

DOI: <https://doi.org/10.36910/6775-2524-0560-2025-61-30>

УДК 004.8 + 004.93

Чумичов Денис Дмитрович, аспірант

<https://orcid.org/0009-0005-2729-0735>

Нікулін Сергій Леонідович, д.г.н., професор

<https://orcid.org/0000-0003-1795-3599>

Національний технічний університет «Дніпровська політехніка», м. Дніпро, Україна

ВИКОРИСТАННЯ ІНДИКАТОРА ДЕГРАДАЦІЇ ЛАНДШАФТУ ДЛЯ ПІДВИЩЕННЯ ТОЧНОСТІ НЕЙРОМЕРЕЖЕВОЇ КЛАСИФІКАЦІЇ СІЛЬСЬКОГОСПОДАРСЬКИХ ЗЕМЕЛЬ ЗА ДАНИМИ СУПУТНИКІВ SENTINEL

Чумичов Д. Д., Нікулін С. Л. Використання контурів об'єктів супутникових знімків sentinel для класифікації сільськогосподарських земель за допомогою нейронних мереж. Дослідження присвячене підвищенню точності класифікації сільськогосподарських угідь на орні та неорні за супутниковими знімками Sentinel-1 і Sentinel-2 шляхом інтеграції спектральних та структурних показників у глибинні нейронні мережі в якості додаткових ознак. Запропоновано використання спеціально розробленого структурного показника – індикатора деградації антропогенного ландшафту LDI (Landscape Degradation Indicator), який кількісно відображає щільність і контрастність контурів об'єктів на місцевості та слугує маркером антропогенного навантаження. Метою роботи є оцінка ефективності LDI як додаткової ознаки при глибокому навчанні моделей класифікації агроландшафтів та порівняння його інформативності з класичним вегетаційним індексом NDVI (Normalized Difference Vegetation Index). Методологія дослідження передбачає використання нейронної мережі з архітектурою U-Net з енкодером EfficientNetV2-L, попередньо навченої на датасеті ImageNet-21k, із застосуванням механізмів уваги, що агрегують часові ознаки у процесі обробки багатоспектральних і радарних знімків. Експериментальні тести проведено на вибірці, що охоплює понад 90 тис. земельних ділянок у регіоні Берлін-Бранденбург (Німеччина), із поділом на орні та неорні землі. Результати моделювання показали, що використання індексу LDI в якості додаткової ознаки підвищує точність класифікації з 88,87% до 91,34% через більш повне врахування структурних особливостей сільськогосподарського ландшафту. Порівняльний аналіз з NDVI продемонстрував перевагу LDI у задачах розрізнення деградованих та занедбаних угідь. А найвищий показник точності (91,98%) отримано при сумісному використанні NDVI та LDI, що свідчить про ефективність поєднання спектральних і структурних індикаторів. Наукова новизна дослідження полягає у впровадженні структурного індикатора LDI як нового параметра для нейромережових моделей класифікації аграрних ділянок.

Ключові слова: багатоканальні космічні зображення, Sentinel, класифікація сільськогосподарських угідь, неорні угіддя, глибинне навчання, нейронна мережа, контури об'єктів, детектор Кенні, структурні ознаки.

Chumychov D., Nikulin S. Using contours of objects from Sentinel satellite images for classifying agricultural lands using neural networks. The study aims to enhance the accuracy of classifying agricultural lands as arable or non-arable using Sentinel-1 and Sentinel-2 satellite images by integrating spectral and structural indicators into deep neural networks as additional features. Proposed use of a specially developed structural indicator – the anthropogenic landscape degradation indicator (LDI), which quantitatively reflects the density and contrast of object contours on the terrain and serves as a marker of anthropogenic load. The aim of this work is to assess the effectiveness of LDI as an additional feature in deep learning of agrolandscape classification models and to compare its informativeness with the classic vegetation index, NDVI (Normalized Difference Vegetation Index). The research methodology involves the use of a neural network with the U-Net architecture with the EfficientNetV2-L encoder, pre-trained on the ImageNet-21k dataset, using attention mechanisms that aggregate temporal features in the process of processing multispectral and radar images. Experimental tests were conducted on a sample covering more than 90 thousand land plots in the Berlin-Brandenburg region (Germany), divided into arable and non-arable lands. The modeling results showed that the use of the LDI index as an additional feature increases the classification accuracy from 88.87% to 91.34% due to a more complete consideration of the structural features of the agricultural landscape. A comparative analysis with NDVI demonstrated the superiority of LDI in the tasks of distinguishing degraded and abandoned lands. Moreover, the highest accuracy rate (91.98%) was obtained with the joint use of NDVI and LDI, which indicates the effectiveness of combining spectral and structural indicators. The scientific novelty of the study lies in the introduction of the structural indicator LDI as a new parameter for neural network models of agricultural land classification.

Keywords: multi-channel space images, Sentinel, agricultural land classification, non-arable land, deep learning, neural network, object contours, Kenny detector, structural features.

Постановка наукової проблеми. Класифікація сільськогосподарських земель за даними супутникових знімків є надзвичайно актуальною через глобальні проблеми деградації земель та їх вплив на продовольчу безпеку. Супутникові дані Sentinel-1 та Sentinel-2 надають регулярну та різноманітну інформацію з просторовою роздільною здатністю, що дозволяє ефективно відстежувати стан угідь. Автоматизований моніторинг з використанням таких даних значно скорочує час та витрати порівняно з традиційними засобами.

Окрім спектральних індексів широко використовуються структурні ознаки, які відображають стан та просторову організацію ландшафтів, що особливо корисно для виявлення

покинутих та/або неорних ділянок. Для формування структурних ознак широко використовуються контури, що виділяються на знімках, та відповідають об'єктам сільськогосподарського ландшафту (кордони полів, дороги, іригаційна інфраструктура тощо), що відбивають стану земель та характер їх використання.

З іншого боку, в останні роки величезного поширення набули методи класифікації знімків сільськогосподарських угідь, які засновані на глибинному навчанні нейронних мереж. Багатьма дослідниками показано, що вони сприяють врахуванню складних просторово-часових особливостей знімків та підвищуючи точність класифікації порівняно з традиційними методами.

Тож, виникає питання – чи здатні структурні ознаки бути корисними при класифікації за допомогою нейронних мереж, знижуючи підвищуючи її точність та надійність.

