

*І. О. БАГМУТ, В. С. ФІГУРСЬКА*

## РОЗРОБКА ТА ПОРІВНЯННЯ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ ДЛЯ СЕГМЕНТАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ З МЕТОЮ ЛОКАЛІЗАЦІЇ ЕРОЗІЇ ҐРУНТІВ

Дана робота присвячена вирішенню задачі автоматичного визначення географічного положення ґрунтів, що виявляють ознаки деградації. У роботі проведено детальне дослідження існуючої літератури за тематикою, розглянуто алгоритми та підходи вирішення задачі та їх переваги і недоліки, а також запропоновано критерії оцінки та базовий алгоритм для порівняння з результатами подальших досліджень та експериментів. Такий підхід забезпечує адекватну оцінку якості розробки програмних засобів сегментації зображень. Оскільки алгоритми машинного навчання потребують попередньої обробки даних, а також існують певні особливості роботи із супутниковими зображеннями, розроблена низка функцій, які надалі можуть використовуватись такими алгоритмами. Результатом роботи є розроблений програмний пакет завантаження та передобробки супутникових зображень, а також тренування і оцінки моделей глибокого навчання.

**Ключові слова:** дистанційне зондування, сегментація зображень, глибоке навчання.

This work is devoted to solve the problem of automatic determination of the geographic location of soils showing signs of degradation. The work carried out a detailed study of the existing literature on the subject, considered algorithms and approaches to solving the problem and their advantages and disadvantages, as well as proposed evaluation criteria and a basic algorithm for comparison with the results of further research and experiments. This approach provides an adequate assessment of the quality of image segmentation software development. Since machine learning algorithms require pre-processing of data, and there are also certain features of working with satellite images, a number of functions have been developed that can be used by such algorithms in the future. The result of the work is a developed software package for downloading and processing satellite images, as well as training and evaluation of deep learning models.

**Key words:** remote sensing, image segmentation, deep learning.

### Вступ.

Ерозія та деградація ґрунтів є все більшою проблемою з екологічної, економічної та соціальної точок зору. Раннє виявлення ерозії ґрунту може допомогти вирішити цю проблему та вжити заходів, необхідних для запобігання подальшої деградації. На сьогодні немає рішення, яке б автоматично надійно виявляло таке явище із високим ступенем точності. Існують супутникові знімки з достатньою роздільною здатністю для виявлення польових аномалій, що можуть бути застосовані для виявлення полів з еродованими та деградованими ділянками. Методи сегментації зображень удосконалюються з розвитком машинного та глибокого навчання. У порівнянні з класичними методами комп'ютерного зору, алгоритми машинного навчання, як правило, надають набагато кращі та точніші результати в цьому завданні. Емпіричні фізичні моделі також використовуються, однак, як самостійний інструмент для оцінки ерозії ґрунтів, такі підходи зазвичай проблематичні для практичного використання.

Попри всі дослідницькі зусилля, не існує агрегованих глобальних джерел даних і продуктів, які б дозволили визначити та локалізувати еродовані та схильні до деградації ділянки ґрунту через динамічний характер процесу, необхідність людського нагляду для оцінки точності прогнозів та специфіки конкретної території. Таким чином, метою даної роботи є дослідження потенціалу узагальнених підходів сегментації зображень для виявлення ерозії ґрунтів. Основні результати роботи викладені в [1].

### Формальна постановка задачі.

Задача полягає у розробці алгоритму сегментації зображень супутникових зображень (Sentinel-2). Конкретніше, необхідно визначити на

супутниковому зображенні області пікселів, які виявляють ознаки ерозійних процесів (низька рослинність, невластива текстура поля, значне відхилення кольору ґрунту, тощо). Алгоритм повинен класифікувати усі пікселі вхідного зображення на два класи: нормальний ґрунт та ґрунт з ознаками деградації. В тому числі алгоритм не повинен виявляти з мінімальною ймовірністю ерозію на ділянках, що не є ґрунтами (водні об'єкти, дороги, урбанізовані ділянки).

В якості вхідних даних (рис. 1) алгоритм може приймати будь-який набір доступних смуг зображень Sentinel-2, на виході алгоритм повинен повернути растрове бінарне зображення, де одиниця відповідатиме пікселям, що проявляють ознаки ерозії, та нуль - пікселям, що не зазнали ерозії або не відносяться до агрокультурних ділянок взагалі.

