

ІНТЕЛЕКТУАЛЬНІ МЕТОДИ ТА МОДЕЛІ ОБРОБКИ СУПУТНИКОВИХ ДАНИХ У ЗАДАЧІ МОНІТОРИНГУ ЗВАЛИЩ

Яйлимова Ганна Олексіївна

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»,
anna.yaylimova@gmail.com

Яйлимов Богдан Ялкапович

Інститут космічних досліджень НАН України та ДКА України,
yaylimov@gmail.com

Шелестов Андрій Юрійович

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»,
andrii.shelestov@gmail.com

Красільнікова Тетяна Миколаївна

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»,
tatijanaeco@gmail.com

Статтю присвячено розв'язанню важливої прикладної задачі пошуку сміттєзвалищ на основі методів машинного навчання з використанням супутникових даних високого просторового розрізнення. Проблема накопичення і зберігання відходів на легальних та несанкціонованих сміттєзвалищах актуальна і на сьогоднішній день. В Україні щороку утворюються мільйони тонн побутових відходів. Найбільші площі під полігони зайняті в Донецькій, Дніпропетровській, Одеській, Запорізькій областях. Так, в Донецькій області площі під сміттєзвалища займають 330 гектарів. Для моніторингу сміттєзвалищ використовуються різні технології, що базуються на супутникових даних і методах штучного інтелекту. Нині існують сервіси, за допомогою яких відстежується розташування сміттєзвалищ, але не надається інформація про територію сміттєзвалища та зміни її площі в часі. У процесі виконання досліджень розв'язано важливу задачу відокремлення полігонів від кар'єрів та штучних об'єктів шляхом послідовного попіксельної та об'єктної класифікації. Основна мета роботи полягала в розробці інтелектуальної інформаційної технології на основі неймережевого підходу і побудові на її основі геопросторового продукту розміщення звалищ для Донецької області, а саме карти класифікації звалищ відходів. Запропонований алгоритм машинного навчання на основі історичних та сучасних супутникових даних дозволяє відстежувати площу полігону відходів та її зміни в часі. Розроблена інформаційна технологія апробована на території чотирьох територіальних громад у Донецькій області, а саме: Ольгинської, Мирноградської, Курахівської та Покровської. У результаті проведених досліджень також розроблено інформаційну панель, яка надає оперативні дані і дозволяє оцінювати динаміку змін сміттєзвалищ у регіоні в часі і просторі. Розроблена технологія має практичне значення для розробки програм керування та поведінки з відходами в місцевих громадах.

Ключові слова: супутниковий моніторинг, супутникові дані, машинне навчання, штучний інтелект, класифікація геопросторових даних, моніторинг сміттєзвалищ.

Вступ

Щороку в світі утворюється понад двох мільярдів тонн побутового сміття. Для України проблема відходів є надзвичайно актуальною, оскільки в нашій державі поки що відсутні можливості, достатні для їх переробки. Нині близько 4–7% площі країни займають сміттєзвалища. Так, за даними Міністерства розвитку громад і територій України за 2021 рік утворилось понад 54 млн. м³ побутових відходів.
© Г.О. ЯЙЛИМОВА, Б.Я. ЯЙЛИМОВ, А.Ю. ШЕЛЕСТОВ, Т.М. КРАСІЛЬНИКОВА, 2022

ходів, які розміщено на 6 тис. сміттєзвалищ і полігонів загальною площею майже 9 тис. га. Кількість перевантажених сміттєзвалищ становить 261 одиницю, не відповідають нормам екологічної безпеки — 868 одиниць, потребують рекультивациі — 424 одиниці. [1]. Виникнення несанкціонованих сміттєзвалищ призводить до забруднення великих територій, погіршення якості ґрунтів і, як наслідок, деградації земель.

Моніторинг зберігання відходів та виявлення сміттєзвалищ є важливим етапом у вирішенні питання попередження забруднення та деградації земель регіонів України, зокрема територій окремих об'єднаних громад. Так, закон України «Про відходи» [2] визначає компетенцію органів виконавчої влади та місцевого самоврядування у сфері зберігання та переробки відходів. Статтею 20 цього закону визначено, що до повноважень місцевих державних адміністрацій належить здійснення контролю за утилізацією відходів, за діяльністю об'єктів їх переробки (місць, що використовуються для збирання, зберігання, сортування, оброблення, перероблення, утилізації, видалення, знешкодження та захоронення відходів). Також під час підготовки проектів місцевих бюджетів місцеві державні адміністрації вносять пропозиції щодо залучення коштів, необхідних для підтримки сміттєзвалищ у належному стані.

Дослідження проведено співробітниками Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського» та Інституту космічних досліджень НАН України та ДКА України в межах проекту «Виявлення та моніторинг звалищ відходів» Національного конкурсу інновацій EastCode2021 за фінансової підтримки урядів Данії, Швейцарії та Швеції.

Отже, розроблена технологія має практичне значення для місцевих громад, адже надає оперативну інформацію про виникнення звалищ відходів та дозволяє оцінити динаміку змін таких стихійних сміттєзвалищ у регіоні в часі і просторі.

Методи дослідження

Для моніторингу сміттєзвалищ можуть використовуватися різні технології, що базуються на супутникових даних і методах штучного інтелекту. Існуючі сервіси, які надають дані про розташування сміттєзвалищ в Україні, мають певні недоліки. Зокрема, за допомогою таких сервісів можна лише визначити місцерозташування сміттєзвалищ, проте знайти територію, яку займає полігон, та визначити його площу неможливо. Аналіз робіт [3–6] свідчить про те, що кожен із методів класифікації має свої переваги та недоліки. Метод попиксельної класифікації дозволяє ідентифікувати штучні об'єкти, але погано справляється з відокремленням сміттєзвалищ від штучних об'єктів, кар'єрів чи пісків. За допомогою об'єктного методу пошуку знаходяться не тільки сміттєзвалища, але і деякі частини міст, які за спектральними характеристиками подібні до звалищ. У даній роботі розв'язано важливу задачу відокремлення полігонів від кар'єрів та штучних об'єктів. При цьому поєднано попиксельну [7] та об'єктну [8] класифікації, що допомагає визначити ті території, які належать саме до класу звалищ.