Метою роботи є дослідження можливості та доцільності використання при глибокому навчанні структурного індикатора LDI (Landscape Degradation Indicator) з метою класифікації земельних угідь на орні та неорні. Цей індикатор відображає середню щільність та контрастність контурів на супутникових зображеннях Sentinel, і був спеціально розроблений для відстеження процесів деградації сільськогосподарчих ландшафтів. Він є чутливим до зменшення антропогенного навантаження на ландшафти і, одночасно, стійким до сезонних відмінностей у вегетації. То ж, робота присвячена вирішенню двох **актуальних проблем** – 1) кількісній оцінці апіорної інформативності індикатора LDI з точки зору його можливості розділяти тестові орні та неорні ділянки, а також 2) можливості зниження помилки класифікації при використанні LDI у якості додаткової ознаки при глибокому навчанні нейронної мережі.

Аналіз останніх досліджень і публікацій. Упродовж останніх років методи класифікації земного покриття на основі супутникових знімків зазнали суттєвої трансформації під впливом розвитку глибокого навчання та появи архітектур із механізмами уваги (attention) і трансформерів. Класичні підходи – порогові алгоритми, методи максимальної правдоподібності, мінімальної відстані, Mahalanobis, а також спектрально-кутові метрики (SAM) – залишаються корисними для базових сценаріїв, однак у більшості сучасних завдань їх замінили згорткові нейронні мережі (CNN), які демонструють високу здатність вилучати нелінійні спектрально-просторові залежності [1, 2].

Систематичні огляди підкреслюють, що архітектури типу U-Net, DeepLab та ResNet-based backbones стали практичним стандартом для класифікації земного покриття, тоді як Vision Transformers (ViT) і Swin Transformers активно інтегруються в задачі семантичної сегментації та класифікації сцен [3, 4].

Останні дослідження фокусуються на багатоджерельному аналізі, який поєднує дані Sentinel-1 (SAR) і Sentinel-2 (оптичні). Такий підхід підвищує стабільність моделей у присутності хмарності, сезонних коливань та різної геометрії зйомки [5, 6]. Поєднання радарних і оптичних каналів дозволяє отримувати більш стійкі ознаки, особливо при використанні багатопланових енкодерів на кшталт EfficientNet або ConvNeXt, які забезпечують адаптивне вилучення інформації з різних сенсорів [7].

Окрему увагу в літературі приділено ознакам, які вважаються важливим доповненням до спектральних індексів (NDVI, EVI, NBR, тощо). Метрики на основі GLCM, LBP або морфологічних дескрипторів покращують відокремлення класів із подібними спектрами, але різною структурою поверхні – наприклад, різні типи агроландшафтів або рослинності [8]. Відомо, що поєднання спектральних і текстурних ознак у нейромережевих моделях підвищує точність класифікації на 5–15 % порівняно з використанням лише спектральних каналів [9]. Серед інтегрованих показників Combined Drought Index (CDI) та його модифікації активно використовуються для оцінки посухи і біофізичних змін у рослинному покриві [10]. CDI дозволяє об'єднувати метеорологічні, радарні та оптичні дані в єдину числову оцінку, чим забезпечує підвищену чутливість до аномалій порівняно з окремими індексами NDVI або SPI [11]. Це демонструє важливість комбінування спектральних, структурних і часових ознак у системах дистанційного моніторингу.

Розвиток нейронних мереж при вирішенні задач дистанційному зондуванні має три умовних аспекти. Перший полягає у еволюції архітектур: від класичних CNN до глибоких мереж із декодерами U-Net, а також до гібридних CNN+Transformer архітектур, таких як TransUNet, Swin-UNet та UNetFormer, що поєднують локальне згорткове вилучення ознак із глобальним самоувагою [12, 13]. Другий включає обробку мультитемпоральних і мультиспектральних даних: завдяки механізмам уваги моделі здатні враховувати часові зміни у послідовностях Sentinel-знімків, що

особливо важливо для моніторингу аграрних угідь і динаміки покриву [14]. Третій – це оптимізація обчислень та інтерпретованість: сучасні системи активно використовують змішану точність (Mixed Precision Training), розподілене навчання, Test-Time Augmentation (TTA) і карти уваги для інтерпретації результатів [15, 16].

Виклад основного матеріалу дослідження. Враховуючи особливості датасету конкурсу BioMassters, розроблена технологія класифікації передбачає попередню стандартизацію вхідних супутникових знімків. Для застосування технології до інших територій необхідно сформувати вхідний набір даних, який відповідає таким критеріям:


- для кожної ділянки мають бути доступні чотириканальні радарні знімки з супутника Sentinel-1 та одинадцятиканальні оптичні знімки Sentinel-2, що охоплюють 12 місяців року з роздільною здатністю 256×256 пікселів;

- кожна ділянка повинна мати двокласову маску класифікації типів землекористування;

- супутні метадані організовано у таблиці формату CSV, де кожен запис містить атрибути окремого знімку.

Супутникові дані отримано з відкритого порталу Copernicus Browser [17]. Для підготовки вхідних фрагментів було розроблено програмний скрипт на Python, який автоматично розбиває великі супутникові сцени на окремі тайли розміром 256×256 пікселів. Алгоритм виконує три основні кроки: 1) обчислення кількості можливих рядків і стовпців поділу початкового знімка; 2) нарізання фрагментів відповідного розміру; 3) збереження кожного фрагмента як окремого GeoTIFF-файлу з унікальною назвою, що відповідає ідентифікатору ділянки.

Для створення навчальних масок використано офіційний набір даних Field Boundaries for Agriculture (fiboa) [18], завантажений у форматі .parquet. Цей файл містить векторну геометрію меж полів та атрибутивну інформацію про вид землекористування. На основі аналізу атрибутів було відібрано ділянки, не задіяні у сільському господарстві, після чого з їхніх контурів сформовано двійкові маски у растровому форматі. Маски зберігалися під назвами, що збігаються з відповідними знімками місцевості. Після завершення етапу формування фрагментів і масок було створено підсумковий файл метаданих, який містив посилання на всі зображення та використовувався для подальшого навчання нейронної мережі. У дослідженні застосовано набір Field Boundaries for Berlin/Brandenburg (Germany), який охоплює приблизно 90 000 офіційно зареєстрованих меж сільськогосподарських ділянок земель Берлін і Бранденбург. Дані надано адміністрацією федеральної землі Brandenburg у проєкції EPSG:25833 (UTM Zone 33N) і конвертовано у формат fiboa GeoParquet. Кожен об'єкт містить відомості про тип землекористування, площу, рік збору даних та інші атрибути. Для спрощення аналізу всі типи землекористування було згруповано у два класи – орні землі та неорні (рис. 1).