Sentinel-2 – це європейська місія з широкого спектру зображення з високою роздільною здатністю [2]. Продуктами обробки даних сенсорів, що знаходяться на супутниках-близнюках цієї місії, є 13 спектральних зображення в різних діапазонах та різної роздільної здатності: чотири смуги – 10 м на піксель, шість смуг – 20 м на піксель і три смуги з просторовою роздільною здатністю 60 м на піксель.

В якості порівняльного алгоритму використовується сегментація шляхом кластеризації пікселів. Таке порівняння із простим алгоритмом дає можливість адекватної оцінки показників та метрик розробленого алгоритму. Мануально створений набір анотованих ділянок еродованого ґрунту використовується частково як дані для тренування, валідації та тесту.

© Багмут І.О., Фігурська В.С., 2022



Рис. 1. Приклади вхідного зображення Sentinel-2:  
а – TCI смуга; б – зображення із анотованими векторними зображеннями деградованих ділянок

Анотація відбувалась з допомогою супутникових зображень PlanetScope, тому певні відхилення при використанні інших супутникових зображень може мати місце. Набір складається з 11 прямокутних ділянок, на яких позначені сегменти агрокультурних ґрунтів, де відбувається деградація. Дані збережені у вигляді векторної графіки. Існуючий набір даних включає ділянки Харківської області, Україна, а саме у Богодухівському, Валківському, Дергачевському, Золочевському, Коломацькому, Краснокутському, Люботинському, Первомайському, Печенежському, Харківському та Чугуєвському районах. Головний показник та вимоги до алгоритму – сегментація еродованих ділянок із показником IoU не менше 0.7 на тестовій ділянці.

**Попередні дослідження.** RUSLE використовувався в кількох роботах [3, 4]. Основна проблема такого підходу полягає в тому, що це рівняння вимагає знати багато емпіричних змінних, пов'язаних із типом ґрунту (коефіцієнт ерозійності), даними про висоту (довжина схилу, коефіцієнти крутизни схилів), дані про кількість опадів та фактор рослинного покриву (С-фактор), які самі змінюються та періодично підлягають корекції.

Підводячи підсумок, можна сказати, що найбільш надійними та точними є моделі, засновані на фізиці, але їх важко змоделювати через необхідність широкого точного оновлення фізичних властивостей ґрунту, з іншого боку, емпіричні моделі менш точні, але вимагають набагато менш ретельних вимірювань. Вибраний підхід є скоріше поєднанням фізичного із міцною основою емпіричного підходу.

Доступність даних супутникових знімків прискорила подальші дослідження методів дистанційного оцінювання факторів у цьому рівнянні. Більше того, більшість супутників фіксують спектр довжин хвиль далеко за межами видимого світла, і користувачі можуть легко отримати доступ до гіперспектральних або мультиспектральних зображень.




Рис. 2. Порівняння Landsat 7 та 8 каналів із Sentinel 2 [5]




Рис. 3. Приклад растрового зображення NDVI [7]

Численні місії NASA доступні до цього дня. Особливий інтерес для ґрунтознавства становлять супутникові зображення середньої та високої роздільної здатності, наприклад, отримані за допомогою спектро радіометра із зображенням середньої роздільної здатності (MODIS), програм Landsat та Sentinel. Ці програми забезпечують різну роздільну здатність до 10 метрів на піксель.

З фізики спектроскопії відомо, що різні молекули по-різному взаємодіють з електромагнітним випромінюванням (ЕМВ) залежно від частоти (тому й довжини хвилі). Лише цей факт можна використати для визначення вмісту матеріалів і поверхонь, включаючи ґрунти та рослинні покриви Землі. Існують деякі проблеми з прямим відбиттям від поверхні до точного хімічного складу:

1. Неминучий шум у сигналах;
2. Вплив і перешкоди кількох джерел ЕМВ.