Постановка завдання

Європейське космічне агентство в межах програми Copernicus дозволяє регулярно отримувати супутникові знімки кожної точки земного покриття з 2016 року. Супутникові дані доступні з просторовим розрізненням 10 м, що дозволяє розв'язувати багато актуальних прикладних задач.

Основна мета роботи полягає в розробці інтелектуальної інформаційної технології на основі нейромережевого підходу і побудові на її основі геопросторового продукту розміщення звалищ у Донецькій області, а саме карти класифікації звалищ відходів. Розроблена інформаційна технологія апробована на території чотирьох територіальних громад Донецької області.

Використані дані

Шляхом аналізу супутникових та статистичних даних для територій східних областей визначено об'єднані територіальні громади Донецької області, які ймовірно містять найбільшу кількість звалищ та територіально розташовані поблизу одна від одної. А саме Ольгинська ОТГ — 11 сіл та селищ міського типу, Мирноградська — 4 місцеві ради, Курахівська — 7 рад, Покровська — 10 рад. З відкритих інформаційних джерел було зібрано дані щодо існуючих полігонів відходів на території вказаних громад, яких налічується 82 об'єкти (рис. 1). На карту також додавались території зі штучними об'єктами, сільськогосподарськими територіями, лісами, луками, водні об'єкти, болота та кар'єри для того, щоб провести аналіз спектральних характеристик для цих об'єктів та визначити інформативні ознаки для класу звалищ.

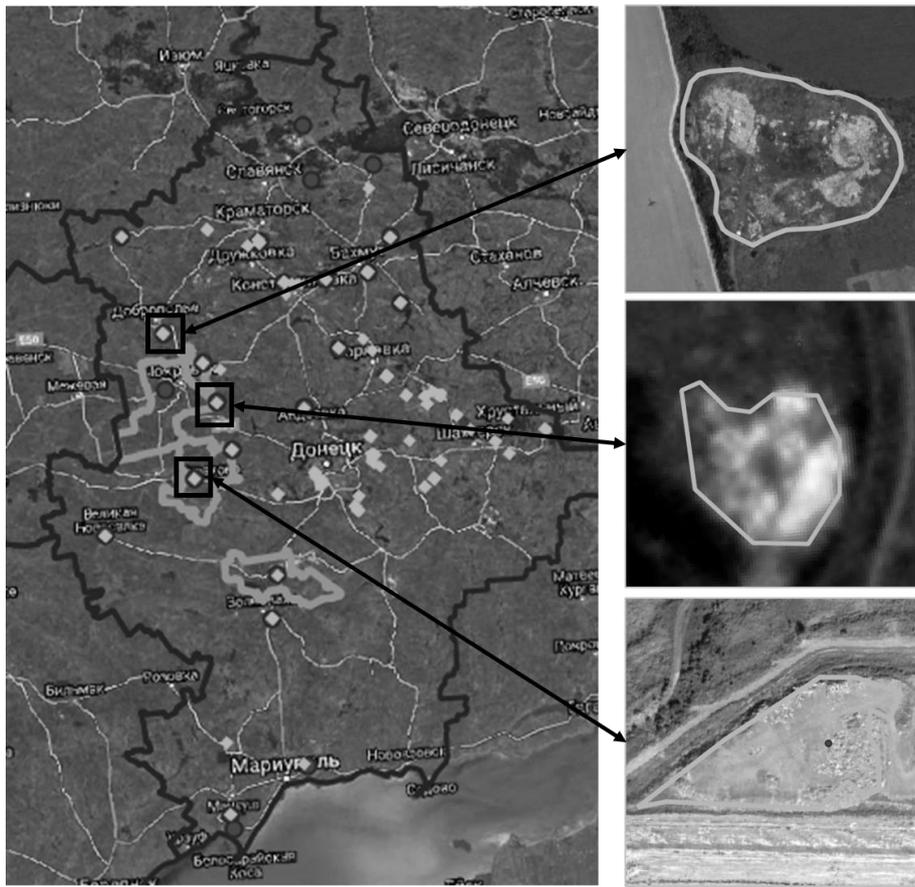


Рис. 1

Усі зображення Sentinel для пілотної території було завантажено з порталу Copernicus Open Access Hub (<https://scihub.copernicus.eu/>) Європейського космічного агентства (ESA) та оброблено за допомогою платформи Sentinel Application Platform (SNAP) з відкритим програмним кодом [9] в автоматичному режимі.

Для радарних супутникових даних Sentinel-1 виконано наступні кроки попередньої обробки (для кожного архіву окремо) в програмному забезпеченні SNAP [9]:

- зчитування архіву даних GRD супутника Sentinel-1;
- корекція координат по орбіті (Apply orbit file);
- фільтрація спеклу (фільтр Lee 7×7) [10];
- радіометричне калібрування з приведенням до значень коефіцієнта зворотного розсіювання сигналу $\text{Sigma}0$ (Calibration);

- здійснення процедури Range-Doppler Terrain Correction з використанням заданої цифрової моделі рельєфу (SRTM 90 метрів);
- переведення даних в децибели (LinearToFromdB);
- формування стеку даних (CreateStack);
- формування знімка з різними поляризаціями (VV, VH);
- поєднання каналів VV та VH у межах однієї гранули в .tif-файлі.

