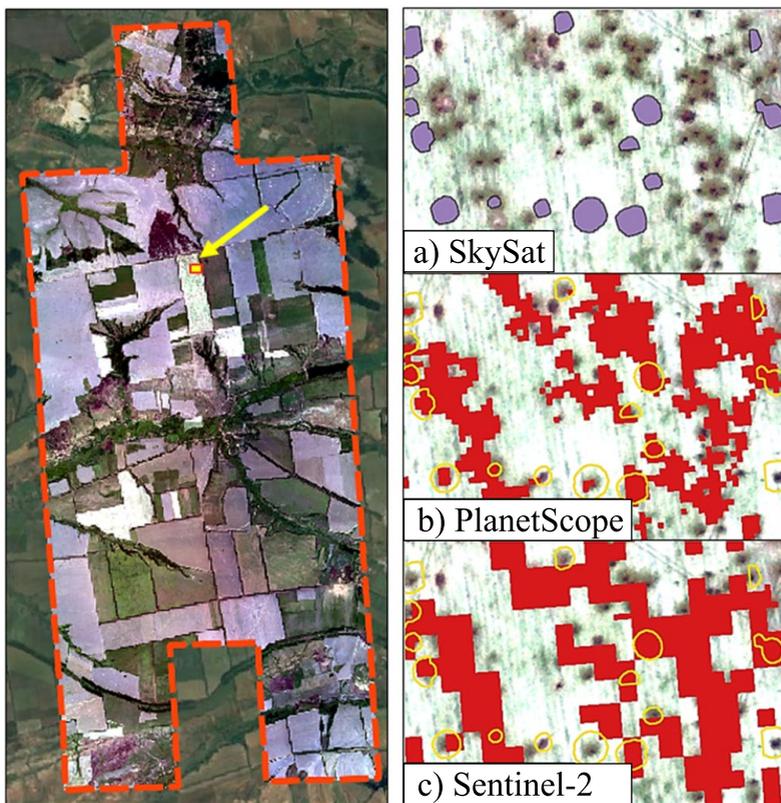


Рис. 30. Виявлені пошкодження з використанням різних супутникових даних і методології

Наступним кроком стала спроба реконструювати історію кратерів. Для досягнення цієї мети випадковим чином були вибрані деякі поля на зображенні SkySat від 2 липня 2022 р. (рис. 31).

Для цього були зібрані всі доступні дані за період з березня по липень із супутників Sentinel-2 і PlanetScope і проаналізовані візуально. Даних Sentinel-2 виявилось недостатньо, оскільки лише три зображення (рис. 32) були безхмарними та придатними для подальшого аналізу. Однак ці зображення чітко зафіксували пошкодження поля. З іншого боку, на рис. 33 зображені знімки PlanetScope, які виявилися найбільш інформативними для виявлення кратерів.



Рис. 31. Територія для спостереження за історією кратерів



Рис. 32. Знімки супутника Sentinel-2, придатні для аналізу обраної території до 2 липня 2022 р.

За результатами аналізу встановлено, що перші пошкодження на досліджуваній території були зафіксовані 25 травня 2022 р. Після цієї дати з'явилися нові пошкодження. Була зафіксована дата візуального виявлення на зображеннях PlanetScore для кожного з кратерів, які раніше були ідентифіковані за допомогою алгоритмів машинного навчання на даних SkySat. Це дозволило визначити, які пошкодження і скільки їх можна спостерігати на зображеннях у конкретний день (рис. 33).

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

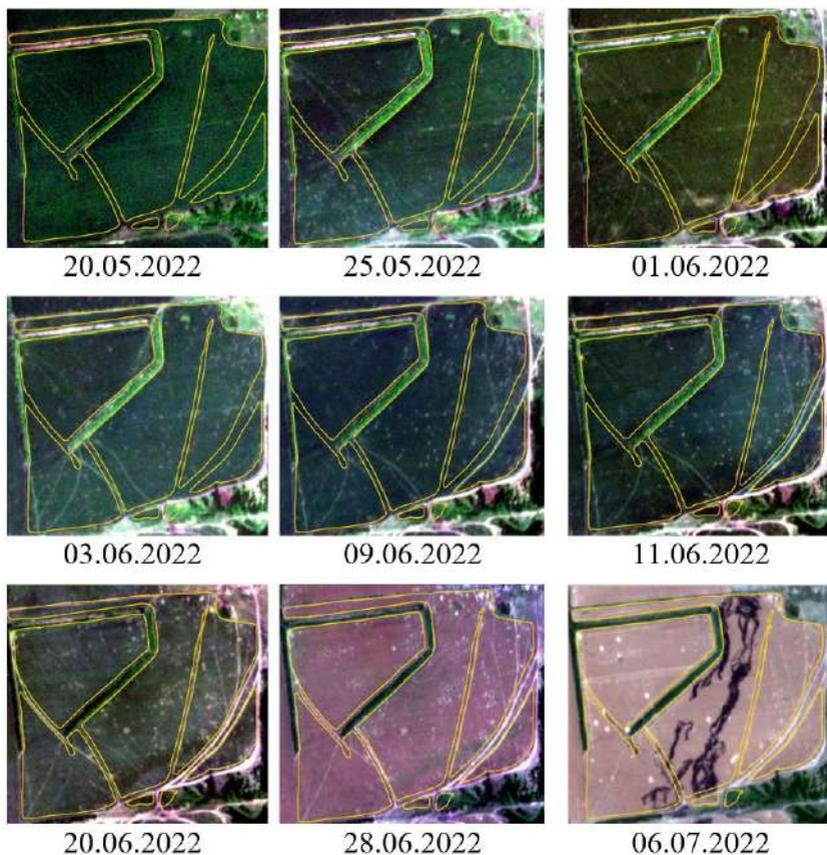


Рис. 33. Найбільш інформативні знімки із супутника PlanetScore для виявлення пошкоджень на вибраній території

На рис. 34 і рис. 35 бачимо, що найбільшу кількість кратерів було виявлено 25 травня 2022 р. (395). Цілком можливо, що кратери, які утворилися в той же період, але не були ідентифіковані відразу, будуть виявлені в майбутньому. Також чітко були зафіксовані нові місця пошкоджень. Зокрема, 20, 28 червня та 6 липня було зафіксовано багато нових кратерів, які значно більші за розміром і світлішого кольору. Варто зазначити, що 178 кратерів не вдалося виявити за допомогою візуального огляду знімків PlanetScore, ймовірно, через їх малий розмір.

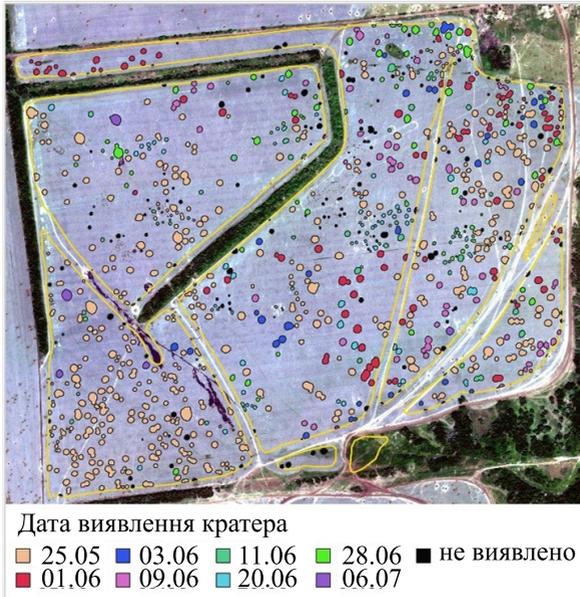


Рис. 34. Кратери, ідентифіковані візуальним оглядом зображень PlanetScore, розподілені за датою

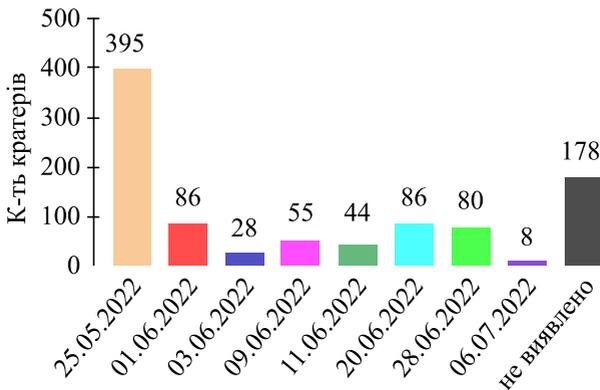


Рис. 35. Розподіл кількості кратерів за датою виявлення

Була також відтворена історія подальшого розвитку цих кратерів. Для цього використані дані Sentinel-2 (рис. 36) і PlanetScore (рис. 37) дані за липень-жовтень 2022 р. та одне зображення PlanetScore за червень 2023 р. Як бачимо з рисунків, 06.07.2022 р. досліджувані поля постраждали від пожежі. Подальше

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

дослідження зображень за 9 та 13 липня дозволило виявити прогресуюче розширення вигорілих областей, зокрема прослідковуючи поширення до лівої частини поля. Пізніше на знімку Sentinel-2 від 17 липня (рис. 36) бачимо поширення пожежі в праву частину поля. До 28 серпня сліди пожежі в основному зникли разом з більшістю кратерів. Однак завдяки спостереженням, проведеним 5 і 15 жовтня, було виявлено, що кратери вкрилися зеленою рослинністю. Більше того, навіть через рік, у червні 2023 р., на досліджуваному полі все ще бачимо ділянки, які постраждали від кратерів і пожежі. Це спостереження дає підстави зробити висновок, що збитки, спричинені військовими діями, можуть зберігатися роками.

Тому, використовуючи відкриті дані Sentinel-2 і PlanetScope, ми змогли визначити приблизні дати появи кратерів, виявлених за даними SkySat, реконструювати історію та простежити динаміку розвитку пошкоджень на родовищах.

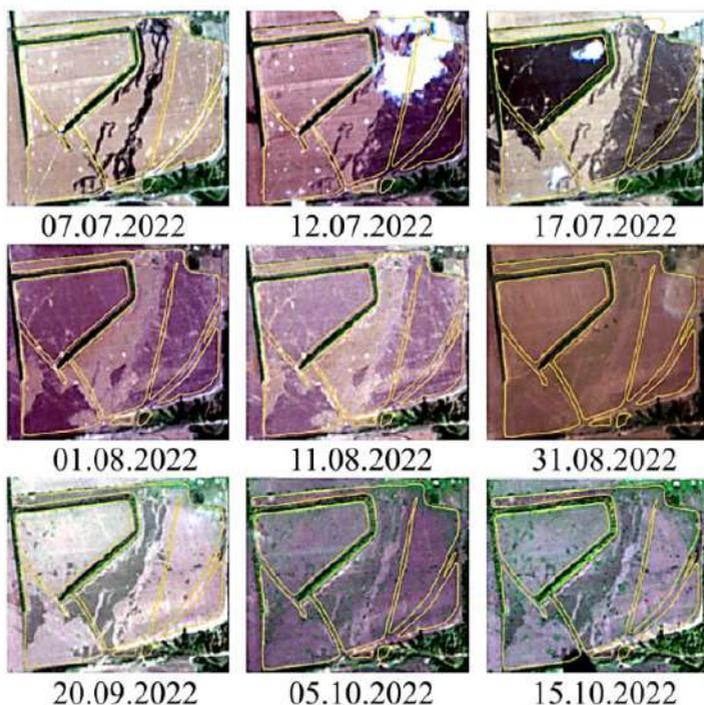


Рис. 36. Динаміка розвитку пошкоджень (Sentinel-2)

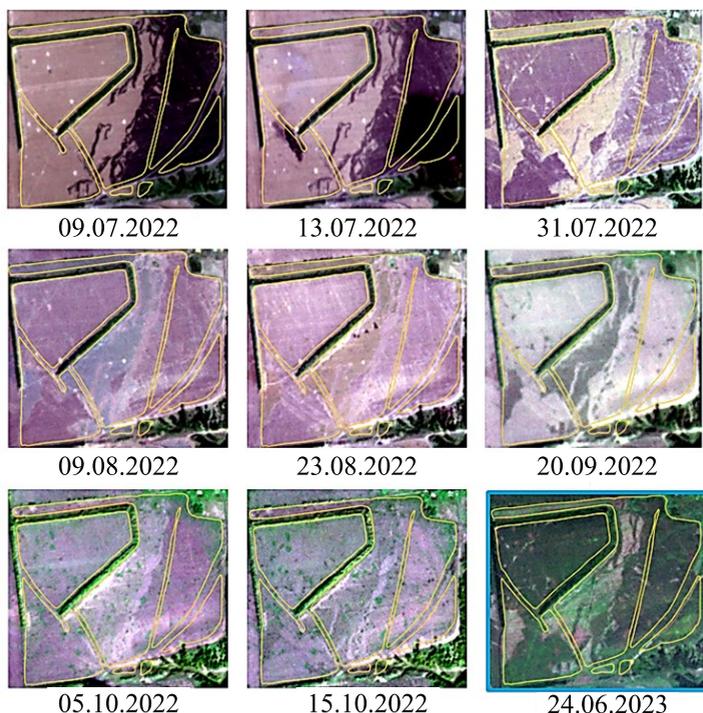


Рис. 37. Динаміка розвитку пошкоджень (PlanetScope)

ВИСНОВКИ

В даному розділі наведено результати комплексного аналізу взаємозв'язків між непрямими індикаторами стану навколишнього середовища (якість повітря, нічне освітлення тощо) та показниками економічної активності регіонів України. Проведені дослідження показали, що динаміка рівня забруднення повітря твердими частинками $PM_{2.5}$ тісно корелює із змінами чисельності населення та може слугувати опосередкованим індикатором міграційних процесів та економічної активності.

Продемонстровано, що показники нічного освітлення, отримані на основі супутникових даних, дають цінну інформацію про рівень економічного розвитку регіонів. Виявлено сильний кореляційний зв'язок між освітленістю та ВВП. Встановлено стійкі кореляційні залежності між економічними показниками окремих галузей промисловості та сільського господарства і непрямими

3.3. Аналіз індикаторів економічної діяльності на основі різнорідних даних

індикаторами, такими як нічне освітлення та якість повітря. Показано, що такі галузі як переробна та видобувна промисловість мають високий рівень кореляції з рівнем ВВП та освітленістю. Це свідчить про те, що рівень освітленості може використовуватися як індикатор економічної діяльності.

На основі аналізу супутникових даних Sentinel та інших джерел геопросторової інформації з використанням методів машинного та глибокого навчання кількісно оцінено вплив війни на економіку та аграрне виробництво в Україні. Наразі супутникова інформація часто є єдиним достовірним джерелом для оцінки площ пошкоджених та окупованих сільськогосподарських земель. Так, окуповані сільськогосподарські землі у 2022 р. становлять 5.7 млн га. Загальна площа безпосередньо пошкоджених полів становить 1,4 млн га (станом на 10 вересня 2023 р.). Отримані результати ілюструють застосовність використання даних спостереження Землі як альтернативного джерела для оперативного моніторингу економічної ситуації в умовах обмеженої офіційної статистики.

Також в даному розділі проаналізовано використання супутникових зображень різної роздільної здатності для виявлення та картування пошкоджень сільськогосподарських угідь в Україні, спричинених війною. Для виявлення пошкоджень, таких як артилерійські воронки, були використані зображення з супутників PlanetScope (3 м), Sentinel-2 (10 м) та SkySat (0,5 м). Продемонстровано ефективність поєднання комерційних та відкритих супутникових даних з різним просторовим розрізненням для аналізу динаміки та оцінки масштабів пошкоджень сільськогосподарських угідь.

Розроблені підходи інтеграції гетерогенних даних із використанням сучасних методів аналізу та глибокого навчання дозволяють підвищити ефективність моніторингу економічної активності.

Результати дослідження вкотре показали, що супутникові дані можуть слугувати потужним інструментом для оцінки стану сільськогосподарських угідь і прогнозування врожайності. В умовах, коли традиційні методи аграрної статистики стають малоефективними через бойові дії або інші кризові фактори, супутникові зображення надають точну картину змін у посівних площах та дозволяють оцінювати втрати аграрного сектору. Це

особливо важливо для країн із сильною залежністю від сільського господарства, таких як Україна, де аграрний сектор є критично важливим для економіки та забезпечення продовольчої безпеки.

Важливо також підкреслити, що непрямі індикатори економічної активності не лише доповнюють класичні статистичні показники, а й у багатьох випадках стають основним джерелом інформації, особливо під час кризових ситуацій, коли доступ до традиційних даних є обмеженим. Використання новітніх технологій збору та аналізу даних, зокрема супутникового моніторингу, дає змогу отримувати актуальну та точну інформацію в реальному часі, що є важливим інструментом для прийняття обґрунтованих управлінських рішень в умовах кризи та оптимізації відновлення економіки країни після війни.

ПЕРЕЛІК ПОСИЛАНЬ

1. Copernicus Atmosphere Monitoring Service. Режим доступу: <https://atmosphere.copernicus.eu/charts/packages/cams/>
2. Lavreniuk M., Shumilo L., Yailymov B., et al. Reviewing Deep Learning Methods in the Applied Problems of Economic Monitoring Based on Geospatial Data. *Cybernetics and Systems Analysis*. 2022. Vol. 58, no. 6. pp. 1008-1020. <https://doi.org/10.1007/s10559-023-00535-9>.
3. Лавренюк М. С., Шуміло Л. Л., Яйлимов Б. Я., та ін. Огляд методів глибокого навчання у прикладних задачах економічного моніторингу на основі геопросторових даних. *Кібернетика та системний аналіз*. 2022. Vol.58. no. 6. pp. 177-192.
4. Dijkstra L., Poelman H., Veneri P. The EU-OECD Definition of a Functional Urban Area. OECD iLibrary OECD Publishing. 2019. DOI: <https://doi.org/10.1787/20737009>.
5. Gerasopoulos E., Bailey J., Athanopoulou E., et al. Earth observation: An integral part of a smart and sustainable city. *Environmental Science & Policy*. 2022. Vol. 132. pp. 296-307. <https://doi.org/10.1016/j.envsci.2022.02.033>.
6. Shelestov A., Yailymova H., Yailymov B., et al. Air quality estimation in Ukraine using SDG 11.6. 2 indicator assessment. *Remote Sensing*. 2021. Vol. 13, no. 23. DOI: doi.org/10.3390/rs13234769.
7. Кусеуль Н.М., Федоров О.П., Шелестов А.Ю. Моніторинг досягнення цілей сталого розвитку України за супутниковими

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

даними. К.: “Наукова думка”. 2023. 164 с.
<https://doi.org/10.15407/978-966-00-1865-5>.

8. Ukrainian census. Режим доступу:
http://db.ukrcensus.gov.ua/PXWEB2007/ukr/news/op_popul.asp.

9. Operational UNHCR Data Portal - Refugee Situation in Ukraine. Режим доступу: <https://data.unhcr.org/en/situations/ukraine>.

10. Yailymova H., Kolotii A., Kussul N., Shelestov A. Air quality as proxy for assesment of economic activity. In IEEE EUROCON 2023-20th International Conference on Smart Technologies. 2023. pp. 89-92.
<https://doi.org/10.1109/EUROCON56442.2023.10198882>.

11. Lehmann A., Mazzetti P., Santoro et al. (2022). Essential earth observation variables for high-level multi-scale indicators and policies. Environmental Science & Policy. 2022. Vol. 131. pp. 105-117.
<https://doi.org/10.1016/j.envsci.2021.12.024>.

12. Shumilo L., Skakun S., Gore M. L., et al. (2023). Conservation policies and management in the Ukrainian Emerald Network have maintained reforestation rate despite the war. Communications Earth & Environment. 2023. Vol 4. No. 1. 443. <https://doi.org/10.1038/s43247-023-01099-4>.

13. Argys L.M., Averett S.L., Yang M. Light pollution, sleep deprivation, and infant health at birth. Southern Economic Journal. 2021. Vol. 87, no. 3. pp. 849-888. DOI: <https://doi.org/10.1002/soej.12477>.

14. VIIRS Stray Light Corrected Nighttime Day/Night Band Composites Version 1. Режим доступу: https://developers.google.com/earth-engine/datasets/catalog/NOAA_VIIRS_DNB_MONTHLY_V1_VCM_SLCFG#bands.

15. Skakun S., Justice C.O., Kussul N., et al. Satellite data reveal cropland losses in South-Eastern Ukraine under military conflict. Frontiers in Earth Science. 2019. Vol. 7. DOI: <https://doi.org/10.3389/feart.2019.00305>.

16. Skakun S., Abys C., Adegbenro M., et al. High-Impact Hot Spots of Land Cover Land Use Change in Ukraine. 2022 12th International Conference on Dependable Systems, Services and

Technologies (DESSERT). 2022. pp. 1-5, DOI: 10.1109/DESSERT58054.2022.10018657.

17. Валовий регіональний продукт (ВРП) з державної статистики України. Режим доступу: (https://ukrstat.gov.ua/operativ/operativ2021/vvp/kvartal_new/vrp/arh_vrp_u.html).

18. Статистичні показники переробної промисловості за кількістю підприємств в регіонах. Режим доступу: https://www.ukrstat.gov.ua/operativ/operativ2021/fin/pdp_roz_reg/kdp_ved_14-20.xlsx.

19. Статистичні показники переробної промисловості за обсягом переробної продукції. Режим доступу: https://www.ukrstat.gov.ua/operativ/operativ2021/fin/pdsg/orpsg_ved_15-20.xlsx.

20. Kussul N., Deininger K., Shumilo L., et al. Biophysical impact of sunflower crop rotation on agricultural fields. Sustainability, 2022. Vol. 14. No. 7. 3965. <https://doi.org/10.3390/su14073965>.

21. Kussul N., Drozd S., Yailymova H., et al. Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning. International Journal of Applied Earth Observation and Geoinformation, 2023. Vol. 125. No. 103562.

22. Yailymova H., Yailymov B., Kussul N., et al. Geospatial Analysis of Life Quality in Ukrainian Rural Areas. In 2023 13th International Conference on Dependable Systems, Services and Technologies (DESSERT). 2023. pp. 1-5. <https://doi.org/10.1109/DESSERT61349.2023.10416517>.

23. Мікава П. В., Дрозд С. Ю. (2023). Метод виявлення пошкоджень земної поверхні внаслідок воєнних дій за допомогою супутникових даних. Проблеми керування та інформатики. 2023. Vol. 68. No. 6. pp. 83–93. doi: 10.34229/1028-0979-2023-6-6.

24. Kussul N., Shelestov A., Yailymova H., et al. Agriculture land appraisal with use of remote sensing and infrastructure data. In IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. 2022. pp. 2785-2788. DOI: 10.1109/IGARSS46834.2022.9884045.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

25. Deininger K., Ali D. A., Kussul N., et al. Quantifying war-induced crop losses in Ukraine in near real time to strengthen local and global food security. *Food Policy*. 2023. Vol. 115, no. 102418. DOI: <https://doi.org/10.1016/j.foodpol.2023.102418>.

26. Lavreniuk M., Shumilo L., Lavreniuk A. Generative Adversarial Networks for the Satellite Data Super Resolution Based on the Transformers with Attention. In *IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium*. 2023. pp. 6294-6297.

27. Shumilo L., Okhrimenko A., Kussul N., et al. Generative adversarial network augmentation for solving the training data imbalance problem in crop classification. *Remote Sensing Letters*. 2023. Vol. 14. No. 11. pp. 1129-1138.

28. Qadir A., Skakun S., Kussul N., et al. A generalized model for mapping sunflower areas using Sentinel-1 SAR data. *Remote Sensing of Environment*. 2024. Vol. 306. 114132. <https://doi.org/10.1016/j.rse.2024.114132>.

29. Shelestov A., Yailymov B., Yailymova H., et al. Advanced Method of Land Cover Classification Based on High Spatial Resolution Data and Convolutional Neural Network. *Proceedings of International Conference on Applied Innovation in IT*. 2022. Vol. 10, No. 1. pp. 125-132. doi:10.25673/76943.

30. Kussul N., Shelestov A., Yailymov B. *Cloud Platforms and Technologies for Big Satellite Data Processing*. Cham: Springer Nature Switzerland. 2022. pp. 303-321. https://doi.org/10.1007/978-3-031-46880-3_19.

31. Shelestov A., Yailymov B., Yailymova H., et al. *Cloud-Based Technologies for Data Processing in Ukraine: International Context*. Cham: Springer International Publishing. 2021. pp. 101-118. DOI: [10.1007/978-3-031-16368-5_5](https://doi.org/10.1007/978-3-031-16368-5_5).

32. Kussul N., Drozd S., Yailymova H. Forecast of Yield of Major Crops in Ukraine in War Conditions 2022 Based on MODIS and Sentinel-2 Satellite Data. In *Proceedings of the 11th International Conference on Applied Innovations in IT, (ICAIIIT)*. 2023. pp. 89-95.

33. Kussul N., Shelestov A., Yailymov B., et al. (2022, December). *Analysis of Cultivated Areas in Ukraine During the War*. In *2022 12th*

International Conference on Dependable Systems, Services and Technologies (DESSERT). 2022. pp. 1-4.

34. Kussul N., et al. Satellite agricultural monitoring in Ukraine at country level: world bank project. In: IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2020. p. 1050-1053.

35. Sarvia F., De Petris S., Borgogno-Mondino E. A methodological proposal to support estimation of damages from hailstorms based on copernicus sentinel 2 data times series. Computational Science and Its Applications–ICCSA 2020: 20th International Conference. Springer International Publishing. 2020. pp. 737-751.

36. Gabbrielli M., Corti M., Perfetto M., Fassa, V., et al. Satellite-based frost damage detection in support of winter cover crops management: A case study on white mustard. *Agronomy*, 2022. Vol. 12, no. 9. DOI: <https://doi.org/10.3390/agronomy12092025>.

37. Skakun S., Kussul N., Shelestov A., et al. The use of satellite data for agriculture drought risk quantification in Ukraine. *Geomatics, Natural Hazards and Risk*. 2016. Vol. 7, no. 3. pp. 901-917.

38. Solaimani K., Sharifipour M., Abdoli Boozhani S. Flood damage detection algorithm using Sentinel-2 images (case study: Golestan flood of March 2019). *Iranian journal of Ecohydrology*. 2020. Vol. 7, no. 2. pp. 303-312. DOI: 10.22059/IJE.2020.292005.1233.

39. Duncan E.C., Skakun S., Kariryaa A., et al. Detection and mapping of artillery craters with very high spatial resolution satellite imagery and deep learning. *Science of Remote Sensing*. 2023. Vol. 7, no. 100092. DOI: <https://doi.org/10.1016/j.srs.2023.100092>.

40. Kussul N., Yailymova H., Drozd S. Detection of War-Damaged Agricultural Fields of Ukraine Based on Vegetation Indices Using Sentinel-2 Data. 2022 12th International Conference on Dependable Systems, Services and Technologies (DESSERT). 2022. pp. 1-5. DOI: 10.1109/DESSERT58054.2022.10018739.