Порівняння спектрів випромінювання різних супутників надано на рисунку 2. Фахівці можуть визначити ділянки ерозії ґрунту, хоча для забезпечення достовірності оцінки необхідні вимірювання та спостереження безпосередньо на місці її виникнення. Отже, зростає потреба в автоматичному виявленні деградації ґрунту. Для зменшення шуму при збереженні корисних сигналів відбиття опромінення молекулами води, ґрунту та рослинності були запропоновані численні спектральні індекси відбиття. Серед найбільш корисних і часто застосовуваних є нормалізований індекс різниці рослинності (Normalized Difference Vegetation Index, NDVI) [6], який дозволяє приводити коефіцієнти відбиття від червоних і ближніх інфрачервоних спектрів (як правило, представлені в

цифровій формі в діапазонах від 300 до 10000 в залежності від рівня попередньої обробки постачальником супутникових зображень) у простий діапазон від -1 до 1, на рисунку 3 представлені приклади типових NDVI, де 1 відповідає яскраво-зеленому кольору, -1 відповідає темно-помаранчевому кольору.




Рис. 4. Приклади різних типів сегментації [10]

Зазвичай задачі сегментації можна далі класифікувати як семантичну, екземплярну та паноптичну сегментацію [8, 9]. На рисунку 4 наочно показано відмінності кожного виду сегментації. Конкретна підкатегорія сегментації зазвичай залежить від застосування, наприклад, у задачах комп'ютерного зору для автоматизації водіння автомобіля застосовують екземплярну та паноптичну сегментацію частіше, ніж для класифікації видів культур.

З точки зору класичних алгоритмів комп'ютерного зору, сегментацію зображень можна

вирішити за допомогою таких методів, як застосування порогового значення [11], виявлення країв і застосування суперпикселів [12]. Такі підходи заслуговують на увагу, оскільки вони все ще застосовуються в деяких сферах практичного використання. Тим не менш, зазвичай класичні методи схильні до помилок і можуть дати несподівані результати в оточеннях, відмінних від тих, в яких вони розробляються та тестують.

Нейронні мережі. Перші визначні кроки у сфері глибокого навчання та розвитку нейронних мереж були здійснені ще в 40х роках ХХ століття. Нейрофізіолог Уоррен МакКалох і математик Уолтер Пітс припустили внутрішню роботу нейронів і змоделивали примітивну нейронну мережу за допомогою електричних ланцюгів на основі їхніх висновків (McCulloch and Pitts, 1943) [13]. Їхня модель була лінійною ступінчастою функцією на основі зважених лінійно інтерпольованих даних, які можуть бути описується наступним чином:

$$X_{out} = \begin{cases} 1, \sum_i w_i x_i \geq \theta, z_j = 0, \forall j \\ 0, \text{інакше} \end{cases} \quad (1)$$

де  $X_{out}$  – вихідне значення;

$X_i$  – вхідне значення, коефіцієнт зваження;

$z_j$  – інгібіторне значення;

$\theta$  – порогове значення.

Така модель поклала основу сучасних алгоритмів глибокого навчання, проте проблеми фіксованих значень зважених коефіцієнтів та сувора дискретизація вихідної функції потребували подальших досліджень.

Наступна модель так званого нейрону описана Розенблаттом (1958) [13], натхненна роботою людського ока та отримала назву перцептрон. В даній моделі найкраща апроксимація функції відгуку досягається за рахунок декількох вхідних сигналів, які сумують з індивідуальним коефіцієнтом зваження, крім того, до результату застосовується нелінійне перетворення, яке згодом набуло назви функції активації. Описана модель зображена на рис. 5.




Рис.5. Ілюстрація роботи моделі «Перцептрон» [13]

Основним механізмом глибокої нейронної мережі є послідовні лінійні операції в поєднанні з відносно простими нелінійними операціями. Завдяки простому введенню нелінійних (часто званих

активаційних) функцій і великої кількості вузлів у мережі, такі графоподібні структури здатні виявити численні складні нелінійні закономірності в даних [14]. Кожна лінійна операція, як правило, є простою процедурою масштабування вхідних даних і додавання деякого члена зміщення, таке обчислення в спільноті глибокого навчання називається шаром. Як правило, кожен шар супроводжується застосуванням нелінійної функції активації. Таким чином, вихід одного шару обчислюється наступним чином:

$$X_{out} = \varphi(w X_{input} + b) \quad (2)$$

де  $X_{input}$  – вхідне значення змінної;

$w$  та  $b$  – параметр масштабу (або «вага») та зміщення лінійної функції;

$\varphi$  – функція активації.