Для підготовки оптичних даних виконано такі кроки попередньої обробки:

- атмосферна корекція на основі алгоритму Sen2Cor (<http://step.esa.int/main/third-party-plugins-2/sen2cor/>);
- маскування хмар та тіней;
- корекція Cirrus.

Крім безкоштовних супутникових даних з просторовим розрізненням 10 м, використано також дані Planet з просторовим розрізненням 3 м. Ці дані складаються з окремих гранул, що зумовлює необхідність їх попередньої обробки перед використанням для класифікації.

Визначення вегетаційних індексів

Для кращого відокремлення звалищ від інших типів земного покриття обчислено ряд вегетаційних індексів для оцінки стану рослинності та її біофізичних параметрів, ідентифікації води та оцінки стану ґрунтів. Після аналізу застосовності 19 таких індексів (див. таблицю) та порівняння даних навчальної вибірки у кількох класах ознак, усі індекси, що надають неузгоджені або нечіткі спектральні зв'язки, було вилучено з подальшого розгляду. У результаті проведеного аналізу для подальшого використання і якості додаткових критеріїв класифікації обрано індекси NDVI, SAVI, NDWI2.

Таблиця

Thematic Group Index Acronym	Thematic Group Index Acronym	Thematic Group Index Acronym
Vegetation	Normalised Difference Vegetation Index	NDVI
	Red-Edge Inflection Point	REIP
	Ratio Vegetation Index	RVI
	Sentinel-2 Red-Edge Position	S2REP
	Soil Adjusted Vegetation Index	SAVI
	Transformed Normalised Difference Vegetation Index	TNDVI
Biophysical	Leaf Area Index	LAI
	Fraction of Absorbed Photosynthetically Active	FAPAR
	Fraction of Vegetation Cover	FVC
	Canopy Chlorophyll Content	CCC
	Canopy Water Content	CWC
Water	Modified Normalised Difference Water Index	MNDWI
	Normalised Difference Pond Index	NDPI
	Normalised Difference Water Index	NDWI
	Normalised Difference Water Index 2	NDWI2
Soil	Brightness Index	BI
	Brightness Index 2	BI2
	Colour Index	CI
	Redness Index	RI

Нормалізований різницевий індекс рослинності NDVI (Normalized Difference Vegetation Index) [11] є простим показником кількості фотосинтетично активної біомаси. Це один із найпоширеніших і використовуваних індексів для розв'язання завдань, що використовують кількісні оцінки рослинного покриву. NDVI дозволяє оцінити рівень фотосинтетичної активності і сильно корелює як з вмістом хлорофілу, так і з життєздатністю рослинності [12]. NDWI (Normalized Difference Water Index) — нормалізований різницевий водний індекс, розроблений МакФітерсом [13], відображає вміст води в рослинах та ґрунті; NDWI варіюється від -1 до 1 . Високі значення NDWI відповідають високому вмісту води в рослинах та покриттю високими рослинами. За допомогою індексу рослинності з корекцією по ґрунту (Soil-Adjusted Vegetation Index, SAVI) [14] намагаються мінімізувати вплив яскравості ґрунту за допомогою коефіцієнта корекції його яскравості.

За щомісячними спостереженнями у 2021 році на обраних територіях Донецької області, а саме: Ольгинській, Мирноградській, Курахівській та Покровській, на графіках (рис. 2–4) наведено середні значення індекси для різних типів земного покриву.

Як видно з наведених графіків, показники для класу звалищ розташовані найближче до таких класів, як штучні об'єкти та відкритий ґрунт. Тому використання лише окремих комбінацій супутникових спектральних каналів недостатньо для коректної ідентифікації звалищ. Проте ці індекси корисно застосовувати як додаткові шари під час класифікації.