41. Shelestov A., Drozd S., Mikava P., et al. War Damage Detection Based on Satellite Data. In *Proceedings of International Conference on Applied Innovation in IT*. 2023. Vol. 11, no. 1. pp. 97-103.

3.3. Аналіз індикаторів економічної діяльності на основі різномірних даних

42. Skysat - Planet Developer Documentation. Режим доступу: <https://developers.planet.com/docs/data/skysat/>.

43. PlanetScope - Planet Developer Documentation. Режим доступу: <https://developers.planet.com/docs/data/planetscope/>.

44. European Space Agency (ESA). Sentinel-2 - Observing the Earth - Copernicus. Режим доступу: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2.

45. Kussul N., Drozd S., Skakun S., Duncan E., Becker-Reshef I. Fusion of very high and moderate spatial resolution satellite data for detection and mapping of damages in agricultural fields. The 13th IEEE International Conference on Dependable Systems, Services and Technologies, DESSERT'2023. 13-15 October, 2023, Athens, Greece. doi: 10.1109/DESSERT61349.2023.10416533.

4. КЛАСИФІКАЦІЇ ТИПІВ ЗЕМНОГО ПОКРИВУ ТА ЗЕМЛЕКОРИСТУВАННЯ НА ОСНОВІ СУПУТНИКОВИХ ДАНИХ З ВИКОРИСТАННЯМ TRANSFER LEARNING

Богдан Яйлимов, завідувач відділу космічних інформаційних
технологій і систем
Інститут космічних досліджень НАН України та ДКА України
yailymov@gmail.com

ВСТУП

Земельні ресурси та їх ефективне використання є ключовими факторами сталого розвитку. Оцінка стану земного покриву та землекористування є важливою для управління природними ресурсами, прогнозування екологічних змін та забезпечення раціонального землекористування. Одним із найважливіших інструментів для цього є супутникові дані, які дозволяють отримувати інформацію про стан земної поверхні на великих територіях з високою точністю.

З розвитком супутникових технологій, таких як Sentinel-1 і Sentinel-2, стало можливим отримувати регулярні дані про стан земного покриву в різних спектральних діапазонах. Це надає можливість виконувати класифікацію типів земного покриву та землекористування з урахуванням таких факторів, як стан рослинності, типи угідь тощо.

Однак однією з проблем при класифікації типів земного покриву є обмеженість наземних даних, які використовуються для навчання моделей. Зокрема, для деяких регіонів, зокрема для східних областей України, збір таких даних є неможливим через військові дії. Це створює проблему точності класифікації для цих регіонів.

Для вирішення цієї проблеми використовують підходи Transfer Learning [1]. Це дозволяє переносити моделі, навчені на даних для одних територій, на інші території з подібними характеристиками, де неможливо зібрати навчальні дані. Дослідження спрямоване на підвищення точності класифікації для територій, для яких відсутні наземні дані, шляхом використання навчальних даних з інших регіонів.

3.4. Класифікації типів земного покриття та землекористування на основі...

Метою даної роботи є побудова високоточних карт класифікації типів земного покриття та землекористування для всієї території України на основі супутникових даних Sentinel-1 та Sentinel-2, використовуючи підхід Transfer Learning для територій для яких відсутні навчальні дані.

4.1. АНАЛІЗ МЕТОДІВ TRANSFER LEARNING ДЛЯ КЛАСИФІКАЦІЇ ЗЕМНОГО ПОКРИТТЯ

Однією з найбільш поширених проблем при побудові карт класифікації є обмеженість навчальних даних для деяких регіонів. Наприклад, у регіонах, де збір наземних даних неможливий через геополітичні або природні обмеження, виникає проблема створення точних карт класифікації. В цьому контексті, методи Transfer Learning набувають особливого значення [2].

Останні дослідження свідчать про високу ефективність перенесення моделей, навчених на одних територіях, до інших регіонів із подібними характеристиками [3]. Зокрема, в роботі [4] автори використовують такий підхід для ідентифікації типів культур в інших регіонах, використовуючи навчену модель на території США. В якості даних використано 30-метрові 15-денні композити часових рядів NDVI на основі даних Landsat-8 та Sentinel-2 (Harmonized Landsat Sentinel-2 - HLS). Такий підхід є ефективним при невеликій кількості класів і у випадку, коли культура має однаковий схожий хід розвитку протягом вегетаційного сезону. В Україні, наприклад, соняшник може мати різні періоди посіву та цвітіння, тому такий підхід може мати певні складнощі.

Застосування Transfer Learning для побудови карт земного покриття стає все більш популярним, зокрема, у контексті супутникових даних [5, 6], де часто неможливо зібрати навчальні дані для кожного регіону. В [6] представлено комплексний огляд методів Transfer Learning в області дистанційного зондування навколишнього середовища. Дослідження охоплює декілька підходів до трансферного навчання, зокрема, методи перенесення на рівні функцій, екземплярів та параметрів. Автори продемонстрували ефективність цих методів у задачах класифікації земного покриття, оцінки біофізичних параметрів, а також інших характеристик моніторингу земної поверхні.

Існує кілька підходів до перенесення моделей, які використовуються для задач класифікації земного покриття. Одним

із них є тонке налаштування (Fine-tuning) попередньо навчених моделей. Fine-tuning - це процес адаптації попередньо навченої моделі до нових даних шляхом налаштування ваг моделі на новому наборі даних [7]. В [7] використана базова модель TransformerEncoder, і після її налаштування авторам вдалося покращити точність перенесеної моделі на територію Сербії.

Часто, під час перенесення моделей використовують вилучення ознак (feature extraction) [8]. Такий підхід дає можливість використовувати попередньо навчені моделі як екстрактори ознак, зберігаючи ваги нижніх шарів та замінюючи або перенавчаючи лише верхні шари. У праці [9] досліджено використання попередньо навчених моделей глибоких згорткових нейронних мереж (Deep Convolutional Neural Networks, DCNN) для класифікації оптичних супутникових зображень. Автори застосували метод виділення ознак (feature extraction), що полягає у вилученні корисної інформації з попередньо навченої моделі, що дозволяє підвищити точність класифікації, адаптуючи моделі, навчені на ImageNet [9].

Автори праці [10] запропонували метод змагальної адаптації домену (adversarial domain adaptation), який використовує змагальні алгоритми для покращення точності класифікації земного покриття в різних географічних регіонах, що дозволило підвищити точність з 0.83 до 0.92.

Застосування Transfer Learning, яке використовує знання з вихідних доменів для покращення продуктивності моделей у цільовому домені, значно зросло. Однак, традиційні методи часто передбачають ідентичні простори ознак і міток у обох доменах, що є непрактичним у багатьох випадках. Гетерогенне Transfer Learning (HTL) вирішує ці розбіжності, ставши важливою стратегією у різних завданнях. У статті [11] представлено всебічний огляд понад 60 методів HTL, включаючи останні досягнення, такі як впровадження моделей на основі трансформерів та технік мультимодального навчання.

У статті [12] автори пропонують використання глибоких нейронних мереж (CNN) для класифікації зображень земного покриття з високим просторовим розрізненням використовуючи метод псевдо-маркування для покращення ефективності перенесення моделей, що дозволяє класифікувати зображення без розмітки. Експерименти проведені на різних наборах даних показали обнадійливі результати, підтверджуючи застосовність запропонованої методології.

3.4. Класифікації типів земного покриття та землекористування на основі...

Авторами праці [13] проведено оцінку тридцяти дев'яти моделей глибокого трансферного навчання для класифікації змін земного покриття, зокрема ResNet50, EfficientNetV2B0 та ResNet152, які показали найкращі результати за показниками каппа та загальної точності.

Існує ще багато методів глибинного навчання, що використовуються для класифікації супутникових даних, зокрема методи трансферного навчання [14]. Проте навіть ці передові підходи стикаються з труднощами через сезонні та географічні відмінності даних, що значно ускладнює процес створення універсальних моделей для різних територій. Як зазначено у [15], попередньо навчені нейронні мережі не завжди підходять для безпосереднього використання в нових умовах. Однак, перенавчання моделей з використанням вже існуючих ваг або заморожування початкових шарів може значно підвищити точність класифікації порівняно з тренуванням моделі з нуля.

Наведені дослідження демонструють широкий спектр підходів до Transfer Learning у контексті класифікації типів земного покриття та підкреслюють важливість адаптації моделей до нових регіонів та умов. Вони також вказують на потенціал для подальшого вдосконалення методів Transfer Learning для вирішення проблем, пов'язаних з обмеженістю даних у певних регіонах.

У контексті класифікації земного покриття особливо ефективними є ансамблеві методи. Дослідження [16] вказує на те, що об'єднання кількох моделей через голосування або інші методи ансамблювання дозволяє підвищити загальну точність класифікації, зменшуючи невизначеність для окремих територій. Наприклад, коли моделі показують різні результати для тих самих територій, метод голосування дозволяє обрати найбільш ймовірний клас на основі ймовірнісних оцінок кожної моделі.

У даному дослідженні використовується один із подібних підходів для побудови карт класифікації для території України. Специфічною проблемою є відсутність наземних даних для східної України. Однак, використовуючи методи Transfer Learning, можна перенести моделі, навчені на даних центральної та західної частини України, до цих регіонів. Крім того, методи ансамблювання, зокрема голосування між кількома моделями, дозволяють підвищити точність кінцевих карт класифікації.

4.2. ПОСТАНОВКА ЗАДАЧІ

Основна задача, яка поставлена в даному розділі, полягає в побудові карт земного покриття для території України на основі супутникових даних Sentinel-1 і Sentinel-2 з використанням методів Transfer Learning. Через складнощі з отриманням наземних даних на певних територіях України, особливо у зонах активних військових дій на сході країни, традиційні методи класифікації не забезпечують необхідної точності для всіх регіонів. Використання наземних досліджень потребує значних людських і фінансових ресурсів та займає багато часу, що не завжди ефективно для оперативної побудови карт великого масштабу. Це призводить до необхідності використання перенесення моделей між регіонами з метою підвищення точності класифікації в тих зонах, де наземні дані відсутні.

Тому запропоновано дослідити різні підходи до перенесення моделей, навчання яких здійснено на регіонах із наявними даними, на регіони, де збір наземних даних є неможливим або неефективним. Основна увага приділяється дослідженню можливостей перенесення моделей, створених для центральних і західних регіонів України, на східні регіони, де відсутні наземні дані. Оцінка ефективності цих підходів здійснюється шляхом перевірки моделей на територіях з різними характеристиками земного покриття.

Запропоновані підходи повинні забезпечити підвищення точності класифікації земного покриття на основі супутникових даних при умові обмеженого доступу до наземних даних або його повної відсутності. Особлива увага приділяється використанню підходів до комбінованого навчання моделей, перенесення навчання між різними регіонами, а також методам інтеграції результатів кількох моделей для досягнення високої точності класифікації.

4.3. ДАНІ ТА ТЕРИТОРІЯ ДОСЛІДЖЕНЬ

Для проведення дослідження було використано супутникові дані Sentinel-1 та Sentinel-2, які охоплюють територію України. Основною метою є побудова карт класифікації для всієї країни, зокрема для регіонів, де відсутні наземні дані.

Супутникові знімки Sentinel-1, що містять радіолокаційні дані, використовуються для отримання інформації про структуру

3.4. Класифікації типів земного покриття та землекористування на основі...

поверхні та стан земного покриття незалежно від погодних умов і освітленості. Знімки Sentinel-2 містять дані оптичного спектру, які забезпечують більш детальну інформацію про рослинність, ґрунти та інші елементи земного покриття. Використання обох типів даних дозволяє створювати більш точні класифікаційні карти земного покриття [17].

Україна покрита 9 смугами Sentinel-1, що забезпечують повне охоплення території країни. Для кожної смуги підготовлено по 15 радарних знімків, які охоплюють період з березня по серпень 2024 року. Для цього дослідження було здійснено підготовку композитних зображень Sentinel-2, які були територіально підлаштовані під смуги даних Sentinel-1 для подальшої обробки. Для центральних і західних регіонів було створено по 4 композити на основі наявних оптичних даних. Для найзахіднішої 80-ї смуги було створено лише 3 оптичних композити через високу частоту хмарності в цьому регіоні. Використання композитів дозволяє зменшити вплив тимчасових погодних умов і отримати більш точну карту земного покриття. Попередня обробка супутникових даних здійснена згідно методології описаної у праці [18].

При побудові карти, зазвичай виникає проблема зі східними областями, де через військові дії збір наземних даних є ускладненим або неможливим. Ці регіони вимагають застосування методів перенесення моделей, що дозволяють використовувати дані з інших частин країни для класифікації.

Щоб перевірити достовірність методів Transfer Learning для території України, в даному розділі пропонується перенести моделі з центральних на західні території (зокрема 80 та 7 смуги), на яких зібрані дані наземних досліджень. Це дозволить провести тестування отриманих результатів. Навчання моделей здійснювалось на центральних 109 та 36 смугах (рис. 1).

Навчальні дані були зібрані у центральній і західній частинах України вздовж доріг в 2024 році. Ці дані були перетворені у векторні полігони з класами земного покриття. Використані наземні дані для проведення дослідження представлено у таблиці 1. Для побудови карти зібрані наземні дані були розподілені на навчальну та тестову вибірки по областях у співвідношенні 80% на 20%. Такий підхід дозволяє забезпечити рівномірний розподіл даних для навчання моделі, а також гарантує, що тестові дані, використані для перевірки якості класифікації, не перетинаються з навчальними. Розподіл по областях допомагає зберегти регіональні особливості та врахувати можливі географічні

Частина 3. Прикладні задачі супутникового інтелекту на ...

відмінності, що важливо для побудови точної карти в умовах неоднорідності даних.

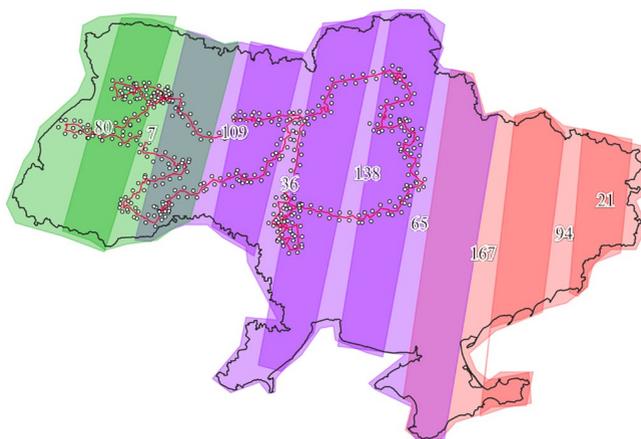


Рис. 1. Територія України поділена смугами відповідно до траєкторії супутника Sentinel-1 та маршрутом збору даних у 2024 році

Таблиця 1 Дані наземних досліджень, використані для експериментів

Наземні дані	Тестові				Навчальні			
	80	7	109	36	80	7	109	36
Штучні об'єкти	7	33	27	24	40	142	114	112
Пшениця	42	136	57	107	189	543	250	438
Ріпак	11	32	17	15	51	123	57	75
Гречка	5	4			23	26	6	5
Кукурудза	25	57	49	125	99	240	187	508
Цукровий буряк	3	6	2	3	15	34	14	23
Соняшник	7	37	33	111	42	161	175	485
Соя	66	228	134	100	245	920	539	441
Інші культури	4	9	6	6	7	34	22	22
Ліс	30	35	31	44	170	220	170	267
Луг	74	87	51	101	292	347	248	434
Відкритий ґрунт	4	3	2	10	23	21	18	55
Водні об'єкти	18	30	37	31	85	144	159	169
Болотна	8	7	7	18	44	50	41	95
Ячмінь	4	39	19	19	30	165	89	97
Горох		3		1	2	15	1	16

3.4. Класифікації типів земного покриття та землекористування на основі...

Люцерна		7	6	8	3	34	24	41
Сади, парки	3	33	40	7	25	159	174	53
Виноград	12	1	1	21	49	7	7	87
Картопля	4	9	1	1	22	55	19	11
Всього	327	796	520	752	1456	3440	2314	3434

4.4. ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ

У даному підрозділі представлено результати експериментів, спрямованих на оцінку ефективності методів перенесення навчання (Transfer Learning) для класифікації супутникових зображень Sentinel-1 і Sentinel-2 в регіонах з обмеженими або відсутніми наземними даними. Проведені п'ять експериментів були спрямовані на вивчення різних підходів до використання моделей перенесення, а також на оцінку ефективності комбінування даних для підвищення точності класифікації. В якості методу класифікації використано ансамбль MLP (multi-layer perceptron). Ефективність його використання для класифікації сільськогосподарських культур практично доведена в праці [19].

Перед початком проведення експерименту для кожної смуги (109 та 36) побудовано окрему модель на основі супутникових даних та даних наземних досліджень, яка потім використовувалася для подальших експериментів з перенесенням навчання. Результатом класифікації є карта класифікації земного покриття та карта ймовірності для кожного пікселя.

Карта класифікації земного покриття представляє собою растрове зображення, яке містить інформацію про клас земної поверхні який може представляти тип культур, земельне використання або інші характеристики земного покриття.

Растрова карта ймовірності для кожного пікселя - містить інформацію про ймовірність належності кожного пікселя до певного класу. Це дозволяє врахувати неточність класифікації, надаючи можливість оцінити, до якого класу піксель відноситься з найбільшою ймовірністю.

Результати класифікації показали, що загальна точність для 109 смуги склала 94.9%, а для 36 смуги – 95% на тестових незалежних даних. Для тестування моделей використовувалися 7 та 80 супутникові смуги з західних регіонів України, де наявні наземні дані для тренування та тестування моделей.

Розглянемо результати експериментів з побудови карт класифікації земного покриву на території України, з використанням різних методів, включаючи перенесення моделей та комбіноване навчання.

Експеримент 1: Перенесення моделі з центральної на західну частину України

Метою даного експерименту було оцінити, наскільки ефективним є перенесення моделі, навченої на даних центральної України, для класифікації територій, де наземні дані відсутні (наприклад, західна Україна). Модель була навчена на даних 36 та 109 смуг і перевірена на даних 7 та 80 смуг (західні регіони).

Результати показали, що точність класифікації для 7 смуги на основі 36 смуги склала 82.1%, а на основі моделі із 109 смуги - 83.8%. Для 80 смуги – 76.4% на основі 36 смуги, та 84.2% на основі 109 смуги. Перевага точності на основі моделі із 109 смуги, ймовірно через більш близькі значення у спектральних каналах, через схожість території та її кліматичних умов. Отримані загальні точності наведені у таблиці 2.

Експеримент 2: Комбіноване навчання моделей

Другий експеримент передбачав навчання моделі на основі даних зі смуг 36 і 109 одночасно. Навчена одна модель використовувалася для класифікації смуг 7 та 80. Результати показали помітне покращення точності в порівнянні з першим експериментом, що демонструє переваги використання комбінованих даних із різних територій для підвищення адаптивності моделей до різних регіонів. Для 7 смуги точність склала 87.4%, а для 80 смуги – 82.2%. Це демонструє, що комбінування даних з різних регіонів допомагає покращити адаптацію моделі та її здатність класифікувати нові території.

Експеримент 3: Метод голосування для покращення класифікації

Третій експеримент включав застосування методу голосування для вибору найбільш імовірного класу на основі результатів класифікації з двох різних моделей (36 та 109 смуги).

Цей підхід забезпечив підвищення точності класифікації, що свідчить про ефективність методу голосування для зменшення невизначеності і поліпшення загальних результатів.

Метод голосування показав точність для 7 смуги – 84.8%, і для 80 смуги – 78.1%. Це підтверджує, що об'єднання кількох моделей може суттєво покращити якість класифікації, особливо у складних умовах, таких як західна Україна.

3.4. Класифікації типів земного покриття та землекористування на основі...

Експеримент 4: Використання перетинів смуг для створення навчальних вибірок

У цьому експерименті було досліджено можливість використання перетинів між смугами супутникових зображень, а отже і карт класифікації для створення додаткових навчальних вибірок зі смуг 109 і 7, а також 7 та 80 (рис. 2).

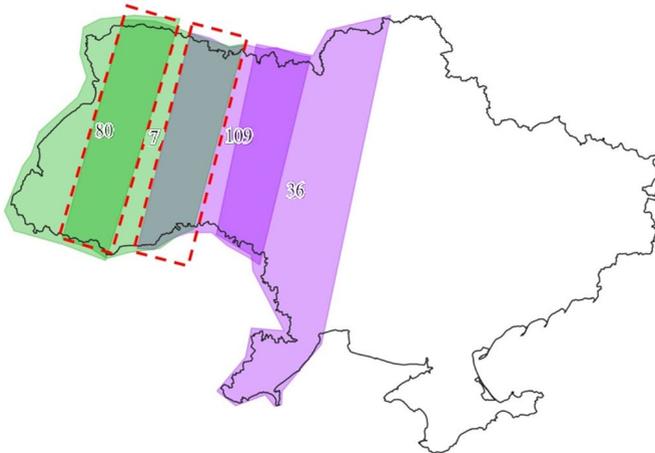


Рис. 2. Перетин між смугами, на основі якого буде сформовано навчальні дані (виділено штриховою лінією)

Для формування навчальної вибірки були використані векторні межі полів, що сформовані та надані для території України компанією Sinergise, та карти класифікації із ймовірністю кожного класу. Всі полігони були попередньо оброблені, зокрема видалялися геометрично недійсні та порожні об'єкти. Для фільтрації полів із надто малою площею (менше ніж 100 м²) використовувалась процедура буферизації з наступним видаленням порожніх результатів. Це дозволило зосередитися на об'єктах, які містять достатню кількість інформації для точного навчання моделей класифікації.

Для кожного поля визначався унікальний клас, а також перевірялося, чи є даний полігон «однорідним», тобто чи містить він лише один клас пікселів. У вибірку були включені лише ті полігони, середня ймовірність яких перевищувала поріг 0.95, щоб забезпечити високу точність навчальних даних. Для уникнення переважання класів із великою кількістю зразків, вибірка для кожного класу була обмежена до 500 полів. Для цього з даного класу обиралися зразки з найвищою середньою ймовірністю.

Таким чином, було забезпечено, що кожен клас буде представленим у вибірці пропорційно та рівномірно.

В результаті сформована вибірка містила лише полігони, які відповідають зазначеним критеріям. Для кожного об'єкта зберігалася інформація про клас та середню ймовірність. Це дозволило отримати збалансовану навчальну вибірку, яка сприяє поліпшенню точності та надійності результатів класифікації.

Модель, що отримана на основі навчальних даних з перетину між 109 і 7 смугами, показала загальну точність отриманої карти для 7 смуги на тестових незалежних даних 88.8%.

Для отримання карти для 80 смуги, використано перетин між 7 та 80 смугами. Точність класифікації для 80 смуги склала 91.2%, що демонструє ефективність використання перетинів смуг для генерації нових навчальних даних.

Експеримент 5: Побудова карт на основі наземних даних

Останній експеримент передбачав порівняння точності класифікації на основі наземних даних з результатами, отриманими за допомогою методів перенесення моделей.

Побудовані карти класифікації для смуг 7 і 80 на основі наземних досліджень демонструють найвищу точність класифікації. Точність класифікації 94.5% для 7 смуги та 96.1 % для 80 смуги. Це вказує на те, що наземні дані, є найбільш точним джерелом для навчання моделей.

Отримані результати дозволили порівняти точність різних підходів до Transfer Learning та визначити найбільш ефективні методи для побудови карт класифікації для територій із відсутніми даними (табл. 2).

Таблиця 2 Точність класифікації для різних експериментів на незалежних тестових наземних даних

Експеримент	Смуга 7 (точність, %)	Смуга 80 (точність, %)
Експеримент 1: Перенесення моделі з центральної на західну частину України	82.1 (на основі моделі з 36 смуги) 83.8 (на основі моделі з 109 смуги)	76.4 (на основі моделі з 36 смуги) 84.2 (на основі моделі з 109 смуги)
Експеримент 2: Комбіноване навчання моделей	87.4	82.2

3.4. Класифікації типів земного покриття та землекористування на основі...

Експеримент 3: Метод голосування для покращення класифікації	84.8	78.1
Експеримент 4: Використання перетинів смуг для створення навчальних вибірок	88.8	91.2
Експеримент 5: Побудова карт на основі наземних даних	94.5	96.1

Аналіз результатів проведених експериментів демонструє, що побудова карт на основі наземних даних демонструє найвищу точність класифікації. Це очікуваний результат, оскільки використання наземних даних зазвичай забезпечує найвищу точність, однак, як було зазначено раніше, такий підхід є ресурсовитратним і не завжди можливим на великих територіях.

Найгірші показники отримані при перенесенні моделі із центральної України на західні регіони. Як показано на рис. 3, фрагменти 80 смуги, перші три експерименти мають невеликий шум на картах. Кращим рішенням для перенесення моделей виявилось використання даних з перетину смуг для створення навчальних вибірок (експеримент 4). Такий підхід має свої обмеження. На нашому прикладі, не можливо побудувати карту для 80 смуги, поки не буде отримано карти, що перетинається (у даному випадку це 7 смуга). Також, від точності попередньої карти залежить точність наступної.

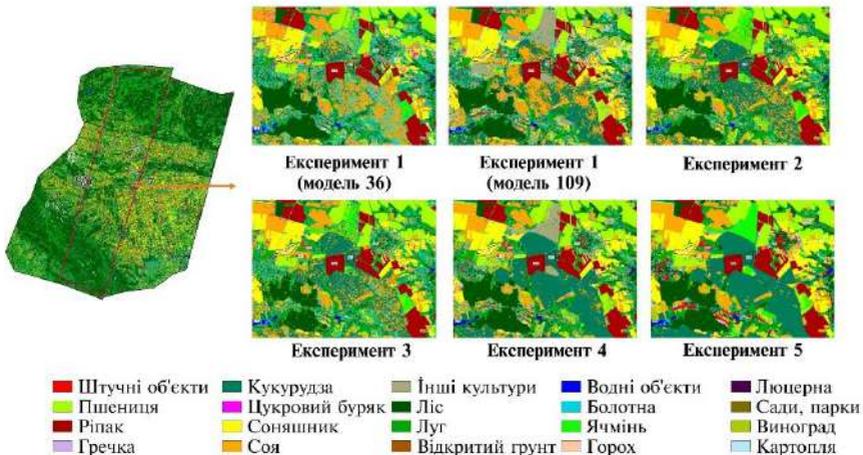


Рис. 3. Приклад результатів класифікації для 80 смуги

Для детальнішого аналізу точності класифікації основних класів (рис. 4-5) було обчислено значення F1-score, яке дозволяє оцінити точність моделі для кожного окремого класу [19]. Результати експериментів показують різну ефективність методів перенесення моделей та комбінованого навчання залежно від класу культури та смуги, на яку було перенесено модель.

Загалом, ріпак демонструє стабільно високу точність для всіх методів і смуг. Це пов'язано з особливостями спектральних характеристик ріпаку, особливо під час його цвітіння, коли він добре виділяється на знімках завдяки яскравим кольорам, що спрощує ідентифікацію незалежно від методу або смуги. Незначні коливання F1-score для ріпаку в різних експериментах вказують на його стійкість до перенесення моделей, навіть за умови різниці в умовах між смугами.