**Згорткові нейронні мережі.** У випадку зображень, як правило, корисно зберігати просторову інформацію. Для досягнення цього широко використовується операція, відома як згортка. Нехай зображення буде представлено у вигляді двовимірної матриці  $X$ , кожен елемент якої представляє конкретне значення пікселя, розмір ядра буде позначено як  $h$ . Результатом згорткової операції буде матриця  $G$ :

$$G[m,n] = \sum_j \sum_k h[j,k] X[m-j,n-k] \quad (3)$$

Простіше пояснюючи, ядро розміру  $h$  зміщується по всій матриці двовимірного зображення, кожен раз, коли операцію можна розглядати як поелементне множення ядра з фрагментом зображення з подальшим підсумовуванням усіх елементів отриманої матриці. На рисунку 6 ця операція наглядно проілюстрована.




Рис. 6. Ілюстрація операції згортки

Операція повторюється знову, коли ядро «ковзає» по ширині та висоті зображення, зазвичай зміщуючи на один піксель за раз, один піксель називається кроком у цій операції, хоча він не обов'язково дорівнює одиниці. Зрозуміло, що вихідне зображення в будь-якому випадку буде меншим щонайменше на два значення по ширині та висоті. Якщо вхідна форма повинна бути збережена, можна застосувати заповнення, тобто межі з кожного боку матриці зображення можуть бути додані перед згорткою. Звичайно заповнювати зображення зі значенням нуль, але можуть бути застосовані й інші методи. Серед них є відступи, відомі як «same» –

копіювання лівого стовпця ліворуч, верхнього рядка угору тощо, відступ «reflect» – копіювання лівого стовпця праворуч, верхнього рядка донизу тощо.

Хоча кроки більше одиниці можуть зменшити розмір зображення, існує ще одна техніка, яка може бути застосована для зменшення розміру зображення, відома як об'єднання. Під час цієї операції зображення або карта об'єктів зменшується шляхом укрупнення значень у невеликому вікні. Агрегації можуть бути довільними, найчастіше використовуються максимальний пулінг (збереження максимального значення у вікні) і середній пулінг (збереження середнього значення у вікні). Візуальне зображення максимального та середнього об'єднання продемонстровано на рисунку 7. Операція усереднення значень в певному вікні не тільки зменшує розміри зображення, але й допомагає зменшити вплив шуму та зайвих функцій.

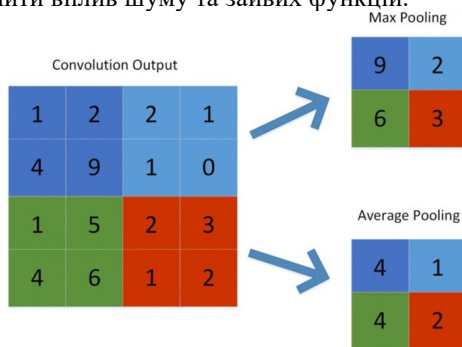


Рис. 7. Ілюстрація операції максимального та середнього пулінгу

Отриману матрицю можна піддати функції активації або використати як вхідне значення до іншої згорткової операції. Після послідовності лінійних, згорткових і активаційних функцій (так званий «Прохід вперед») мережа оновлюється за допомогою зворотного поширення помилки [15]. Функція втрат – це функція, яка виводить ступінь, наскільки результат мережі відрізняється від реального очікуваного результату, існує безліч таких функцій, і вибір повинен залежати від виконуваного завдання. Загалом, зворотне поширення помилки – це механізм піддавання параметрів вузлів мережі (тобто функцій, «ваги») впливу градієнта. Цей градієнт розраховується як часткова похідна по параметрам вузла. Нехай  $J$  позначає значення функції втрат, а  $\epsilon$  параметром швидкості навчання, тоді оновлення ваги за допомогою зворотного поширення помилки буде розраховано наступним чином:

$$W_i = W_i + \epsilon \cdot J(W) \quad (4)$$

**Обрані моделі для порівняння.** У сегментації зображень найбільший прорив відбувся з архітектурою U-Net [16]. Запропонована архітектура спирається на архітектуру кодер-декодер типу. Основним алгоритмом такої архітектури є створення двоступеневої моделі, тоді як на першому етапі модуль кодувальника «вчиться» створювати інформаційне представлення у просторі високої

розмірності, а модуль декодера «вчиться» отримувати цю інформацію з отриманої матриці. Зокрема, в U-Net ця частина кодування реалізована як послідовність операцій об'єднання, що застосовуються до карт об'єктів, а частина декодування – як послідовність операцій підвищення дискретизації, відомих як «згортка нагору» або «транспонована згортка». Ця операція тісно пов'язана зі звичайною згорткою, але замість того, щоб об'єднувати ядро пікселів для зменшення розміру, вона інтерполює менше вікно, щоб відповідати розміру ядра. В результаті транспонованої згортки з розміром ядра 3 і кроком 1 без додаткового заповнення буде отримано з патча 4x4 пікселів вихід з розміром 16x16 (рис. 8).




