

УДК 004.93

П.В. Мікава, Б.Я. Яйлимов

МЕТОДИ МАШИННОГО НАВЧАННЯ ДЛЯ МОНІТОРИНГУ НАВКОЛИШНЬОГО СЕРЕДОВИЩА

Мікава Поліна Віталіївна

Навчально-науковий фізико-технічний інститут Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського»,
orcid: 0009-0002-6242-5218

geor.polina@gmail.com

Яйлимов Богдан Ялканович

Інститут космічних досліджень НАН України та ДКА України, Київ,
orcid: 0000-0002-2635-9842

yailyimov@gmail.com

У роботі запропоновано комплексний підхід до виявлення звалищ, який має дві основні складові. Перша базується на класифікації часових рядів мультиспектральних супутникових даних з використанням ансамблю нейронних мереж. Друга використовує модифіковану архітектуру U-Net для семантичної сегментації космічних знімків з метою безпосереднього виділення звалищ. Новизна представленого рішення полягає у використанні комбінованої функції втрат при навчанні моделі U-Net, що поєднує бінарну крос-ентропію та коефіцієнт Dice. Бінарна крос-ентропія забезпечує надійну піксельну класифікацію, тоді як коефіцієнт Dice оптимізує сегментацію шляхом максимізації перетину між прогнозованими та істинними масками звалищ. Ця комбінація дозволяє досягти балансу між точністю класифікації та чутливістю до малих об'єктів, що важливо для виявлення звалищ за супутниковими даними. Запропоновано інтегрувати результати двох підходів на рівні прийняття рішень за допомогою ймовірнісного злиття з використанням ймовірностей кожної моделі. Такий гібридний метод дозволяє компенсувати недоліки кожного методу та підвищити загальну точність ідентифікації звалищ. Експериментальна перевірка на тестових даних продемонструвала ефективність розглянутого підходу. Загальна точність класифікації земного покриття склала 97,4 %, а точність визначення звалищ — 86,4 %. Розроблений метод застосовано для картографування звалищ на території Донецької області. Результати верифіковано експертами на місцевості. Отримані дані можуть бути використані місцевою владою для оперативного реагування та прийняття управлінських рішень.

Ключові слова: методи машинного навчання, супутникові дані, методи глибокого навчання, злиття даних, U-Net, CNN, функція активації, піксельні методи, класифікації.

Вступ

Використання супутникових даних і машинного навчання для моніторингу навколишнього середовища та аналізу звалищ розглянуто в кількох дослідженнях. Зокрема, в роботі [1] показано, що мультиспектральні та теплові супутникові зображення можуть бути використані для виявлення підземних пожеж і теплових аномалій на звалищах. Аналізуючи тенденції температури за супутниковими даними, автори визначили гарячі точки на звалищах і допомогли дистанційно стежити за пожежами на них. Це забезпечує економічно ефективний підхід для власників і операторів сміттєзвалищ для покращення управління пожежами на звалищах.

Автори роботи [2] запропонували підхід, який поєднує гіперспектральні зображення з бортових датчиків і топографічні карти звалищ для визначення екологічних об'єктів інтересу (Environmental Performance Index — EPI) на території звалищ. Завдяки аналізу гіперспектральних даних вони охарактеризували поверхневі матеріали. Поєднавши це з картами звалищ і наземними обстеженнями, автори виявили місця з потенційним забрудненням для подальшого відбору хімічних проб. Така методологія дозволила покращити характеристику сміттєзвалища та виділити конкретні ділянки, які потребують детальної перевірки.

У роботі [3] представлено статистико-числову модель з використанням даних викидів на поверхні звалища після відбору польових проб і дистанційного зондування. Модель дозволяє визначати джерела викидів метану зі сміттєзвалищ — знаходити гарячі точки викидів і аналізувати вплив характеристик сміттєзвалища, таких як щільність відходів, вміст вологи та властивості покривного ґрунту, на потоки метану. Такий підхід демонструє ефективність обчислювального моделювання в дослідженнях викидів парникових газів зі звалищ.

У статті [4] запропоновано методологію, засновану на комп'ютерному моделюванні роботи полігону та систематичному аналізі отриманих даних для оцінки різних конфігурацій полігону. Шляхом моделювання та утворення різних фільтрів з використанням різних комбінацій проєктних параметрів, таких як розмір камери, нахил, глибина тощо, автори визначили оптимальні значення для покращеного управління фільтратом. Такий підхід дозволяє тестувати та оптимізувати параметри планування та будівництва полігонів.

Процес картографування сміттєзвалищ, що здійснюється за допомогою машинного навчання з використанням зображень безпілотного літального апарату (БПЛА), наведено у роботі [5]. Після обробки даних будуються 3D-моделі та визначаються особливості рельєфу. В подальшому розроблені методи використовуються в навчанні випадкових моделей лісу для класифікації сміттєзвалищ на ортомозаїках, створених за допомогою БПЛА. Представлена методологія забезпечує швидкий і недорогий підхід для отримання карт звалищ з високою роздільною здатністю проти ручного оцифрування або супутникового картографування.