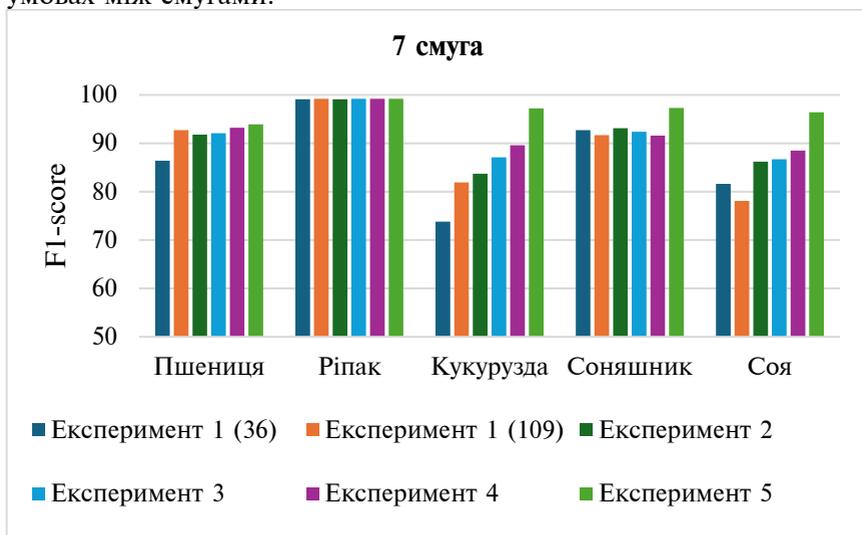


Рис. 4. F1-score основних культур для 7 смуги

Для пшениці спостерігається також висока точність класифікації незалежно від методу, що пояснюється тим, що більшість площ засіяні озимими зерновими. Під час початку вегетаційного сезону пшениця вже має високу вегетацію відносно інших культур, що робить її ідентифікацію відносно простою. Комбіноване навчання моделей і метод голосування покращили результати для пшениці, але навіть при перенесенні моделей з інших смуг точність залишалася на високому рівні, що вказує на високу узгодженість спектральних характеристик цієї культури.

3.4. Класифікації типів земного покриття та землекористування на основі...

Основні проблеми виникають із класифікацією кукурудзи та сої. Їхні спектральні характеристики досить схожі, особливо на початку вегетаційного сезону, що ускладнює точну класифікацію. Експерименти показують, що точність для кукурудзи та сої значно знижується, особливо при перенесенні моделі на 80 смугу. Наприклад, в експерименті 1 при перенесенні моделей із 36 смуги на 80 смугу F1-score для кукурудзи впав до 61.2%, а для сої — до 64.3%. Це свідчить про те, що класифікація цих культур є чутливою до змін спектральних характеристик і умов регіону.

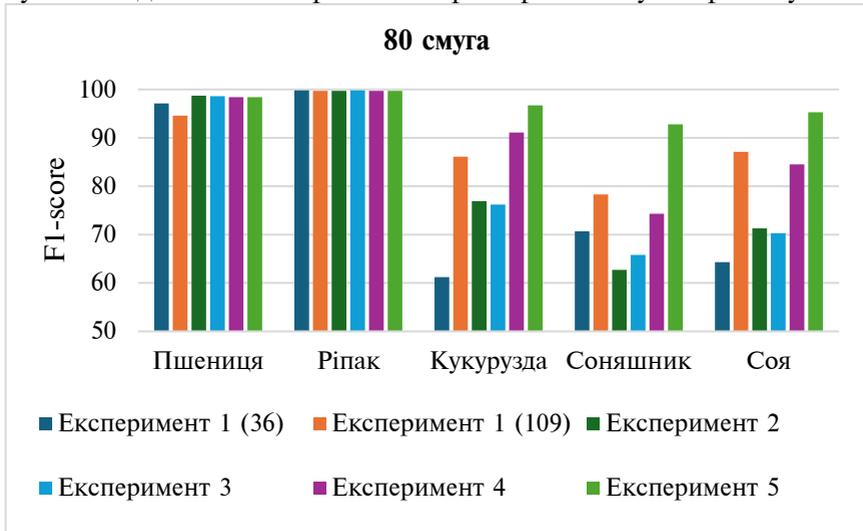


Рис. 5. F1-score основних культур для 80 смуги

Важливо відзначити, що експеримент 4, де використовувалися перетини смуг для створення навчальних вибірок, показав значно менший спад точності на 80 смугі порівняно з іншими методами. Це свідчить про те, що такий підхід дозволяє моделі краще адаптуватися до нових умов, враховувати регіональні відмінності, а також немає залежності від кількості вхідних ознак відносно інших смуг. Для кукурудзи та сої цей підхід дав помітно кращі результати, ніж інші методи перенесення моделей.

Найвищі результати для всіх культур показав експеримент 5 з використанням наземних даних. Це підтверджує важливість використання наземних даних для побудови точних моделей

класифікації, особливо для культур із подібними спектральними характеристиками.

Варто підкреслити результати другого експерименту, коли використовувалися всі дані (моделі) для побудови карти. Перевагою такого підходу є те, що результуюча модель може добре навчитися завдяки великій кількості навчальних даних, і як наслідок отримати хороший результат при перенесенні для інших територій. Основним недоліком такого підходу є те, що кількість знімків та період їхньої зйомки може значно відрізнятись, що може негативно вплинути на результат. Для приведення даних до однакового розміру, необхідно або зменшувати кількість даних щоб вирівняти їх кількість або додавати штучно нові дані. Такі підходи не гарантують отримання точних результатів.

Саме тому, підхід описаний в четвертому експерименті було використано для побудови карти для всієї території України. Так як мають достатню кількість даних для західних та центральних територій стає можливим отримання карт для сходу із високою точністю.

Для оперативного створення карти класифікації України та її оновлення із появою нових даних розроблено сценарії із використання хмарної платформи AWS (Amazon Web Services).

4.5. ІМПЛЕМЕНТАЦІЯ МОДЕЛІ МАШИННОГО НАВЧАННЯ З БАГАТОВИМІРНИМ ВЕКТОРНИМ ВИХОДОМ НА ОСНОВІ TRANSFER LEARNING НА ХМАРНІЙ ПЛАТФОРМІ AWS

Побудова карт класифікації земного покриття з використанням оптичних та радарних супутникових даних для території України з просторовим розрізненням 10 м є важливим завданням для моніторингу та аналізу аграрної діяльності та землекористування [20]. Для великої території найкраще виконувати побудову таких карт із використанням хмарних платформ [21] або високопродуктивних обчислень [22, 23]. Це може бути реалізовано на різних платформах, таких як AWS, Creodias та інші, оскільки супутникові дані Sentinel-1 і Sentinel-2 доступні на цих платформах. У подальшому дослідженні розглядатиметься приклад реалізації на AWS, хоча в загальному випадку вибір хмарної платформи не є критичним і може бути замінений іншими рішеннями.

3.4. Класифікації типів земного покриття та землекористування на основі...

Україна, розташована в Східній Європі, має велику територію та різноманітні типи культур, що робить її ідеальним об'єктом для дослідження з використанням супутникових даних. Для території України супутникові дані Sentinel-1 та Sentinel-2 є зручними завдяки їх доступності та можливості отримання інформації з різних спектральних і радарних діапазонів.

Якщо розглянути як відбувається зйомка України супутниками Sentinel-1, то щоб покрити країну необхідно 9 смуг (рис. 6). Для 6 (або 5 залежно від року) з них наявні дані наземних спостережень, які використовуються для навчання та тестування моделей класифікації. Для інших смуг (східних у всіх роках та для західних територій у 2017 році) дані відсутні, що потребує перенесення моделей для отримання карти класифікації всієї країни.

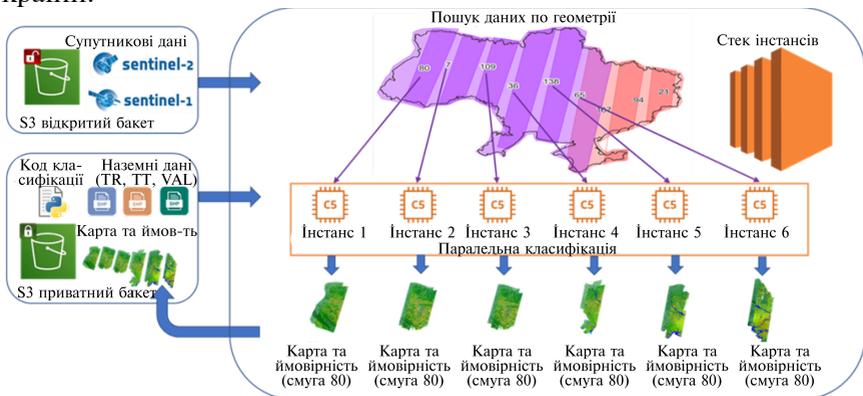


Рис. 6. Загальна схема побудови карт класифікації земного покриття в хмарній платформі AWS

Завдяки використанню хмарних платформ супутникові дані доступні безпосередньо на бакетах, що забезпечує можливість прямого доступу до них і значно скорочує час обробки. Для попередньої обробки даних Sentinel-1 використовуються інстанси, на яких встановлено програмний пакет SNAP (Sentinel Application Platform). SNAP дозволяє виконувати різноманітні операції, включаючи калібрування, геометричну корекцію, фільтрацію та інші операції над радарними даними.

При необхідності виконання атмосферної корекції для оптичних даних Sentinel-2, використовується інструмент Sen2Cor. Sen2Cor дозволяє виправляти атмосферний вплив на оптичні

зображення, враховуючи різні атмосферні умови та ефекти, такі як розсіювання світла атмосферою. Цей інструмент допомагає отримати більш точні та коректні дані, що можуть бути використані для аналізу та класифікації земного покриву. Велика частина обробки автоматизована за допомогою скриптів на мові програмування Python.

Навчальні, тестові та валідаційні дані, необхідні для навчання та тестування моделей класифікації, зберігаються на закритому бакеті AWS. Крім того, на бакеті AWS збережений код, який використовується для класифікації та обробки даних. Це дозволяє забезпечити централізований та надійний доступ до програмного забезпечення та алгоритмів, які використовуються в процесі створення карт класифікації земного покриву. Такий підхід сприяє збереженню даних та програмного забезпечення в безпечному та контрольованому середовищі, що є важливим аспектом при роботі з великими обсягами даних та конфіденційною інформацією.

Для досягнення ефективності та швидкості обробки великих обсягів даних для побудови карт класифікації земного покриву для України, використовується паралельний підхід. Попередня обробка та класифікація виконуються одночасно для кожної зі смуг, на які поділена територія України, і це відбувається на окремих обчислювальних інстансах.

Паралельна обробка даних для кожної смуги дозволяє оптимізувати використання ресурсів і швидкість обробки, а також підвищує продуктивність із врахуванням великих масштабів. Такий підхід обробки даних є особливо важливим при обробці великого обсягу супутникових даних для аналізу земного покриву на великій території. В результаті використання паралельного обчислення вдається зменшити час обробки та підвищити продуктивність завдяки розподіленню завдань на декілька незалежних інстансів.

Результатом виконання коду на кожному інстансі є: карта класифікації земного покриву та ймовірність належності кожного пікселя до визначеного класу.

Обидва растри зберігаються у форматі Geotiff на закритому бакеті AWS. Збереження цих даних на серверах AWS забезпечує їх доступність та зберігання в безпечному середовищі для подальшого аналізу та використання.

Для смуг супутникових даних, де відсутні навчальні дані, застосовується підхід перенесення моделей. Оскільки смуги перекриваються між собою, це дає можливість використовувати інформацію з попередньої смуги (рис. 7). Процес перенесення

3.4. Класифікації типів земного покриття та землекористування на основі...

навчання базується не на навченій моделі, а на результатах класифікації моделі. Тобто, щоб побудувати карту класифікації для наступної смуги створюються навчальні дані у місці перетину двох сусідніх смуг. Навчальні дані з попередньої смуги формуються на основі вибору пікселів з високою ймовірністю належності до різних класів земного покриття (обираються пікселі із ймовірністю не менше за 0.95). Кількість пікселів обирається рівномірно, з метою забезпечення балансу в навчальних даних. Після створення навчальних даних проводиться процес класифікації супутникових даних для смуги, для якої не було навчальних даних. Результати класифікації зберігаються на бакеті. Отримавши навчальні дані з попередньої смуги, аналогічний процес створення навчальної вибірки та класифікації виконується для всіх наступних смуг. Цей процес повторюється для кожної смуги без наявних навчальних даних до завершення побудови карт класифікації для всіх смуг. Такий підхід дозволяє ефективно побудувати карту класифікації для території України, навіть якщо не всі смуги мають навчальні дані.

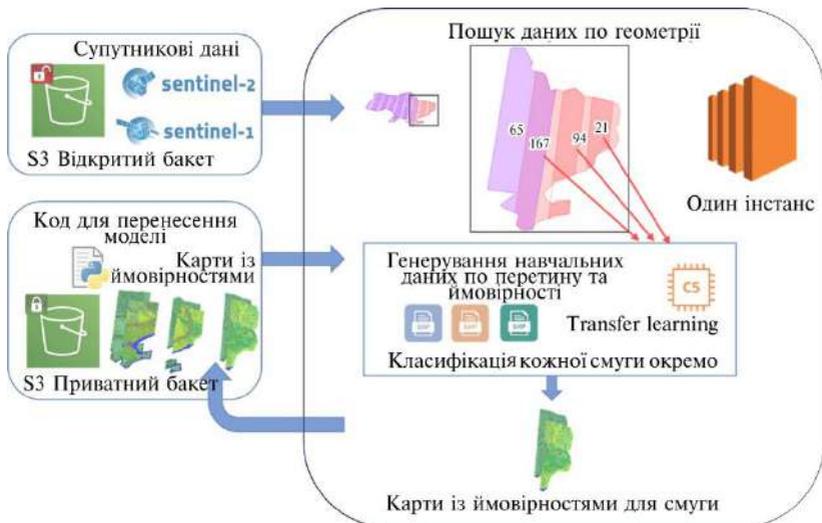


Рис. 7. Загальна схема побудови карт класифікації для територій із відсутніми навчальними даними в AWS

Недоліком такого підходу є те, що процес побудови карт класифікації для різних смуг супутникових даних є послідовним. Оскільки для створення наступної смуги потрібно використовувати попередню смугу, це означає, що робота над

класифікацією нових смуг не може розпочатися, поки не буде завершена попередня. Необхідність чекати завершення попередньої смуги може обмежувати продуктивністю та швидкістю класифікації супутникових даних, але з іншого боку, такий підхід дозволяє коректно виконувати класифікацію для різних смуг та забезпечити належну якість результатів.

Після успішної побудови та збереження усіх 9 смуг класифікації на вказаному бакеті, наступним кроком є об'єднання цих результатів, щоб отримати карту класифікації для всієї території України. Цей процес виконується на одному інстансі (рис. 8).

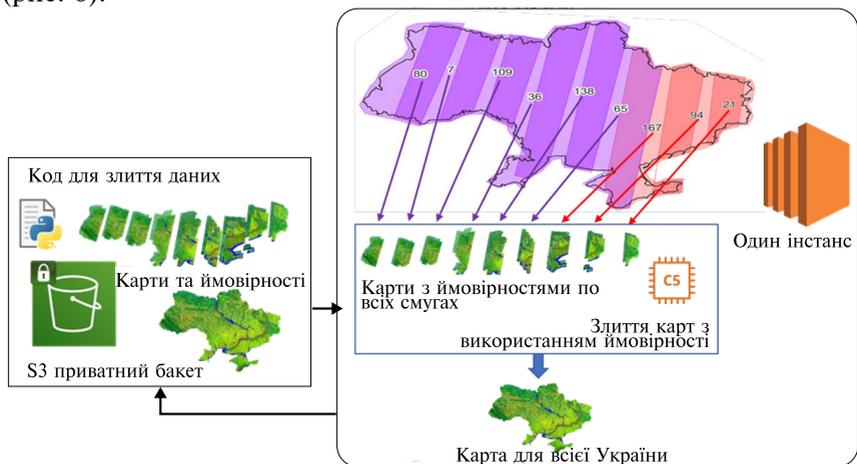


Рис. 8. Загальна схема злиття карт класифікації із врахуванням ймовірності кожного пікселя в AWS

Для об'єднання карт класифікації різних смуг супутникових даних в місця перетину сусідніх смуг вибирається піксель, для якого ймовірність належності до певного класу земного покриття є найвищою. Це допомагає визначити клас земного покриття для кожного пікселя для території України. Обрані пікселі з високою ймовірністю належності до класів земного покриття об'єднуються, щоб сформувати кінцеву карту класифікації для всієї України.

Такий підхід дозволяє створити єдину карту класифікації земного покриття для України, яка враховує результати класифікації для кожної смуги супутникових даних та забезпечує належну точність та інтерпретацію результатів.

ВИСНОВКИ

У даному розділі розглянуто можливості побудови карти класифікації земного покриття в умовах відсутності даних для деяких регіонів, зокрема для території України. Результати експериментів показали, що методи Transfer Learning можуть бути успішно застосовані для класифікації типів земного покриття в регіонах з обмеженими або відсутніми наземними даними. Перенесення моделей, навчених на даних з центральних регіонів України, на західні регіони продемонструвало прийнятну точність класифікації від 76.4% до 84.2%. Подібні моделі трансферного навчання розроблено кафедрою математичного моделювання і аналізу даних НТУУ “КПІ” для розв’язання інших задач супутникового моніторингу [24].

Використання комбінованих даних з різних регіонів для навчання моделей показало покращення точності класифікації до 87.4% для смуги 7, що свідчить про ефективність цього підходу для підвищення адаптивності моделей до різних географічних умов. Застосування методу голосування для вибору найбільш імовірного класу на основі результатів кількох моделей дозволило досягти точності 84.8% для смуги 7, підтверджуючи ефективність цього методу для зменшення невизначеності при класифікації.

Найбільш ефективним підходом виявилось використання перетинів смуг супутникових зображень для створення додаткових навчальних вибірок (експеримент 4). Цей метод дозволив досягти точності 91.2% для смуги 80, що наближається до точності класифікації на основі наземних даних. Хоча побудова карт на основі наземних даних все ще забезпечує найвищу точність класифікації (94.5-96.1%), запропоновані методи Transfer Learning дозволяють отримати досить точні результати в умовах відсутності наземних даних.

В рамках дослідження продемонстровано можливості хмарної платформи для ефективної паралельної обробки великих масивів супутникових даних з використанням її гнучких ресурсів. Зокрема, розроблено та впроваджено інформаційну технологію класифікації земного покриття для всієї території України на основі машинного навчання з використанням даних супутників Sentinel-1 та Sentinel-2. Основною перевагою хмарних платформ є здатність масштабувати обчислювальні ресурси під потреби великих проєктів, що значно прискорює процес обробки та дозволяє виконувати класифікацію на великих територіях. Розподілена

паралельна обробка даних здійснюється по смугах зйомки на окремих інстансах.

Для забезпечення класифікації на всій території України, зокрема в регіонах, де відсутні наземні дані, запропоновано використовувати метод перенесення навчання із застосуванням перетинів смуг для створення навчальних вибірок, що продемонстрував одні з найкращих результатів під час експериментів. Процес перенесення ґрунтується не на самій навчальній моделі, а на результатах її класифікації, оскільки сусідні смуги перекриваються між собою, що дозволяє використовувати інформацію з попередньої смуги для наступної. Таким чином, продемонстровано ефективність сучасних інструментів машинного навчання та хмарних технологій для обробки великих масивів супутникових даних.

Запропоновані підходи можуть бути застосовані для моніторингу земного покриву для інших країн, де збір наземних даних є складним або неможливим. Подальші дослідження можуть бути спрямовані на вдосконалення методів Transfer Learning для підвищення точності класифікації та та розробку нових методів геопросторового інтелекту [25].

ПЕРЕЛІК ПОСИЛАНЬ

1. Neyshabur, B., Sedghi, H., & Zhang, C. (2020). What is being transferred in transfer learning?. *Adv ances in neural information processing systems*, 33, 512-523.

2. Pandžić, M., Pavlović, D., Matavulj, P., Brdar, S., Marko, O., Crnojević, V., & Kilibarda, M. (2024). Interseasonal transfer learning for crop mapping using Sentinel-1 data. *International Journal of Applied Earth Observation and Geoinformation*, 128, 103718.

3. Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A review of deep transfer learning and recent advancements. *Technologies*, 11(2), 40.

4. Hao, P., Di, L., Zhang, C., & Guo, L. (2020). Transfer Learning for Crop classification with Cropland Data Layer data (CDL) as training samples. *Science of The Total Environment*, 733, 138869.

5. Papoutsis, I., Bountos, N. I., Zavras, A., Michail, D., & Tryfonopoulos, C. (2023). Benchmarking and scaling of deep learning models for land cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 195, 250-268.

3.4. Класифікації типів земного покриття та землекористування на основі...

6. Ma, Y., Chen, S., Ermon, S., & Lobell, D. B. (2024). Transfer learning in environmental remote sensing. *Remote Sensing of Environment*, 301, 113924.

7. Antonijević, O., Jelić, S., Bajat, B. et al. Transfer learning approach based on satellite image time series for the crop classification problem. *J Big Data* 10, 54 (2023). <https://doi.org/10.1186/s40537-023-00735-2>.

8. Dey, M., Prakash, P. S., & Aithal, B. H. (2024). UnetEdge: A transfer learning-based framework for road feature segmentation from high-resolution remote sensing images. *Remote Sensing Applications: Society and Environment*, 34, 101160.

9. Zou, M., Zhong, Y. Transfer Learning for Classification of Optical Satellite Image. *Sens Imaging* 19, 6 (2018). <https://doi.org/10.1007/s11220-018-0191-1>.

10. Wang, Y., Feng, L., Zhang, Z., & Tian, F. (2023). An unsupervised domain adaptation deep learning method for spatial and temporal transferable crop type mapping using Sentinel-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 199, 102-117.

11. Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.

12. Tong, X. Y., Xia, G. S., Lu, Q., Shen, H., Li, S., You, S., & Zhang, L. (2020). Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment*, 237, 111322.

13. Dastour, H., & Hassan, Q. K. (2023). A comparison of deep transfer learning methods for land use and land cover classification. *Sustainability*, 15(10), 7854.

14. Nowakowski, A., Mrziglod, J., Spiller, D., Bonifacio, R., Ferrari, I., Mathieu, P. P., ... & Kim, D. H. (2021). Crop type mapping by using transfer learning. *International Journal of Applied Earth Observation and Geoinformation*, 98, 102313.

15. Gadiraju, K. K., & Vatsavai, R. R. (2023). Remote sensing based crop type classification via deep transfer learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 4699-4712.

16. Benbriqa, H., Abnane, I., Idri, A., Tabiti, K. (2021). Deep and Ensemble Learning Based Land Use and Land Cover Classification. In: Gervasi, O., et al. *Computational Science and Its Applications – ICCSA 2021. ICCSA 2021. Lecture Notes in Computer Science*, vol 12951. Springer, Cham. https://doi.org/10.1007/978-3-030-86970-0_41.

17. Skakun, S., Kussul, N., Shelestov, A. Y., Lavreniuk, M., & Kussul, O. (2015). Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(8), 3712-3719.

18. Mikava, P., & Yailymov, B. (2024). Методи машинного навчання для моніторингу навколишнього середовища. *International Scientific Technical Journal "Problems of Control and Informatics"*, 69(2), 108-122.

19. Shelestov, A., Lavreniuk, M., Vasiliev, V., Shumilo, L., Kolotii, A., Yailymov, B., ... & Yailymova, H. (2019). Cloud approach to automated crop classification using Sentinel-1 imagery. *IEEE Transactions on Big Data*, 6(3), 572-582.

20. Lavreniuk, M., Kussul, N., & Novikov, A. (2018, July). Deep learning crop classification approach based on sparse coding of time series of satellite data. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4812-4815). IEEE.

21. Kussul, N., Shelestov, A., & Yailymov, B. (2022, November). Cloud Platforms and Technologies for Big Satellite Data Processing. In *International scientific and practical conference Information and communication technologies and sustainable development* (pp. 303-321). Cham: Springer Nature Switzerland.

22. Куссуль Н. Н. Grid-системы для задач исследования Земли. *Архитектура, модели и технологии / Н. Н. Куссуль, А. Ю.Шелестов. — К. : Наукова думка, 2008. — 452 с.*

23. G. M. Bakan and N. N. Kussul, "Fuzzy ellipsoidal filtering algorithm of static object state", *Problemy Upravleniya I Informatiki (Avtomatika)*, vol. 5, no. 5, pp. 77-92, 1996.

24. N. Kussul, V. Kuzin, Y. Salii, B. Yailymov and A. Shelestov, "Single-polarized SAR Image Preprocessing in Scope of Transfer Learning for Oil Spill Detection," *2024 IEEE 12th International Conference on Intelligent Systems (IS)*, Varna, Bulgaria, 2024, pp. 1-6, doi: 10.1109/IS61756.2024.10705228.

25. Kussul, N., Shelestov, A., Basarab, R., Skakun, S., Kussul, O., & Lavrenyuk, M. (2015). Geospatial Intelligence and Data Fusion Techniques for Sustainable Development Problems. *ICTERI, 1356*, 196-203.

СУЧАСНІ ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ ДЛЯ КОМП'ЮТЕРНОГО ЗОРУ І ГЛИБОКИХ НЕЙРОННИХ МЕРЕЖ

1. СУЧАСНІ ПІДХОДИ ДО ЗЛИТТЯ ТА ГАРМОНІЗАЦІЇ РІЗНОРІДНИХ ГЕОПРОСТОРОВИХ ДАНИХ

Андрій Шелестов, професор
Кафедра математичного моделювання і аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

andrii.shelestov@gmail.com

ВСТУП

Хмарні платформи відіграють критичну роль у забезпеченні ефективного злиття та гармонізації різнорідних геопросторових даних, враховуючи їхню різноманітність та велику кількість. Ці інноваційні технологічні засоби надають потужні інструменти для оптимального поєднання та аналізу різних джерел географічної інформації.

Одним з ключових аспектів хмарних платформ є їх можливості для зберігання, обробки та обміну даними в реальному часі. Це дозволяє різним користувачам з різних місць спільно працювати над даними та спрощує процеси спільної обробки. Ще однією значущою перевагою є можливість інтеграції різних форматів даних з різних джерел. Це допомагає уникнути проблем з несумісністю та забезпечує безперешкодний потік інформації з різних джерел. Хмарні платформи також надають набір інструментів для обробки та аналізу геопросторових даних. Це може включати в себе використання геоінформаційних систем (ГІС), візуальний аналіз даних, статистичний аналіз та методи машинного навчання для вилучення додаткової інформації з наявних датасетів.