Рис. 8. Архітектура U-Net

Як і вище описана архітектура, модель UNet++ має в основі енкодер-декодер структуру. Обидві мережі мають ключову подібність: пропусні з'єднання (skip connections), які поєднують глибокі, семантичні, грубозерністі карти ознак з підмережі декодера з поверхневими, низькорівневими, дрібнозерністими картами функцій з підмережі енкодера. Пропусні з'єднання показали свою ефективність у відновленні дрібних деталей цільових об'єктів; генерування сегментаційної маски з дрібними деталями навіть на складному фоні.

Дана архітектура вносить деякі корективи в організації таких пропусних з'єднаннях. В UNet карти функцій кодера безпосередньо повторно отримані в декодері; однак в UNet++ вони зазнають щільної згортки за допомогою додаткових блоків, кількість шарів згортки залежить від рівня піраміди. наприклад, шлях пропуску між вузлами  $X^{0,0}$  і  $X^{1,3}$  складається з щільного блоку згортки з трьома шарами, де кожен шар передуює шар конкатенації, який об'єднує вихідні дані попереднього шар згортки того самого щільного блоку з відповідною дискретизацією вихід нижнього щільного блоку. Блок щільної згортки приносить семантичний рівень карт функцій енкодера ближче до рівня карт функцій, очікуваний в декодері. Гіпотеза полягає в тому, що оптимізатор зіткнеться з легшою проблемою

оптимізації, коли отримані карти функцій енкodера та відповідні карти функцій декодера семантично подібні [17]. Формально можна сформулювати шлях пропуску наступним чином: нехай  $x^{i,j}$  позначає вихід вузла  $X^{i,j}$ , де  $i$  індексує рівень понижуючої дискретизації вздовж кодера, а  $j$  індексує шар згортки щільного блоку вздовж шляху пропуску. The стек карт функцій, представлених  $x^{i,j}$ , обчислюється наступними функціями

$$x^{i,j} = \begin{cases} H(x^{i-1,j}), j = 0 \\ H([x^{i,k}]^{j-1}, U(x^{i+1,j-1})), j > 0 \end{cases}$$

На рис. 9а представлена загальна архітектура енкodер-декодер, де чорний колір позначає оригінальний U-Net, зелений і синій показують згортку конволюційних блоків, а червоний колір вказує на глибокий нагляд. Червоний, зелений і синій компоненти відрізняють UNet++ від U-Net. На рис. 9b детально представлено аналіз першого шляху пропуску UNet++. На рис. 9c показано, що за

допомогою Net++ можна скоротити час для висновків, якщо тренуватися з глибоким наглядом.

HRNet підтримує представлення високої роздільної здатності шляхом паралельного з'єднання згортки із високою та низькою роздільною здатністю, де відбувається повторюване багатомасштабне злиття між паралельними згортками [18]. Архітектура показана на рис. 10. Головна ідея та концептуальна відмінність моделі — одночасна згортка зображень різних розмірів із об'єднанням проміжних результатів в блоках мульти-розмірності. Вхідний сигнал піддається згортці, після чого одночасно проходить паралельні згортки в інших гілках із зменшеною в двічі роздільною здатністю. На етапі поєднання проміжних карт прогнозів мережа має змогу так би мовити узгодити результати різних розмірів, після чого такий процес повторюється із додатковим зменшенням зображення паралельно двічі. Паралельну згортку оригінального та зменшеного зображення називатимемо другим, третім та четвертим етапами.




Рис. 9. Архітектура UNet++:

а – загальна архітектура енкodер-декодер; б – аналіз першого шляху пропуску UNet++; с – UNet++




Рис. 10. Архітектура мережі HRNet та блоків мережі: а – згортки; б – блок мультирозмірного злиття; с – повноз'єднаний блок





Рис. 11. Приклади композитного кольорового зображення та індексів NDVI та NDMI та результати тестування різних моделей



Згортка з різною роздільною здатністю зображена на рис. 10б. Такий спосіб подібний до повного підключення з кількома гілками правильної згортки, зображеної на рис. 10с. Звичайну згортку

можна розділити на кілька маленьких, як пояснюється в [19].