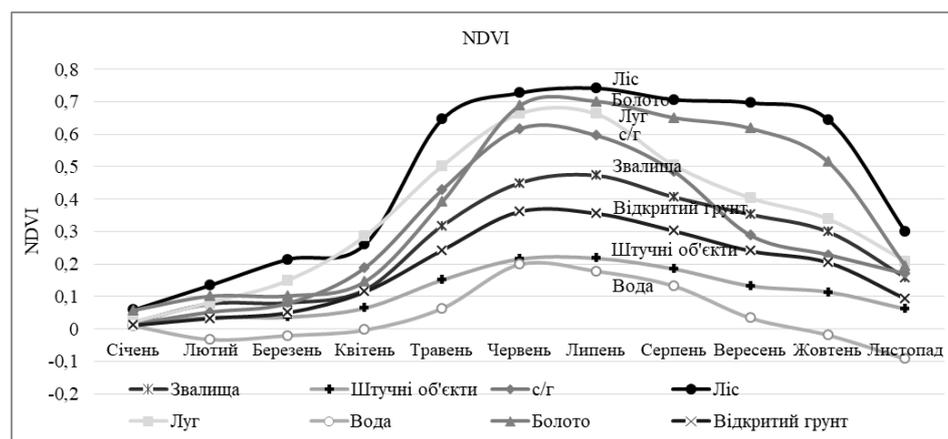


Рис. 2

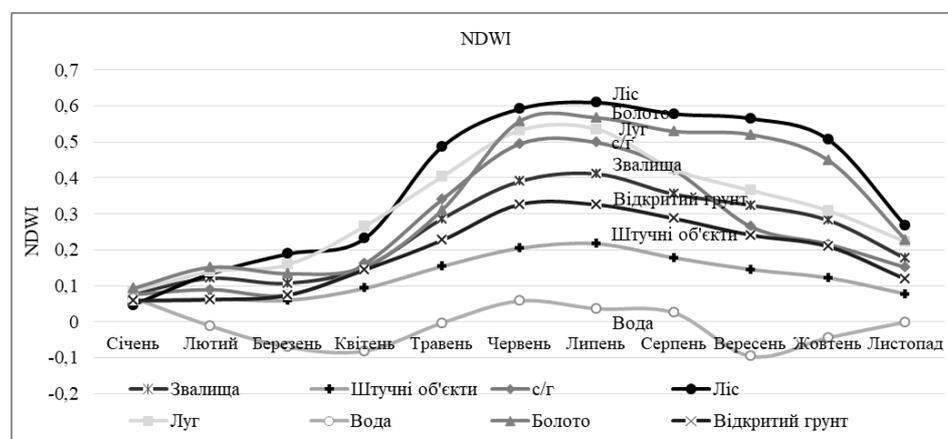


Рис. 3

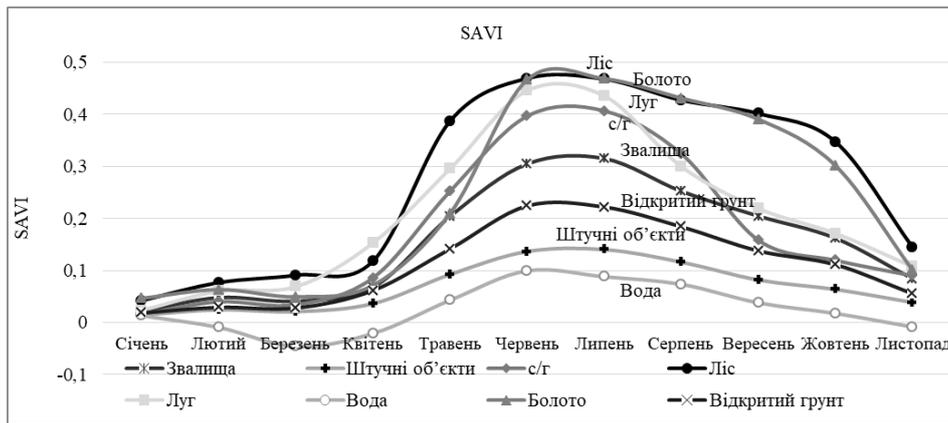


Рис. 4

Аналіз показників температур

Для виявлення та моніторингу звалищ часто застосовують методи, що базуються на використанні термальних каналів супутникових зображень. Відомі публікації, зокрема [15–17], що температура у місцях із звалищами вища у порівнянні із іншими ділянками земного покриття. Проте такий підхід є ефективним не для всіх випадків. Якщо потрібно здійснити моніторинг території, що містить різні типи земного покриття, такий підхід часто є незастосовним. У роботі проведено аналіз дослідження ефективності використання температурних даних Land Surface Temperature (LST) супутника Landsat-8. Зокрема, використано термальний канал B10 (T_b), а також канали B4 і B5 для обчислення вегетаційного індексу NDVI. Обчислення температури земної поверхні проводилося за формулою

$$LST = \frac{T_b}{\left(1 + \frac{\lambda T_b}{d}\right)} \ln e,$$

де $e = 0,004 + 0,986P_v$, обчислення P_v — за формулою

$$P_v = \left(\frac{NDVI - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}} \right)^2.$$

На основі отриманих значень температури проведено дослідження різних типів земної поверхні (приклад наведено на рис. 5 для звалища на території Покровської ТГ). Результати проведених досліджень дозволяють зробити висновок про те, що температура на звалищах практично така ж, як і на штучних об'єктах, а на полях сільськогосподарського призначення, особливо зораних, вища, ніж на звалищах. На рис. 5 темним кольором показана нижча температура, світлим — відповідно вища. Відокремлення земель сільськогосподарського призначення не викликає ускладнень, проте проблемним є відділення коректним чином штучних об'єктів (будинки, дороги, площі та ін.) від звалищ.

Тому дані із температурою земної поверхні можна використовувати як додаткове джерело інформації. Проте при класифікації даних високого просторового розрізнення, зокрема даних Planet з просторовим розрізненням 3 м, температура вносить додаткову похибку, просторове розрізнення якої становить 30 м.

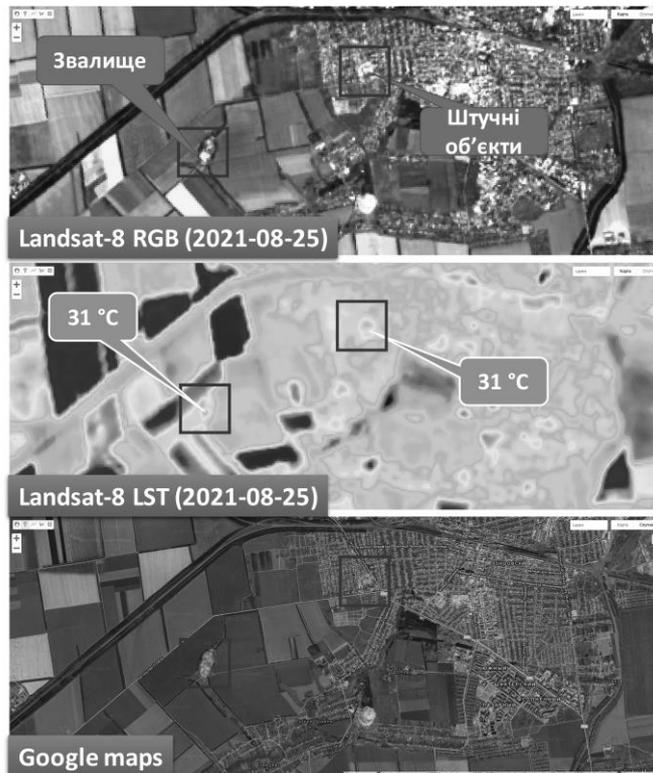


Рис. 5

Оцінювання динаміки змін сміттєзвалищ

Для коректного використання нейромережових моделей попередньо проведено візуальний аналіз динаміки змін сміттєзвалищ. Для цього застосовувалась настільна версія програми Google Earth Pro, в якій є можливість використання історичних супутникових даних. Такі дані доступні лише для перегляду, і використовувати їх для побудови карт класифікації не є можливим. Отже, традиційний спосіб, який застосовується для моніторингу змін земного покриття на основі часових рядів супутникових даних, не дасть у даному випадку хороших результатів, оскільки можлива зміна контурів та площі звалища навіть протягом місяця. В цьому випадку доцільно відслідковувати звалища за конкретну дату.