Важливою функцією хмарних платформ є забезпечення доступу до готових наборів даних та географічних послуг. Це може

включати в себе геопросторові дані, картографічні послуги, інструменти геоаналізу та візуалізації. Завдяки цим можливостям, хмарні платформи дозволяють вирішувати складні задачі злиття та гармонізації геопросторових даних. Вони забезпечують швидкий доступ, зручність спільної роботи та розширені можливості аналізу, що робить їх незамінними інструментами для дослідження геопросторової інформації.

1.1. ХМАРНІ ПЛАТФОРМИ ЯК ІНСТРУМЕНТ ГАРМОНІЗАЦІЇ РІЗНОРІДНИХ ДАНИХ

На даний момент у світі існує чимало хмарних платформ, які надають інфраструктуру для роботи з готовими до використання супутниковими даними у зручний спосіб, що дозволяє перейти від підготовки даних до власне їх аналізу. Зокрема, Open Geospatial Consortium (OGC) [1] у травні 2023 року анонсував формування робочої групи [2] по розробці стандартів геопросторових даних, готових до аналізу (Analysis Ready Data — ARD). Дана робоча група у партнерстві з ISO/TC 211 [3] працює з багатокomпонентним стандартом для даних, готових до геопросторового аналізу, який спиратиметься на попередню роботу, виконану Комітетом з супутникових спостережень Землі CEOS [4]. Концепція ARD спочатку була розроблена комітетом CEOS, який визначає ARD як «супутникові дані, які були оброблені відповідно до мінімального набору вимог і організовані у форматі, який дозволяє здійснювати як швидкий аналіз із мінімумом додаткових зусиль користувача, так і аналіз часових рядів, а також виконувати злиття з іншими наборами даних». Прийнявши визначення CEOS-ARD як відправну точку, робоча група OGC розширить сферу застосування ARD із супутникових даних на всі геопросторові дані та розробить відповідні стандарти обміну та представлення геопросторової інформації. Використання хмарних платформ для роботи з готовими до аналізу супутниковими даними, таких як Google Earth Engine (GEE) або хмарної платформи CREODIAS, має кілька значних переваг.

- **Масштабованість:** Хмарні платформи надають доступ до потужних обчислювальних ресурсів, що дозволяє обробляти великі обсяги супутникових даних. Можна працювати з великими архівами зображень та проводити складні обчислення без необхідності підтримки власних великих обчислювальних потужностей.

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

- **Швидкість та продуктивність:** Хмарні платформи використовують розподілені обчислення, що дозволяє розподілити завдання обробки даних між кількома серверами. Це забезпечує швидшу обробку даних, оскільки завдання можуть бути виконані паралельно.

- **Зручний доступ до даних:** Завантаження та зберігання великого обсягу супутникових даних може бути складним завданням, якщо для цього використовуються власні ресурси організації або розробника. Хмарні платформи надають централізований доступ до великих архівів даних без необхідності їх локального зберігання, що зручно для спільної роботи та обміну даними з колегами. Формат зберігання ARD-даних у хмарі передбачає можливість вчитки лише цільової частини знімку.

- **Висока доступність:** Хмарні платформи надійні і мають високу доступність, оскільки вони забезпечують резервне копіювання та реплікацію даних на різних серверах. Можна бути впевненим в доступності даних та сервісів в будь-який час.

- **Інтеграція та спільна робота:** Хмарні платформи мають інтегровані інструменти та сервіси, що сприяють спільній роботі, обміну даними та взаємодії між різними користувачами. Вони дозволяють легко обмінюватися результатами, візуалізувати дані та спільно працювати над проектами.

- **Оновлення та вдосконалення:** Хмарні платформи постійно оновлюються та покращуються, включаючи додавання нових функцій, інструментів та джерел даних. Є доступ до нових можливостей без необхідності самостійного оновлення апаратного забезпечення або програмного забезпечення.

Ці переваги хмарних платформ забезпечують зручний та ефективний спосіб роботи з великими обсягами попередньо оброблених та гармонізованих супутникових даних, дозволяючи швидко виконувати обробку, аналіз та візуалізацію даних без значних обчислювальних ресурсів та сховищ даних на локальному рівні.

1.2. ІНФРАСТРУКТУРА GOOGLE EARTH ENGINE

Google Earth Engine (GEE) - це хмарна платформа, розроблена компанією Google, яка призначена для обробки, аналізу та візуалізації геопросторових даних, зокрема супутникових зображень. GEE поєднує в собі великі обсяги супутникових даних з розподіленими обчисленнями та хмарною інфраструктурою, що

дозволяє виконувати обробку даних великого масштабу безпосередньо в хмарі (рис. 1).

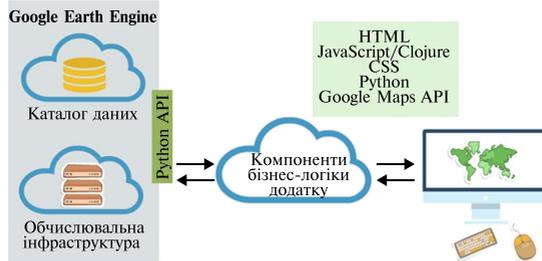


Рис. 1. Інфраструктура GEE для роботи з геопросторовими даними

Основні характеристики та можливості Google Earth Engine вклячають наступні.

- **Великий обсяг наявних даних.** GEE містить велику кількість супутникових даних з різних джерел, таких як Landsat, Sentinel та MODIS, а також інших джерел. Це дозволяє швидко отримувати доступ до багатогігабайтних архівів зображень та даних про земну поверхню.

- **Хмарна інфраструктура.** GEE використовує хмарну інфраструктуру Google для розподілених обчислень. Це означає, що є можливість обробляти дані безпосередньо на серверах Google, замість завантаження їх в локальну інфраструктуру чи на користувацький комп'ютер. Це забезпечує швидку та ефективну обробку великих обсягів даних.

- **Програмний інтерфейс (API).** GEE надає API для роботи з платформою, яке дозволяє розробникам створювати власні програми та скрипти для доступу до даних і виконання аналізу. API підтримує кілька мов програмування, зокрема JavaScript та Python.

- **Аналіз та обробка даних.** GEE має вбудовані алгоритми для обробки супутникових даних. Це вклячає розрахунок статистики, класифікацію, фільтрацію, аналіз часових рядів тощо.

- **Візуалізація даних.** GEE надає потужні інструменти для візуалізації супутникових даних. Є можливість створювати зображення, відео, анімацію та використовувати інші візуальні ефекти для представлення даних на карті або в інтерактивному режимі.

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

В інфраструктурі Google Earth Engine (GEE) доступні різні способи роботи з супутниковими даними. Ось деякі з них:

- **Запити з використанням JavaScript або Python.** GEE надає можливість створювати та виконувати запити до попередньо підготовленого каталогу супутникових даних за допомогою мов програмування JavaScript або Python.

- **Вбудовані алгоритми обробки.** GEE має багато вбудованих алгоритмів обробки супутникових даних, які можна використовувати для видалення додаткової інформації з зображень. Це включає фільтрацію, класифікацію, аналіз часових рядів, отримання індексів (наприклад, NDVI, NDWI) та багато іншого.

- **Візуалізація даних.** GEE має потужні можливості по візуалізації супутникових даних. Можна створювати кольорові зображення, зображення з псевдокольорами, анімацію та інші візуальні ефекти для наочного представлення даних та результатів їх обробки.

- **Обробка великого обсягу даних:** Інфраструктура GEE спеціально розроблена для обробки супутникових даних великого об'єму. GEE використовує розподілені обчислення та хмарну інфраструктуру компанії Google для швидкої та ефективної обробки даних великого обсягу без необхідності їх локального завантаження.

- **Інтеграція з іншими інструментами:** GEE підтримує інтеграцію з різними інструментами та сервісами, включаючи Google Maps API, Google Earth, Google Drive та інші. Це дозволяє легко обмінюватися даними, візуалізувати їх на карті та інтегрувати з іншими проектами. Можна виконувати роботи в онлайн-редакторі в браузері (рис. 2).

GEE надає доступ до широкого переліку супутникових даних і геопросторових даних з різних джерел. Ось кілька прикладів джерел даних, доступних у відкритому каталозі GEE (<https://developers.google.com/earth-engine/datasets/catalog>):

- **Landsat.** Каталог Landsat включає дані різних супутників Landsat, таких як Landsat 5, Landsat 7 та Landsat 8. Ці колекції містять мультиспектральні зображення з високим просторовим розрізненням.

- **Sentinel.** Каталог Sentinel містить дані супутників Sentinel-2 та Sentinel-1. Sentinel-2 надає мультиспектральні зображення з просторовим розрізненням 10 м, а Sentinel-1 надає радарні дані з просторовим розрізненням 10 м.

- **MODIS.** Каталог MODIS містить дані супутників Terra та Aqua, обладнаних інструментом MODIS (Moderate Resolution Imaging Spectroradiometer). Ці дані використовуються для спостережень за кліматом, дослідження змін екології та інших глобальних процесів.

- **Landsat Global Archive Consolidation.** Цей каталог містить зображення з Landsat, які були відновлені та виправлені для забезпечення вищої якості даних.

Векторні дані: GEE також має колекцію векторних даних, таких як кордони країн, адміністративні одиниці, гідрографічні дані тощо.

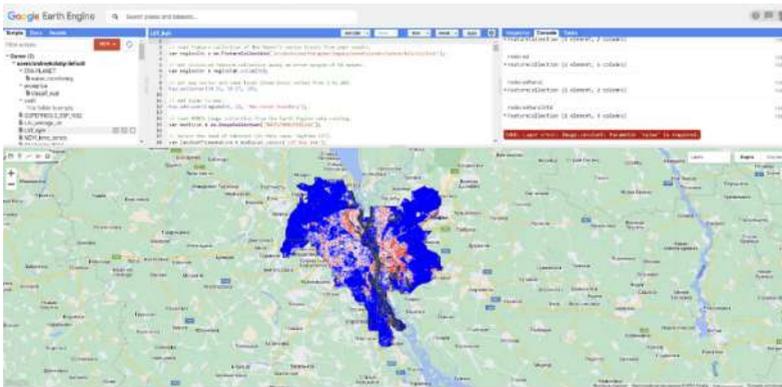


Рис. 2. Редактор коду GEE та приклад візуалізації даних

Каталог даних (рис. 3) постійно оновлюється, і в ньому можуть бути представлені дані з інших джерел, а також спеціалізовані набори даних для конкретних галузей застосування. Користувачі можуть здійснювати пошук та використовувати ці дані в прикладних дослідженнях на платформі GEE.

CREODIAS [6] - це хмарна платформа, розроблена за підтримки Європейського космічного агентства, яка надає користувачам прямий доступ до широкого спектра супутникових даних, зокрема даних від супутників Sentinel Європейської програми Copernicus, Landsat, MODIS та інших геопросторових продуктів. CREODIAS забезпечує доступ до репозиторію даних Copernicus і дозволяє користувачам зберігати, обробляти та аналізувати великі обсяги даних спостереження Землі в хмарному середовищі. Платформа надає оброблені супутникові дані (ARD) з зручним веб-інтерфейсом, полегшуючи доступ до них для дослідників, бізнесу та інших організацій.

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

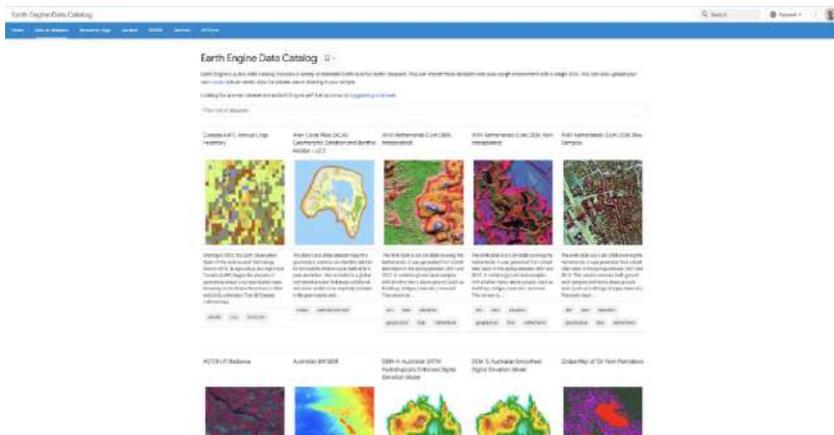


Рис. 3. Каталог даних GEE

1.3. ІНФРАСТРУКТУРА CREODIAS

CREODIAS надає наступні можливості (рис. 4).

- **Доступ до даних.** CREODIAS надає доступ до великої кількості даних спостереження Землі з різних супутників. Ці дані можна використовувати для різних цілей, наприклад для моніторингу землекористування, відстеження зміни клімату та управління природними ресурсами.

- **Обробка даних.** CREODIAS пропонує різноманітні інструменти та сервіси для обробки даних спостереження Землі. Ці інструменти можна використовувати для отримання інформації з даних, такої як розташування об'єктів, ступінь ґрунтового покриття та кількість рослинності.

- **Візуалізація даних.** CREODIAS надає різні засоби візуалізації даних спостереження Землі. Ці інструменти можна використовувати для побудови карт, діаграм та інших представлень.

- **Технічна підтримка.** В межах сервісу підтримки користувачам пропонується технічна підтримка.

- **Документація:** CREODIAS містить детальну документацію, яка може допомогти користувачам дізнатися про платформу, наявні інструменти та послуги.

- **Форуми користувачів.** CREODIAS пропонує набір форумів користувачів, де можна ставити запитання та ділитися інформацією.

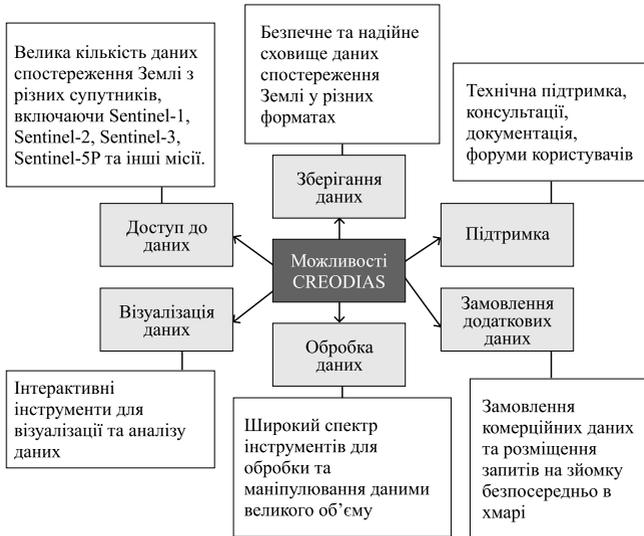


Рис. 4. Можливості хмарної платформи CREODIAS

В каталозі платформи представлені дані наступних супутникових апаратів:

- **Sentinel-1.** Радарні дані просторового розрізнення 10 м, вимірювання висоти поверхні, виявлення змін, вимірювання деформацій та багато іншого.

- **Sentinel-2.** Оптичні дані з просторовим розрізненням 10 м, що включають багатоспектральні зображення, які можуть використовуватись для оцінки вегетації, моніторингу водних ресурсів, класифікації земельного покриття, картографування тощо.

- **Sentinel-3.** Дані про океан, включаючи океанографічні параметри, температуру поверхні моря, стан хвиль, хмарність над поверхнею води, забруднення води та інші показники стану океану.

- **Sentinel-5P.** Дані про атмосферу, включаючи інформацію про розподіл газів, аерозолів, озоновий шар та інші атмосферні параметри.

- **Sentinel-6.** Дані моніторингу океанів, зокрема вимірювання рівня моря, хвиль та інших параметрів води.

- **EUMETSAT.** Дані геостационарних метеорологічних супутників Європейського метеорологічного центру EUMETSAT, включаючи дані з супутників Meteosat та MetOp.

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

Варто також висвітлити деякі ключові особливості платформи CREODIAS (рис. 5), зокрема наступні.

- **Плата за використання та пакетні підписки.** Користувачі можуть вибрати модель ціноутворення, яка найкраще відповідає їх потребам незалежно від того, чи хочуть вони платити за кожне окреме використання платформи чи підписатися на місячний або річний план.

- **Відкритість та сумісність.** платформа CREODIAS є відкритою та сумісною з різними стандартами, що дозволяє компаніям легко інтегрувати її зі іншими існуючими системами.

- **Безкоштовне надання послуг.** Платформа CREODIAS пропонує безкоштовне надання послуг, а саме кожен може отримати до неї доступ та використовувати її в некомерційних цілях.

- **Комерційний модуль для використання сторонніми операторами.** CREODIAS також пропонує комерційний модуль, який надає можливість розгортання власних програм та сервісів на платформі.

Європейська хмарна платформа пропонує зручні інструменти для навігації у великому обсязі супутникових знімків. За допомогою програми EO Browser (рис. 6) [7] можна легко отримати необхідні зображення шляхом простого запиту. Для цього потрібно вказати всього три параметри: ім'я супутникової системи, відсоток хмарності в межах від 0 до 100 та період часу. Отримані результати можна переглядати в режимах True або False Color, а також із застосуванням індексів, таких як NDVI чи EVI, або власних комбінацій каналів. Після пошуку можна зберегти посилання для подальшого обміну результатами, або завантажити зображення без геопросторової прив'язки. Цей засіб особливо корисний для швидкого виконання візуального аналізу конкретної території та порівняльного аналізу різних зображень.

Каталог даних хмарної платформи Creodias доступний за посиланням [8]. Він дозволяє виконувати операції з пошуку за локацією, часовим інтервалом, типом продукту, хмарним покривом (для оптичних даних). Після обробки дані можуть бути скопійовані у файлове сховище користувача.

Data Explorer (рис. 7) [8] — це сервіс, який втілює весь раніше накопичений досвід платформи та її користувачів і відрізняється розширеним функціоналом. За допомогою даного інструменту можна більш детально ознайомитися з наявними продуктами та одночасно використати їх при розв'язанні користувацьких задач.

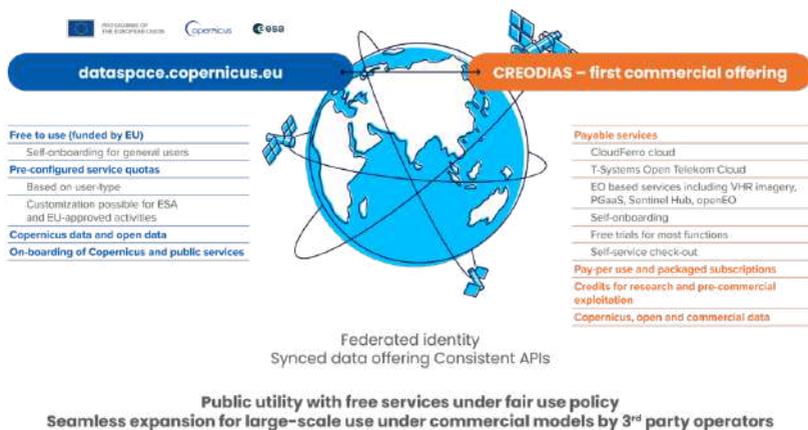


Рис. 5. Особливості хмарної платформи CREODIAS

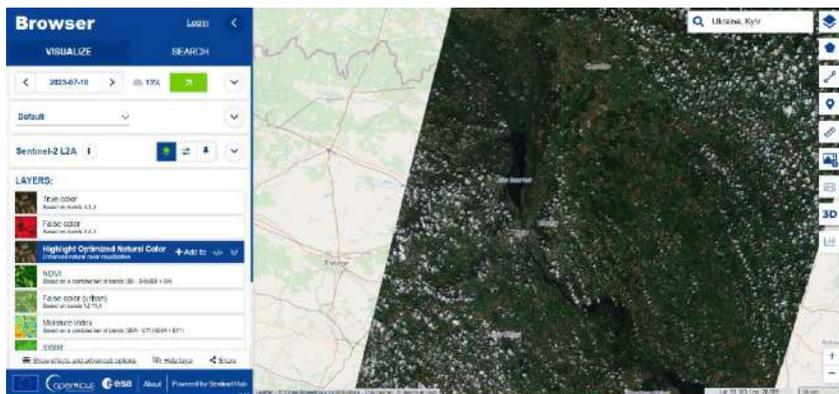


Рис. 6. Сервіс EO Browser

Для роботи з супутниковими даними на платформі CREODIAS можна використовувати API-інтерфейс, який нею надається. API CREODIAS дозволяє отримувати доступ до каталогу даних, здійснювати їх пошук, отримувати метадані та завантажувати безпосередньо самі супутникові дані.

Основними елементами API CREODIAS є наступні.

- **Catalog API:** Цей API дозволяє здійснювати пошук та отримувати інформацію про наявні супутникові дані в інфраструктурі. Є можливість шукати дані за датою,

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

географічними координатами, супутниковим сенсором, типом даних та іншими параметрами. Запити до Catalog API дозволяють знайти необхідні дані для вашого застосування.

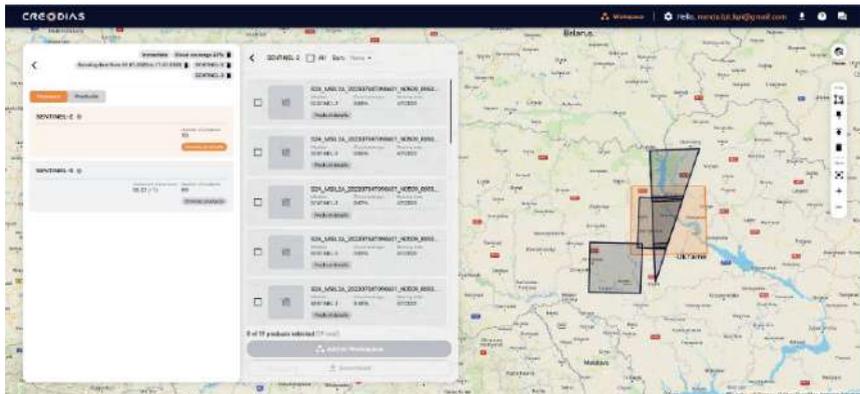


Рис. 7. Data Explorer

- **Download API:** Цей API дозволяє завантажувати супутникові дані. Після пошуку та вибору необхідних даних можна використати інструменти Download API для отримання власних файлів даних. Завантаження може здійснюватися через протокол FTP або за допомогою HTTPS-запиту.

- **Metadata API:** Цей API дозволяє отримати метадані про супутникові дані. Є можливість отримати детальну інформацію про кожний супутниковий знімок, включаючи параметри супутникового сенсора, дату та час зйомки, розміри файлу та інші характеристики. Ця інформація корисна для подальшого аналізу та використання супутникових даних.

Для взаємодії з API CREODIAS можна використовувати різні мови програмування та спеціалізовані бібліотеки. Наприклад, у Python можна використовувати бібліотеки, такі як creodiaspy або sentinelsat, для спрощення комунікації з API та зручного отримання даних.

В платформі присутній також **Horizon Cloud Dashboard** — це Веб-інтерфейс, що дозволяє легко керувати хмарними ресурсами, такими як віртуальні машини, томи сховищ і мережі (рис. 8). Він заснований на відкритому ПЗ OpenStack. Завдяки цьому інструменту, користувачі можуть швидко створювати і налаштовувати нові віртуальні машини з різними операційними системами, змінювати параметри, наприклад, об'єм SSD-диска,

або змінювати об'єм оперативної пам'яті та кількість ядер CPU. Через цей інтерфейс надається також доступ до різних хмарних послуг, таких як сховище об'єктів, бази даних і засоби балансування навантаження. Horizon Cloud Dashboard є потужним інструментом керування хмарними ресурсами. Це ідеальний вибір для організацій, що шукають масштабовану та надійну хмарну платформу з відкритим кодом.

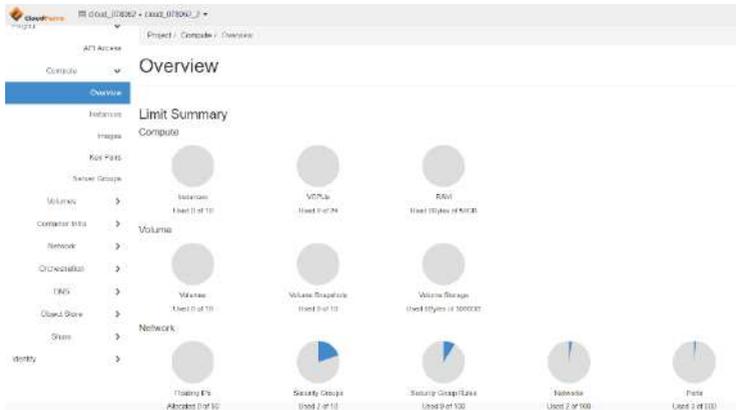


Рис. 8. Horizon Cloud Management Panel

На віртуальних обчислювальних ресурсах, доступних в інфраструктурі CREODIAS, є можливість працювати з геопросторовими даними, які зберігаються у хмарі, напряду (рис. 9).

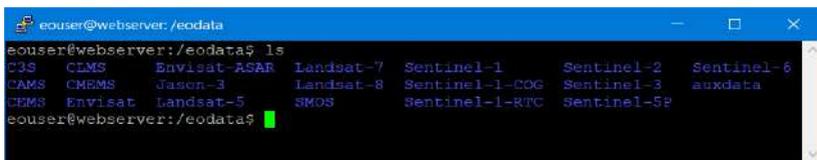


Рис. 9. Каталог даних на хмарному обчислювальному сервері CREODIAS

ВИСНОВКИ

В даному розділі проаналізовано сучасні хмарні платформи обробки геопросторових даних Google Earth Engine та CREODIAS. Вони дозволяють використовувати великі обсяги гармонізованих

4.1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових...

даних, готових для подальшого аналізу, та потужну обчислювальну інфраструктуру. Сучасні хмарні платформи, які містять як обчислювальну інфраструктуру, так і каталоги гармонізованих готових до використання супутникових даних (Analysis ready data — ARD) стали невід'ємною частиною сучасного геопросторового аналізу та складовою парадигми, яка передбачає зміщення фокусу уваги на дослідження, а не на зусилля з попередньої підготовки даних. Хмарні платформи надають можливості масштабування обчислювальної інфраструктури, зручний доступ до даних, можливості інтеграції та спільної роботи. Широкий спектр даних, масштабовані обчислювальні потужності дозволяють швидко та ефективно організовувати роботу з геопросторовими даними.

Хмарні платформи дозволяють ефективно розв'язувати складні задачі обробки геопросторових даних без витрат на створення власної ІТ-інфраструктури [9–12]. Використання хмарних платформ є перспективним напрямком для розробки інформаційних систем геопросторового аналізу [13–15].

ПЕРЕЛІК ПОСИЛАНЬ

1. Консорціум по розробці стандартів обміну геопросторовою інформацією OGC. [Електронний ресурс]. Режим доступу до ресурсу: <https://www.ogc.org/>.

2. Робоча група OGC щодо стандартів ARD [Електронний ресурс]. – Режим доступу до ресурсу: <https://www.ogc.org/press-release/ogc-forms-new-analysis-ready-data-standards-working-group/>.