Модель машинного навчання з використанням даних ґрунту для прогнозування кількості нітратів на сільськогосподарських полях розроблено у роботі [6]. Незважаючи на те що така модель показала хороші результати на тестових даних, реальна можливість її застосування обмежена через біофізичні процеси. Це підкреслює необхідність гібридних підходів, що поєднують дані з різних джерел.

У роботі [7] створено моделі машинного навчання з використанням соціально-економічних та екологічних даних для прогнозування утворення твердих побутових відходів у містах В'єтнаму. Авторами протестовано різні підходи до моделювання, такі як штучні нейронні мережі та методи на основі дерев рішень і опорних векторів. У дослідженні запропоновано керувану даними систему підтримки прийняття рішень для планування управління твердими відходами, яку можна було б перенавчати та оновлювати новими даними.

Автори роботи [8] поєднали супутникові вимірювання снігового покриву та інших змінних водного балансу з гідрологічним моделюванням і даними зміни підземних вод, щоб оцінити забір підземних вод за допомогою методів машинно-

го навчання. Завдяки об'єднанню багатьох джерел даних, пов'язаних з параметрами водного балансу, покращені моделі змогли передбачити навантаження на ґрунтові води в регіонах, що зрошуються в Каліфорнії, США. Така методологія підкреслює потенціал поєднання даних спостереження Землі з гідрологічним моделюванням і польовими вимірюваннями для управління водними ресурсами за допомогою методів ШІ.

Огляд останніх досягнень у застосуванні методів машинного навчання до супутникових зображень для прогнозного картографування, пов'язаного зі сталим розвитком і екологічними результатами, представлено у роботі [9]. Авторами розглянуто, як нові набори даних, алгоритми та обчислювальні можливості покращили супутникове прогнозування в різних сферах, зокрема картографування бідності, моніторинг врожайності, вирубки лісів тощо. В огляді сформульовано можливості та проблеми застосування ШІ до даних спостереження Землі для соціально-екологічного розуміння.

Методи машинного навчання у роботі [10] використано для моніторингу промислових об'єктів, що займаються випалюванням цегли у Південній та Південно-Східній Азії, за допомогою супутникових зображень. Цегляні печі застосовують у неформальній промисловості, відходи діяльності якої сильно забруднюють навколишнє середовище, але ідентифікувати їх у великих регіонах складно. Використовуючи зображення відомих місць розташування печей як тренувальні дані, ця модель згорткової нейронної мережі дозволяє точно виявляти такі промислові об'єкти на нових супутникових зображеннях. У дослідженні продемонстровано ефективність трансферного навчання та глибокого навчання для автоматизованого виділення ознак і масштабованого відображення невеликих промислових об'єктів з космосу.

У роботі [11] за допомогою географічних і соціально-економічних даних та даних управління відходами розроблено логістичну регресійну модель, щоб попередити виникнення незаконних звалищ в Андалусії, Іспанія. Автори продемонстрували поєднання просторових факторів з поведінковими змінними людини для ймовірного моделювання незаконних звалищ.

Автори роботи [12] реалізували модель штучної нейронної мережі, використовуючи дані про кількість відходів для прогнозування збору твердих відходів і оцінки необхідної площі звалища в Дакці, Бангладеш. Такий підхід підкреслив доцільність використання обчислювальних моделей для планування місць розташування полігонів та комплексного управління твердими відходами.

Методологію ансамблю, що поєднує покрокове обмеження площі та алгоритми відстані Махаланобіса для оцінки придатності полігону, запропоновано у роботі [13]. Ця ймовірна просторова модель дозволяє зрозуміти впливові фактори навколишнього середовища та закономірності розташування звалищ.

У розглянутих роботах підкреслено можливості застосування ШІ та супутникових даних для моніторингу навколишнього середовища включно з визначенням характеристик сміттєзвалищ. Однак залишаються невирішеними проблеми, пов'язані з отриманням міток, узагальненням моделі, інтеграцією різних модальностей даних і навчанням моделей для операційного використання. Потрібні подальші дослідження, щоб розробити надійні та стійкі рішення, які допоможуть отримати корисну інформацію. У даній роботі розв'язується задача розробки та злиття різних моделей для визначення місця знаходження сміттєзвалищ.

Дані та їх попередня обробка

Наземні дані. Інформацію про відомі звалища на території Донецької області зібрано за допомогою відкритих джерел даних, зокрема — порталу відкритих даних Донецької ОДА «Існуючі полігони твердих побутових відходів», на якому

представлено офіційні полігони для збору сміття. На рис. 1 зображено 25 локацій звалищ, які зазначені за офіційними показниками у векторному точковому форматі. Оскільки дані про звалища представлено у форматі точок, на їхній основі створено вектори (контури) самих звалищ станом на липень 2021 року, адже зазначені навіть на офіційному сайті точки розташування звалищ частково застарілі. До навчальних даних додано полігони, актуальні на 2021 рік та відображені на інформаційному порталі <https://wikimapia.org>. Загальна кількість полігонів становить 82 (на рис. 1 наведено приклад їхнього розташування).