Легенда: – Орні угіддя (нецільовий клас); – Не орні угіддя (цільовий клас).

Рис. 1. Досліджувана територія федеральних земель Берлін та Бранденбург

Сутність та обчислення Land Degradation Indicator (LDI) Показник LDI (Landscape Degradation Indicator; показник деградації ландшафту) використовується для кількісної оцінки змін антропогенних ландшафтів на основі супутникових знімків Sentinel-2. Він відображає щільність і інтенсивність контрастних границь яскравості (edges) між різними об'єктами на поверхні землі, такими як межі полів, дороги, будівлі тощо. Його практичне застосування у аграрних регіонах базується на припущенні, що чим інтенсивніші і чисельніші ці межі, тим вища антропогенна діяльність. Тобто, зниження значень LDI свідчить про деградацію антропогенного (у тому числі, сільськогосподарського) ландшафту через зменшення людської діяльності, наприклад, занедбання сільського господарства внаслідок деяких зовнішніх факторів (депопуляція території, рішення природоохоронних органів або інших).

Таким чином, обчислення LDI базується на аналізі контрастних крайових ефектів об'єктів місцевості, що виявляються на супутникових знімках, і опосередковано відбивають рівень людської активності та ступінь деградації сільськогосподарських ландшафтів.

На першому етапі обчислення LDI відбувається виявлення (контрастних границь яскравості на знімку, для чого використовується спеціально модифікований алгоритм Кенні (Canny edge detector). Традиційний алгоритм Кенні включає 6 кроків, починаючи від згладжування зображення гаусовим фільтром до гістерезисного порогування. Для потреб LDI використовується усічений алгоритм Кенні, що пропускає заключний крок перетворення граничних пікселів в бінарні значення. Це дозволяє зберегти інформацію про амплітуду градієнту, що характеризує не лише наявність у пікселі контуру, а й його "виразність".

Характеристика контрастних границь задається величиною градієнта $M_{i,j}$ для пікселя з координатами (i, j) , що є значенням градієнта відображення у зображенні:

$$M_{i,j} = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}, \quad (1)$$

де I – інтенсивність відбиття у спектральному каналі супутникового знімка.

Показник LDI для кожного пікселя у зображенні розраховується як середнє значення градієнтної величини у вікні розміром $K \times L$ пікселів, що ковзає по всьому зображенню:

$$LDI_{i,j} = \frac{1}{K \times L} \sum_{k=1}^K \sum_{l=1}^L M_{i+k,j+l}, \quad (2)$$

де:

- i, j – координати центрального пікселя вікна,
- k, l – індекси пікселів всередині ковзного вікна,
- $M_{i+k,j+l}$ – величина градієнту у пікселі $(i + k, j + l)$.

Ця операція усереднення дозволяє зменшити вплив локального шуму та дрібних ландшафтних об'єктів, формуючи узагальнений показник щільності і контрастності границь, що опосередковано відображає інтенсивність антропогенної активності в досліджуваній області.

Для порівняння змін стану ландшафту у часі обчислюється різниця ΔLDI карт LDI, на основі знімків, отриманих у різні моменти:

$$\Delta LDI = LDI_{t_2} - LDI_{t_1}, \quad (3)$$

Для розрахунку LDI використовуються знімки Sentinel-1 з поляризацією VV та VH, а також канали Sentinel-2. Переважно застосовується червоний спектральний канал (B04) Sentinel-2 з просторовою роздільною здатністю 10 м, оскільки саме він забезпечує максимальну інформативність для виявлення змін контурної щільності аграрних ландшафтів [19].

Параметри ковзного вікна підбираються в залежності від масштабу аналізу: великі вікна (наприклад, 2×2 км) допомагають узагальнити дані і виділити основні тенденції, тоді як малі (до 100×100 м) використовуються для більш детального дослідження конкретних локальних змін. В даній роботі, за результатами обчислювальних експериментів, було обрано вікно розміром 500×500 м.

У ході роботи було побудовано низку карт індикатора LDI – за значеннями 4-го каналу Sentinel-2, а також знімків Sentinel-1 з поляризаціями VV та VH. Використані знімки за дві дати –

08.03.2024 (весняні) та 21.07.2024 (літні). Крім того, для різночасових пар карт LDI будувались карти Δ LDI (рис. 2).




Рис. 2. Побудовані карти індикатора LDI: а – фрагмент 4-го каналу знімка Sentinel-2 від 08.03.2024; б – карта контурів; в – карта LDI, побудована у ковзному вікні 500х500м

Оцінка апіорної інформативності LDI. Оцінка ефективності застосування індикатора LDI (як і будь-яких інших ознак) при класифікації супутникових знімків може базуватись як на апіорних, так і апостеріорних оцінках їх інформативності. Хоча останні є більш надійними, для їх отримання, в нашому випадку, необхідне виконання часозатратних операцій глибинного навчання. Тому, при наявності великого обсягу контрольних об'єктів з відомими властивостями, обчислення апіорних оцінок може бути ефективним засобом виявлення інформативних ознак та відсіювання неінформативних.

В даній роботі оцінка апіорної інформативності деякої ознаки базувалась на порівнянні двох гістограм, – побудованих по значенням ознаки для пікселів, що відповідають 1) орним і 2) неорним ділянкам. Очевидно, що при повному співпадінні цих двох гістограм розділення орних та неорних ділянок за значеннями ознаки неможливо, і навпаки, при їх повному неспівпадінні розділення буде ідеальним. На практиці нормальною ситуацією буде часткове співпадіння, і чим воно менше, тим більшу апіорну інформативність має ознака. На рисунку 3 показані приклади гістограм розподілу значень орних та неорних ділянок для 4-го каналу Sentinel-2 (08.03.2024) та розрахованого від нього індикатора LDI.




Рис. 3. Приклади гістограм розподілу значень орних та неорних ділянок: а – еталонні маски тестової вибірки; б – відповідні маски, отримані моделлю без включення знімків LDI.

Для оцінки ступеню подібності гістограм було використано декілька широко відомих критеріїв – χ^2 -квадрат, відстань Бхаттачарія, відносну площу перетину гістограм (змінюється від 0 до 1), та коефіцієнт кореляції між значеннями гістограм [20].

Гістограми будувались по значенням пікселів, окремо для тих, що відповідають орним ділянкам, та, окремо, неорним (див. рис. 2).

Зазначені показники були обраховані для всіх карт LDI та Δ LDI, перелічених у попередньому розділі. Крім того, для порівняння, вказані критерії були обраховані для самих

супутникових знімків Sentinel-1 та 2, а також для різниць між парами весняних (08.03.2024) та літніх (21.07.2024) знімків. Отримані результати наведено у таблиці 1.