Вхідні канали розділені на кілька підмножин, так само як і вихідні канали. Вхідні та вихідні підмножини з'єднані повнозв'язаним способом, і

кожне з'єднання – це звичайна згортка. Кожна підмножина виходу каналів є підсумовуванням виходів згорток над кожною підмножиною вхідних каналів.

Відмінності полягають у двох аспектах. По-перше, для різної роздільної здатності кожна множина каналів проходить операцію згортки. По-друге, з'єднання між вхідними каналами та вихідні каналами потрібно обробляти із зниженням роздільної здатності, як реалізовано в [18] за допомогою згорток  $3 \times 3$  із кроком 2. Збільшення роздільної здатності реалізовано шляхом білінійного підвищення дискретизації.

**Розробка та підготування моделей глибокого навчання.** Для подальшого використання для алгоритмів машинного навчання та аналізу результатів розроблений програмний пакет, що полегшує значну частину передобробки. Відтак розроблений наступний функціонал: створення трьох каналового зображення у видимому спектрі, розрахунок та збереження спектральних індексів (NDVI, NDMI, NDRE, NDWI, EVI), створення та збереження композитного зображення з декількох смуг, сворення та збереження частини зображення як окремого файлу та інші. Деякі важливі функції приведені у додатках, повний пакет знаходиться у відкритому репозиторії та знаходиться за посиланням: [https://github.com/erelin6613/soil\\_erosion](https://github.com/erelin6613/soil_erosion)

За допомогою мови програмування Python та допоміжних пакетів (пакет автоматичного диференціювання та організації процесу навчання Pytorch, пакети роботи із векторними та растровими зображеннями Rasterio, OpenCV, Pillow, пакет для виконання математичних операцій з матрицями та векторами NumPy тощо) були написані програмні файли для передобробки та процесу тренування моделей UNet, UNet++ та HRNet та їх оцінки.

Проведення експериментів відбувались при однакових умовах, в тому числі на однаковому обладнанні. Також тренування проходило з однаковими гіперпараметрами, однакову кількість епох з однаковими наборами тренувальних, валідаційних та тестувальних даних. Не зважаючи на архітектурні відмінності моделей, такий експеримент дозволяє якомога краще оцінити корисність моделі за умов відносно невеликого набору даних та обмежених технічних ресурсів. Результати процесу навчання та оцінки наведені на рис. 11 та таблиці 1.

Таблиця 1. Результати оцінки моделей

Модель	Показник IoU	Кількість параметрів
UNet, Resnet50 backbone	0,4543	24436369
UNetPlusPlus, Resnet50 backbone	0,4056	48985745
HRNet-18	0,3240	96019370

Результати свідчать, що для даних умов найкращі показники здобуває модель UNet. В даному випадку спостерігається обернено

пропорційна залежність показника якості від кількості параметрів.

На практиці доведено, що для невеликих наборів даних використання моделей з великою кількістю параметрів за однакових умов тренування недоцільне.

**Висновки та перспективи подальшого розвитку даного напрямку.** Предмет передбачення та оцінки ерозії ґрунтів вивчається протягом тривалого часу, розроблені численні методи для вирішення проблеми раннього виявлення та прогнозування. Особливий інтерес представляє застосування таких моделей для дистанційного зондування, оскільки дослідження in-situ є ресурсомістким і трудомістким. Суто фізичні та емпіричні моделі погано підходять для такого моделювання через необхідність ретельного вимірювання властивостей ґрунту. Однак у поєднанні з методами цифрової обробки сигналів вони мають великі перспективи для розробки ефективних алгоритмів прогнозування деградації ґрунту.

Дані дистанційного зондування забезпечують не тільки візуальне зображення еродованих ділянок, але й спектральний профіль поверхні, який описує властивості ґрунтів. У профайлах відбиття електромагнітного випромінювання може бути необмежена кількість шаблонів, які вказують на профіль ґрунту, ці шаблони можна вивчити за допомогою алгоритмів машинного навчання. Такий підхід є кращим не тільки через аспект економії часу, а й через потенціал для виявлення нових закономірностей і зв'язків, які ще не відкриті людьми.