Рис. 1

Крім звалищ відходів, у дослідження включено території зі штучними об'єктами, сільськогосподарськими угіддями, лісами, лугами, водоймами, болотами та кар'єрами для того, щоб ці території не сприймалися як звалища. Приклад підготовлених даних представлено на рис. 2.




Рис. 2

У табл. 1 представлено дані (кількість полів для кожного типу земного покриття), використані для навчання та тестування моделей.

Таблиця 1

Тип земного покриття	Кількість полів у тестових даних
Штучний об'єкт	50
Сільськогосподарське угіддя	107
Ліс	41
Луг	37
Водойма	34
Болото	40
Звалище	82
Відкритий ґрунт	21

Супутникові дані. Всі зображення серії Sentinel для пілотної території завантажено через Copernicus Open Access Hub (<https://scihub.copernicus.eu/>) та оброблено за допомогою платформи Sentinel Application Platform (SNAP) з відкритим вихідним кодом Європейського космічного агентства (European Space Agency — ESA). Обробка супутникових даних відбувалась в автоматичному режимі та не мала проміжних результатів, лише вхідні дані, які було завантажено, та вихідні, які використовуються для класифікації.

Для попередньої обробки радарних супутникових даних Sentinel-1 використано програму SNAP. Поетапно проведено наступні операції для кожного архіву окремо. Здійснено зчитування архіву GRD супутника Sentinel-1 та корекцію координат по орбіті за допомогою методу Apply orbit file. Після цього застосовано спекл-фільтрацію з використанням фільтра Lee 7x7. Наступний етап — радіометричне калібрування даних з приведенням до значень коефіцієнта зворотного розсіювання сигналу σ_0 . Для процедури Range-Doppler Terrain Correction використано цифрову модель рельєфу SRTM з просторовим розрізненням 30 м. Процес повної обробки радарних даних Sentinel-1 представлено на рис. 3.

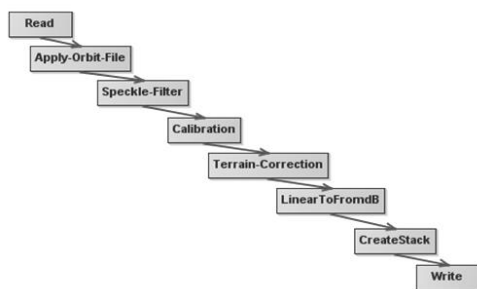


Рис. 3

Для оптичних даних виконано атмосферну корекцію з використанням алгоритмів Sen2Cor. Цей процес передбачає видалення впливу атмосферних складових з отриманих зображень, що дозволяє отримати більш точні та надійні дані про об'єкти на земній поверхні. Алгоритми Sen2Cor використовуються для компенсації впливу атмосферних аерозолів та інших атмосферних ефектів, що можуть виникати під час збору оптичних даних супутникової зйомки. Результатом цього процесу є покращення якості зображень та зменшення спотворень, що дозволяє більш точно аналізувати об'єкти та явища на земній поверхні.

Додатково, крім 10-метрових супутникових даних, використано комерційні дані Planet, які мають просторове розрізнення 3 м на піксель. Як показано на рис. 4 (інтерфейс платформи Planet для завантаження даних), ці дані складаються з окремих гранул, що передбачає їх попередню обробку перед використанням для класифікації.

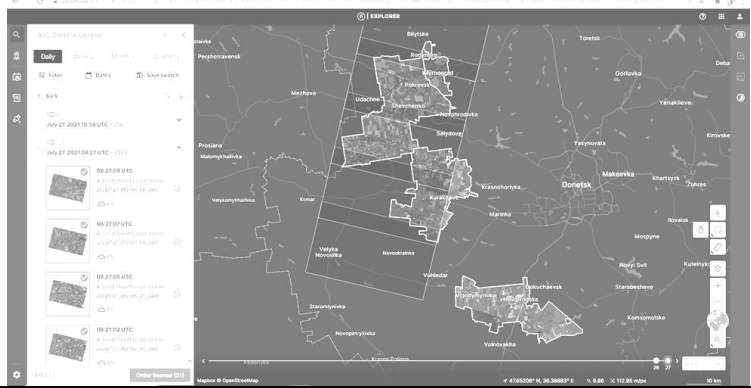


Рис. 4

На рис. 5 показано різницю в просторовому розрізненні на прикладі одного зі звалищ пилотної території Мирноградської ТГ (а — Google, просторове розрізнення — 0,4 м; б — Planet за 27 липня 2021 року, просторове розрізнення — 3 м; в — Sentinel-2 за 27 липня 2021 року, просторове розрізнення — 10 м).




Рис. 5

Як показує досвід, використовувати підложку Google для детектування сучасних змін земного покриття неможливо, оскільки немає гарантії, що знімок, який демонструється, зроблено у останній або навіть передостанній рік. Тому в даному дослідженні використано дані Sentinel-1, 2 та Planet.