Таблиця 1. Оцінка інформативності ознак

Зображення	Показники подібності гістограм			
	Площа перетину гістограм 1 - повна подібність	Критерій χ^2 0 - повна подібність	Відстань Бхаттачарія 0 - повна подібність	Коефіцієнт кореляції 1 - повна подібність
Sentinel-2, канал 4 (08.03.2024)	0,70	0,27	0,27	0,68
Sentinel-2, канал 4 (21.07.2024)	0,63	0,36	0,32	0,74
Sentinel-1, канал VV (08.03.2024)	0,94	0,01	0,06	0,99
Sentinel-1, канал VV (21.07.2024)	0,91	0,03	0,08	0,97
Sentinel-1, канал VH (08.03.2024)	0,85	0,06	0,12	0,94
Sentinel-1, канал VH (21.07.2024)	0,92	0,02	0,07	0,97
Різниця між весняними і літніми знімками Sentinel-2, канал 4	0,69	0,26	0,27	0,84
Різниця між весняними і літніми знімками Sentinel-1, VV	0,95	0,01	0,04	0,99
Різниця між весняними і літніми знімками Sentinel-1, VH	0,89	0,04	0,1	0,96
LDI по Sentinel-2, канал 4 (08.03.2024)	0,90	0,04	0,09	0,97
LDI по Sentinel-2, канал 4 (21.07.2024)	0,83	0,10	0,16	0,89
LDI по Sentinel-1, VV (08.03.2024)	0,87	0,06	0,12	0,95
LDI по Sentinel-1, VV (21.07.2024)	0,90	0,05	0,10	0,97
LDI по Sentinel-1, VH (08.03.2024)	0,85	0,09	0,14	0,91
LDI по Sentinel-1, VH (21.07.2024)	0,89	0,05	0,11	0,97
Δ LDI (Sentinel-2, канал 4)	0,82	0,12	0,16	0,89
Δ LDI (Sentinel-1, VV)	0,56	0,55	0,42	0,56
Δ LDI (Sentinel-1, VH)	0,85	0,09	0,14	0,93

Таблиця 1 демонструє, що найбільшу апіорну інформативність, з точки зору розділення орних та неорних ділянок забезпечує карта Δ LDI, побудована для знімка Sentinel-1 з поляризацією VV. При цьому що самі знімки Sentinel-1 мають досить невисоку інформативність. Слід також зауважити, що літні знімки та відповідні карти LDI у середньому інформативніші за весняні, але поступаються різисним.

Таким чином, було встановлено, що карти Δ LDI мають високу апіорну інформативність, тож їх використання при класифікації сільгоспугідь запропонованою нижче технологією може бути доцільним, що і було продемонстровано далі.

Технологія класифікації сільгоспугідь. Запропонована технологія ґрунтується на вдосконаленому алгоритмі класифікації космічних знімків, розробленому на основі підходу – переможця міжнародного змагання BioMassters [13]. Її принципом є ітеративне навчання глибокої нейронної мережі, під час якого модель послідовно вдосконалює власні параметри в декілька циклів. Кожна з чотирьох навчальних ітерацій використовує результати попередньої як початкові ваги, що забезпечує поступове уточнення просторово-часових ознак. Архітектурну основу системи становить глибока сегментаційна мережа типу U-Net, де в ролі енкодера застосовано EfficientNetV2-L, попередньо натренований на великому наборі зображень ImageNet-21k. Така архітектура дозволяє ефективно вилучати багаторівневі спектрально-просторові характеристики, що є ключовим для оброблення часових багатоспектральних даних супутників. Важливим удосконаленням є впровадження механізмів уваги (attention pooling), які дають змогу підсилювати найбільш інформативні часові ознаки, підвищуючи точність тематичної класифікації.

Для оцінювання впливу спектральних та структурних індексів на результати класифікації було сформовано наступні набори вхідних даних, що відрізняються за складом каналів:

1. На вхід алгоритму подаються одинадцять каналів Sentinel-2, об'єднані з двома каналами Sentinel-1 одинарної поляризації: VV та VH. У результаті формується тензор форми $X \in R^{T \times C \times H \times W}$, де $T=2$ – кількість часових зрізів (місяців), $C=13$ – загальна кількість каналів (2 канали Sentinel-1 та 11 каналів Sentinel-2), $H=W=256$ – розміри знімка в пікселях.

2. До вхідних даних додатково включено карту LDI, створену на основі четвертого каналу Sentinel-2 (B04) та двох радіолокаційних знімків Sentinel-1 (VV та VH) за різні дати спостереження. У цьому випадку тензор розширюється до $C=14$, завдяки додаванню одного додаткового шару LDI.

3. До складу вхідних ознак, окрім базових каналів Sentinel-1 та Sentinel-2, було включено карту NDVI, створену за червоним (B04) і ближнім інфрачервоним (B08) каналами Sentinel-2.

4. Вхідні дані містять одинадцять каналів Sentinel-2, два каналами Sentinel-1 (VV та VH), а також карти LDI і NDVI. У цьому випадку кількість каналів складає $C=15$.

Для підвищення здатності моделі до узагальнення застосовується комплекс аугментацій: випадкове горизонтальне віддзеркалення ($p = 0.5$), обертання на кути, кратні 90° , випадкові повороти у межах $\pm 45^\circ$ навколо зміщеного центру, а також спеціальна аугментація часових пропусків (time dropout), яка випадковим чином обнуляє близько 30% часових зрізів, моделюючи відсутність даних у певні періоди. Цей процес описується формулою:

$$\tilde{X}_t = m_t \cdot X_t, m_t = \{0, \text{з імовірністю } p_{drop}, 1, \text{інакше}\}. \quad (4)$$

де m_t – маска відсутності даних на часовому індексі t , $\tilde{X}_t$ – отриманий після аугментації тензор.

Навчання здійснюється у середовищі з підтримкою розподілених обчислень на кількох GPU, що суттєво скорочує час тренування. Для економії відеопам'яті та прискорення обчислень використовується змішана точність (Automatic Mixed Precision, AMP) – частина операцій виконується у форматі float16, а критичні елементи зберігаються у float32 для уникнення втрати точності. Це економить пам'ять відеокарт і дозволяє збільшувати розмір батчів.