3. Технічний комітет по стандартизації [Електронний ресурс]. – Режим доступу до ресурсу: <https://www.iso.org/committee/54904.html>.

4. Комітет CEOS. URL: <https://ceos.org/>.

5. Google Earth Engine CEOS. [Електронний ресурс]. – Режим доступу до ресурсу: <https://earthengine.google.com/>.

6. Хмарна платформа CREODIAS. URL: [Електронний ресурс]. – Режим доступу до ресурсу: <https://creodias.eu/>.

7. Сервіс EO Browser платформи CREODIAS. [Електронний ресурс]. – Режим доступу до ресурсу: <https://browser.creodias.eu/>.

8. Сервіс Data Explorer платформи CREODIAS. [Електронний ресурс]. – Режим доступу до ресурсу: <https://explore.creodias.eu/>.

9. Kussul, N., Shelestov, A., Yailymov, B. та ін. Cloud Platforms and Technologies for Big Satellite Data Processing. In: Dovgyi, S.,

Trofymchuk, O., Ustimenko, V., Globa, L. (eds) Information and Communication Technologies and Sustainable Development. ICT&SD 2022. Lecture Notes in Networks and Systems, 2023. vol 809. Springer, Cham. pp. 303–321. https://doi.org/10.1007/978-3-031-46880-3_19

10. Shelestov, A., Saliy, Y., Hordiiko та ін., N. Current Advances on Cloud-Based Distributed Computing for Forest Monitoring, Yailymova, H. In: Dovgyi, S., Trofymchuk, O., Ustimenko, V., Globa, L. (eds) Information and Communication Technologies and Sustainable Development. ICT&SD 2022. Lecture Notes in Networks and Systems, 2023. vol 809. Springer, Cham. pp. 322–336. https://doi.org/10.1007/978-3-031-46880-3_20.

11. B. Yailymov, A. Shelestov, H. Yailymova та ін. Google Earth Engine Framework for Satellite Data-Driven Wildfire Monitoring in Ukraine, In: Fire. 2023; 6(11):411. <https://doi.org/10.3390/fire6110411>.

12. N. Kussul, S. Drozd, H. Yailymova et. al. Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning // International Journal of Applied Earth Observation and Geoinformation, Dec. 2023, Vol 125, 103562, pp. 1-21, <https://doi.org/10.1016/j.jag.2023.103562>.

13. Kuzin V., Shelestov A., Musial J. EO4UA initiative: scientific European Support of Ukrainian scientific community // In: *12th International Conference on Dependable Systems, Services and Technologies (DESSERT'2022), December 9-11, 2022, Greece, Athens*. DOI: 10.1109/DESSERT58054.2022.10018706.

14. A. Shelestov, B. Yailymov, H. Yailymova et al. Cloud-Based Technologies for Data Processing in Ukraine: International Context, // In: Ilchenko, M., Uryvsky, L., Globa, L. (eds) Progress in Advanced Information and Communication Technology and Systems. MCiT 2021. Lecture Notes in Networks and Systems, vol 548. Springer, Cham. pp. 101–118. DOI: 10.1007/978-3-031-16368-5_5.

15. L. Shumilo, S. Drozd, N. Kussul et.al. Mathematical Models and Informational Technologies of Crop Yield Forecasting in Cloud Environment // In: Ilchenko, M., Uryvsky, L., Globa, L. (eds) Progress in Advanced Information and Communication Technology and Systems. MCiT 2021. Lecture Notes in Networks and Systems, vol 548. Springer, Cham. pp. 143–164. DOI: 10.1007/978-3-031-16368-5_7.

2. ЗАСОБИ ПУБЛІКАЦІЇ ТА ПРЕДСТАВЛЕННЯ ГЕОПРОСТОРОВИХ ДАНИХ В ІНТЕРНЕТ

Андрій Колотій, старший викладач¹, старший науковий співробітник²

¹ Кафедра математичного моделювання та аналізу даних
Навчально-науковий Фізико-технічний інститут
Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»

² Відділ космічних інформаційних технологій і систем
Інститут космічних досліджень НАН України та ДКА України

andrew.k.911@gmail.com

ВСТУП

Геопросторові дані відіграють ключову роль у багатьох сучасних сферах діяльності, від управління природними ресурсами до міського планування та екологічного моніторингу. Їх належна обробка, зберігання та представлення стали важливими завданнями для багатьох організацій та наукових установ. Зокрема, значне місце в цих процесах займають геопортали — веб-системи, які надають користувачам зручний доступ до різноманітних картографічних ресурсів і можливість інтерактивної взаємодії з ними.

Розвиток технологій, поява відкритих даних та вдосконалення мережесних інструментів значно спростили процеси публікації та візуалізації геопросторових даних в Інтернеті. Це призвело до зростання популярності геопорталів, які дозволяють користувачам без прив'язки до конкретного місця працювати з великими обсягами геоінформації. Інструменти геопорталів знаходять застосування в таких сферах, як моніторинг навколишнього середовища, розробка міської інфраструктури, управління ресурсами та створення систем «розумних міст».

В даному розділі наведено огляд сучасних підходів до публікації геопросторових даних через Інтернет, аналіз ключових компонентів та технологій для створення ефективних геопорталів, а також визначення основних факторів, що впливають на вибір відповідних технологічних рішень для їх реалізації.

2.1. ОГЛЯД ПОРТАЛІВ

Геопортали стали невід'ємною частиною сучасних інформаційних систем [1], які надають можливість зберігати, візуалізувати та аналізувати геопросторові дані без прив'язки до конкретного робочого місця. Вони є інструментами, що дозволяють об'єднати різноманітні джерела даних у зручному Веб-інтерфейсі, надаючи користувачам доступ до картографічної інформації, супутникових знімків, даних про землекористування тощо [2]. Сучасні геопортали використовуються в різних галузях, включаючи управління природними ресурсами, планування міської інфраструктури, екологічний моніторинг та застосунки розумного міста [3]. Завдяки розвитку технологій і доступності відкритих даних, створення геопорталів стало доступнішим, що сприяє їх широкому застосуванню. У цьому розділі розглядаються ключові компоненти та технології, які використовуються для створення геопорталів, а також фактори, що впливають на вибір технологічної платформи для їх реалізації.

Геопортали є потужними інструментами для зберігання, візуалізації та аналізу геопросторових даних. Вони об'єднують дані з різних джерел, надаючи користувачам можливість переглядати, аналізувати та взаємодіяти з цими даними. Розглянемо основні компоненти, які впливають на вибір тієї чи іншої технологічної платформи.

Першим кроком у створенні геопорталу є визначення його цілей та вимог. Необхідно чітко зрозуміти, які задачі має вирішувати геопортал. Це можуть бути такі завдання, як навігація, екологічний моніторинг, управління ресурсами, або вирішення питань, пов'язаних з розумними містами. Важливо також визначити основну аудиторію користувачів геопорталу. Це можуть бути громадські організації, державні установи, комерційні компанії або звичайні громадяни. Від цього залежить набір функцій, які повинні бути реалізовані, такі як пошук, фільтрація, аналіз даних та інтеграція з іншими сервісами.

Наступним етапом є збір та підготовка даних. Слід визначити, які саме дані потрібні для досягнення поставлених цілей, а також знайти відповідні джерела для їх отримання. Це можуть бути відкриті дані, комерційні дані, дані від державних установ або результати власних досліджень. Необхідно також врахувати типи даних, які будуть використовуватися, наприклад, векторні дані (точки, лінії, полігони) та растрові дані (супутникові знімки, карти

4.2. Засоби публікації та представлення геопросторових даних в інтернет

висот, аерофотозйомка). Дані можуть бути представлені у різних *форматах*, таких як Shapefile, GeoJSON, KML, GeoTIFF.

Архітектура геопорталу складається з кількох важливих компонентів. *Серверна частина* відповідає за обробку даних та управління запитами. Популярними рішеннями з відкритим вихідним кодом є GeoServer, MapServer та QGIS Server [4], які використовуються для публікації геопросторових даних. Для зберігання геопросторових даних часто використовують бази даних, зокрема PostGIS — розширення PostgreSQL. *Технології кешування*, такі як GeoWebCache або MapProxy, використовуються для підвищення швидкості завантаження карт та зменшення навантаження на обчислювальні ресурси. Стандартизовані API та сервіси, наприклад ті, що задовольняють OGC стандартам (WMS, WFS, WCS), забезпечують доступ до даних для інших систем і додатків. Сама можливість використання різноманітних картографічних сервісів стала знаковою віхою розвитку геопорталів [5].

Інтерфейс користувача є одним з ключових елементів геопорталу. В його основі зазвичай лежить Веб-додаток з інтуїтивно зрозумілим інтерфейсом. На сьогодні стандартом галузі є *JavaScript-бібліотеки*, такі як *Leaflet*, *OpenLayers* або *Mapbox GL JS*, які дозволяють створювати інтерактивні карти. Дизайн користувацького інтерфейсу (UX/UI дизайн) має забезпечувати зручність використання, доступність та привабливий зовнішній вигляд.

Інтеграція з іншими системами та розширюваність функціоналу є важливими аспектами для забезпечення гнучкості та масштабованості геопорталу. Геопортал має бути здатним, принаймні на рівні архітектури, інтегруватися з іншими інформаційними системами, такими як ERP, CRM, та забезпечувати можливість додавання нових функцій та модулів у майбутньому.

Останнім, але не менш важливим аспектом є *безпека та доступність*. Необхідно забезпечити захист даних та доступність лише для авторизованих користувачів, а також можливість *гнучкого керування доступом* до різних функцій порталу. Геопортал повинен бути доступним на різних пристроях і відповідати *вимогам доступності* для людей з особливими потребами.

Якщо підсумувати поточний *стан розвитку* популярних технологій [6] для створення геопорталів, то популярними технологіями та інструментами є наступні.

Сервери карт: GeoServer, MapServer, QGIS Server

Бази даних: PostGIS, MongoDB, CouchDB

Фронтенд-бібліотеки: Leaflet, OpenLayers, Mapbox GL JS тощо

Картографічні сервіси: Google Maps API, ArcGIS Online, Bing Maps

Нижче більш детально розглянуті основні серверні інструменти, клієнтські бібліотеки та «коробочні» (майже готові до використання) рішення на прикладі Mapbender.

2.2. СЕРВЕРНА ЧАСТИНА

2.2.1. GEOSERVER

GeoServer [7] — це популярний сервер з відкритим вихідним кодом для публікації та управління геопросторовими даними. Дистрибутиви програмного забезпечення доступні на сторінці проекту Geoserver (рис. 1). Він дозволяє користувачам обмінюватись, обробляти і редагувати геопросторову інформацію відповідно до стандартів OGC (Open Geospatial Consortium), таких як WMS (Web Map Service), WFS (Web Feature Service), WCS (Web Coverage Service) тощо.

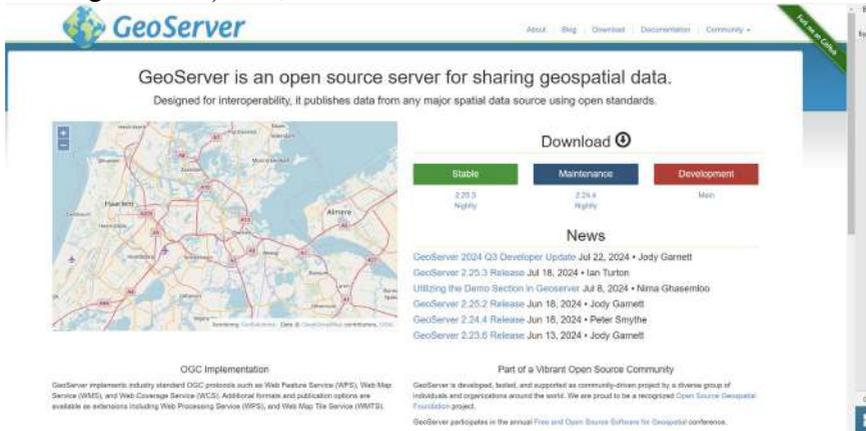


Рис. 1. Стартова сторінка проекту GeoServer

GeoServer складається з кількох ключових компонентів, які забезпечують його функціональність та масштабованість.

Архітектура та ядро базуються на Java-технологіях, що дозволяє запускати GeoServer в будь-якому середовищі, яке підтримує JVM (Java Virtual Machine). Для управління конфігурацією та забезпечення гнучкості обробки Веб-запитів

4.2. Засоби публікації та представлення геопросторових даних в інтернет

GeoServer використовує Spring Framework [8]. Для роботи з геопросторовими даними використовується бібліотека GeoTools [9], яка підтримує багато форматів даних та операцій з геоданими.

Підтримка стандартів OGC [10] є важливим аспектом GeoServer. Сервіс WMS дозволяє динамічно генерувати карти з геопросторових даних, підтримуючи різні формати виводу (PNG, JPEG, GIF, SVG, PDF). Сервіс WFS забезпечує доступ до векторних даних і маніпуляцію ними у таких форматах, як GML та GeoJSON. Сервіс WCS надає доступ до растрових даних, таких як супутникові знімки, а *Web Processing Service* (WPS) дозволяє виконувати просторовий аналіз та обробку даних на сервері.

Управління даними в GeoServer включає можливість підключення до різноманітних баз даних, таких як PostGIS, Oracle Spatial, MySQL та MS SQL Server. GeoServer також підтримує роботу з основними форматами геопросторових даних, включаючи Shapefile, GeoTIFF, KML, CSV та GeoJSON. Управління джерелами даних, стилями та сервісами здійснюється через Веб-інтерфейс.

Конфігурація та налаштування здійснюються за допомогою інтуїтивно зрозумілої адміністративної панелі, яка дозволяє налаштовувати джерела даних, стилі, користувачів та політики доступу. Для налаштування сервера та його сервісів також можна використовувати XML-файли. GeoServer надає RESTful API для автоматизації завдань управління та конфігурації.

Безпека забезпечується завдяки підтримці різних механізмів аутентифікації, таких як LDAP та JDBC, а також можливості обмеження доступу до даних на рівні користувача або групи. Для захисту даних під час передачі підтримуються безпечні з'єднання за допомогою SSL/TLS.

Масштабованість і продуктивність GeoServer підвищуються завдяки використанню GeoWebCache для кешування растрових фрагментів і прискорення рендерингу карт. Крім того, GeoServer підтримує кластерну роботу, що дозволяє розподіляти обробку даних і підвищувати надійність (відмовостійкість) системи.

Інтеграція з іншими системами забезпечується завдяки підтримці плагінів та розширень, які дозволяють інтегрувати GeoServer з іншими сервісами та розширювати його функціональність. Наприклад, інтеграція з GDAL дозволяє підтримувати додаткові формати даних. GeoServer також легко взаємодіє з іншими GIS-системами, такими як QGIS та ArcGIS.

GeoServer є досить потужним, гнучким та універсальним рішенням для створення геопорталів, що дозволяє інтегрувати та

візуалізувати геопросторові дані з різних джерел. Його архітектура забезпечує високу продуктивність, масштабованість та безпеку, що робить GeoServer відмінним вибором для різноманітних застосувань у галузі геоінформаційних систем.

2.2.2. MAPSERVER

MapServer [11] — ще один з популярних серверів з відкритим вихідним кодом для публікації геопросторових даних у Веб-середовищі. Дистрибутиви програмного забезпечення доступні на сторінці проекту MapServer (рис. 2). Він надає можливості для побудови карт і публікації географічних даних, а також підтримує різноманітні Інтернет-протоколи та формати. MapServer відомий своєю високою продуктивністю та гнучкістю в налаштуванні.

Серверна частина MapServer складається з кількох основних компонентів, кожен з яких забезпечує його функціональність та інтеграційні можливості.

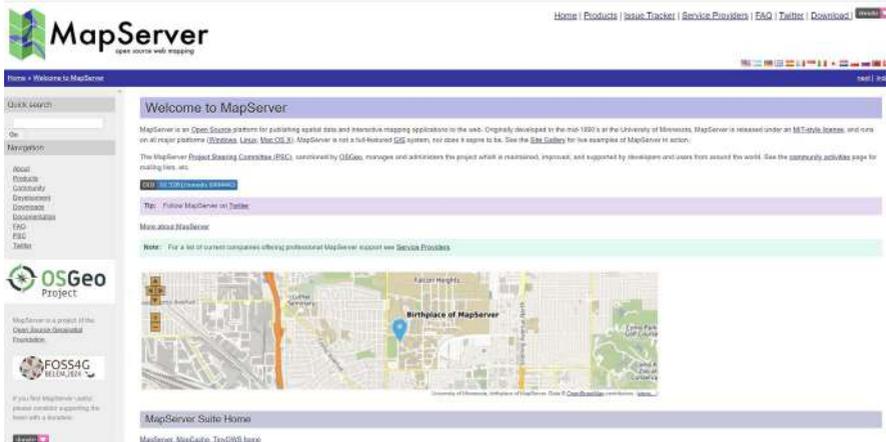


Рис. 2. Стартова сторінка проекту MapServer

Архітектура та ядро MapServer побудовані на мовах програмування C і C++, що дозволяє досягати високої продуктивності та ефективного використання ресурсів. MapServer може функціонувати як CGI-додаток або через MapScript, що забезпечує його сумісність із різними середовищами та інтеграцію з іншими мовами програмування, такими як Python, PHP, Perl, Ruby, Java та C#.

4.2. Засоби публікації та представлення геопросторових даних в інтернет

Підтримка стандартів OGC є важливою частиною MapServer. Він забезпечує динамічне створення картографічних зображень через WMS сервіс, підтримуючи різні формати виводу, такі як PNG, JPEG, GIF, SVG та PDF. WFS дозволяє доступ до векторних геоданих у форматах GML та GeoJSON, а WCS надає доступ до растрових даних, таких як супутникові знімки та моделі висот. Крім того, MapServer підтримує WPS для виконання геопросторових обчислень і аналізів на сервері, а також Tile Map Service (TMS) і Web Map Tile Service (WMTS) для створення тайлів (фрагментів растрових зображень), що підвищує швидкість передачі та відображення карт.

Управління даними в MapServer здійснюється за допомогою підтримки різноманітних файлових форматів, включаючи Shapefile, GeoTIFF, та інші формати, сумісні з OGR [12] (частина бібліотеки GDAL (Geospatial Data Abstraction Library) для роботи з векторними даними), такі як CSV, KML та GML. MapServer підтримує підключення до баз даних, таких як PostGIS, Oracle Spatial і MySQL, що дозволяє обробляти векторні та растрові дані, а також накладати їх один на одного.

Конфігурація та налаштування здійснюються через основний конфігураційний файл MapFile, який описує джерела даних, шари, стилі та проєкції. MapFile використовується для налаштування відображення карт і визначення параметрів роботи сервера. Крім того, MapServer підтримує складні стилі та символи для візуалізації геопросторових даних, включаючи використання Styled Layer Descriptor (SLD).

Безпека в MapServer забезпечується через налаштування контролю доступу до даних і сервісів за допомогою аутентифікації та авторизації, а також підтримку шифрування з'єднань за допомогою HTTPS для захисту даних під час передачі.

Масштабованість і продуктивність досягаються завдяки використанню зовнішніх інструментів для кешування картографічних елементів (прямокутних фрагментів карти або тайлів), таких як MapCache, що підвищує швидкість відображення карт. Крім того, оптимізація конфігураційних файлів і налаштувань сервера дозволяє покращити загальну продуктивність системи.

Інтеграція з іншими системами здійснюється через MapScript API, який дозволяє інтегрувати MapServer з іншими програмами та мовами програмування, такими як Python, PHP, Perl, Ruby, Java, C#. Крім того, MapServer підтримує плагіни для розширення функціональності та інтеграції з іншими системами.

MapServer є потужним та гнучким інструментом для публікації геопросторових даних у Веб-середовищі, але вже на мові C/C++. Він забезпечує високу продуктивність, підтримку стандартів OGC та можливість інтеграції з різними системами і мовами програмування. Це робить MapServer ідеальним вибором для створення геопорталів і геоінформаційних систем різної складності, коли акцент робиться на швидкодію.

2.2.3. QGIS SERVER

QGIS Server [13] — це серверний компонент з відкритим вихідним кодом, який дозволяє публікувати геопросторові дані і сервіси на основі проєктів QGIS. Дистрибутиви програмного забезпечення доступні на сторінці проєкту MapServer (рис. 3). QGIS Server надає можливість створювати картографічні продукти для Веб та геоінформаційні сервіси, підтримуючи стандарти OGC, такі як WMS, WFS, WCS та ін. Завдяки QGIS Server можна легко розгорнути комплексні ГІС-рішення, використовуючи переваги QGIS Desktop для попередньої підготовки даних і проєктів [14].



Рис. 3. Стартова сторінка проєкту QGIS Server

Серверна частина QGIS Server складається з кількох основних компонентів, які забезпечують його функціональність та гнучкість у використанні.

Архітектура та ядро QGIS Server побудовані на C++ і підтримують розширення через Python, що дозволяє досягати

4.2. Засоби публікації та представлення геопросторових даних в інтернет

високої продуктивності та гнучкості в налаштуваннях. QGIS Server використовує ядро QGIS, яке забезпечує доступ до всіх функцій і можливостей QGIS Desktop для обробки та візуалізації даних. Крім того, QGIS Server підтримує QGIS Processing Framework, що надає велику кількість інструментів для обробки даних, включаючи обчислення, аналіз та трансформацію даних.

Підтримка стандартів OGC в QGIS Server включає кілька важливих сервісів. WMS дозволяє створювати та публікувати картографічні зображення в різних форматах, таких як PNG, JPEG, SVG та PDF, із підтримкою стилізації шарів. WFS забезпечує доступ до векторних геоданих у форматах GML та GeoJSON, а WCS надає доступ до растрових даних, таких як супутникові знімки та моделі висот. QGIS Server також підтримує WPS для серверної обробки даних з використанням геоалгоритмів із QGIS Processing Toolbox, а також WMTS для публікації карт у вигляді набору растрових фрагментів, що підвищує швидкість рендерингу та відображення карт.

Управління даними в QGIS Server здійснюється за допомогою підтримки підключення до різних геопросторових баз даних, таких як PostGIS, Oracle Spatial, MySQL та SpatiaLite. Сервер також працює з широким спектром геопросторових форматів, включаючи Shapefile, GeoTIFF, KML, GML, GPX, GeoJSON та багато інших. Крім того, QGIS Server підтримує роботу з різними проєкціями і можливість трансформації між ними в реальному часі.

Конфігурація та налаштування QGIS Server базуються на використанні проєктів QGIS (.qgs/.qgz), які визначають шари, стилі, символію та загальний вигляд карт. Це дозволяє використовувати всі можливості QGIS Desktop без необхідності додаткових налаштувань сервера. Підтримка SLD (Styled Layer Descriptor) і QML (QGIS Layer Style File) дозволяє детально налаштовувати відображення даних, а можливість налаштування серверних проєктів через графічний інтерфейс QGIS Desktop робить процес конфігурації простим і зручним.

Безпека QGIS Server забезпечується за допомогою різних механізмів аутентифікації та авторизації, таких як базова аутентифікація, OAuth2 і LDAP. Сервер також дозволяє налаштовувати права доступу до різних шарів і сервісів для різних груп користувачів, а підтримка SSL/TLS забезпечує шифрування з'єднань для захисту даних під час передачі.

Масштабованість і продуктивність QGIS Server досягається через оптимізацію рендерингу карт, використання кешування та

інтеграцію з зовнішніми системами кешування для зменшення навантаження на сервер. Крім того, сервер підтримує розподілені обчислення і кластеризацію, що забезпечує високу доступність та надійність сервісів.

Інтеграція з іншими системами в QGIS Server можлива завдяки підтримці плагінів Python, які дозволяють розширювати функціональність сервера та інтегрувати його з іншими системами. Використання PyQGIS надає програмний доступ до функціональності QGIS Server, що дозволяє автоматизувати процеси та інтегрувати різні системи. Сервер також легко інтегрується з іншими ГІС-системами, такими як QGIS Desktop, ArcGIS, GRASS GIS та інші інструменти.

QGIS Server є потужним і гнучким інструментом для публікації геопросторових даних та картографічних сервісів, але має додаткові вимоги до проєктів, які може підтримувати. Його тісна інтеграція з QGIS Desktop робить його ідеальним рішенням для організацій, які вже використовують QGIS у своїй роботі. Завдяки підтримці стандартів OGC і широким можливостям налаштування, QGIS Server може бути використаний для створення складних геоінформаційних систем, забезпечуючи високу продуктивність і надійність.

2.3. КЛІЄНТСЬКІ БІБЛІОТЕКИ

2.3.1. LEAFLET

Leaflet [15] — це легка і проста у використанні бібліотека JavaScript, яка використовується для створення інтерактивних карт у веб-додатках, розроблена в Україні. Посилання на документацію та дистрибутив бібліотеки доступні на сторінці проєкту Leaflet (рис. 4). Завдяки своїй гнучкості і потужним можливостям Leaflet став популярним інструментом для розробки геопорталів, які надають користувачам можливість взаємодії з геопросторовими даними через Веб-інтерфейс [16].

Бібліотека Leaflet пропонує широкий спектр можливостей, що робить її популярним вибором для розробників інтерактивних карт.

Легкість і швидкодія Leaflet досягається завдяки малому розміру, всього близько 39KB (gzip), що робить цю бібліотеку майже ідеальним рішенням для використання на Веб-сайтах з обмеженими ресурсами. Завдяки оптимізованому рендерингу та

4.2. Засоби публікації та представлення геопросторових даних в інтернет

кешуванню, Leaflet забезпечує високу швидкість роботи навіть на мобільних пристроях.



Рис. 4. Стартова сторінка проєкту Leaflet

Підтримка різноманітних форматів даних дозволяє працювати з векторними шарами, такими як GeoJSON, які легко візуалізувати і стилізувати. Leaflet також підтримує додавання картографічних зображень з популярних картографічних сервісів, таких як OpenStreetMap, Google Maps, Mapbox тощо. Крім того, бібліотека надає можливість кластеризації, що дозволяє об'єднувати велику кількість точок даних у кластери для покращення візуалізації.

Інтерактивність є однією з ключових особливостей Leaflet. Бібліотека підтримує різноманітні події, такі як клацання миші, наведення курсору, масштабування, що дозволяє створювати динамічні та інтерактивні карти. Leaflet також дозволяє додавати інтерактивні елементи (попапи і тултіпи) для відображення інформації при натисканні на об'єкти на карті, а також легко управляти шарами і контролерами, що дає змогу користувачам перемикатися між різними наборами даних.

Масштабованість та розширюваність Leaflet забезпечується завдяки великій кількості доступних плагінів, які розширюють функціональні можливості бібліотеки, додаючи підтримку графіків, маршрутизації, анімацій і багато іншого. Крім того, бібліотека пропонує широкі можливості для кастомізації, включаючи створення власних іконок, стилів для ліній і полігонів.

Відкритий код і спільнота є важливими аспектами Leaflet. Це проєкт з відкритим кодом, що робить його доступним для

модифікацій і вдосконалень від спільноти розробників. Завдяки широкій та активній спільноті користувачів і розробників, створюються додаткові інструменти та забезпечується підтримка і розвиток бібліотеки.