Математична модель U-Net для сегментації супутникових зображень

У даній статті проблема виявлення звалищ розглядається як задача семантичної сегментації супутникових знімків, для розв'язання якої запропоновано використовувати архітектуру нейронної мережі U-Net. Вибір моделі U-Net зумовлено її високою ефективністю у вирішенні подібних задач сегментації, що підкріплено її унікальною архітектурою та здатністю точно виділяти необхідні об'єкти на зображеннях [14].

Архітектура U-Net, розроблена спеціально для обробки медичних зображень, знайшла широке застосування у багатьох інших областях завдяки ефективності у сегментації об'єктів на зображеннях. Її U-подібна структура (рис. 6) складається зі зорткової частини, яка захоплює контекст, і розширювального шляху, який забезпечує точну локалізацію. Пропускові з'єднання (skip connections) між цими шляхами гарантують, що інформація на різних рівнях абстракції ефективно передається вперед по мережі, що сприяє точній сегментації об'єктів.




Рис. 6

Шлях звуження, схожий на типову архітектуру згорткової нейронної мережі (Convolutional Neural Network — CNN), складається з повторюваних блоків, кожен з яких включає дві згортки з наступними функціями активації (зазвичай ReLU), і після них виконується операція max-pooling для зменшення розмірності.

Для першої згортки використовується активаційна функція ReLU:

$$\text{ReLU}(x) = \max(0, x).$$

Значення активації a_i після i -ї згортки обчислюється за формулою

$$a_i = \text{ReLU}(W_i * x_i + b_i),$$

де $*$ вказує на операцію згортки; W_i та b_i — ваги і зміщення i -ї згортки відповідно.

До отриманих значень активації застосовується згортка Max-pooling:

$$p_i = \max(a_i),$$

яка забезпечує зменшення розмірності даних на наступному шарі.

Розширювальний шлях архітектури U-Net є ключовою складовою, яка відповідає за точне відновлення розмірів зображення та деталізацію сегментації. Він складається з блоків, що включають операцію транспонованої згортки (для збільшення розміру), за якою слідує дві звичайні згортки з функцією активації ReLU.

Ця частина мережі працює як декодер, який поступово перетворює низькорозмірні, глибокоабстрактні характеристики, отримані на шляху звуження, знову у високо-розмірний простір, наближаючи їхні розміри до розмірів вихідного зображення.

Розширювальний шлях складається з декількох етапів транспонованої згортки та згорткових операцій, які поєднані з пропусковими з'єднаннями. На початку кожного етапу розширювального шляху виконується транспонована згорткова операція, яка збільшує розміри карти ознак. Ця операція дозволяє відновити просторові розміри даних після їхнього зменшення:

$$u_i = \text{TransConv}(W_{u_i} * a_i + b_{u_i}),$$

де u_i — вихід транспонованої згортки; W_{u_i} та b_{u_i} — ваги і зміщення транспонованої згортки.

Значення активації після транспонованої згортки визначається за формулою

$$a'_i = \text{ReLU}(W'_i * u_i + b'_i),$$

де a'_i — активація після згортки на розширювальному шляху.

Після транспонованої згортки карта ознак об'єднується з відповідною картою ознак зі згорткового шляху через пропускові з'єднання. Це дозволяє моделі використовувати як контекстну, так і просторову інформацію для більш точної сегментації:

$$a'_i = a'_i + a_j,$$

де a'_i — активація на розширювальному шляху після пропускового з'єднання;
 a_j — активація зі згорткового шляху.

Після об'єднання з пропусковим з'єднанням слідує один або декілька згорткових блоків, кожен з яких складається з декількох згорткових операцій, за якими зазвичай йдуть нелінійні активаційні функції, такі як ReLU. Ці блоки дозволяють мережі додатково обробляти об'єднані дані для отримання більш точних ознак.

Функціональна роль розширювального шляху в архітектурі U-Net критично важлива для досягнення високої точності сегментації. Основна функція розширювального шляху полягає у відновленні просторових розмірів зображення після їх зменшення на шляху звуження. Це досягається за допомогою транспонованих згорткових операцій, які збільшують розмір карт ознак на кожному етапі розширювального шляху. Пропускові з'єднання від шляху звуження до розширювального дозволяють інтегрувати детальну інформацію з ранніх шарів мережі безпосередньо з абстрактними, глибокими характеристиками. Ця інтеграція забезпечує збереження важливих деталей та контексту, необхідних для точної сегментації. Розширювальний шлях у моделі U-Net поєднує детальну інформацію з пропускових з'єднань з глибокими, абстрактними картами ознак, що допомагає моделі поліпшити точність локалізації об'єктів. Це особливо важливо для задач, у яких необхідно точно виділити границі об'єктів, наприклад, при виявленні звалищ на супутникових зображеннях.

У сукупності розширювальний шлях U-Net відіграє вирішальну роль у відновленні детальної просторової інформації, необхідної для точної сегментації об'єктів на зображеннях.