Для підвищення ефективності використання супутникових даних для моніторингу звалищ разом з безкоштовними даними Sentinel з просторовим розрізненням 10 м було використано також дані більш високого просторового розрізнення, а саме дані Planet з просторовим розрізненням 3 м.

Розробка моделі штучного інтелекту на основі нейронних мереж. Попіксельний алгоритм класифікації

Як один із методів виявлення звалищ використано ансамбль нейронних мереж на основі багатошарового перцептрона (MLP — multi-layer perceptron), в якому кількість прихованих нейронів підбирається в залежності від кількості каналів зображень, поданих на вхід для навчання [18–20].

Для підвищення ефективності класифікації використано не один окремий класифікатор, а їх ансамбль. При цьому в процесі класифікації злиття даних здійснюється на рівні прийняття рішень (рис. 6).

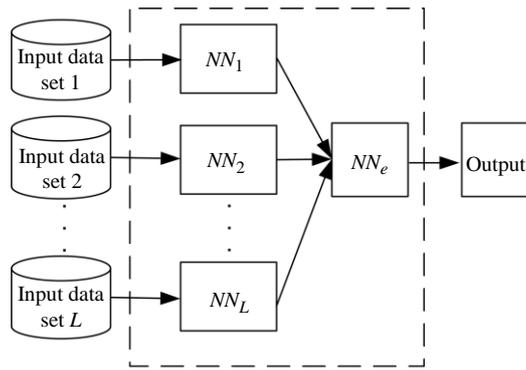


Рис. 6

Під час навчання нейронної мережі з використанням багатошарового перцептрона як критерій якості навчання використано функцію помилок крос-ентропії, для якої здійснюється пошук мінімуму:

$$E(w) = -\ln p(T | w) = -\sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk} \rightarrow \min,$$

де w — вектор вагових коефіцієнтів, T — множина, яка складається з вектора спектральних каналів для кожного пікселя та відповідного йому класу k в навчальній вибірці; N — кількість полігонів у вибірці; K — число класів; t_{nk} — цільові виходи; y_{nk} — виходи MLP, $p(\cdot)$ — умовна ймовірність.

На виході кожного класифікатора отримуємо апостеріорну ймовірність належності вхідного образу до певного класу. Виходи окремих класифікаторів об'єднуються простим додаванням, після чого обчислюється середня ймовірність належності вхідного образу до конкретного класу (рис. 7).

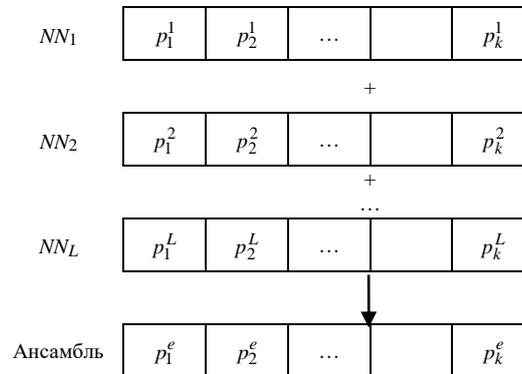


Рис. 7

Як показано нижче, вхідний образ відносять до класу з максимальною апостеріорною ймовірністю

$$k^* = \arg \max_{k=1, K} p_k^e, \quad p_i^e = \frac{1}{L} \sum_{l=1}^L p_i^l,$$

де k^* — клас, до якого вхідний образ відносить ансамбль класифікаторів, p_i^e — апостеріорна ймовірність належності класу до ансамблю, p_i^l — апостеріорна ймовірність належності класу для кожного класифікатора MLP, L — кількість класифікаторів в ансамблі, K — кількість класів.

Результатом попіксельної класифікації є набір даних, де кожному пікселю відповідає певний клас земного покриву.

Об'єктний алгоритм класифікації звалищ

Ще один підхід виявлення звалищ базується на використанні однієї з найбільш точних архітектур глибокого навчання для розв'язання задач семантичної сегментації — модель U-Net. Архітектура моделі U-Net традиційно складається зі згорткової та деконволюційної частин, які з'єднані між собою за допомогою операції конкатенації (рис. 8). У згортковій частині використано кілька блоків, які складаються з послідовно застосованої згорткової операції з функцією активації ReLU. Після кожного двох згорткових блоків використовується шар maxpooling для зменшення ширини та висоти тензора з фактором $2 \times$.

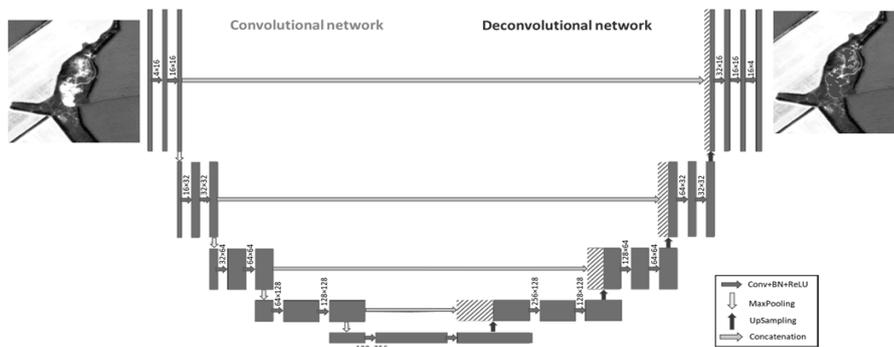


Рис. 8

Традиційно для навчання багатопередового перцептрона та моделей глибокого навчання як функція втрат вибирається крос-ентропія CE [8] або зважена крос-ентропія:

$$CE = - \sum_{k=1}^N \sum_{c=1}^C \alpha_c y_c \log(p_c),$$

де C — кількість класів, N — кількість елементів у вибірці, y — цільовий вектор, тут для нього вибираємо one-hot-кодування, p — вихід останнього шару нейронної мережі, α_c — коефіцієнт для контролю впливу класу, $\alpha_c = \frac{N_c}{N}$.