Приклади використання Leaflet для створення геопорталів.

Розглянемо приклад розробки простого Веб-додатка з картою на базі Open Street Map. Почнемо з декларації DOCTYPE для HTML. У заголовковій частині (блок **head**) підключені метатеги для встановлення кодування сторінки (UTF-8) та налаштування для адаптивного дизайну (viewport). Підключено CSS бібліотеки Leaflet для стилізації карти та налаштування висоти елемента карти через стиль.

Тіло сторінки (блок **body**) включає div елемент з ідентифікатором «map», який буде використовуватись як контейнер для відображення карти. Підключається JavaScript файл бібліотеки Leaflet, яка використовується для роботи з картами. В блоці JavaScript коду ініціалізується карта з центром на координатах Києва та заданим рівнем масштабування. Додається шар картографічного зображення з OpenStreetMap для відображення карти. Потім додаються різні геооб'єкти: маркер, круг і полігон, кожен з яких має власне спливаюче вікно із текстом. Результат представлений на рис. 5.

```
<!DOCTYPE html>
<html>
<head>
  <title>Simple Map</title>
  <meta charset="utf-8" />
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
  <link rel="stylesheet" href="https://unpkg.com/leaflet/dist/leaflet.css" />
  <style>
    #map { height: 500px; }
  </style>
</head>
<body>
  <div id="map"></div>

  <script src="https://unpkg.com/leaflet/dist/leaflet.js"></script>
  <script>
    // Ініціалізація карти
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
var map = L.map('map').setView([50.4501, 30.5234], 13); //
Координати Києва

// Додавання картографічного зображення з OpenStreetMap
L.tileLayer('https://{s}.tile.openstreetmap.org/{z}/{x}/{y}.png', {
  maxZoom: 19,
  attribution: 'Map data © OpenStreetMap contributors'
}).addTo(map);

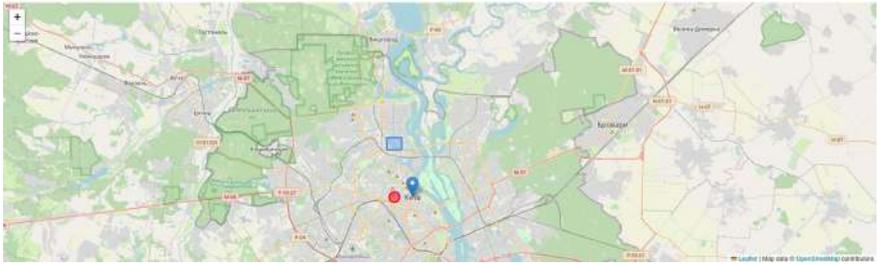
// Додавання маркера
var marker = L.marker([50.4501, 30.5234]).addTo(map)
  .bindPopup('<b>Київ</b><br>Столиця України.')
  .openPopup();

// Додавання круга
var circle = L.circle([50.4501, 30.5], {
  color: 'red',
  fillColor: '#f03',
  fillOpacity: 0.5,
  radius: 500
}).addTo(map).bindPopup('Це круг.');
```

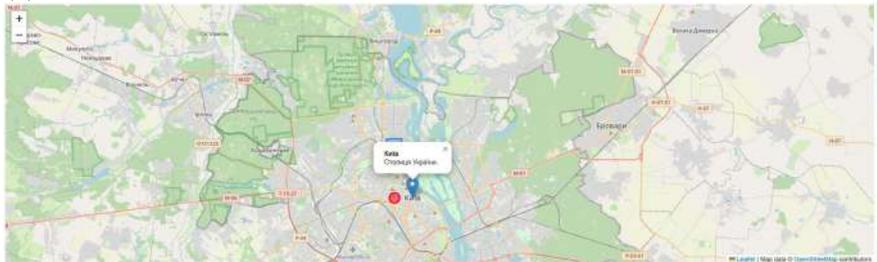
```

// Додавання полігона
var polygon = L.polygon([
  [50.49, 30.49],
  [50.50, 30.49],
  [50.50, 30.51],
  [50.49, 30.51]
]).addTo(map).bindPopup('Це полігон.');
```

```
</script>
</body>
</html>
```



(а)



(б)

Рис. 5. Створення карти OSM з кількома маркерами (а) та текстовим описовим атрибутом (б)

Використання даних в форматі GeoJSON (масив точкових даних) для візуалізації можна представити наступним чином.

```
<!DOCTYPE html>
<html>
<head>
  <title>GeoJSON Example</title>
  <meta charset="utf-8" />
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
  <link rel="stylesheet" href="https://unpkg.com/leaflet/dist/leaflet.css" />
  <style>
    #map { height: 500px; }
  </style>
</head>
<body>
  <div id="map"></div>

  <script src="https://unpkg.com/leaflet/dist/leaflet.js"></script>
</script>
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
// Ініціалізація карти
var map = L.map('map').setView([50.4501, 30.5234], 13);

// Додавання картографічного зображення з OpenStreetMap
L.tileLayer('https://{s}.tile.openstreetmap.org/{z}/{x}/{y}.png', {
  maxZoom: 19,
  attribution: 'Map data © OpenStreetMap contributors'
}).addTo(map);

// GeoJSON дані
var geojsonData = {
  "type": "FeatureCollection",
  "features": [
    {
      "type": "Feature",
      "properties": {
        "name": "Місце А",
        "popupContent": "Це місце А!"
      },
      "geometry": {
        "type": "Point",
        "coordinates": [30.5234, 50.4501]
      }
    },
    {
      "type": "Feature",
      "properties": {
        "name": "Місце В",
        "popupContent": "Це місце В!"
      },
      "geometry": {
        "type": "Point",
        "coordinates": [30.5250, 50.4520]
      }
    }
  ]
};

// Додавання GeoJSON до карти
L.geoJSON(geojsonData, {
```

```
onEachFeature: function (feature, layer) {
    if (feature.properties && feature.properties.popupContent) {
        layer.bindPopup(feature.properties.popupContent);
    }
}
}).addTo(map);
</script>
</body>
</html>
```

Цей HTML-документ є представленням Веб-сторінки з інтерактивною картою, яка відображає дані в форматі GeoJSON за допомогою бібліотеки Leaflet. У заголовній частині (head) частині аналогічно попередньому прикладу задається заголовок сторінки, встановлюється кодування символів (UTF-8) і налаштовується адаптивність сторінки для мобільних пристроїв, а також підключається CSS-файл бібліотеки Leaflet для стилізації карти, а також задається стиль для елемента з картою, встановлюючи висоту карти на 500 пікселів.

У body частині сторінки міститься контейнер з ідентифікатором «map», який використовується для відображення карти.

JavaScript код ініціалізує карту, встановлюючи її центр на координатах Києва з рівнем масштабування 13. Потім на карту додається шар картографічного зображення з OpenStreetMap, який використовується як базова карта. Далі в коді визначається об'єкт GeoJSON, який містить два об'єкти з типом «Feature», що мають тип геометрії «Point» з відповідними координатами. Кожен об'єкт також містить властивості, включаючи ім'я та текст для спливаючого вікна (popup). Останній блок коду додає GeoJSON дані на карту за допомогою функції L.geoJSON. При додаванні кожного об'єкта на карту, для кожного з них створюється спливаюче вікно, якщо об'єкт має властивість popupContent. Нарешті, всі об'єкти додаються на карту. Результат виконання коду представлений на рис. 6.

Leaflet дозволяє легко нарощувати функціонал шляхом підключення плагінів з додатковими функціями, наприклад для підтримки побудови маршрутів. Плагін Leaflet Routing Machine [17] дозволяє додавати можливості побудови маршруту на карту. Прокладемо маршрут між точками А та В.

4.2. Засоби публікації та представлення геопросторових даних в інтернет



Рис. 6. Побудова карти OSM з кількома маркерами в JSON-форматі

```
<!DOCTYPE html>
<html>
<head>
  <title>Routing Example</title>
  <meta charset="utf-8" />
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
  <link rel="stylesheet" href="https://unpkg.com/leaflet/dist/leaflet.css" />
  <link rel="stylesheet" href="https://unpkg.com/leaflet-routing-
machine/dist/leaflet-routing-machine.css" />
  <style>
    #map { height: 500px; }
  </style>
</head>
<body>
  <div id="map"></div>

  <script src="https://unpkg.com/leaflet/dist/leaflet.js"></script>
  <script src="https://unpkg.com/leaflet-routing-machine/dist/leaflet-
routing-machine.js"></script>
  <script>
    // Ініціалізація карти
    var map = L.map('map').setView([50.4501, 30.5234], 13);

    // Додавання картографічного зображення з OpenStreetMap
    L.tileLayer('https://{s}.tile.openstreetmap.org/{z}/{x}/{y}.png', {
      maxZoom: 19,
      attribution: 'Map data © <a
href="https://www.openstreetmap.org/copyright">OpenStreetMap</a>
contributors'
    }).addTo(map);
```

```
// Маршрутизація
L.Routing.control({
  waypoints: [
    L.latLng(50.4501, 30.5234),
    L.latLng(50.4547, 30.5238)
  ],
  routeWhileDragging: true
}).addTo(map);
</script>
</body>
</html>
```

HTML-документ починається з декларації DOCTYPE. У заголовковій частині (**head**) визначені метатеги для встановлення кодування сторінки (UTF-8) та забезпечення адаптивності дизайну для мобільних пристроїв. Підключено два CSS файли: один для базової стилізації карти через бібліотеку Leaflet, а інший для додавання стилів для маршрутизації з використанням бібліотеки Leaflet Routing Machine. Стиль задає висоту контейнера карти.

Аналогічно попередньому прикладу тіло сторінки (**body**) містить `div` елемент з ідентифікатором «`map`», який буде використовуватися як контейнер для карти. Підключаються JavaScript файли бібліотек Leaflet та Leaflet Routing Machine для роботи з картою та реалізації функціоналу маршрутизації.

Блок JavaScript коду ініціалізує карту з центром на Києві (координати) та заданим рівнем масштабування. Додається шар зображення з OpenStreetMap для відображення базової карти. Додається маршрутизатор (`L.Routing.control`) на карту з початковою і кінцевою точками маршруту, дозволяючи користувачам змінювати маршрут перетягуванням його на карті. Графічний вигляд створеного маршруту представлений на рис. 7.

Leaflet дозволяє досить легко налагоджувати використання шарів і контролів.

```
<!DOCTYPE html>
<html>
<head>
  <title>Layers Example</title>
  <meta charset="utf-8" />
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
<link rel="stylesheet" href="https://unpkg.com/leaflet/dist/leaflet.css" />
<style>
  #map { height: 500px; }
</style>
</head>
<body>
  <div id="map"></div>

  <script src="https://unpkg.com/leaflet/dist/leaflet.js"></script>
  <script>
    // Ініціалізація карти
    var map = L.map('map').setView([50.4501, 30.5234], 13);

    // Зображення OpenStreetMap
    var osmLayer =
L.tileLayer('https://{s}.tile.openstreetmap.org/{z}/{x}/{y}.png', {
  maxZoom: 19,
  attribution: 'Map data ©
href="https://www.openstreetmap.org/copyright">OpenStreetMap</a>
contributors'
});

    // Зображення Google Maps
    var googleLayer =
L.tileLayer('http://{s}.google.com/vt/lyrs=m&x={x}&y={y}&z={z}', {
  maxZoom: 20,
  subdomains: ['mt0', 'mt1', 'mt2', 'mt3'],
  attribution: 'Map data ©
href="https://www.google.com/maps">Google Maps</a>'
});

    // Додавання зображення на карту
    osmLayer.addTo(map);

    // Маркери
    var markerA = L.marker([50.4501, 30.5234]).bindPopup('Місце А');
    var markerB = L.marker([50.4547, 30.5238]).bindPopup('Місце В');

    // Група маркерів
    var markersGroup = L.layerGroup([markerA, markerB]);

    // Контролери шарів
```


4.2. Засоби публікації та представлення геопросторових даних в інтернет



Рис. 8. Додавання шарів на карту

Виділимо основні **переваги та недоліки використання Leaflet**. Бібліотека Leaflet є доволі цікавим та легким у використанні рішенням для розробки користувацького інтерфейсу геопорталу. Вона має свої переваги та недоліки, які наведені нижче.

Переваги. Leaflet легко інтегрується з іншими JavaScript-фреймворками, такими як React, Angular і Vue.js, що дозволяє створювати складні Веб-додатки з інтерактивними картами. Завдяки оптимізації та кешуванню, бібліотека забезпечує високу продуктивність навіть на мобільних пристроях і в умовах обмежених ресурсів. Leaflet пропонує великий вибір інструментів для створення кастомних рішень, які можуть задовольнити потреби різних проєктів. Крім того, активна спільнота розробників постійно оновлює бібліотеку та створює нові плагіни та інструменти.

Недоліки. Попри всі переваги, Leaflet може мати деякі обмеження у функціональності в порівнянні з іншими бібліотеками, наприклад OpenLayers, особливо коли йдеться про роботу з великими наборами даних. Також деякі складні функції, наприклад, обробка 3D-даних або підтримка специфічних форматів, можуть вимагати використання додаткових плагінів або розширень.

В цілому ж **Leaflet** — це потужна і гнучка бібліотека для створення інтерактивних карт, яка ідеально підходить для розробки геопорталів помірної складності. Завдяки легкості інтеграції, широкій підтримці стандартів і наявності великої кількості плагінів, Leaflet може бути ефективним рішенням для різних веб-проєктів, що потребують візуалізації геопросторових даних.

2.3.2. OPENLAYERS

OpenLayers [18] — це потужна бібліотека JavaScript з відкритим кодом, яка використовується для створення динамічних Веб-карт та інтерактивних геопорталів. Дистрибутив бібліотеки та документація доступні та сторінці Openlayers (рис. 9). OpenLayers забезпечує широкі можливості для роботи з різноманітними геопросторовими даними і підтримує великий набір функцій, включаючи візуалізацію векторних і растрових шарів, роботу з різними проєкціями, інтеграцію з геопросторовими сервісами та багато іншого. Завдяки своїй потужності і гнучкості, OpenLayers є відмінним вибором для розробників, які створюють геоінформаційні системи [19].

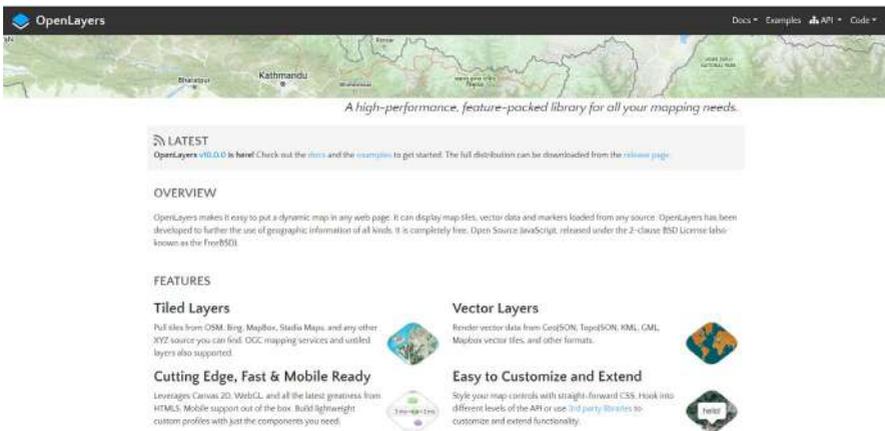


Рис. 9. Стартова сторінка проєкту OpenLayers

OpenLayers пропонує широкий спектр можливостей для роботи з геопросторовими даними.

Бібліотека **підтримує роботу з векторними форматами**, такими як GeoJSON, KML, GML, GPX, IGC, TороJSON, а також із **растровими даними**, дозволяючи використовувати різноманітні картографічні сервіси, зокрема WMS, WMTS, TMS та інші.

OpenLayers має **вбудовану підтримку більшості проєкцій і систем координат**, а також забезпечує легке перетворення координат між різними системами координат, що спрощує роботу з даними з різних джерел.

Бібліотека дозволяє **відстежувати та обробляти різноманітні події на карті**, такі як клцання миші, панорамування,

4.2. Засоби публікації та представлення геопросторових даних в інтернет

масштабування та зміна вигляду карти. Крім того, є можливість додавання інтерактивних елементів та інформаційних вікон для відображення деталей про об'єкти на карті. OpenLayers надає доволі широкі **можливості налаштування стилів** для векторних шарів, включаючи маркери, лінії та полігони, а також дозволяє додавати анімації об'єктів на карті для створення динамічних візуалізацій.

Бібліотека легко **інтегрується з популярними геосервісами**, такими як Google Maps, Bing Maps, Mapbox, а також підтримує стандарти OGC, включаючи WMS, WFS, WCS, що розширює її можливості в контексті роботи з геоданими.

OpenLayers **оптимізована для роботи з великими наборами даних**, що забезпечує високу продуктивність і масштабованість. Підтримка кешування елементів картографічного зображення допомагає знизити навантаження на сервер і покращити швидкість завантаження карт.

Реалізуємо просте відображення карти за допомогою OpenLayers з OSM-зображенням.

```
<!DOCTYPE html>
<html lang="en">
  <head>
    <meta charset="UTF-8" />
    <meta name="viewport" content="width=device-width, initial-scale=1.0" />
  </head>
  <title>OpenLayers OpenStreetMap Example</title>
  <link
    rel="stylesheet"
    href="https://cdn.jsdelivr.net/npm/ol@v7.4.0/ol.css"
  />
  <style>
    .map {
      height: 500px;
      width: 100%;
    }
  </style>
</head>
<body>
  <h2>Карта OpenStreetMap за допомогою OpenLayers</h2>
  <div id="map" class="map"></div>
  <script type="module">
    import Map from "https://cdn.jsdelivr.net/npm/ol@v7.4.0/Map.js";
```

```
import View from "https://cdn.jsdelivr.net/npm/ol@v7.4.0/View.js";
import TileLayer from "https://cdn.jsdelivr.net/npm/ol@v7.4.0/layer/Tile.js";
import OSM from "https://cdn.jsdelivr.net/npm/ol@v7.4.0/source/OSM.js";

// Створення растрового шару з OpenStreetMap
const osmLayer = new TileLayer({
  source: new OSM(),
});

// Створення карти
const map = new Map({
  target: "map", // Ідентифікатор елемента HTML, в якому буде
  // відображена карта
  layers: [osmLayer], // Додаємо шар з OSM
  view: new View({
    center: [3398015, 6524165], // Центр карти у форматі EPSG:3857
    // (Web Mercator)
    zoom: 12, // Початковий масштаб
  }),
});
</script>
</body>
</html>
```

У заголовковій частині (**head**) встановлюється кодування символів (UTF-8) і налаштовується адаптивний дизайн для мобільних пристроїв. Також підключається CSS-файл бібліотеки OpenLayers для стилізації карти. У тілі сторінки (**body**) є заголовок і контейнер з ідентифікатором «map», який буде використовуватися для відображення карти. Карта має висоту 500 пікселів і ширину 100%, щоб заповнювати весь доступний простір на сторінці.

JavaScript код підключається як модуль і імпортує необхідні класи з бібліотеки OpenLayers: Map, View, TileLayer та OSM. Створюється шар картографічного зображення, який використовує OpenStreetMap як джерело даних. Потім створюється карта, яка відображається в контейнері з ідентифікатором «map». Карта містить шар з OpenStreetMap (рис. 10) і задається початковий вигляд з центром на визначених координатах у системі координат EPSG:3857 (Web Mercator) і з початковим масштабом 12.

4.2. Засоби публікації та представлення геопросторових даних в інтернет

Карта OpenStreetMap за допомогою OpenLayers



Рис. 10. Відображення базової карти засобами OpenLayers

Відобразимо дані в GeoJSON-форматі засобами OpenLayers:

```
<!DOCTYPE html>
<html lang="en">
<head>
  <meta charset="UTF-8">
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
  <title>OpenLayers GeoJSON Example for Kyiv</title>
  <link rel="stylesheet"
href="https://cdnjs.cloudflare.com/ajax/libs/ol3/4.6.5/ol.css">
  <script
src="https://cdnjs.cloudflare.com/ajax/libs/ol3/4.6.5/ol.js"></script>
  <style>
    .map {
      height: 100vh;
      width: 100%;
    }
  </style>
</head>
<body>
  <div id="map" class="map"></div>
  <script>
    // Додамо повідомлення для налагодження
    console.log('Initializing map...');

    // Створення карти
    var map = new ol.Map({
      target: 'map',
      layers: [
```

```
        new ol.layer.Tile({
            source: new ol.source.OSM()
        })
    ],
    view: new ol.View({
        center: ol.proj.fromLonLat([30.5234, 50.4501]), // Координати
Києва
        zoom: 12
    })
});

console.log('Map initialized.');
```

```
// GeoJSON об'єкти
var geojsonObject = {
    'type': 'FeatureCollection',
    'features': [
        {
            'type': 'Feature',
            'geometry': {
                'type': 'Point',
                'coordinates': [30.5134, 50.4501] // Координати точки в
Києві
            },
            'properties': {
                'name': 'Kyiv Center'
            }
        },
        {
            'type': 'Feature',
            'geometry': {
                'type': 'Point',
                'coordinates': [30.5216, 50.4476] // Координати іншої
точки в Києві
            },
            'properties': {
                'name': 'Another Point'
            }
        }
    ]
};
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
console.log('GeoJSON object created.');
```

```
// Створення вектора джерела даних
var vectorSource = new ol.source.Vector({
  features: new ol.format.GeoJSON().readFeatures(geojsonObject,
{
  featureProjection: 'EPSG:3857'
  })
});
```

```
console.log('Vector source created.');
```

```
// Створення векторного шару
var vectorLayer = new ol.layer.Vector({
  source: vectorSource
});
```

```
console.log('Vector layer created.');
```

```
// Додавання векторного шару до карти
map.addLayer(vectorLayer);
```

```
console.log('Vector layer added to map.');
```

```
</script>
</body>
</html>
```

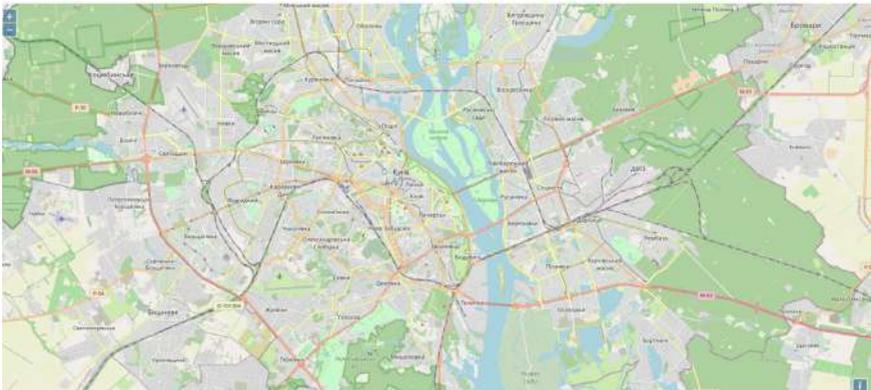


Рис. 11. Відображення векторних елементів в GeoJson форматі засобами OpenLayers

В даному прикладі створюється Веб-сторінка, яка відображає інтерактивну карту з GeoJSON даними за допомогою бібліотеки OpenLayers. У заголовковій частині (**head**) встановлюється кодування символів (UTF-8), налаштовується адаптивний дизайн для мобільних пристроїв, підключається CSS-файл для стилізації карти та JavaScript-файл бібліотеки OpenLayers.

У тілі сторінки (**body**) знаходиться контейнер з ідентифікатором `map`, в якому буде відображатися карта. CSS стиль задає висоту карти на весь екран (100vh) і ширину на 100%.

JavaScript код починається з виведення повідомлення в консоль для налагодження. Далі створюється карта з базовим шаром OpenStreetMap, яка центрована на координатах Києва та має початковий масштаб 12. Координати перетворюються у систему координат EPSG:3857 (Web Mercator). Створюється GeoJSON об'єкт, який містить два точкових об'єкти з їхніми координатами і властивостями. Потім цей GeoJSON об'єкт зчитується і перетворюється у векторні об'єкти OpenLayers з проекцією EPSG:3857. Створюється векторний шар, який використовує зчитані векторні об'єкти як джерело даних. Цей шар додається на карту. Кожен крок супроводжується виведенням відповідного повідомлення в консоль для полегшення налагодження коду.

До переваг OpenLayers можна віднести **широкий функціонал**, який надає максимальний набір інструментів для роботи з геопросторовими даними, дозволяючи реалізовувати складні рішення в геоінформаційних системах. Завдяки підтримці стандартів OGC (Open Geospatial Consortium), OpenLayers **легко інтегрується з іншими геоінформаційними системами та сервісами**. Бібліотека **забезпечує велику гнучкість у налаштуванні та стилізації карт**, що дозволяє створювати кастомні рішення під конкретні потреби проектів. Вона також **здатна ефективно обробляти великі набори даних**, забезпечуючи високу продуктивність. Активна спільнота розробників постійно вдосконалює бібліотеку, додаючи нові функції та виправляючи недоліки.

Проте OpenLayers має і **недоліки**. У порівнянні з іншими бібліотеками, такими як Leaflet, вона може бути **складнішою в налаштуванні та використанні**, що може вимагати більше часу на вивчення. Крім того, OpenLayers має більший розмір, ніж інші подібні бібліотеки, що може вплинути на швидкість завантаження карт у веб-додатках, особливо за умов обмеженої пропускної здатності мережевого з'єднання. Деякі функції можуть також не

4.2. Засоби публікації та представлення геопросторових даних в інтернет

підтримуватися старими версіями браузерів, що може створювати проблеми з сумісністю.

OpenLayers — це потужна бібліотека для створення геопорталів та інтерактивних карт, яка надає великий функціонал для роботи з різними типами геопросторових даних. Вона є відмінним вибором для проєктів, які вимагають високої продуктивності та гнучкості в налаштуванні, а також інтеграції з геосервісами і стандартами OGC. Однак, її використання може вимагати більше часу на освоєння та налаштування, ніж у випадку з іншими бібліотеками, такими як Leaflet.

2.3.3. MAPBOX GL JS

Mapbox [20] є досить зручною платформою для створення інтерактивних карт і геопорталів. Вона забезпечує розробників інструментами для інтеграції картографічних сервісів у Веб- та мобільні додатки. Відзначається досить повною та актуальною документацією, доступною на сайті проєкту (рис. 12а). Mapbox використовує бібліотеку **Mapbox GL JS** для рендерингу векторних карт з високою продуктивністю. Для використання необхідний токен, який можна створити у користувацькому профілі (рис. 12б).

Основні можливості Mapbox: Mapbox пропонує кілька основних можливостей, серед яких підтримка векторних карт з забезпеченням високої продуктивності і деталізації карт. Користувачі можуть легко налаштовувати стилі карт для створення унікального вигляду. Доступні також функції геокодування для пошуку місць і адрес, а також інтеграція навігаційних маршрутів. Крім того, Mapbox дозволяє інтегрувати та візуалізувати власні дані у форматі GeoJSON. Даний продукт є комерційним і його використання в безкоштовному режимі має суттєві обмеження [19].