Моделі U-Net завершується вихідним шаром (наприклад, згортка 1×1), який перетворює останню карту активації на бажане число каналів вихідного зображення (у задачі сегментації для кожного класу є окремий канал):

$$y = \sigma(W_y * a'_n + b_y),$$

де σ — активаційна функція (наприклад, softmax для багатокласової сегментації); W_y та b_y — ваги і зміщення вихідного шару; a'_n — остання активація на розширювальному шляху.

Ефективність моделі U-Net значною мірою залежить від використаної функції втрат. У контексті сегментації звалищ, якому притаманна велика незбалансованість між класами, традиційні функції втрат можуть не забезпечити оптимальних результатів, тому пропонується використовувати комбіновану функцію втрат, що об'єднує перекресну ентропію та коефіцієнт Dice. Перекресна ентропія забезпечує надійну піксельну класифікацію, тоді як коефіцієнт Dice оптимізує сегментацію, зосереджуючись на збільшенні перетину між передбаченими та істинними масками звалищ. Ця комбінація дозволяє досягти балансу між точністю класифікації та чутливістю до малих об'єктів, що є ключовим для виявлення звалищ на супутникових зображеннях.

Комбінована функція втрат у нашій задачі включає як перекресну ентропію (Cross-Entropy Loss), так і коефіцієнт Dice (Dice Loss). Така комбінація допомагає моделі краще навчатися на незбалансованих даних, на яких об'єкти звалищ можуть становити лише малу частину зображення.

Перекресна ентропія є стандартною функцією втрат для задач класифікації. Вона вимірює розбіжність між істинним розподілом міток і передбаченим розподілом. Формула для перекресної ентропії має такий вигляд:

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)].$$

Коефіцієнт Dice використовується для вимірювання подібності між двома зразками і особливо корисний у задачах сегментації з незбалансованими класами. Формула обрахунку Dice Loss має вигляд

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^N y_i p_i + \epsilon}{\sum_{i=1}^N y_i^2 + \sum_{i=1}^N p_i^2 + \epsilon}.$$

Комбінована функція втрат для U-Net може бути виражена як зважена сума перехресної ентропії та коефіцієнта Dice:

$$L = \alpha L_{\text{CE}} + (1 - \alpha) L_{\text{Dice}},$$

де α — гіперпараметр, що визначає вагу кожної функції втрат у загальній сумі.

Таким чином, для навчання запропонованої модифікації U-Net використано комбіновану функцію втрат, що поєднує переваги бінарної крос-ентропії та Dice-втрат.

Бінарна крос-ентропія є однією з найпоширеніших функцій втрат для задач класифікації в комп'ютерному зорі. Вона ефективно оцінює прогнозовані ймовірності кожного класу на піксельному рівні. Однак ця метрика чутлива до дисбалансу класів, що є типовою проблемою для сегментації звалищ, адже більшість пікселів зображення належить фону.

З іншого боку коефіцієнт Dice (Dice-втрати) базується на оцінці перетину множин і тому краще працює з незбалансованими даними. Вони більш сфокусовані на просторових співвідношеннях між об'єктами.

Отже, комбінація цих функцій втрат дозволяє покращити навчання U-Net одночасно для якісної «піксельної» класифікації та адекватного просторового виділення об'єктів. Експерименти підтвердили ефективність такого підходу для вирішення задачі семантичної сегментації звалищ.

Злиття

За результатами класифікації отримано карти звалищ на основі двох методів. Перший, попиксельний, метод використовує ансамбль нейронних мереж на основі багатопарових перцептронів (MLP — Multi-Layer Perceptron) [15–17]. В основі другого, глибокого, методу навчання лежить модель U-Net (з покращеною функцією втрат).

Під час аналізу отриманих результатів виявлено, що кожен з підходів має свої переваги та недоліки. Наприклад, попиксельний метод класифікації земного покриву забезпечує високу точність для основних класів (штучні об'єкти, водні об'єкти, ліси, необроблювані землі та ін.), але має тенденцію неправильно класифікувати звалища як відкритий ґрунт (наприклад, кар'єри або піски) через подібні спектральні характеристики цих об'єктів. З іншого боку, метод на основі сегментації з використанням моделі U-Net схильний до помилок у розпізнаванні штучних об'єктів, що впливає на точність класифікації звалищ. Тому пропонується поєднати результати обох моделей, враховуючи ймовірність кожного класу.

У рамках такого підходу рекомендується використовувати класифікацію на основі часових рядів супутникових даних, а для створення кінцевої карти — метод об'єднання даних на рівні прийняття рішень з урахуванням апостеріорної ймовірності належності кожного пікселя до певного класу:

$$\text{Im}_{\text{res}}(i, j) = \begin{cases} \text{Im}_1(i, j), P(\text{Im}_1(i, j)) > P(\text{Im}_2(i, j)) \\ \text{Im}_2(i, j), P(\text{Im}_1(i, j)) \leq P(\text{Im}_2(i, j)), \end{cases}$$

де $Im_1(i, j)$ та $Im_2(i, j)$ — результати класифікації пікселя (i, j) по кожному окремому методу; $Im_{res}(i, j)$ — остаточна класифікація; $P(\cdot) = UA(\cdot)$, де $P(\cdot)$ — ймовірність події з матриці невідповідності (точність користувача).