Перед кожною функцією активації Relu застосовується пакетна нормалізація, яка дозволяє масштабувати вхідні дані для шарів, як правило, міні-пакетів, з використанням середнього значення та дисперсії. Таке масштабування усуває внутрішній коваріантний зсув і, таким чином, прискорює процес навчання. Між верхнім і нижнім шарами на шляху стискання застосовується операція об'єднання 2×2 max, що призводить до зниження роздільної здатності карт об'єктів. Розмір об'єктів у нижньому шарі контуру стискання зменшується до $1/64$ від вихідного зображення. Нижній шар стандартної моделі U-Net відповідає тій же структурі нижнього шару, тобто включає дві послідовні згортки, пакетну нормалізацію та операцію Relu.

В нейронній мережі, що використана для побудови карти звалищ, застосовується шар Softmax для перетворення об'єктів на ймовірність належності пікселя кожному типу земного покриття. Дана функція приводить K -вимірний вектор z з довільними значеннями компонент до K -вимірного вектора $\sigma(z)$ з дійсними значеннями компонент на відрізьку $[0, 1]$, що в сумі дають одиницю. Функція задається наступним чином:

$$\sigma: \mathbb{R}^K \rightarrow [0, 1]^K,$$

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}.$$

Ймовірність того, що у вибірці є об'єкт x_i з класом y_i , дорівнює

$$b(x_i)^{[y_i=+1]}(1-b(x_i)^{[y_i=-1]}).$$

Тому правдоподібність вибірки можна представити в наступному вигляді (ймовірність отримати таку вибірку з точки зору алгоритму):

$$Q(a, X) = \prod_{i=1}^l b(x_i)^{[y_i=+1]}(1-b(x_i)^{[y_i=-1]}),$$

де X — простір об'єктів x , $y_i = +1$ — ідентифікатор того, що об'єкт x належить класу $+1$.

Дану функцію правдоподібності можна використовувати як функціонал для навчання алгоритму, з поправкою, що зручніше оптимізувати його логарифм:

$$-\sum_{i=1}^l ([y_i = +1] \log b(x_i) + [y_i = -1] \log (1 - b(x_i))) \rightarrow \min.$$

Така функція втрат дозволяє коректно оцінювати ймовірності. З огляду на те, що потрібно відфільтрувати отриману маску штучних об'єктів від недостовірних територій, які помилково потрапили у цю маску внаслідок класифікації, використовувався метод порогової фільтрації (за принципом порогової класифікації) з порогом 80 % за ймовірнісним каналом для класу штучних об'єктів.

Загальна схема виявлення несанкціонованих сміттєзвалищ за допомогою супутникових даних представлена на рис. 9.

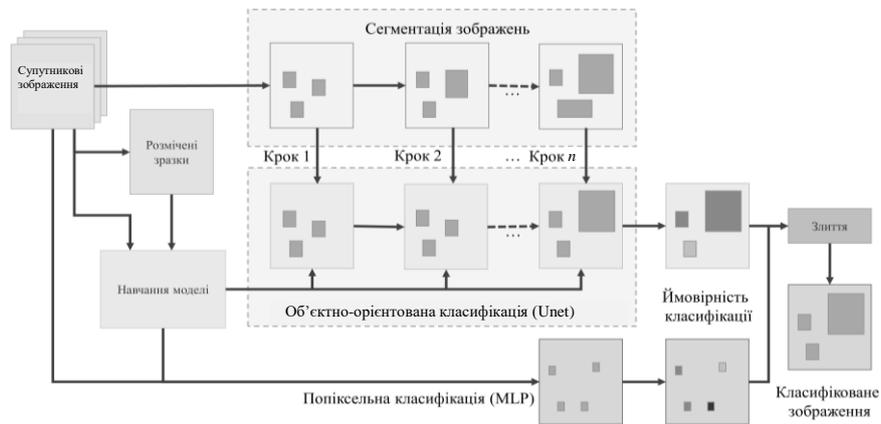


Рис. 9

Побудова геопросторової карти розміщення звалищ для Донецької області за 2021 рік з просторовим розрізненням 10 м

На основі двох запропонованих методів класифікації побудовано карти звалищ. При аналізі отриманих результатів виявлено, що кожний із підходів має свої переваги та недоліки.

Приклад отриманих результатів представлено на рис. 10. Попіксельний метод класифікації земного покриття має високу точність для основних класів земного покриття (штучні об'єкти, водні об'єкти, ліси, необроблювані землі та ін.), проте клас звалищ дуже часто помилково відноситься до класу відкритого ґрунту (кар'єри, піски). Це пов'язано з тим, що спектральні характеристики для таких об'єктів є близькими. Щодо методу на основі сегментації з використанням U-Net-моделі, то виникають помилки, які пов'язані з штучними об'єктами, і, таким чином, це впливає на точність розпізнавання звалищ. Тому запропоновано поєднати результати виходів двох моделей із урахуванням ймовірності кожного класу. Після отримання растрової карти звалищ про-

диться спочатку її векторизація на основі відкритої бібліотеки GDAL, а потім об'єднання з результатами об'єктної класифікації на основі U-Net [8]. Тому результуючий шар є векторний, що використовується для подальшої публікації інформації.