Оптимізація параметрів мережі здійснюється за допомогою алгоритму AdamW, який поєднує метод адаптивного градієнтного спуску з ваговим розпадом для кращої регуляризації моделі. Оновлення ваги мережі в i -му кроці можна подати у вигляді:

$$\theta_{i+1} = \theta_i - \eta \left(\frac{\hat{m}_i}{\sqrt{\hat{v}_i + \epsilon}} + \lambda \theta_i \right), \quad (5)$$

де η – навчальна швидкість (learning rate), $\hat{m}_i$ та $\hat{v}_i$ – скориговані моменти першого та другого порядків для градієнтів, λ – коефіцієнт вагового розпаду, що забезпечує регуляризацію.

Для регулювання швидкості використано косинусний планувальник (cosine scheduler), що поступово зменшує кроку навчання за формулою:

$$\eta_t = \eta_{min} + \frac{1}{2}(\eta_{max} - \eta_{min}) \left(1 + \cos \left(\frac{t\pi}{T} \right) \right), \quad (6)$$

де t – поточний крок, T – загальна кількість кроків навчання, η_{max} і η_{min} – максимальний і мінімальний learning rate відповідно.

При навчанні взаємодія моделі з даними відбувається у вигляді циклу по епохах, кожна з яких включає такі етапи: передавання входів та масок на GPU, обчислення прогнозів (forward pass), оцінка функції втрат (loss function, наприклад RMSE або MAE) та обчислення градієнтів (backward pass), а також оновлення параметрів оптимізатором. Градієнти проходять процедуру масштабування і відсікання аномально високих значень (gradient clipping).

Для перевірки якості моделі використовується валідаційний набір, де застосовується техніка Test-Time Augmentation (ТТА). Вона полягає у виконанні прогнозів не лише на оригінальних знімках, а й на трансформованих (горизонтально і вертикально віддзеркалених, та із подвійним віддзеркаленням). Остаточний прогноз є середнім значенням:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N f(T_i(X)), \quad (7)$$

де f – модель, T_i – i -та трансформація, N – їх кількість (у нашому випадку $N=4$), а X – вхідні дані.

Результати класифікації на виході моделі у вигляді растрових карт класів застосовуються для тематичного картування космоснімків.

Узагальнена схема алгоритму зображена на рисунку 4.

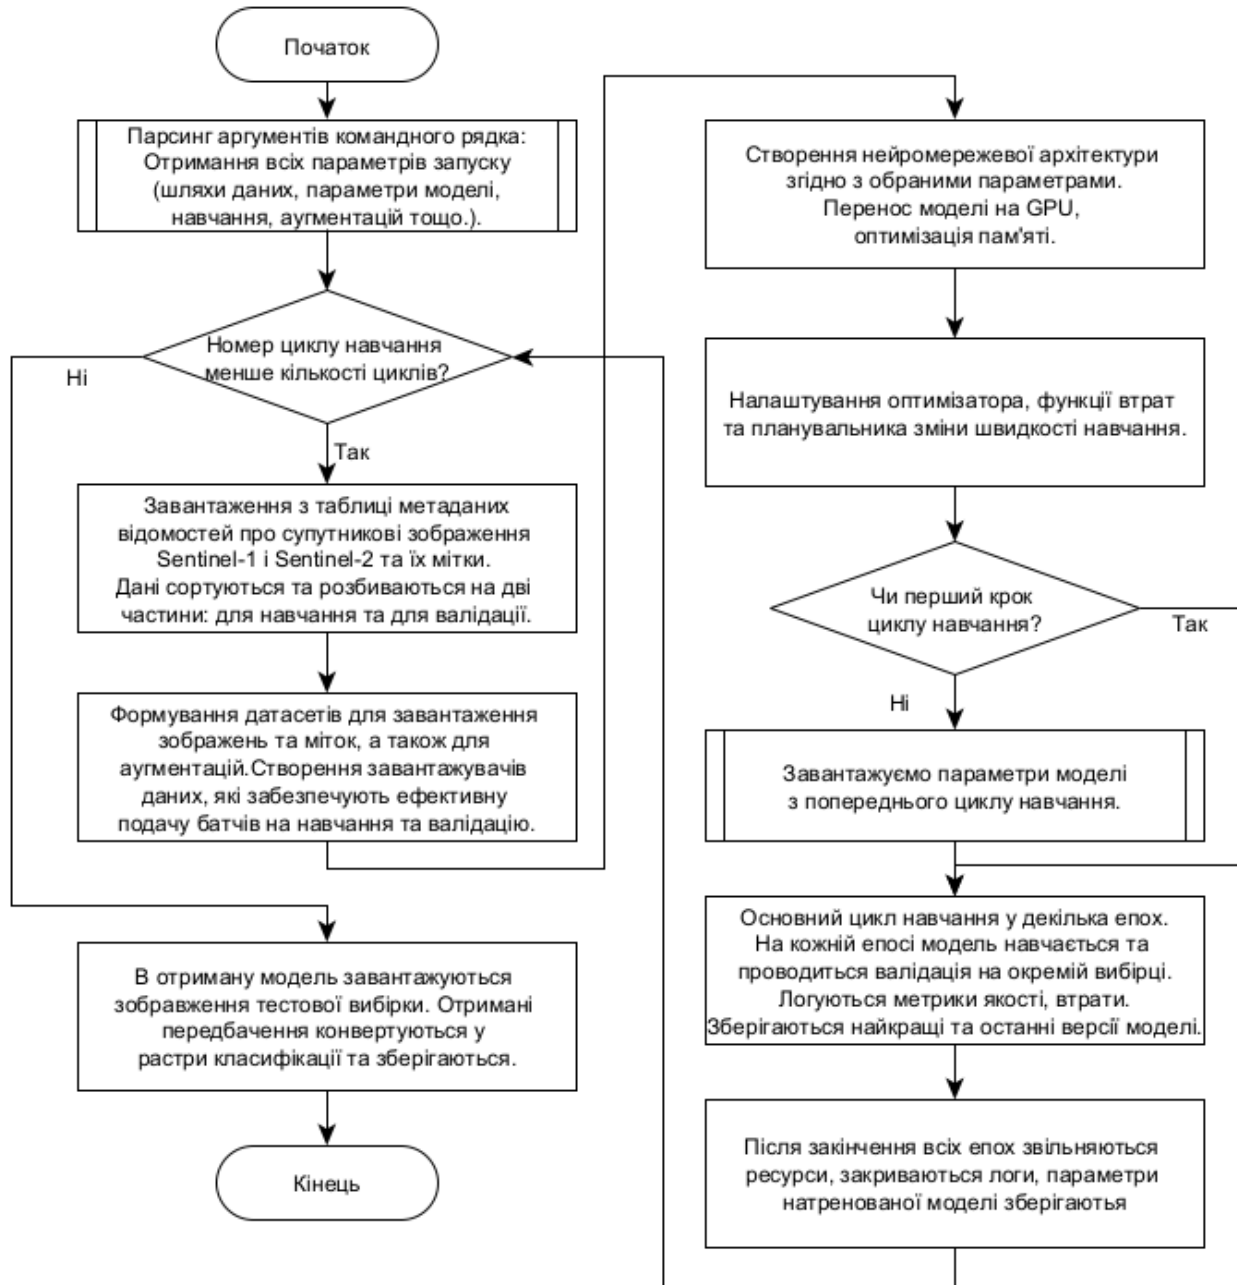


Рис. 4. Схема алгоритму нейромережевої класифікації сільгоспугідь з використанням знімків Sentinel-1 та Sentinel-2