В ході експериментів тренування декількох моделей (UNet, UNet++, HRNet-18) встановлено, що рівноцінні умови тренування найкращі результати досягають моделі з відносно невеликою кількістю параметрів, в даному випадку UNet.

#### Список літератури

1. European Space Agency, Sentinel-2 mission: Overview. Електронний ресурс.
2. Panditharathne, D. & Abeysingha, Nimal & Nirmanee, K G & Mallawatantri, Ananda. (2019). Application of Revised Universal Soil Loss Equation (Rusle) Model to Assess Soil Erosion in “Kalu Ganga” River Basin in Sri Lanka. Applied and Environmental Soil Science. 2019. 1-15. 10.1155/2019/4037379.
3. Thapa, Pawan. (2020). Spatial Estimation of Soil Erosion Using RUSLE Modeling: A case study of Dolakha District, Nepal. 10.21203/rs.3.rs-25478/v4.
4. El Jazouli, A., Barakat, A., Ghafiri, A. et al. Soil erosion modeled with USLE, GIS, and remote sensing: a case study of Ikkour watershed in Middle Atlas (Morocco). *Geosci. Lett.* 4, 25 (2017).
5. N.R. Pal, S.K. Pal, A review on image segmentation techniques, *Pattern Recognition* 26(9) (1993) 1277–1294.
6. N.M. Zaitoun, M.J. Aqel, Survey on image segmentation techniques, *Procedia Computer Science* 65 (2015) 797–806, International Conf. on Communications,