Розглянемо приклад використання Mapbox GL JS для відображення карти та відображення даних у форматі GeoJSON. Для роботи з Mapbox необхідний токен, який можна отримати, зареєструвавшись на офіційному сайті проєкту.

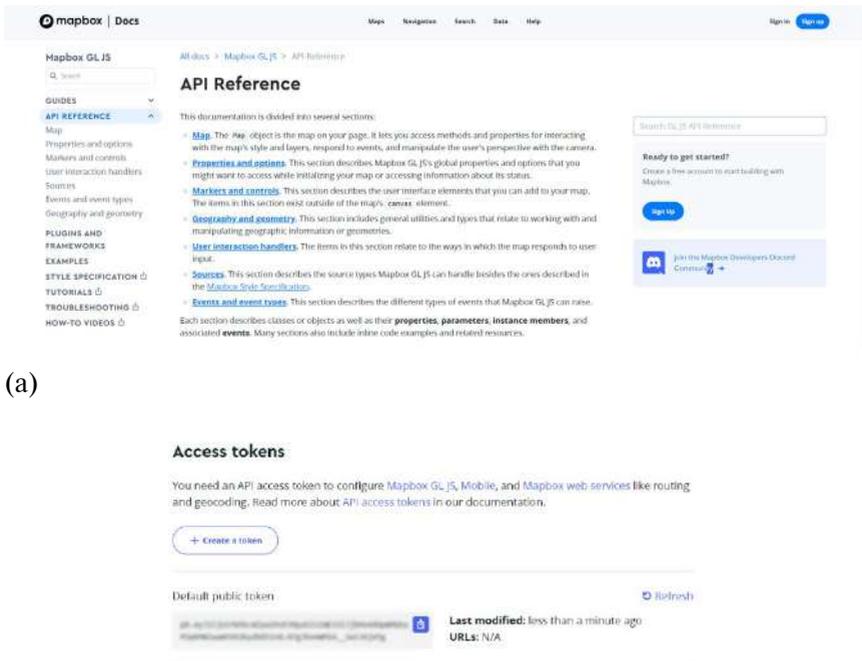
```
<!DOCTYPE html>
<html lang="en">
<head>
  <meta charset="UTF-8">
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
```

```
<title>Mapbox GL JS Example</title>
<script src="https://api.mapbox.com/mapbox-gl-js/v2.3.1/mapbox-
gl.js"></script>
<link href="https://api.mapbox.com/mapbox-gl-js/v2.3.1/mapbox-
gl.css" rel="stylesheet" />
<style>
  body { margin: 0; padding: 0; }
  #map { position: absolute; top: 0; bottom: 0; width: 100%; }
  .map-overlay { position: absolute; background: white; padding: 10px;
font-family: sans-serif; }
  .map-overlay .mapboxgl-ctrl { margin-bottom: 10px; }
  .map-overlay .mapboxgl-ctrl-group { display: inline-block; }
</style>
</head>
<body>
  <div id="map"></div>
  <div class="map-overlay" id="menu">
    <input id="streets-v11" type="radio" name="rtoggle" value="streets-
v11" checked="checked">
    <label for="streets-v11">Streets</label>
    <input id="outdoors-v11" type="radio" name="rtoggle"
value="outdoors-v11">
    <label for="outdoors-v11">Outdoors</label>
    <input id="satellite-v9" type="radio" name="rtoggle" value="satellite-
v9">
    <label for="satellite-v9">Satellite</label>
    <input id="light-v10" type="radio" name="rtoggle" value="light-v10">
    <label for="light-v10">Light</label>
    <input id="dark-v10" type="radio" name="rtoggle" value="dark-v10">
    <label for="dark-v10">Dark</label>
  </div>
  <script>
    // Вставте свій Mapbox API ключ сюди
    mapboxgl.accessToken = 'YOUR_MAPBOX_ACCESS_TOKEN';
    // Створення карти
    var map = new mapboxgl.Map({
      container: 'map',
      style: 'mapbox://styles/mapbox/streets-v11', // початковий стиль
карти
      center: [30.5234, 50.4501], // Координати Києва
      zoom: 12
    });
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
// Додавання контролю перемикання шарів
var layerList = document.getElementById('menu');
var inputs = layerList.getElementsByTagName('input');

function switchLayer(layer) {
    var layerId = layer.target.value;
    map.setStyle('mapbox://styles/mapbox/' + layerId);
}
for (var i = 0; i < inputs.length; i++) {
    inputs[i].onclick = switchLayer;
}
</script>
</body>
</html>
```



(a)

(b)

Рис. 12. Стартова сторінка проекту Марбокс (а) та інтерфейс для створення токенів доступу (б)

В наведеному прикладі створюється інтерактивна карта за допомогою Mapbox GL JS JS (рис. 13). У частині `head` визначені основні метатеги для налаштування кодування сторінки та забезпечення підтримки мобільних пристроїв. Підключаються JavaScript і CSS файли з бібліотеки Mapbox GL JS для роботи з картами.

У частині `body` сторінки знаходиться контейнер з ідентифікатором `map`, який використовується для відображення карти, а також блок елементів з класом `map-overlay`, що містить перемикачі для вибору різних стилів карт.

Код JavaScript починається з визначення API ключа Mapbox (`mapboxgl.accessToken`), який необхідний для доступу до сервісу Mapbox. Потім створюється карта з початковим стилем `streets-v11`, центром з координатами Києва та початковим рівнем масштабування 12.

Також додається функціонал для перемикання шарів карти. Блок перемикачів в елементі з ідентифікатором `'menu'` дозволяє користувачам вибирати різні стилі карт. При виборі іншого шару викликається функція `switchLayer`, яка змінює стиль карти на вибраний.



Рис. 13. Вивід списку базових шарів для території м. Києва

Тепер додамо декілька векторних точок до попереднього прикладу.

```
<!DOCTYPE html>  
<html lang="en">
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
<head>
  <meta charset="UTF-8">
  <meta name="viewport" content="width=device-width, initial-
scale=1.0">
  <title>Mapbox GL JS Example</title>
  <script src="https://api.mapbox.com/mapbox-gl-js/v2.3.1/mapbox-
gl.js"></script>
  <link href="https://api.mapbox.com/mapbox-gl-js/v2.3.1/mapbox-
gl.css" rel="stylesheet" />
  <style>
    body { margin: 0; padding: 0; }
    #map { position: absolute; top: 0; bottom: 0; width: 100%; }
    .map-overlay { position: absolute; background: white; padding: 10px;
font-family: sans-serif; }
    .map-overlay .mapboxgl-ctrl { margin-bottom: 10px; }
    .map-overlay .mapboxgl-ctrl-group { display: inline-block; }
  </style>
</head>
<body>
  <div id="map"></div>
  <div class="map-overlay" id="menu">
    <input id="streets-v11" type="radio" name="rtoggle" value="streets-
v11" checked="checked">
    <label for="streets-v11">Streets</label>
    <input id="outdoors-v11" type="radio" name="rtoggle"
value="outdoors-v11">
    <label for="outdoors-v11">Outdoors</label>
    <input id="satellite-v9" type="radio" name="rtoggle" value="satellite-
v9">
    <label for="satellite-v9">Satellite</label>
    <input id="light-v10" type="radio" name="rtoggle" value="light-v10">
    <label for="light-v10">Light</label>
    <input id="dark-v10" type="radio" name="rtoggle" value="dark-v10">
    <label for="dark-v10">Dark</label>
  </div>
  <script>
    // Вставте свій Mapbox API ключ сюди
    mapboxgl.accessToken = 'YOUR_MAPBOX_ACCESS_TOKEN';
```

```
// Створення карти
var map = new mapboxgl.Мар({
    container: 'map',
    style: 'mapbox://styles/mapbox/streets-v11', // початковий стиль
карти
    center: [30.5234, 50.4501], // Координати Києва
    zoom: 12
});

// Додавання контролю перемикання шарів
var layerList = document.getElementById('menu');
var inputs = layerList.getElementsByTagName('input');
function switchLayer(layer) {
    var layerId = layer.target.value;
    map.setStyle('mapbox://styles/mapbox/' + layerId);
}

for (var i = 0; i < inputs.length; i++) {
    inputs[i].onclick = switchLayer;
}

// Додавання векторних даних
map.on('load', function () {
    // Додавання джерела даних
    map.addSource('places', {
        'type': 'geojson',
        'data': {
            'type': 'FeatureCollection',
            'features': [
                {
                    'type': 'Feature',
                    'geometry': {
                        'type': 'Point',
                        'coordinates': [30.5234, 50.4501]
                    },
                    'properties': {
                        'title': 'Kyiv Center',
                        'description': 'Center of Kyiv'
                    }
                }
            ]
        }
    });
});
```

4.2. Засоби публікації та представлення геопросторових даних в інтернет

```
        'type': 'Feature',
        'geometry': {
            'type': 'Point',
            'coordinates': [30.5176, 50.4476]
        },
        'properties': {
            'title': 'Another Point',
            'description': 'Another point in Kyiv'
        }
    }
});
// Додавання шару даних
map.addLayer({
    'id': 'places',
    'type': 'circle',
    'source': 'places',
    'paint': {
        'circle-radius': 10,
        'circle-color': '#007cbf'
    }
});

// Додавання pop-up при кліку на точку
map.on('click', 'places', function (e) {
    var coordinates = e.features[0].geometry.coordinates.slice();
    var title = e.features[0].properties.title;
    var description = e.features[0].properties.description;
    new mapboxgl.Popup()
        .setLngLat(coordinates)
        .setHTML('<strong>' + title + '</strong><p>' + description +
'</p>')
        .addTo(map);
});

// Зміна курсору на "поинтер" при наведенні на точку
map.on('mouseenter', 'places', function () {
    map.getCanvas().style.cursor = 'pointer';
});

// Зміна курсору назад при виході з точки
map.on('mouseleave', 'places', function () {
```

```
map.getCanvas().style.cursor = "
}); });
</script>
</body>
</html>
```

В наведеному прикладі аналогічно попередньому створюється інтерактивна карта за допомогою Mapbox GL JS, яка дозволяє користувачам перемикатися між різними стилями карт і взаємодіяти з векторними даними. У частині head визначені основні метатеги для налаштування кодування сторінки (UTF-8) та забезпечення адаптивності на мобільних пристроях. Далі підключаються файли CSS і JavaScript з бібліотеки Mapbox GL JS для роботи з картами, а також задаються стилі, щоб карта займала весь екран, а елементи інтерфейсу займали певні позиції відносно розміру екрану.

У частині body для відображення карти (#map) використано контейнер, а також блок перемикачів, які дозволяють користувачам змінювати стилі відображення карт (наприклад, Streets, Outdoors, Satellite).

Код JavaScript починається з визначення API ключа для Mapbox для доступу до сервісу. Далі створюється карта з початковим стилем streets-v11, центром з координатами Києва та масштабом 12. Код також додає функціонал для перемикання шарів карти через перемикачі. При виборі іншого стилю карти викликається функція switchLayer, яка змінює стиль карти на вибраній. При завантаженні карти додається джерело даних типу GeoJSON, яке містить дві точки з їх координатами та описом JS (рис. 14). Ці дані додаються як шар «circle» з визначеними параметрами (радіус кола та його колір). При натисканні на одну з точок з'являється спливаюче вікно з інформацією про цю точку. Також додається функціонал для зміни курсору миші на «pointer» при наведенні на точку, що покращує інтерфейс користувача.

Переваги та недоліки Mapbox. Переваги Mapbox GL JS включають високу продуктивність завдяки використанню WebGL, що забезпечує плавність роботи навіть з великими обсягами даних. Mapbox Studio дозволяє створювати власні стилі карт, які можна використовувати в додатках, а також налаштовувати карти за допомогою JSON стилів. Mapbox пропонує широкий набір інструментів для роботи з картами, таких як Mapbox Navigation SDK і Mapbox Geocoding API. Бібліотека підтримує різні формати

4.2. Засоби публікації та представлення геопросторових даних в інтернет

даних, включаючи GeoJSON, KML, GPX та Shapefiles, і дозволяє інтегруватися з іншими системами через REST API. Крім того, Марбох дозволяє додавати інтерактивні елементи та анімації на карти, а також забезпечує високу доступність сервісів завдяки хмарній інфраструктурі, що дозволяє обробляти великі обсяги даних і запити. Якісна документація та активна спільнота користувачів надають численні приклади та підтримку.

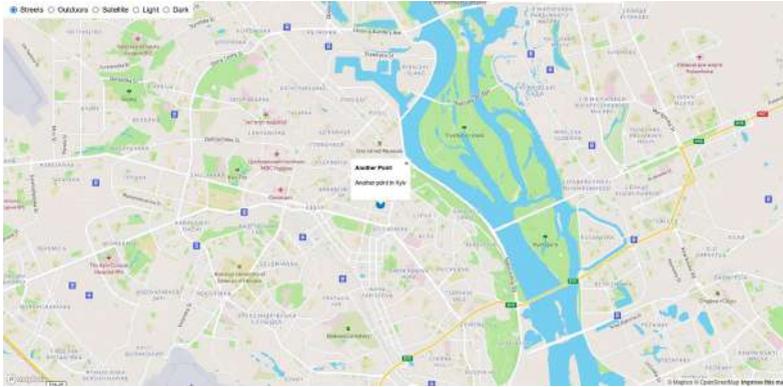


Рис. 14. Виведення векторних даних засобами Марбох

Недоліки Марбох включають вартість використання, яка може бути значною для великих проєктів через модель тарифікації на основі кількості запитів та обсягу даних. Безкоштовний тарифний план має обмеження, що може стати проблемою для масштабних проєктів. Використання Марбох залежить від стабільного інтернет-з'єднання, що може викликати затримки або проблеми з доступністю в регіонах з поганим інтернет-з'єднанням. Налаштування може бути складним для новачків через великий набір функцій та можливостей, що потребує часу для навчання. Марбох має обмежену підтримку офлайн-карт у веб-версії, що потребує додаткових налаштувань для створення офлайн-карт для мобільних додатків. Крім того, використання Марбох залежить від стабільності та політики стороннього провайдера, що може змінювати умови використання або тарифи.

Марбох є цікавим комерційним інструментом для створення інтерактивних карт та геопорталів, що надає широкий спектр можливостей для налаштування та інтеграції. Однак, вартість та складність можуть бути недоліками для деяких проєктів. При

виборі Mapbox важливо враховувати вимоги проєкту, можливі альтернативи та бюджетні можливості.

2.4. ГОТОВІ ДО ВИКОРИСТАННЯ РІШЕННЯ (MAPBENDER)

Mapbox [20] - **Mapbender** [21] — це Веб-GIS (геоінформаційна система), розроблена для управління геопросторовими даними та сервісами, яка дозволяє створювати, редагувати та публікувати геопросторові продукти у вигляді наборів тематичних шарів. Mapbender є частиною OSGeo (Open Source Geospatial Foundation) проєктів і забезпечує користувачів інструментами для роботи з даними через веб-інтерфейс [22]. Архітектурна схема MapBender представлена на рис. 15.

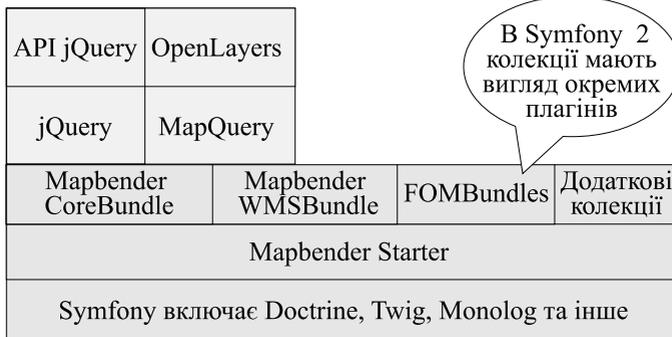


Рис. 15. Внутрішня архітектура Mapbender

Архітектура Mapbender складається з наступних блоків.

1. Клієнтська частина (frontend) забезпечує інтерфейс для кінцевих користувачів, дозволяючи їм взаємодіяти з Веб-картами. Вона побудована на основі стеку наступних технологій і складається з кількох ключових компонентів.

HTML задає структуру Веб-сторінок, створюючи основний каркас інтерфейсу користувача, тоді як **CSS** відповідає за стилізацію, забезпечуючи привабливий та зручний дизайн. **JavaScript** додає інтерактивність і динамічність, використовуючи такі бібліотеки, як **jQuery**, що полегшує роботу з DOM (Document Object Model) та обробку подій, і **OpenLayers**, яка дозволяє відображати, панорамувати, масштабувати та взаємодіяти з картографічними даними.

4.2. Засоби публікації та представлення геопросторових даних в інтернет

Клієнтська частина також включає **віджети** — інтерактивні компоненти, що надають різноманітні функції для роботи з картами. Серед них навігаційні віджети для панорамування, масштабування і повертання карти, інструменти для малювання та вимірювання точок, ліній і полігонів на карті, віджети для вибору та налаштування видимості шарів, інструменти для відображення інформації про об'єкти на карті, легенди та масштабні лінійки, а також інструменти для пошуку та геокодування.

Інтерактивні карти в Mapbender створюються за допомогою бібліотеки OpenLayers, що дозволяє користувачам переглядати картографічні дані в різних проєкціях та масштабах, накладати кілька шарів даних і налаштовувати їх прозорість, а також використовувати різні базові карти, такі як OpenStreetMap, Google Maps та Bing Maps.

Клієнтська частина також дозволяє взаємодіяти з різними картографічними сервісами для отримання та відображення геопросторових даних. Перш за все до них слід віднести WMS для обміну картографічними зображеннями, WFS для обміну геопросторовими об'єктами та WMTS для обміну картографічними фрагментами через Інтернет.

Користувачі можуть налаштовувати інтерфейс клієнтської частини Mapbender відповідно до своїх потреб. Зокрема, можна додавати, видаляти або налаштовувати віджети, вибирати шари даних, які відобразатимуться за замовчуванням, та їхнього порядку відображення. Також забезпечується персоналізація інтерфейсу, дозволяючи зберігати налаштування для кожного користувача для створення персоналізованого досвіду.

2. Серверна частина (backend). Mapbender використовує популярні веб-сервери для обробки HTTP-запитів. **Apache** є широко використовуваним веб-сервером, відомим своєю надійністю та гнучкістю, тоді як **Nginx** забезпечує високу продуктивність і ефективне використання ресурсів.

PHP є основною мовою програмування для серверної частини Mapbender. Вона обробляє запити від клієнтської частини, взаємодіє з базою даних і формує відповіді. Mapbender побудований на Symfony, популярному PHP фреймворку, який забезпечує структуровану архітектуру та набір інструментів для розробки веб-додатків.

Symfony-контролери відповідають за обробку HTTP-запитів, виконання бізнес-логіки та повернення відповідей клієнтській частині. Вони обробляють конкретні запити, виконують необхідні дії, такі як отримання даних з бази даних або виклик геосервісів,

і формують відповіді. Маршрутизація визначає, які контролери оброблятимуть певні URL-запити, забезпечуючи правильний розподіл запитів та логіку роботи додатку.

Mapbender використовує **реляційні бази даних** для зберігання конфігурацій та геопросторових даних. Основною системою управління базами даних є PostgreSQL, яка забезпечує надійне зберігання та доступ до даних, а розширення PostGIS додає підтримку геопросторових даних та запитів.

Серверна частина Mapbender **взаємодіє з різними геосервісами** для отримання та надання геопросторових даних. Це включає стандарти WMS для обміну картографічними зображеннями, WFS для обміну геопросторовими об'єктами та WMTS для обміну фрагментами картографічних зображень через Інтернет.

Mapbender надає **API для інтеграції** з іншими системами та розширення функціональних можливостей. **REST API** забезпечує програмний доступ до функцій Mapbender, що дозволяє автоматизувати завдання та інтегрувати Mapbender з іншими додатками. Система підтримує розширення через плагіни та модулі, що дозволяє додавати нові функції або інтегрувати сторонні сервіси.

Mapbender забезпечує надійні механізми для аутентифікації та авторизації користувачів. Система дозволяє створювати користувачів та призначати їм ролі з відповідними правами доступу, а також забезпечує детальні налаштування прав доступу для різних функцій та даних, що гарантує безпеку та конфіденційність.

Mapbender також включає інструменти збору службової інформації та моніторингу. Журнали подій містять записи про дії користувачів та системи, що допомагає у відстеженні та розв'язанні проблем. Інструменти для моніторингу продуктивності серверної частини дозволяють своєчасно виявляти та вирішувати проблеми з продуктивністю.

До переваг клієнтської частини Mapbender можна віднести інтерактивність та вдалий користувацький досвід.

Mapbender пропонує інтуїтивний інтерфейс, який розроблений для зручності використання кінцевими користувачами. Він забезпечує простоту навігації та легкий доступ до основних функцій. Адаптивний дизайн дозволяє користуватися Mapbender на різних пристроях, включаючи комп'ютери, планшети та смартфони, забезпечуючи однаковий досвід використання незалежно від розміру екрана.

4.2. Засоби публікації та представлення геопросторових даних в інтернет

Інтерактивні функції включають динамічне завантаження даних, що відображаються в реальному часі, а також можливість взаємодії з картами через кліки, перетягування, масштабування та інші дії.

Клієнтська частина Mapbender спроектована для легкої інтеграції з іншими системами та сервісами. Вона підтримує загальноприйняті стандарти, такі як WMS, WFS, WMTS, що забезпечує сумісність з іншими геопросторовими системами та інструментами. Крім того, API надає програмний доступ до функцій Mapbender, дозволяючи розробникам створювати власні рішення та інтеграції.

До переваг серверної частини Mapbender можна віднести наступні особливості. Дане ПЗ є проектом з відкритим кодом, що означає, що користувачі мають доступ до вихідного коду і можуть його модифікувати, налаштовувати під свої потреби та розповсюджувати. Безкоштовність використання робить Mapbender доступним для різних організацій та проектів незалежно від їх бюджету.

Mapbender також відзначається гнучкістю та масштабованістю. Його модульна архітектура дозволяє додавати нові функції та розширення без значних змін у базовій структурі. Mapbender може бути налаштований для роботи з великими обсягами даних та високими навантаженнями, що робить його придатним для проектів різного масштабу.

Він підтримує основні стандарти для роботи з геопросторовими даними, зокрема стандарти OGC, такі як WMS, WFS, та WMTS. Це забезпечує сумісність з іншими ГІС-системами та сервісами, а також полегшує інтеграцію з різними базами даних та геосервісами.

Mapbender використовує Symfony як основний фреймворк для серверної частини, що забезпечує стабільність, безпеку та багатий набір інструментів для розробки веб-додатків. Він також має вбудовані механізми для управління доступом, що дозволяють налаштовувати права доступу для різних користувачів та ролей.

Керувати налаштуваннями та адмініструвати Mapbender можна через зручний Веб-інтерфейс, який дозволяє легко управляти користувачами, правами доступу, шарами даних та іншими параметрами.

Mapbender забезпечує інтеграцію та розширюваність завдяки наявності REST API для програмного доступу до своїх функцій, що дозволяє інтегрувати його з іншими системами та автоматизувати процеси. Система підтримує створення та

використання плагінів і модулів, що дозволяє додавати нові функції та інтеграції без зміни основного коду.

Висока продуктивність Marbender досягається завдяки використанню сучасних технологій та оптимізованих алгоритмів, які забезпечують ефективну роботу навіть з великими обсягами даних. Система також підтримує кешування, що зменшує навантаження на сервер та прискорює відображення даних.

Більшу частину операцій по керуванню таким геопорталом можна зробити у зручному Веб-інтерфейсі. На рисунках (рис. 16-18) нижче представлені окремі елементи керування, доступні в Marbender.



Рис. 16. Створення групи Viewer

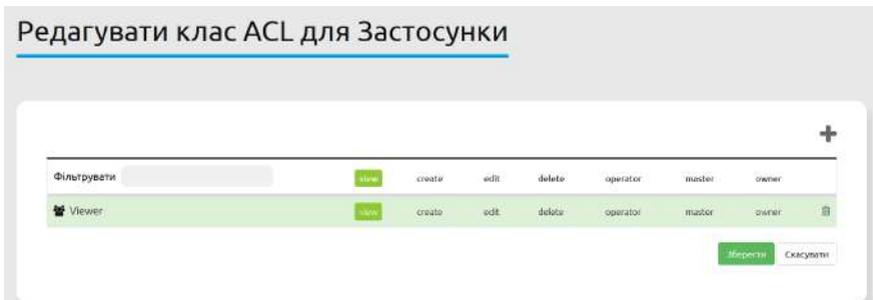


Рис. 17. Робота зі списками контролю доступу для групи Viewer



Додати джерело

Тип *
OGC WMS

Service URL-адреса сервісу *
http://localhost:8080/geoserver/ows?service=wms&version=1.3.0&request=GetCapabilities&AcceptLanguages=uk

Ім'я користувача
admin

Пароль

Зберегти Скасувати

Рис. 18. Додавання нового джерела даних з доступом по протоколу WMS

В межах проєкту e-shape “EO in support of agricultural activities: new horizons” [23] на базі Mapbender було розгорнуто портал, який є практичною демонстрацією можливостей цього додатку. Для дашборду визначено набір користувацьких інструментів (рис. 19) та продемонстровано можливості зміни стилів для зовнішнього вигляду дашборду (рис. 20). Створений дашборд отримує дані по WMS протоколу з низки налаштованих джерел (рис. 21).

Портал містить деякі геопросторові продукти, які оцінюють індикатор цілі сталого розвитку 2.4.1 «Частка сільськогосподарських площ під продуктивним та сталим сільським господарством» та 15.3.1 «Частка деградованої землі від загальної площі землі» (рис. 22). Також створений портал містить низку растрових геопросторових продуктів, зокрема LAI (Leaf Area Index) для території України (рис. 23).