Таким чином, представлений алгоритм поєднує в собі передові методи глибинного навчання, обробки супутникових даних, а також високопродуктивні обчислювальні технології. Це забезпечує:

– високу якість класифікації завдяки ефективній архітектурі мережі із застосуванням механізмів уваги;

- сталість моделі до відсутності даних і геометричних трансформацій завдяки складним аугментаціям;
- прискорене навчання завдяки розподіленому навчанню та змішаній точності;
- надійність і точність прогнозів за рахунок Test-Time Augmentation.

Результати класифікації. Для оцінювання впливу індексу LDI у розробленій моделі було проведено експериментальне тестування на основі супутникових даних Sentinel-1 та Sentinel-2. Навчальна вибірка містила 3690 знімків, а для валідації якості класифікації використовувалося ще 922 зображення. Загалом у межах досліджуваної території було проаналізовано 90770 окремих земельних ділянок, серед яких 43736 належали до цільової категорії – неорних угідь. Для забезпечення об'єктивності оцінки близько 20% ділянок, розташованих у північній частині регіону, було віднесено до тестового набору, тоді як решта використовувалася для навчання нейронної мережі.

На рисунку 5 наведено приклади результатів роботи моделі: еталонні класифікаційні маски тестових зображень (а-в), відповідні прогнозні карти, отримані в результаті моделювання без включення карти індикатора LDI (г-е) та з його включенням (є-з). Візуальний аналіз демонструє, що модель достовірно відтворює просторову структуру об'єктів і правильно ідентифікує основні класи землекористування, демонструючи стабільну узгодженість із реальними даними.




Рис. 5. Результати роботи моделі: а-в – еталонні маски тестової вибірки; г-е – відповідні маски, отримані моделлю без включення знімків LDI; є-з – відповідні маски, отримані моделлю з включенням знімків LDI.

Для кількісної оцінки точності класифікації було використано 18154 тестові ділянки. Для кожної ділянки були отримані прогнози маски, які порівнювалися з еталонними картами тестової вибірки. У разі якщо більш ніж 50% пікселів в межах ділянки класифікувались правильно, то вся ця ділянка вважалась класифікованою правильно. Загальна частка правильно класифікованих ділянок з тестового набору наведена у таблиці 2.

Таблиця 2. Частка правильно класифікованих ділянок без використання і з використанням карт LDI

Результат роботи моделі	Частка правильно класифікованих ділянок, %
без включення карт LDI	88.87
з включенням карт LDI	91.34

Отримані дані свідчать, що врахування індексу LDI підвищує точність класифікації на 2,47%. Такий приріст зумовлений здатністю LDI точніше описувати структурні відмінності ландшафту на різночасових знімках. Це підтверджує доцільність використання ландшафтних індексів, які дозволяють моделі глибше враховувати структурні особливості земної поверхні.

Обговорення. Як впливає з таблиці 1, карти індикатора LDI, а особливо їх різниця за різні дати, мають більш високу апіорну інформативність порівняно зі вхідними знімками Sentinel 1 та 2. Разом з тим, постає питання порівняння інформативності LDI з іншими відомими індексами. З цією метою за описаною вище методикою була розрахована також апіорна інформативність карт NDVI. Результати наведені в таблиці 3.

Таблиця 3. Оцінка інформативності ознак

Зображення	Показники подібності гістограм			
	Площа перегину гістограм 1 - повна подібність	Критерій χ^2 0 - повна подібність	Відстань Бхатта-чарія 0 - повна подібність	Коефіцієнт кореляції 1 - повна подібність
Карта NDVI (08.03.2024)	0,74	0,23	0,26	0,76
Карта NDVI (21.07.2024)	0,57	0,53	0,41	0,39
Різниця між картами NDVI	0,76	0,18	0,22	0,81

Порівняно з даними, наведеними в таблиці 1, карта NDVI (21.07.2024) забезпечує кращий результат для одного з показників – коефіцієнта кореляції; для трьох інших показників найкращий результати, що відбивають апіорну інформативність, досягаються для різнісної карти Δ LDI (Sentinel-1, VV). Це свідчить про більш високу інформативність індексу NDVI порівняно з вхідними знімками та їх різницями, але в цілому порівняно з індикатором LDI. Слід зауважити, що NDVI є класичним спектральним індексом, що відображає рівень фотосинтетичної активності рослин, тоді як LDI враховує не лише стан вегетації, але й структурні зміни ландшафту, пов'язані з деградаційними процесами – ущільненням ґрунтів, втратою біомаси або антропогенним впливом. Порівняльний аналіз показав, що LDI має в цілому значнішу відмінність значень між класами землекористування, що свідчить про більшу інформативність цього показника у при розрізненні орних та неорних (в тому числі, деградованих) ділянок.

На рисунку 6 продемонстровано приклади результатів класифікації за різними комбінаціями індексів: еталонні класифікаційні маски тестових зображень (а-в), відповідні прогнозовані карти, отримані в результаті моделювання без використання карт LDI та NDVI (г-е), з урахуванням карт LDI (є-з), з урахуванням карт NDVI (и-й), з урахуванням карт LDI та NDVI (к-м). Зображення показують, що інтеграція LDI та NDVI дозволяє моделі більш точно відтворювати просторову структуру об'єктів і краще диференціювати орні та неорні землі.




Рис. 6. Результати роботи моделі: а-в – еталонні маски тестової вибірки; г-е – відповідні маски, отримані моделлю з включенням карт LDI; е-з – відповідні маски, отримані моделлю з включенням карт NDVI; и-й – відповідні маски, отримані моделлю з включенням карт NDVI та LDI

Розраховані частки правильно класифікованих ділянок для кожного результату роботи моделі з включенням карт NDVI подано у таблиці 4.