Після отримання растрової карти звалищ проводиться її векторизація з використанням коду на основі відкритої бібліотеки GDAL. Тому результуючий шар — векторний, що в подальшому використовується для публікації інформації. Внаслідок цього знайдено 11 локацій зі звалищами на пілотній та суміжній територіях. Ідентифіковані звалища відмічені на рис. 7.






Рис. 7


На рис. 8 наведено супутникові дані та контури всіх детектованих звалищ. У першій колонці зображень міститься Google-карта як підложка, у другій — супутниковий знімок Sentinel-2 за 27 липня 2021 року (просторове розрізнення — 10 м), у третій — супутниковий знімок Planet за 27 липня 2021 року (просторове розрізнення — 3 м), у четвертій колонці виділено ідентифіковані звалища за розробленою технологією.



Код поля змінено

Код поля змінено





Валідація отриманого геопросторового продукту

Після проведення всіх необхідних дій для отримання карт класифікації земельного покриття потрібно оцінити точність результатів. Її можна визначити як ступінь, відповідно до якої отриманий результат класифікації узгоджується із заданим еталоном.

Для порівняння результатів різних методів класифікації карт земельного покриття використовується матриця невідповідностей (confusion matrix) на незалежній тестовій вибірці. Крім того, застосовуються такі метрики, як загальна точність класифікації (Overall Accuracy — OA), індекс Карра, точність PA (Producer Accuracy) та точність UA (User Accuracy).

Оцінка точності карти класифікації земного покриття ґрунтується на кількох припущеннях. По-перше, еталонні дані повинні бути статистично достовірними, наприклад тестова вибірка, яка використовується для підрахунку точності карти класифікації. По-друге, еталонні дані повинні точно відображатися на карті з урахуванням проєкції та геоприв'язки. По-третє, кожен піксель на карті має відповідати одному з можливих типів земного покриття. В кінцевому розрахунку, якщо час між отриманням карти класифікації та еталонними даними значно великий, припускається, що земний покрив за цей період залишився без змін.

Матриця невідповідності, яка використовується для оцінки точності, містить інформацію про розмір помилок у класифікації, що дозволяє коригувати обчислення площ [9]. У табл. 1 наведено розподіл тестових даних за типами земного покриття, на основі яких будувалась матриця невідповідності.

На основі описаних вище метрик проведено розрахунок точності для отриманої карти звалищ. Зібрані дані щодо розташування звалищ випадковим чином поділені у співвідношенні 80:20, одна з незалежних частин (20 %) використовувалась для тестування. В табл. 2 наведено результуючу матрицю невідповідності для отриманої карти земного покриття для пілотної території. Після тестування на незалежних даних отримано загальну точність для класу звалищ F1-score — 86,4 % з індексом Карра 0,94.

Таблиця 2

Індекс Карра — 0,94	Штучний об'єкт	Сільськогосподарське угіддя	Ліс	Луг	Відкритий ґрунт	Звалище	Водойма	Болото	UA	F1
Штучний об'єкт	6985	1425	0	0	445	601	226	0	72,1	78,9
Сільськогосподарське угіддя	250	3999395	664	6592	400	124	293	1539	99,8	98,6
Ліс	0	2579	251670	0	0	0	84	4	99	98,7
Луг	33	71060	148	252144	130	404	0	1134	77,6	83,2
Відкритий ґрунт	88	1754	0	0	8387	501	0	0	78,2	82,6
Звалище	658	106	0	0	223	8325	0	0	89,4	86,4
Водойма	0	1153	0	0	0	0	985721	36	99,9	99,9

Болото	0	28687	3371	22413	0	0	0	17433	24,2	37,9
РА	87,2	97,4	98,4	89,7	87,5	83,6	99,9	86,5	ОА — 97,4 %	

Крім того, отримані дані підтверджено користувачами з пілотних ТГ, серед них є несанкціоновані. В Ольгинській ТГ, крім офіційно відомого звалища, знайдено ще дві додаткові локації зі звалищами; також знайдено додаткове звалище в Покровській ТГ.

Висновок

У даній роботі розглянуто моніторинг навколишнього середовища з застосуванням методів машинного навчання. Запропоновано підхід, який поєднує класифікацію часових рядів даних дистанційного зондування землі та глибинне навчання для семантичної сегментації зображень. Використано дві моделі: багатошаровий перцептрон для класифікації часових рядів та модифіковану модель U-Net для моніторингу звалищ відходів. Представлено метод злиття двох моделей на рівні прийняття рішень з урахуванням ймовірностей результатів кожної моделі. Результати, перевірені на тестових даних, показали ефективність запропонованого підходу. Загальна точність класифікації земного покриття склала 97,4 %. Практичне застосування розробленого методу продемонстровано на прикладі створення карт звалищ для території Донецької області. Результати верифіковані експертами на місцевості.