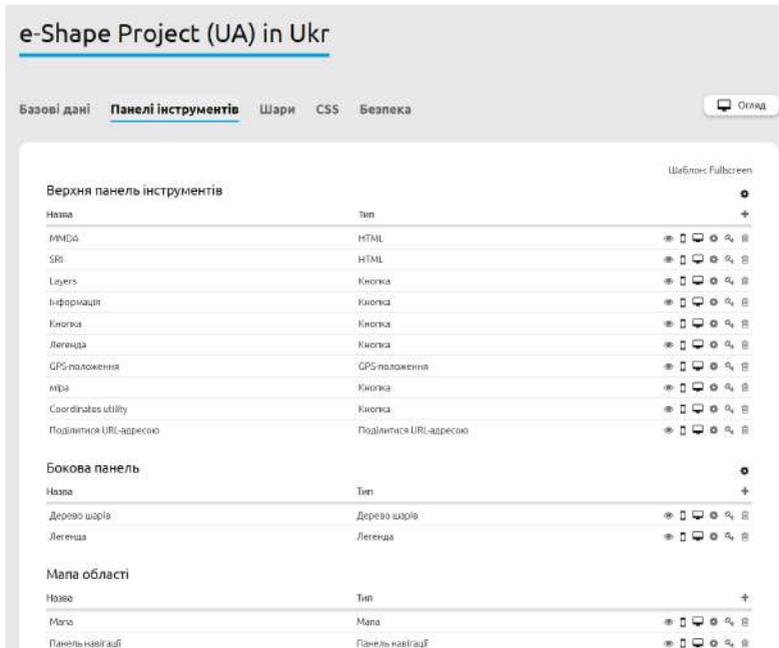


Рис. 19. Налаштування віджетів для дашборду

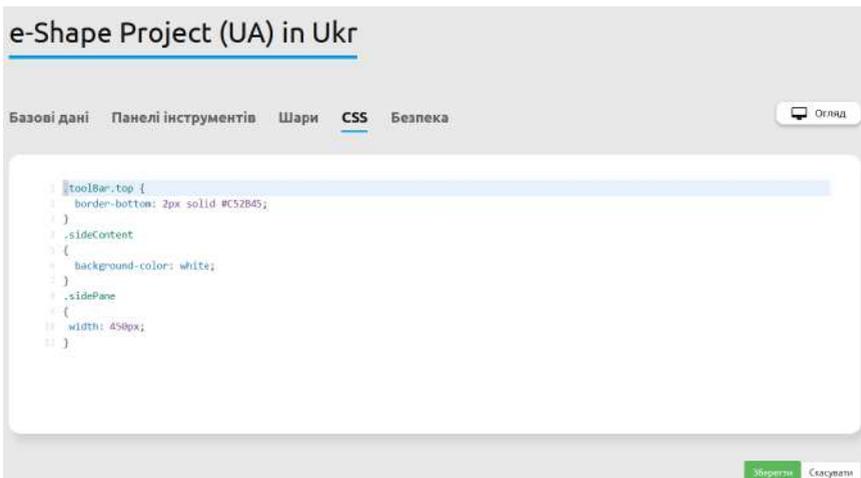


Рис. 20. Використання CSS для зміни зовнішнього вигляду дашборду

4.2. Засоби публікації та представлення геопросторових даних в інтернет

e-Shape Project (UA) in Ukr

Базові дані Панелі інструментів **Шари** CSS Безпека

Огляд

Фільтрувати +

Ukraine

Id	Назва	Тип	+ ☰ ☲
6/122	Індикатор ЦСР 2.4.1 Україна (DID NOT FIND 118n CONTENT FOR THIS ELEMENT)	↓ WMS	☰ ☲
6/123	Карта деградації земель України (DID NOT FIND 118n CONTENT FOR THIS ELEMENT)	↓ WMS	☰ ☲
6/124	MODIS LAI Україна (DID NOT FIND 118n CONTENT FOR THIS ELEMENT)	↓ WMS	☰ ☲
6/125	Змодельований LAI Україна (DID NOT FIND 118n CONTENT FOR THIS ELEMENT)	↓ WMS	☰ ☲
1/120	OSM Demo (OSM Demo)	↓ WMS	☰ ☲

overview

Id	Назва	Тип	+ ☰ ☲
1/121	OSM Demo (OSM Demo)	↓ WMS	☰ ☲

[Зберегти](#) [Скасувати](#)

Рис. 21. Налаштування шарів даних дошборду

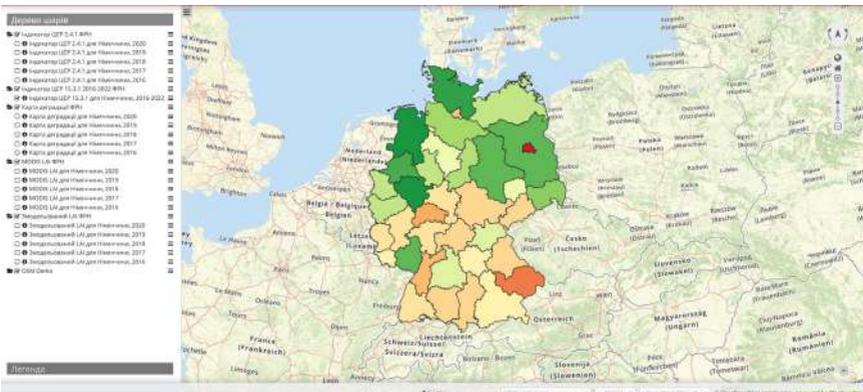


Рис. 22. Відображення векторних даних на дашборді

Mapbender є доволі зручним і готовим для використання клієнтським рішенням для створення геопорталів, але при виборі його як основи накладаються певні архітектурні та функціональні обмеження, які можуть ускладнювати значну кастомізацію проекту під власні потреби або вимагати для цього значно більше зусиль, ніж вже розглянуті аналоги (Leaflet, OpenLayers тощо).

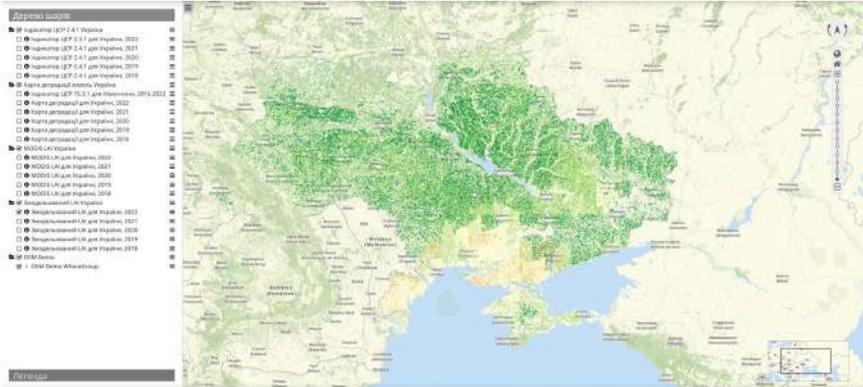


Рис. 23. Відображення растрових даних на дашборді

ВИСНОВКИ

Технології створення геопорталів грають ключову роль у розвитку сучасних систем для роботи з геопросторовими даними. Вони дозволяють ефективно візуалізувати, аналізувати та управляти геоданими, надаючи користувачам зручні інструменти для доступу до картографічної інформації. У цьому розділі розглянуто такі рішення, як Geoserver, MapServer, QGIS Server, Leaflet, OpenLayers, Mapbox та Mapbender, кожне з яких має свої переваги і підходить для певних типів проєктів.

Geoserver є одним із найбільш популярних серверних рішень для роботи з геопросторовими даними. Він підтримує численні формати даних і стандарти OGC, що робить його ідеальним рішенням для інтеграції з іншими системами. Geoserver дозволяє легко публікувати та обробляти великі обсяги геоданих, забезпечуючи високий рівень гнучкості та масштабованості. Його функції, включаючи можливість створення складних стилів для карт і підтримку великих наборів даних, роблять його популярним вибором для організацій, які працюють з великими і складними геопросторовими проєктами.

MapServer є ще одним серверним рішенням, яке відзначається високою продуктивністю і можливістю роботи з широким спектром форматів даних. Він підходить для проєктів, де потрібна ефективна обробка та відображення великих обсягів геоданих. MapServer підтримує стандарти OGC, що дозволяє інтегрувати його з іншими ГІС-системами та інструментами. Його здатність працювати з різноманітними джерелами даних і високий

4.2. Засоби публікації та представлення геопросторових даних в інтернет

рівень продуктивності роблять його відмінним вибором для проєктів з високими вимогами до швидкості обробки та відображення даних.

QGIS Server є серверною частиною популярного настільного ГІС-рішення QGIS. Він дозволяє легко публікувати картографічні дані, створені в QGIS Desktop, у Веб-додатках. QGIS Server інтегрується з QGIS Desktop, що робить його зручним інструментом для тих, хто вже використовує QGIS для створення карт. Ця технологія забезпечує зручний та інтуїтивно зрозумілий інтерфейс для публікації карт, а також підтримує основні геопросторові стандарти, що робить його відповідним вибором для проєктів, де потрібно швидко створити веб-карти з мінімальними витратами на налаштування.

На стороні клієнта існує кілька бібліотек для роботи з картами у Веб-додатках, які мають різні можливості та різну складність використання.

Leaflet є легкою та простою у використанні бібліотекою, яка ідеально підходить для створення базових картографічних додатків. Вона має невеликий розмір, що забезпечує швидке завантаження і високу продуктивність навіть на мобільних пристроях. Leaflet підтримує широкий спектр плагінів, які розширюють її функціональність, роблячи її популярним вибором для невеликих та середніх проєктів, де потрібна інтерактивність і легкість у використанні.

OpenLayers є значно складнішою бібліотекою, яка забезпечує ширшу функціональність порівняно з Leaflet. Вона підтримує роботу з різними форматами даних і проєкціями, що зумовлює її відповідність для складних картографічних проєктів. OpenLayers надає гнучкість у налаштуванні та дозволяє створювати кастомні рішення для різних типів проєктів. Завдяки підтримці основних стандартів OGC, вона легко інтегрується з серверними рішеннями, такими як Geoserver і MapServer.

Mapbox є потужною комерційною платформою для створення інтерактивних карт, яка використовує векторні карти для забезпечення високої продуктивності і деталізації. Вона надає інструменти для кастомізації карт, що дозволяє створювати унікальні картографічні рішення. Mapbox також пропонує різноманітні API для геокодування, навігації та інших геофункцій, що робить її популярним вибором для проєктів, де потрібна висока інтерактивність і деталізація карт. Завдяки підтримці хмарної інфраструктури, Mapbox забезпечує високу

доступність і масштабованість, що робить її придатною для великих проєктів.

Mapbender є готовим рішенням для створення геопорталів, яке надає користувачам зручний веб-інтерфейс для роботи з картами. Вона інтегрується з різними геосервісами, такими як WMS, WFS та WMTS, і забезпечує легкість у налаштуванні та використанні. Mapbender підтримує розширення через плагіни та модулі, що дозволяє додавати нові функції та інтеграції без зміни основного коду. Це робить Mapbender відмінним вибором для організацій, які шукають простий та ефективний інструмент для створення та адміністрування геопорталів.

Все це представляє собою різноманітний набір інструментів для створення геопорталів. Вибір відповідної технології залежить від специфічних вимог проєкту, таких як обсяг даних, необхідність у кастомізації, інтерактивність і бюджет. Використання цих інструментів дозволяє створювати ефективні, функціональні та масштабовані рішення для роботи з геопросторовими даними.

ПЕРЕЛІК ПОСИЛАНЬ

1. Шелестов, А. Ю., Куссуль, Н. М., Скакун, С. В., Кравченко, О. М., Волошин, С. В., & Загородній, Є. В. (2011). Геоінформаційна система моніторингу для сільськогосподарського підприємства. *Наукові праці Донецького національного технічного університету. Серія: Інформатика, кібернетика та обчислювальна техніка*, (13), 121-125.
2. Шелестов, А. Ю., Кравченко, А. Н., Скакун, С. В., Волошин, С. В., & Куссуль, Н. Н. (2013). Информационная система агромониторинга на основе геопространственных данных. *Кибернетика и системный анализ*.
3. Шелестов, А. Ю., Куссуль, Н. М., Волошин, С. В., Скакун, С. В., Кравченко, О. М., & Колотій, А. В. (2011). Геоінформаційна система фермера. *Наука та інновації*, 7(3), 25-29.
4. Corti, P., Bartoli, F., Fabiani, A., Giovando, C., Kralidis, A. T., & Tzotsos, A. (2019). *GeoNode: an open source framework to build spatial data infrastructures* (No. e27534v1). PeerJ Preprints.
5. Kulawiak, M., Dawidowicz, A., & Pacholczyk, M. E. (2019). Analysis of server-side and client-side Web-GIS data processing methods on the example of JTS and JSTS using open data from OSM and geoportals. *Computers & Geosciences*, 129, 26-37.

4.2. Засоби публікації та представлення геопросторових даних в інтернет

6. Jiang, H., van Genderen, J., Mazzetti, P., Koo, H., & Chen, M. (2020). Current status and future directions of geoportals. *International Journal of Digital Earth*.
7. Сайт GeoServer. <https://geoserver.org/>
8. Сайт Spring Framework. <https://spring.io/projects/spring-framework>
9. Сайт GeoTools. <https://www.geotools.org/>
10. Gui, Z., Cao, J., Liu, X., Cheng, X., & Wu, H. (2016). Global-scale resource survey and performance monitoring of public OGC web map services. *ISPRS International Journal of Geo-Information*, 5(6), 88.
11. Сайт MapServer. <https://mapserver.org/>
12. Сайт GDAL/OGR. <https://gdal.org/en/latest/faq.html#what-is-this-ogr-stuff>
13. Сайт QGIS Server. https://docs.qgis.org/3.34/en/docs/server_manual/index.html
14. Khan, S., & Mohiuddin, K. (2018). Evaluating the parameters of ArcGIS and QGIS for GIS Applications. *Int. J. Adv. Res. Sci. Eng*, 7, 582-594.
15. Сайт Leaflet. <https://leafletjs.com/>
16. Horbiński, T., & Lorek, D. (2022). The use of Leaflet and GeoJSON files for creating the interactive web map of the preindustrial state of the natural environment. *Journal of Spatial Science*, 67(1), 61-77.
17. Сайт плагіну для Leaflet. <https://www.liedman.net/leaflet-routing-machine/>
18. Сайт OpenLayers. <https://openlayers.org/>
19. Zunino, A., Velázquez, G., Celestini, J. P., Mateos, C., Hirsch, M., & Rodriguez, J. M. (2020). Evaluating the performance of three popular Web mapping libraries: A case study using Argentina's life quality index. *ISPRS International Journal of Geo-Information*, 9(10), 563.
20. Сайт Mapbox. <https://docs.mapbox.com/mapbox-gl-js/api/>
21. Сайт MapBender. <https://mapbender.org/en/>
22. Kuzin, V., Musial, J., & Shelestov, A. (2022, December). EO4ua initiative: Scientific European support of Ukrainian scientific community. In *2022 12th International Conference on Dependable Systems, Services and Technologies (DESSERT)* (pp. 1-5). IEEE
23. Сайт проєкту e-shape. <https://e-shape.eu/index.php/showcases/pilot-1-6-service-for-sdg-2-4-1-and-15-3-1-indicators-assessment>

ПІСЛЯМОВА

Завершуючи цю монографію, ми щиро дякуємо усім, хто долучився до її створення: авторам, редакторам, видавцям і партнерам. Відданість справі, професіоналізм і командна робота стали основою для створення цього видання, яке об'єднує результати сучасних досліджень у галузі комп'ютерного зору, глибинних нейронних мереж і їх застосування для обробки даних у задачах еколого-економічного аналізу. Цей проєкт об'єднав зусилля досвідчених науковців, молодих дослідників, аспірантів і студентів кафедри математичного моделювання та аналізу даних, створивши ще міцніший фундамент для нашої наукової спільноти.

Монографія була реалізована завдяки значному досвіду виконання національних і міжнародних проєктів за підтримки Міністерства освіти і науки України, Національної академії наук України, Європейської комісії та інших міжнародних організацій. Особливо хочемо подякувати нашим аспірантам і молодим науковцям, які внесли вагомий інтелектуальний і творчий внесок у цю роботу, демонструючи наполегливість, інноваційність і прагнення до результату. Спільна робота над цією монографією не лише допомогла досягти важливих наукових результатів, а й зміцнила нашу команду, об'єднавши колектив навколо спільної мети.

Окрема подяка нашим родинам, які підтримують нас у всіх починаннях і з розумінням ставляться до годин, витрачених на дослідження, написання текстів і редагування поза робочим часом, під час вихідних і відпусток. Ваша підтримка є неоціненною частиною цього процесу.

Ця монографія є не лише підсумком значного етапу нашої роботи, але й початком нових перспектив. Викладені підходи й методи мають великий потенціал для розвитку інтелектуальних систем, які можуть знайти широке застосування у практичній діяльності, прийнятті стратегічних рішень і забезпеченні сталого розвитку. Ми сподіваємося, що ця праця стане джерелом нових ідей для наступних проєктів і подальших досліджень.

Результати, представлені у монографії, відіграють ключову роль у професійному зростанні молодих науковців. На основі цих досліджень уже планується захист кількох дисертацій аспірантів, що стане важливим внеском у розвиток прикладної математики в Україні.

Попереду у нас нові горизонти. Вже починаються нові міжнародні проєкти, що ґрунтуватимуться на наявних результатах

і сприятимуть впровадженню новітніх технологій штучного інтелекту в різні сфери життя. Ми віримо, що ця монографія надихне колег-науковців на нові відкриття, приверне увагу студентів до вивчення прикладної математики та сприятиме створенню інноваційних рішень для вирішення сучасних викликів.

З вдячністю та найкращими побажаннями,
Авторський колектив.

ЗМІСТ

ВСТУП	3
Частина 1. Аналіз сучасного стану методів комп'ютерного зору і глибинних нейронних мереж для еколого-економічного аналізу.....	11
Розділ 1. Аналіз методів та моделей глибинного навчання для розв'язання прикладних задач.....	11
Вступ	11
1.1. Визначення штучного інтелекту.....	13
1.2. Машинне навчання	13
1.3. Огляд моделей та методів глибинного навчання для супутникового моніторингу.....	16
1.4. Згорткові нейронні мережі (CNN).....	17
1.5. Рекурентні нейронні мережі (RNN).....	22
1.6. Генеративні змагальні мережі.....	24
1.7. Використання генеративних змагальних мереж у супутниковому моніторингу	25
1.8. Трансформери.....	27
1.9. Графова нейронна мережа (GNN).....	29
Висновки	35
Перелік посилань.....	37
Розділ 2. Аналіз методів 3D реконструкції середовища для доповненої реальності	49
Вступ	49
2.1. Тривимірна реконструкція як важлива складова доповненої реальності	50
2.2. Методи реконструкції карти глибини по 2D даним.....	53
2.2.1. Лінійна перспектива.....	54
2.2.2. Атмосферне розсіювання.....	55
2.2.3. Розуміння форми по затіненню	56
2.2.4. Бінокулярний диспарат.....	56
2.2.5. Паралакс руху	57
2.2.6. Розмиття зображення.....	58
2.2.7. Силует (Shape-from-silhouette).....	59
2.2.8. Структура з руху (Structure from Motion – SfM).....	60
2.3. Класичні методи 3D реконструкції середовища	61
2.3.1. Відновлення структури з руху для задачі 3D реконструкції	61
2.3.2. Багатовидове стереоспівставлення.....	64
2.3.3. Реконструкція поверхні	66

2.3.4. Поєднання методів SfM, MVS та реконструкції поверхні	66
2.4. Сучасні методи 3D реконструкції середовища	67
2.4.1. HighRes-MVSNet	68
2.4.2. 3D-FHNet	70
2.4.3. Atlas	72
2.4.4. Simplerecon	73
2.4.5. Marigold	75
Висновки	78
Перелік посилань.....	79
Розділ 3. Аналіз методів та моделей комп'ютерного зору та глибинних нейронних мереж для визначення пошкоджень земного покриву	82
Вступ	82
3.1. Методи визначення незаконних звалищ	85
3.2. Методи оцінки пошкоджень внаслідок воєнних дій	94
Висновки	121
Перелік посилань.....	122
Частина 2. Методи комп'ютерного зору і глибинних нейронних мереж для супутникового інтелекту.....	127
Розділ 1.Метод виявлення аномалій в даних навчання моделей комп'ютерного зору на основі методів кластеризації... 	127
Вступ	127
1.1. Постановка задачі	129
1.2. Розв'язання задачі	132
1.3. Аналіз результатів	134
1.4. Можливості практичного застосування	136
Обговорення і висновки.....	138
Перелік посилань.....	139
Розділ 2. Методи сегментації зображень різної природи для випадку незбалансованого набору.....	143
Вступ	143
2.1. Вдосконалення методу глибинного навчання для класифікації земного покриву та виявлення типу сільськогосподарських культур.....	144
2.1.1. Огляд літератури	144
2.1.2. Постановка задачі	146
2.1.3. Розв'язання задачі.....	147
2.1.3.1. Генеративна змагальна мережа	149
2.1.3.2. Схема аугментації.....	151
2.1.3.3. Класичний підхід до аугментації	151
2.1.4. Обговорення і висновки	152

2.2. Вдосконалення методу глибинного навчання для сегментації гістологічних зображень	154
2.2.1. Огляд літератури	155
2.2.2. Постановка задачі	156
2.2.3. Розв'язання задачі	157
2.2.3.1. Покращення алгоритму виявлення неоднозначних даних	158
2.2.3.2. Набори вагових масок	161
2.2.3.3. Архітектура моделі та схема експерименту	163
2.2.4. Обговорення і висновки	164
Висновки	166
Перелік посилань	168
Розділ 3. 1+λ GP encodings еволюційний алгоритм для безпечної роботи з даними різних модальностей	172
Вступ	172
3.1. 1+λ еволюційний алгоритм з GP кодуванням	173
3.2. Постановка задачі та запропонований підхід	176
3.3. Набори даних	178
3.4. Особливості навчання	181
3.5. Аналіз результатів експериментів	183
3.6. Аналіз результатів	186
Висновки	187
Перелік посилань	188
Розділ 4. Задача розмітки на деревах для поступового надходження даних	192
Вступ	192
4.1. Задача розмітки на деревах	193
4.1.1. Постановка задачі	193
4.1.2. Зведення задачі пошуку оптимальної розмітки дерева до задачі пошуку найкращого шляху на графі спеціального вигляду	193
4.2. Задача розмітки для випадку поступового надходження даних	196
4.2.1. Задача розмітки для випадку поступового надходження даних	197
4.3. Застосування запропонованого методу на прикладі задачі стереозору	202
4.3.1. Задача стереозору	202
4.3.2. Пошук карти глибини при повних даних	203
4.3.3. Зведення задачі до пошуку найкоротшого шляху на графі	205

4.3.4. Пошук карти глибини при поступовому надходженні даних	206
4.3.5. Неупорядковане надходження даних. Найгірший випадок	209
4.3.6. Практичний аналіз роботи запропонованого методу на прикладі задачі стереозору	210
4.4. Результати.....	212
4.5. Подальші дослідження	213
Висновки	213
Перелік посилань.....	214
Розділ 5. Генеративні мережі для підвищення просторового розрізнення супутникових даних на основі трансформерів з увагою (transformers with attention)	216
Вступ	216
5.1. Огляд літератури	219
5.2. Постановка задачі	223
5.3. Розв'язання задачі	223
5.4. Аналіз результатів	228
Висновки	234
Перелік посилань.....	238
Частина 3. Прикладні задачі супутникового інтелекту на мультимодальних даних	242
Розділ 1. Визначення оптимальних місць для розміщення сонячних електростанцій на території України	242
Вступ	242
1.1. Огляд літератури	243
1.2. Постановка задачі	245
1.3. Використані дані.....	246
1.4. Опис методології.....	250
1.5. Нечітка логіка для нормалізації вхідних геопросторових даних	252
1.6. Визначення вагових коефіцієнтів за допомогою методу попарних порівнянь	258
1.7. Модель зваженої суми.....	261
1.8. Оцінка придатності земель України для встановлення сонячних електростанцій	262
Висновки	265
Перелік посилань.....	266
Розділ 2. Моделювання розвитку інфраструктури сіл на основі графових даних.....	269
Вступ	269
2.1. Сучасні підходи до оцінки розвитку сільських громад	269

2.1.1. Геопросторова характеристика сільських поселень у провінції Цзянсі	271
2.1.2. Геопросторовий аналіз якості життя у сільських районах України	273
2.1.3. Геопросторові технології для картографування та аналізу поселень в Індії.....	275
2.1.4. Просторово-часовий аналіз глобальних даних про міські будівлі в OSM	276
2.1.5. Кластеризація графових даних.....	278
2.2. Постановка задачі оцінки розвитку сільської інфраструктури.	279
2.3. Використані дані.....	280
2.4. Методології розв'язання задачі кластеризації	284
2.5. Методи візуалізації геопросторових даних	293
2.5.1. Візуалізація результатів кластерного аналізу.....	298
2.5.2. Оптимізація оцінок доступності на основі графових даних	316
2.6. Обговорення.....	325
Висновки	327
Перелік посилань.....	329
Розділ 3. Аналіз індикаторів економічної діяльності на основі різнорідних даних	332
Вступ	332
3.1. Виявлення ознак економічної діяльності в регіонах за даними різної природи.....	333
3.1.1. Оцінка динаміки економічної діяльності за якістю повітря	333
3.1.2. Оцінка динаміки економічної діяльності за нічним освітленням.....	337
3.1.3. Моніторинг економічної діяльності з використанням різнорідних геопросторових даних та супутникових даних підвищеного розрізнення в умовах війни	345
3.1.4. Моніторинг пошкоджень полів з використанням різнорідних геопросторових даних та супутникових даних підвищеного розрізнення в умовах війни	355
3.1.5. Використані дані	358
3.1.6. Методологія порівняння використання даних різного просторового розрізнення	360
3.1.7. Результат використання даних різного розрізнення	363
Висновки	372
Перелік посилань.....	374

Розділ 4. Класифікації типів земного покриття та землекористування на основі супутникових даних з використанням Transfer Learning	380
Вступ	380
4.1. Аналіз методів Transfer Learning для класифікації земного покриття	381
4.2. Постановка задачі	384
4.3. Дані та територія досліджень	384
4.4. Проведення експериментів	387
4.5. Імплементация моделі машинного навчання з багатовимірним векторним виходом на основі Transfer Learning на хмарній платформі AWS	394
Висновки	399
Перелік посилань	400
Частина 4. Сучасні інформаційні технології для комп'ютерного зору і глибоких нейронних мереж	403
Розділ 1. Сучасні підходи до злиття та гармонізації різнорідних геопросторових даних	403
Вступ	403
1.1. Хмарні платформи як інструмент гармонізації різнорідних даних	404
1.2. Інфраструктура Google Earth Engine	405
1.3. Інфраструктура CREODIAS	409
Висновки	414
Перелік посилань	415
Розділ 2. Засоби публікації та представлення геопросторових даних в Інтернет	417
Вступ	417
2.1. Огляд порталів	418
2.2. Серверна частина	420
2.2.1. GeoServer	420
2.2.2. MapServer	422
2.2.3. QGIS Server	424
2.3. Клієнтські бібліотеки	426
2.3.1. Leaflet	426
2.3.2. OpenLayers	438
2.3.3. Mapbox GL JS	445
2.4. Готові до використання рішення (MapBender)	454
Висновки	462
Перелік посилань	464
Післямова	466
ЗМІСТ	468

Наукове видання

**ЗА РЕДАКЦІЄЮ
КУССУЛЬ Наталії Миколаївни
ШЕЛЕСТОВА Андрія Юрійовича**

**МЕТОДИ КОМП'ЮТЕРНОГО ЗОРУ І
ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ
ДЛЯ ЕКОЛОГО-ЕКОНОМІЧНОГО
АНАЛІЗУ**