Таблиця 4. Частка правильно класифікованих ділянок без використання і з використанням карт NDVI

Результат роботи моделі	Частка правильно класифікованих ділянок, %
з включенням карт LDI	91.34
з включенням карт NDVI	89.93
з включенням карт LDI та NDVI	91.98

Тестування різних конфігурацій ознак підтвердило, що обидва індекси позитивно впливають на точність класифікації. Базова модель без додаткових індексів забезпечила середню точність 88,87%, що відповідає рівню сучасних архітектур на подібних датасетах. Додавання NDVI призвело до підвищення точності до 89,93%, тоді як використання лише LDI – до 91,34%. Найвищий результат було отримано при комбінованому використанні обох індексів – 91,98%, що свідчить про їхню комплементарність. NDVI підвищує чутливість моделі до сезонної динаміки рослинності, тоді як LDI – до просторових структурних змін, пов'язаних із деградацією ландшафтів і зміною типу землекористування. Таким чином, об'єднання цих індексів дозволяє моделі формувати більш збалансовані спектрально-текстурні представлення ландшафтів.

Попри отримані результати, дослідження має певні обмеження. По-перше, індекси розраховувалися на основі фіксованих часових зрізів і не враховували сезонну варіацію або погодні фактори. По-друге, модель не проводила просторову нормалізацію між сценами, що може впливати на узагальнення результатів при перенесенні на інші регіони.

Практична значимість запропонованого підходу полягає у можливості його інтеграції у системи моніторингу стану сільськогосподарських земель. Поєднання NDVI і LDI забезпечує підвищену чутливість до змін як у біомасі, так і у структурі поверхні, що є цінним для раннього виявлення деградації ґрунтів, контролю сівозмін, оцінки ефективності агротехнічних заходів та управління стійкістю агроландшафтів. Перспективним напрямком подальших досліджень є розширення часової вибірки, інтеграція різноджерельних даних та розробка адаптивних моделей для оперативного моніторингу деградаційних процесів на великих територіях.

Висновки і перспективи подальших досліджень. Розроблена методика класифікації аграрних територій на основі поєднання даних Sentinel-1 та Sentinel-2 і структурного індикатора LDI продемонструвала високу ефективність при розрізненні орних і неорних земель. Включення індексу LDI у процес навчання нейронної мережі дозволило підвищити точність класифікації на 2,47% порівняно з базовою моделлю. Порівняння з NDVI показало, що LDI є більш чутливим до структурних змін поверхні, що робить його ефективним інструментом для оцінювання деградації земель і моніторингу стану агроландшафтів.

Тож, отримані результати демонструють доцільність використання індексів вегетації та деградації ландшафту на підвищення ефективності класифікації сільськогосподарських угідь за супутниковими знімками. Про це свідчать як порівняльна оцінка апіорної інформативності LDI відносно NDVI, так і результати класифікації за допомогою запропонованої нейромережі.

Слід зазначити важливість цілеспрямованого відбору ознак із високою апіорною інформативністю для глибокого навчання нейронних мереж, що може підвищити точність класифікації. Отримані результати підтверджують доцільність використання комбінації спектральних та структурних індексів для вдосконалення моделей дистанційного зондування. Це відкриває перспективи створення інтегрованих систем моніторингу, здатних автоматично виявляти зміни у стані земельного покриття, зокрема деградованих або покинутих ділянок.

Подальші дослідження доцільно спрямувати на розширення часової бази даних, оптимізацію параметрів LDI для різних типів ландшафтів і застосування трансформерних архітектур для оброблення багатовислових серій супутникових спостережень. Важливим напрямом також є інтеграція запропонованого підходу у системи підтримки прийняття рішень у сфері агромоніторингу та оцінки екологічного стану територій.

Список бібліографічного опису

1. Vali, A., Comai, S. & Matteucci, M. (2020) Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sens*, 12(15), P. 2495. DOI: <https://doi.org/10.3390/rs12152495>
2. Adegun, A.A. et al. (2023) Review of Deep Learning Methods for Remote Sensing Satellite Image Classification. *Journal of Big Data*. DOI: <https://doi.org/10.1186/s40537-023-00772-x>
3. Aleissae, A.A., Kumar, A., Anwer, R.M. et al. (2023) Transformers in Remote Sensing: A Survey. *Remote Sens*, 15(7), P. 1860. DOI: <https://doi.org/10.3390/rs15071860>
4. Mehmood, A., et al. (2021) Vision Transformers for Remote Sensing Applications: A Review. *Remote Sens*, 13(3), P. 516. DOI: <https://doi.org/10.3390/rs13030516>
5. Li, X., et al. (2022) Multi-Source Data Fusion for Land Cover Classification Using Sentinel-1 and Sentinel-2 Imagery. *ISPRS J. Photogramm. Remote Sens*, 183, P. 210–223. DOI: <https://doi.org/10.1016/j.isprsjprs.2021.11.015>
6. Zhang, Y., et al. Integrating SAR and Optical Data for Land-Cover Mapping Using Deep Neural Networks. (2021) *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens*, 14, P. 7642–7655. DOI: <https://doi.org/10.1109/JSTARS.2021.3093179>
7. Sumbul, G., et al. (2021) BigEarthNet-MM: A Large-Scale Multi-Modal Multi-Label Benchmark for Remote Sensing Image Understanding. *IEEE Access*, 9, P. 155606–155620. DOI: <https://doi.org/10.1109/ACCESS.2021.3127813>
8. Arafa, A.A., et al. (2021) Texture-Based Land Cover Classification Using GLCM and Deep Learning. *PeerJ Comput. Sci*, 7, e536. DOI: <https://doi.org/10.7717/peerj-cs.536>
9. Zhou, W., et al. (2022) Deep Learning-Based Change Detection Reviews and Benchmarks. *Remote Sens*, 14(4), P. 871. DOI: <https://doi.org/10.3390/rs14040871>
10. Cammalleri, C., et al. (2021) A Revision of the Combined Drought Indicator (CDI) Used in the European Drought Observatory (EDO). *Nat. Hazards Earth Syst. Sci*, 21, P. 481–503. DOI: <https://doi.org/10.5194/nhess-21-481-2021>
11. Zargar, A., et al. (2022) Drought Monitoring Using CDI Variants and Multi-Sensor Data. *Remote Sens*, 14(17), P. 4231. DOI: <https://doi.org/10.3390/rs14174231>
12. Chen, J., et al. (2021) TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. *arXiv preprint*. DOI: <https://doi.org/10.48550/arXiv.2102.04306>
13. Zheng, Z., et al. (2022) UNetFormer: A Unified Transformer Framework for Efficient Semantic Segmentation. *Remote Sens*, 14(15), P. 3585. DOI: <https://doi.org/10.3390/rs14153585>
14. Wu, Y., et al. (2023) Spatio-Temporal Attention Networks for Crop Mapping Using Multi-Temporal Satellite Images. *IEEE Trans. Geosci. Remote Sens*, 61, P. 1–15. DOI: <https://doi.org/10.1109/TGRS.2023.3245958>
15. Wang, L., et al. (2023) Efficient Mixed Precision Training for Remote Sensing Neural Networks. *Comput. Geosci*, 174, P. 105493. DOI: <https://doi.org/10.1016/j.cageo.2023.105493>
16. Ghorbanian, A., et al. (2023) Explainable AI in Remote Sensing: From Methods to Applications. *IEEE Geosci. Remote Sens. Mag.* 11(3), P. 94–119. DOI: <https://doi.org/10.1109/MGRS.2023.3240982>
17. Copernicus Browser. URL: <https://browser.dataspace.copernicus.eu>. (дата звернення: 15.08.2025).
18. Field Boundaries for Agriculture (fiboa). URL: <https://fiboa.org>. (дата звернення: 10.08.2025).
19. Nikulin, S., & Sergieieva, K. (2025). Assessing degradation of war-affected anthropogenic landscape using Sentinel-2 images. *International Journal of Remote Sensing*, 46(15), P. 5732–5772. DOI: <https://doi.org/10.1080/01431161.2025.2526001>
20. Marin-Reyes, P. & Lorenzo-Navarro, J. & Castrillón Santana, M. (2016). Comparative study of histogram distance measures for re-identification. DOI: <https://doi.org/10.48550/arXiv.1611.08134>