Отримані в роботі наукові дані свідчать про ефективність застосування розробленого підходу для оперативного моніторингу стану довкілля та вирішення суміжних задач. Слід зазначити, що реалізація запропонованих моделей вимагає використання високопродуктивних обчислювальних ресурсів, таких як хмарні ресурси або кластерні системи [18]. Це пов'язано зі значною обчислювальною складністю моделей глибокого навчання, особливо при обробці великих обсягів супутникових даних. Задача виявлення звалищ є задачею з незбалансованими класами, оскільки площа звалищ зазвичай значно менша проти площ інших типів земного покриття. Для ефективного розв'язання таких задач можна використовувати генеративні змагальні мережі (Generative Adversarial Networks — GAN), які дозволяють синтезувати додаткові навчальні приклади для класів з меншою представленістю [19]. Це дозволить збалансувати розподіл класів у навчальних даних і потенційно покращити результати класифікації.

Розроблений підхід може бути адаптований для виявлення та оцінки втрат від війни, наприклад для моніторингу змін лісового покриття [20] або оцінки пошкоджень сільськогосподарських угідь внаслідок воєнних дій [21]. Це дозволить оперативно отримувати актуальну інформацію про стан довкілля та наслідки воєнних дій для прийняття ефективних управлінських рішень.

P. Mikava, B. Yailymov

MACHINE LEARNING METHODS FOR ENVIRONMENTAL MONITORING

Polina Mikava

National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute»,
geor.polina@gmail.com

Bohdan Yailymov

Institute of Space Research of the National Academy of Sciences of Ukraine and SSA
of Ukraine, Kyiv,

yailyimov@gmail.com

The paper proposes a comprehensive approach to the detection of landfills, which includes two main components. The first is based on the classification of time series of multispectral satellite data using an ensemble of neural networks. The second one uses a modified U-Net architecture for semantic segmentation of space images in landfills highlighting process. The novelty of the proposed solution is the use of a combined loss function when training the U-Net model, which combines binary cross-entropy and the Dice coefficient. Binary cross-entropy provides reliable pixel-by-pixel classification, while the Dice coefficient optimizes segmentation by maximizing the intersection between predicted and true dump masks. This combination allows for a balance between classification accuracy and sensitivity to small objects, which is key for landfill detection from satellite data. It is proposed to integrate the results of the two approaches at the decision-making level using probabilistic fusion using the probabilities of each model. Such a hybrid method makes it possible to compensate for the shortcomings of each method and increase the overall accuracy of landfill identification. Experimental verification on test data demonstrated the effectiveness of the proposed approach. The overall accuracy of land cover classification was 97,4%, and the accuracy of determining landfills was 86,4 %. The developed method is applied to the mapping of landfills in the territory of Donetsk region. The results were verified by experts on the ground. The obtained data can be used by local authorities for prompt response and management decisions.

Keywords: machine learning methods, satellite data, deep learning methods, data fusion, U-Net, CNN, activation function, pixel-by-pixel methods, classifications.

ПОСИЛАННЯ

1. Nazari R., Alfergani H., Haas F., Karimi M.E., Fahad M.G.R., Sabrin S., Everett J., Bouaynaya N., Peters R.W. Application of satellite remote sensing in monitoring elevated internal temperatures of landfills. *Applied Sciences*. 2020. Vol. 10, N 19. P. 6801. DOI: <https://doi.org/10.3390/app10196801>
2. Manzo C., Mei A., Zampetti E., Bassani C., Paciucci L., Manetti P. Top-down approach from satellite to terrestrial rover application for environmental monitoring of landfills. *Science of the Total Environment*. 2017. Vol. 584–585. P. 1333–1348. DOI: <https://doi.org/10.1016/j.scitotenv.2017.01.033>
3. Perera L.A.K., Achari G., Hettiaratchi J.P.A. An assessment of the spatial variability of greenhouse gas emissions from landfills: a GIS based statistical-numerical approach. *Journal of Environmental Informatics*. 2004. Vol. 4, N 1. P. 11–30. DOI: <https://doi.org/10.3808/JEI.200400033>
4. Cuartas M., López A., Pérez F., Lobo A. Analysis of landfill design variables based on scientific computing. *Waste Management*. 2018. Vol. 71. P. 287–300. DOI: <https://doi.org/10.1016/j.wasman.2017.10.043>
5. Wyard C., Beaumont B., Grippa T., Georganos S., Hallot E. UAVs for fine-scale open-source landfill mapping. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. Belgium : Brussels, IEEE, 2021. P. 8217–8220. DOI: <https://doi.org/10.1109/IGARSS47720.2021.9553815>
6. Spijker J., Fraters D., Vrijhoef A. A machine learning based modelling framework to predict nitrate leaching from agricultural soils across the Netherlands. *Environmental Research Communications*. 2021. Vol. 3, N 4. P. 045002. DOI: <https://doi.org/10.1088/2515-7620/abf15f>
7. Nguyen X.C., Nguyen T.T.H., La D.D., Kumar G., Rene E.R., Nguyen D.D., Chang S.W., Chung W.J., Nguyen X.H., Nguyen V.K. Development of machine learning-based models to forecast solid waste generation in residential areas: a case study from Vietnam. *Resources, Conservation and Recycling*. 2021. Vol. 167. P. 105381. DOI: <https://doi.org/10.1016/J.RESCONREC.2020.105381>
8. Majumdar S., Smith R., Butler Jr J.J., Lakshmi V. Groundwater withdrawal prediction using integrated multitemporal remote sensing data sets and machine learning. *Water Resources Research*. 2020. Vol. 56, N 11. e2020WR028059. DOI: <https://doi.org/10.1029/2020WR028059>