- management, and Information technology (ICCMIT'2015).
7. Gurung, Amit and Sangyal Lama Tamang. "Image Segmentation using Multi-Threshold technique by Histogram Sampling." *ArXiv abs/1909.05084* (2019)
  8. Achanta, Radhakrishna & Shaji, Appu & Smith, Kevin & Lucchi, Aurélien & Fua, Pascal & Süssstrunk, Sabine. (2010). SLIC superpixels. Technical report, EPFL.
  9. Wang, Haohan and Bhiksha Raj. "On the Origin of Deep Learning On the Origin of Deep Learning." (2017).
  10. Wiatowski, Thomas & Bölcskei, Helmut. (2015). A Mathematical Theory of Deep Convolutional Neural Networks for Feature Extraction. *IEEE Transactions on Information Theory*. PP. 10.1109/TIT.2017.2776228.
  11. Zweifel, Lauren & Meusburger, K. & Alewell, Christine. (2019). Spatio-temporal pattern of soil degradation in a Swiss Alpine grassland catchment. *Remote Sensing of Environment*. 235. 10.1016/j.rse.2019.111441.
  12. Wiegand, C.; Rutzing, M.; Heinrich, K.; Geitner, C. Automated extraction of shallow erosion areas based on multi-temporal ortho-imagery. *Remote Sens*. 2013,5, 2292–2307.
  13. He, Kaiming & Zhang, Xiangyu & Ren, Shaoqing & Sun, Jian. (2016). Deep Residual Learning for Image Recognition. 770-778. 10.1109/CVPR.2016.90.
  14. Ronneberger, O.; Fischer, P.; Brox, T. U-net: Convolutional networks for biomedical image segmentation. In *Proceedings of the Medical Image Computing and Computer-assisted intervention—MICCAI 2015*, Munich, Germany, 5–9 October 2015; Volume 9351, pp. 234–241.
  15. Zhou, Zongwei & Rahman Siddiquee, Md Mahfuzur & Tajbakhsh, Nima & Liang, Jianming. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation.
  16. K. Sun, B. Xiao, D. Liu, and J. Wang. Deep high-resolution representation learning for human pose estimation. In *CVPR*, 2019. 1, 2, 3, 4, 8, 9
  17. T. Zhang, G. Qi, B. Xiao, and J. Wang. Interleaved group convolutions. In *ICCV*, pages 4383–4392, 2017. 3
  18. Zhang, Yiwen & Lai, Haoran & Yang, Wei. (2021). Cascade UNet and CH-UNet for Thyroid Nodule Segmentation and Benign and Malignant Classification. 10.1007/978-3-030-71827-5\_17.
  19. Heidary, Farnoosh & Yazdi, Mehran & Dehghani, Maryam & Setoodeh, Peyman. (2021). Urban Change Detection by Fully Convolutional Siamese Concatenate Network with Attention.
  20. Xu, Hanqiu, Xiujuan Hu, Huade Guan, Bobo Zhang, Meiya Wang, Shanmu Chen, and Minghua Chen. 2019. A Remote Sensing Based Method to Detect Soil Erosion in Forests. *Remote Sensing* 11, no. 5: 513.
  21. Mwaniki, Mercy & Agutu, Nathan & Mbaka, John & Ngigi, Tg & Waithaka, Edward. (2015). Landslide scar/soil erodibility mapping using Landsat TM/ETM+ bands 7 and 3 Normalised Difference Index: A case study of central region of Kenya. *Applied Geography*. 64. 108-120. 10.1016/j.apgeog.2015.09.009.
  22. Chen, Fen & Van de Voorde, Tim & Roberts, Dar & Zhao, Haojie & Chen, Jingbo. (2021). Detection of Ground Materials Using Normalized Difference Indices with a Threshold: Risk and Ways to Improve. *Remote Sensing*. 13. 10.3390/rs13030450.
  23. Rukhovich, Dmitry I., Polina V. Koroleva, Danila D. Rukhovich, and Natalia V. Kalinina 2021. The Use of Deep Machine Learning for the Automated Selection of Remote Sensing Data for the Determination of Areas of Arable Land Degradation Processes Distribution. *Remote Sensing* 13, No. 1: 155.
  24. Avwunudiogba, Augustine & Hudson, Paul. (2014). A Review of Soil Erosion Models with Special Reference to the needs of Humid Tropical Mountainous Environments. *European Journal of Sustainable Development*. 3. 299-310. 10.14207/ejsd.2014.v3n4p299
  25. Laflen, John & Flanagan, Dennis. (2013). The development of U. S. soil erosion prediction and modeling. *International Soil and Water Conservation Research*. 34. 10.1016/S2095-6339(15)30034-4.
  26. Anejionu, O.C.D., Nwilo, P.C., and Ebinne, E.S. (2013). Long Term Assessment and Mapping of Erosion Hotspots in South East Nigeria. TSO 3B – Remote Sensing for Land use and Planning – 6448, FIG Working Week, 2013.
  27. Chandramohan, T. & Venkatesh, Basappa & Balchand, A. (2015). Evaluation of Three Soil Erosion Models for Small Watersheds. *Aquatic Procedia*. 4. 1227-1234. 10.1016/j.aqpro.2015.02.156.
  28. Singh, Vijay & Asce, F&Cui, Huijuan&Byrd, Aaron. (2014). Sediment Graphs Based on Entropy Theory. *Journal of Hydrologic Engineering*. 20. 10.1061/(ASCE)HE.1943-5584.0001068.
  29. Beasley, David & Huggins, L. & Monke, E.. (1980). ANSWERS: a model for watershed planning.. *Transactions of the ASAE*. 23. 10.13031/2013.34692.
  30. Bahrawi, Jarbou & Elhag, Mohamed & Aldhebani, Amal & Galal, Hanaa & Hegazy, Ahmad & Alghailani, Ebtisam. (2016). Soil Erosion Estimation Using Remote Sensing Techniques in Wadi Yalamlam Basin, Saudi Arabia. *Advances in Materials Science and Engineering*. 2016. 1-8. 10.1155/2016/9585962.
  31. Panagos, Panos & Karydas, Christos & Borrelli, Pasquale & Ballabio, Cristiano & Meusburger, K.. (2014). Advances in soil erosion modelling through remote sensing data availability at European scale. *Proc SPIE*. 9229. 1-10. 10.1117/12.2066383.
  32. Sultana, Farhana & Sufian, A. & Dutta, Paramartha. (2020). Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey. *Knowledge-Based Systems*. 201-202. 10.1016/j.knosys.2020.106062.

Надійшла (received) 19.10.2022

*Відомості про авторів / Сведения об авторах / About the Authors*

**Багмут Іван Олександрович (Багмут Иван Александрович, Bahmut Ivan Aleksandrovich)** – кандидат технічних наук, професор кафедри комп'ютерного моделювання, Національний технічний університет «Харківський політехнічний інститут», м. Харків, Україна;

ORCID: <http://orcid.org/0000-0002-1389-6921>; e-mail: bis.khr@gmail.com

**Фігурська Валентина Степанівна (Фигурская Валентина Степановна, Fihurska Valentyna Stepanovna)** – студентка 5 курсу НТУ «ХПІ», м. Харків, Україна.