References

1. Vali, A., Comai, S. & Matteucci, M. (2020) Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sens*, 12(15), P. 2495. DOI: <https://doi.org/10.3390/rs12152495>
2. Adegun, A.A. et al. (2023) Review of Deep Learning Methods for Remote Sensing Satellite Image Classification. *Journal of Big Data*. DOI: <https://doi.org/10.1186/s40537-023-00772-x>
3. Aleissae, A.A., Kumar, A., Anwer, R.M. et al. (2023) Transformers in Remote Sensing: A Survey. *Remote Sens*, 15(7), P. 1860. DOI: <https://doi.org/10.3390/rs15071860>
4. Mehmood, A., et al. (2021) Vision Transformers for Remote Sensing Applications: A Review. *Remote Sens*, 13(3), P. 516. DOI: <https://doi.org/10.3390/rs13030516>
5. Li, X., et al. (2022) Multi-Source Data Fusion for Land Cover Classification Using Sentinel-1 and Sentinel-2 Imagery. *ISPRS J. Photogramm. Remote Sens*, 183, P. 210–223. DOI: <https://doi.org/10.1016/j.isprsjprs.2021.11.015>
6. Zhang, Y., et al. Integrating SAR and Optical Data for Land-Cover Mapping Using Deep Neural Networks. (2021) *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens*, 14, P. 7642–7655. DOI: <https://doi.org/10.1109/JSTARS.2021.3093179>
7. Sumbul, G., et al. (2021) BigEarthNet-MM: A Large-Scale Multi-Modal Multi-Label Benchmark for Remote Sensing Image Understanding. *IEEE Access*, 9, P. 155606–155620. DOI: <https://doi.org/10.1109/ACCESS.2021.3127813>
8. Arafa, A.A., et al. (2021) Texture-Based Land Cover Classification Using GLCM and Deep Learning. *PeerJ Comput. Sci*, 7, e536. DOI: <https://doi.org/10.7717/peerj-cs.536>
9. Zhou, W., et al. (2022) Deep Learning-Based Change Detection Reviews and Benchmarks. *Remote Sens*, 14(4), P. 871. DOI: <https://doi.org/10.3390/rs14040871>
10. Cammalleri, C., et al. (2021) A Revision of the Combined Drought Indicator (CDI) Used in the European Drought Observatory (EDO). *Nat. Hazards Earth Syst. Sci*, 21, P. 481–503. DOI: <https://doi.org/10.5194/nhess-21-481-2021>

11. Zargar, A., et al. (2022) Drought Monitoring Using CDI Variants and Multi-Sensor Data. *Remote Sens*, 14(17), P. 4231. DOI: <https://doi.org/10.3390/rs14174231>
12. Chen, J., et al. (2021) TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. *arXiv preprint*. DOI: <https://doi.org/10.48550/arXiv.2102.04306>
13. Zheng, Z., et al. (2022) UNetFormer: A Unified Transformer Framework for Efficient Semantic Segmentation. *Remote Sens*, 14(15), P. 3585. DOI: <https://doi.org/10.3390/rs14153585>
14. Wu, Y., et al. (2023) Spatio-Temporal Attention Networks for Crop Mapping Using Multi-Temporal Satellite Images. *IEEE Trans. Geosci. Remote Sens*, 61, P. 1–15. DOI: <https://doi.org/10.1109/TGRS.2023.3245958>
15. Wang, L., et al. (2023) Efficient Mixed Precision Training for Remote Sensing Neural Networks. *Comput. Geosci*, 174, P. 105493. DOI: <https://doi.org/10.1016/j.cageo.2023.105493>
16. Ghorbanian, A., et al. (2023) Explainable AI in Remote Sensing: From Methods to Applications. *IEEE Geosci. Remote Sens. Mag.* 11(3), P. 94–119. DOI: <https://doi.org/10.1109/MGRS.2023.3240982>
17. Copernicus Browser. (n.d.). Retrieved August 15, 2025, from: <https://browser.dataspace.copernicus.eu>
18. Field Boundaries for Agriculture (fiboa). (n.d.). Retrieved August 10, 2025, from: <https://fiboa.org>
19. Nikulin, S., & Sergieieva, K. (2025). Assessing degradation of war-affected anthropogenic landscape using Sentinel-2 images. *International Journal of Remote Sensing*, 46(15), P. 5732–5772. DOI: <https://doi.org/10.1080/01431161.2025.2526001>
20. Marín-Reyes, P. & Lorenzo-Navarro, J. & Castrillón Santana, M. (2016). Comparative study of histogram distance measures for re-identification. DOI: <https://doi.org/10.48550/arXiv.1611.08134>