9. Burke M., Driscoll A., Lobell D.B., Ermon S. Using satellite imagery to understand and promote sustainable development. *Science*. 2021. Vol. 371, N 6535. eabe8628. DOI: <https://doi.org/10.1126/science.abe8628>
10. Lee J., Brooks N.R., Tajwar F., Burke M., Ermon S., Lobell D.B., Biswas D., Luby S.P. Scalable deep learning to identify brick kilns and aid regulatory capacity. *Proceedings of the National Academy of Sciences*. 2021. Vol. 118, N 17. e2018863118. DOI: <https://doi.org/10.1073/pnas.2018863118>
11. Lucendo-Monedero Á., Jordá-Borrell R., Ruiz-Rodríguez F. Predictive model for areas with illegal landfills using logistic regression. *Journal of Environmental Planning and Management*. 2015. Vol. 58, N 7. P. 1309–1326. DOI: <https://doi.org/10.1080/09640568.2014.993751>
12. Hoque M., Rahman M. Landfill area estimation based on solid waste collection prediction using ANN model and final waste disposal options. *Journal of Cleaner Production*. 2020. Vol. 256. P. 120387. DOI: <https://doi.org/10.1016/j.jclepro.2020.120387>
13. Moghaddam D., Haghizadeh A., Tahmasebipour N., Zeinivand H. Introducing the coupled step-wise areal constraining and Mahalanobis distance: a promising MCDM-based probabilistic model for landfill site selection. *Environmental Science and Pollution Research*. 2020. Vol. 27, N 20. P. 24954–24966. DOI: <https://doi.org/10.1007/s11356-020-08746-9>
14. Shumilo L., Kussul N., Lavreniuk M. U-Net model for logging detection based on the Sentinel-1 and Sentinel-2 data. *IEEE International Geoscience and Remote Sensing Symposium, IGARSS*. Belgium : Brussels, 2021. P. 4680–4683. DOI: <https://doi.org/10.1109/IGARSS47720.2021.9554885>
15. Kussul N., Lavreniuk M., Shumilo L. Deep recurrent neural network for crop classification task based on Sentinel-1 and Sentinel-2 imagery. *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. USA : Waikoloa, HI, 2020. P. 6914–6917. DOI: <https://doi.org/10.1109/IGARSS39084.2020.9324699>
16. Яйлимова Г.О., Яйлимов Б.Я., Шелестов А.Ю., Красильнікова Т.М. Інтелектуальні методи та моделі обробки супутникових даних у задачі моніторингу звалищ. *Міжнародний науково-технічний журнал Проблеми керування та інформатики*. 2022. Т. 67, № 2. С. 128–140. DOI: <https://doi.org/10.34229/1028-0979-2022-2-9>
17. Yailymova H., Mikava P., Kussul N., Krasilnikova T., Shelestov A., Yailymov B., Titkov D. Neural network model for monitoring of landfills using remote sensing data. *2022 IEEE 3rd International Conference on System Analysis & Intelligent Computing (SAIC)*. Ukraine : Kyiv, 2022. P. 1–4. DOI: <https://doi.org/10.1109/SAIC57818.2022.9923013>
18. Shelestov A.Y., Kussul N.N. Using the fuzzy-ellipsoid method for robust estimation of the state of a grid system node. *Cybernetics and Systems Analysis*. 2008. N 44. P. 847–854.
19. 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, N 11. P. 1129–1138. DOI: <https://doi.org/10.1080/2150704X.2023.2275551>
20. Shumilo L., Skakun S., Gore M.L., Shelestov A., Kussul N., Hurtt G., Yarotskiy V. Conservation policies and management in the Ukrainian Emerald Network have maintained reforestation rate despite the war. *Communications Earth & Environment*. 2023. Vol. 4, N 1. P. 443. DOI: <https://doi.org/10.1038/s43247-023-01099-4>
21. Kussul N., Drozd S., Yailymova H., Shelestov A., Lemoine G., Deininger K. 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. P. 103562. DOI: <https://doi.org/10.1016/j.jag.2023.103562>

Отримано 14.03.2024