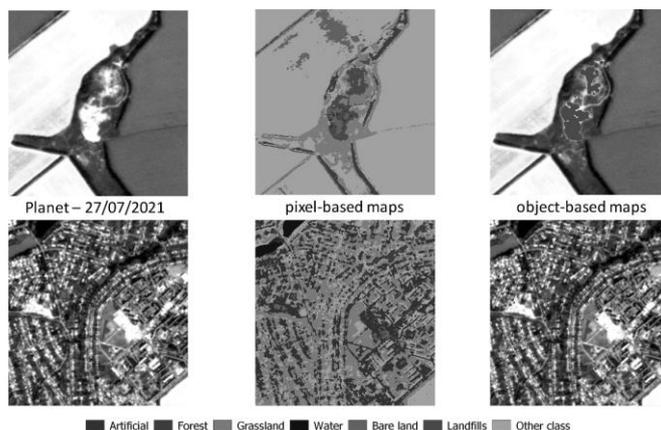


Рис. 10

Валідація результатів

Після отримання геопросторового продукту розміщення звалищ для Донецької області здійснено оцінку його точності [21]. Для порівняння результатів різних методів класифікації та фільтрації карт земного покриття використано матрицю невідповідностей (confusion matrix) на незалежній тестовій вибірці та наступні метрики, які обчислюються на її основі: загальна точність класифікації (OA) (Overall Accuracy), індекс Каппа, точність PA (Producer Accuracy) та точність UA (User Accuracy).

Слід зауважити, що інтерпретація точності карти класифікації земного покриття базується на кількох припущеннях.

1. Еталонні дані є статистично достовірними (наприклад, тестова вибірка, яка використовується для підрахунку точності карти класифікації).
2. Еталонні дані точно співвідносяться з картою (проекція, геоприв'язка).
3. Кожен піксель карти є чистим і відповідає одному з можливих типів земельного покриття.
4. Якщо час між отриманням карти класифікації та еталонними даними досить великий, вважається, що земний покрив не змінювався протягом даного періоду.

У результаті тестування на незалежних даних отримано загальну точність для класу звалищ F1-score 86 % з коефіцієнтом Карра (Каппа) 0,91.

Крім того, отримані дані перевірено безпосередньо користувачами з пілотних ТГ. В Ольгинській ТГ, крім офіційно відомого звалища, знайдено ще дві додаткові локації зі звалищами, а також додаткове звалище в Покровській ТГ.

Розробка програмного забезпечення веб-інтерфейсу

Для представлення отриманих карт звалищ для чотирьох ТГ Донецької області створено інформаційний дашборд (dashboard). Як додаткові шари даних використано адміністративні межі регіонів та карти звалищ за 27.07.2021 р. та 15.09.2021 р. Представлені продукти дозволяють оцінити динаміку змін звалищ у часі на основі даних з різним просторовим розрізненням, а саме безкоштовних даних Sentinel-2 з просторовим розрізненням 10 м та платних даних Planet з просторовим розрізненням 3 м. На основі отриманих геопросторових продуктів отримано площі для кожного із звалищ. Для зручності користувача продукти відображаються на інтерактивній мапі Google. У лівій верхній частині дашборду представлена інформація про проект та донорів, а та-

кож контактні дані розробників і виконавців. Розроблений дашборд відповідає всім сучасним вимогам до інтерфейсу та розміщений на домені <http://inform.ikd.kiev.ua/ldms/>.

Висновок

У результаті проведених досліджень розроблено інтелектуальну інформаційну технологію на основі нейромережевого підходу та побудовано на її основі геопросторовий продукт розміщення звалищ для Донецької області, а саме карти класифікації звалищ відходів. Розроблена інформаційна технологія апробована на території чотирьох територіальних громад Донецької області. Для створення інформаційної панелі користувачів використано адміністративні межі регіонів та карти звалищ відходів за 2021 рік. Проведені дослідження з використанням даних з різним просторовим розрізненням допомогли доповнити представлені продукти необхідною інформацією, що дало можливість оцінити динаміку змін звалищ за певний період часу. Створення таких дашбордів може стати складовою системи інформаційного забезпечення сфери керування відходами в об'єднаних громадах, удосконалення порядку ведення обліку відходів, інформування про розташування місць чи об'єктів керування відходами, передбачення їх впливу на стан навколишнього природного середовища та здоров'я громадян. Отже, відслідковування місць розташування сміттєзвалищ та динаміки їх змін має важливе практичне значення для місцевих громад та реалізації програм з керування і поводження з відходами в регіонах України.

H. Yailymova, B. Yailymov, A. Shelestov, T. Krasilnikova

INTELLECTUAL METHODS AND MODELS OF SATELLITE DATA PROCESSING IN LANDFILLS MONITORING PROBLEMS

Hanna Yailymova

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

Bohdan Yailymov

Institute of Space Research of the National Academy of Sciences of Ukraine and SSA of Ukraine),
yailymov@gmail.com

Andrii Shelestov

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

Tetiana Krasilnikova

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

The article is devoted to solving an important applied problem of landfill search based on machine learning methods using high-resolution satellite data. The problem of accumulation and storage of waste in legal and unauthorized landfills is relevant today. Millions of tons of household waste are generated in Ukraine every year. The largest areas for landfills are occupied in Donetsk, Dnipropetrovsk, Odesa, Zaporizhzhia regions. So, in the Donetsk region the areas under landfills occupy 330 hectares. Various technologies based on satellite data and artificial intelligence methods are used to monitor landfills. Currently, there are services that track the location of landfills, but do not provide information about the territory of the landfill and changes in its area over time. In the process of research, the important task of separating landfills from quarries and artificial objects by combining pixel-based and object-based classification was solved. The main purpose of the work was to develop intelligent information technology based on the neural network approach and build on its basis a geospatial product of landfills for the Donetsk region, namely classification maps of landfills. The proposed machine learning algorithm based on historical and modern satellite data allows tracking the area of the landfill and its changes over time. The

developed information technology was tested on the territory of four territorial communities in Donetsk region, namely Olhyn, Myrnohrad, Kurakhiv and Pokrovsky communities. As a result of the research, an information panel was also developed, which provides operational data and allows to assess the dynamics of changes in landfills in the region in time and space. The developed technology is of practical importance for the development of waste management and management programs in local communities.

Keywords: satellite monitoring, satellite data, machine learning, artificial intelligence, geospatial data classification, landfills monitoring.

1. The state of the sphere of household waste management in Ukraine in 2021. URL: <https://www.minregion.gov.ua/wp-content/uploads/2021/10/stan-sfery-povodzhennya-z-pobutovymy-vidhodamy.pdf>
2. Law of Ukraine «On Waste». URL: <https://zakon.rada.gov.ua/laws/show/187/98-%D0%B2%D1%80#Text>.
3. Khosravi V., Doulati F., Gholizadeh A., Saberioon M. Satellite imagery for monitoring and mapping soil chromium pollution in a mine waste dump. *Remote Sensing*. 2021. **13**, N 7. 1277. 20 p. DOI: 10.3390/rs13071277.
4. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. ICLR. 2015. 1409.1556. P. 1–14. DOI: 10.48550/arXiv.1409.1556.
5. Olugboja A., Wang Z. Intelligent waste classification system using deep learning convolutional neural network. *Procedia Manufacturing*. 2019. **35**. P. 607–612. DOI: 10.1016/j.promfg.2019.05.086.
6. Rocio Nahime T., Fraternali P. Learning to identify illegal landfills through scene classification in aerial images. *Remote Sensing*. 2021. **13**, N 22: 4520. DOI: 10.3390/rs13224520.
7. Kussul N., Lavreniuk M., Shumilo L. Deep recurrent neural network for crop classification task based on sentinel-1 and sentinel-2 imagery. In *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. 2020. P. 6914–6917. DOI: 10.1109/IGARSS39084.2020.9324699.
8. Shumilo L., Kussul N., Lavreniuk M. U-Net model for logging detection based on the sentinel-1 and sentinel-2 data. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. 2021. P. 4680–4683. DOI: 10.1109/IGARSS47720.2021.9554885.
9. STEP: Science Toolbox Exploitation Platform. URL: <http://step.esa.int/main/toolboxes/snap/>.
10. Impact of SAR data filtering on crop classification accuracy. M. Lavreniuk, N. Kussul, M. Meretsky, V. Lukin, S. Abramov, O. Rubel. *IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON)*. 2017. P. 912–917. DOI: 10.1109/UKRCON.2017.810038.
11. Tucker C.J. Red and photographic infrared combinations for monitoring vegetation. *Remote Sens. of Environ.* 1979. **8**. P. 127–150. DOI: 10.1016/0034-4257(79)90013-0.
12. Curran P.J. Remote sensing of foliar chemistry. *Remote Sens. of Environ.* 1989. **29**. P. 271–278. DOI: 10.1016/0034-4257(89)90069-2.
13. McFeeters S.K. The use of normalised difference water index (NDWI) in the delineation of open water features. *Int. J. Remote Sens.* 1996. **17**. P. 1425–1432. DOI: 10.1080/01431169608948714.
14. Huete A.R. A soil-adjusted vegetation index (SAVI). *Remote Sens. of Environ.* 1988. **25**. P. 295–309. DOI: 10.1016/0034-4257(88)90106-X.
15. Jim'enez-Mu'noz J. et al. Land surface temperature retrieval methods from Landsat-8 thermal infrared sensor data. *IEEE Geoscience and Remote Sensing Letters*. 2014. **11**. P. 1840–1843.
16. Sobrino J. et al. Single-channel and two-channel methods for land 96 surface temperature retrieval from DAIS data and its application to the Barrax site. *International Journal of Remote Sensing*. 2004. **25**, N 1. P. 215–230.
17. Wang F. et al. An improved mono-window algorithm for land surface temperature retrieval from Landsat 8 thermal infrared sensor data. *Remote sensing*. 2015. **7**, N 4. P. 4268–4289.
18. Deep learning approach for large scale land cover mapping based on remote sensing data fusion. N. Kussul, A. Shelestov, M. Lavreniuk, I. Butko, S. Skakun. *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 2016. P. 198–201. DOI: 10.1109/IGARSS.2016.7729043.
19. Cloud approach to automated crop classification using Sentinel-1 imagery. A. Shelestov, M. Lavreniuk, V. Vasiliev, L. Shumilo, A. Kolotii, B. Yailymov, N. Kussul, H. Yailymova. *IEEE Transactions on Big Data*. 2020. **6**, N 3. P. 572–582. DOI: 10.1109/TBDATA.2019.2940237.
20. Land cover changes analysis based on deep machine learning technique. N. Kussul, N. Lavreniuk, A. Shelestov, B. Yailymov, I. Butko. *Journal of Automation and Information Sciences*. 2016. **48**, N 5. P. 42–54. DOI: 10.1615/JAutomatInfScien.v48.i5.40.
21. Азарсков В.Н., Блохин Л.Н., Житецкий Л.С., Куцскуль Н.Н. Робастные методы оценивания, идентификации и адаптивного управления. Київ : Вид-во Національного авіаційного ун-ту МОН України. 2004. 498 с.

Отримано 15.04.2022