

ВИЯВЛЕННЯ НАФТОВИХ РОЗЛИВІВ В МОРІ З ВИКОРИСТАННЯМ ФУНДАМЕНТАЛЬНОЇ МОДЕЛІ PRITHVI 2.0

В. Г. Кузін^{1,2,a}, А. Ю. Шелестов^{1,2}

¹ Навчально-науковий Фізико-технічний інститут

² Інститут космічних досліджень НАН України та ДКА України

Анотація

Виявлення нафтових плям на морі є важливим завданням для моніторингу екологічних надзвичайних ситуацій. Модель PRITHVI 2.0, розроблена NASA, демонструє високу ефективність у задачах аналізу супутникових даних завдяки попередньому навчанню на великій кількості зображень з різних сенсорів. У цій статті ми досліджуємо її можливості, адаптуємо цю модель до задачі сегментації нафтових плям, використовуючи відкриті SAR дані NOAA/NESDIS із застосуванням до них методу попередньої обробки, який забезпечує формування інформативного RGB-представлення одноканальних VV-поляризованих знімків. В експериментальній частині ми порівнюємо продуктивність двох конфігурацій PRITHVI 2.0 (300M та 600M параметрів) на датасеті, що включає 512 зображень із різних регіонів світового океану. Найкраща модель (PRITHVI-EO-2.0-600M) досягає 55,2% mIoU та 75,3% піксельної точності на тестовому наборі даних. Результати показують, що PRITHVI 2.0 здатна ефективно виявляти нафтові плями навіть за обмеженої кількості навчальних даних, що відкриває нові можливості для моніторингу екологічних катастроф за допомогою фундаментальних моделей та сприяє реалізації проекту створення масштабованого цифрового двійника для моніторингу змін земного покриття.

Ключові слова: виявлення розливів нафти, радар із синтезованою апертурою (РСА), глибоке навчання, попередня обробка зображень

Вступ

Щороку в морських водах відбуваються тисячі розливів нафти, що несуть серйозні екологічні та економічні загрози. Лише в США Офіс реагування та відновлення Національного управління океанічних і атмосферних досліджень (NOAA) щорічно фіксує понад 150 інцидентів розливу нафти та хімічних речовин. Хоча більшість із них є невеликими за обсягом, окремі масштабні катастрофи, такі як аварія на платформі Deepwater Horizon 20 квітня 2010 року (рис. 1), призводять до руйнівних наслідків для морської екосистеми, економіки та людської безпеки. У квітні 2025 року, виповнюється 15 років з моменту цієї наймасштабнішої нафтової аварії в історії США, що підкреслює незмінну актуальність задачі швидкого й точного виявлення нафтових плям у морському середовищі.

На сьогоднішній день машинне та глибинне навчання стали практично стандартом у задачах виявлення нафтових плям за супутниковими зображеннями, особливо за SAR-даними. Застосовуються найрізноманітніші підходи, від класичних SVM, ANN і Random Forest до сучасних CNN і YOLO-моделей, а останнім часом і до гібридних архітектур, що поєднують CNN із трансформерами. Більшість з них

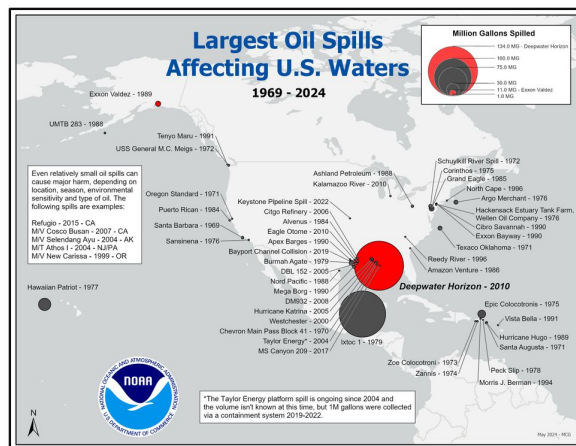


Рис. 1. Найбільші розливи нафти, що вразили води США з 1969 по 2024 рік [1].

демонструють високу точність і добре справляються з задачами сегментації або класифікації, особливо при наявності якісно підготовленого навчального набору [2, 3, 4, 5]. Водночас, попри розмаїття методів, більшість досліджень орієнтовані на вузькі, часто локальні задачі з обмеженим охопленням і складною генералізацією. Часто моделі потребують значного

^avolHkuz@gmail.com

доопрацювання під нові регіони чи сенсори, а питання масштабованості, адаптації до різних морських умов і стійкості до шумів залишаються відкритими. Саме тому сьогодні особливо актуальним стає пошук універсальніших рішень, які можна легко адаптувати до нових умов із мінімальними зусиллями.

Це зумовлює зростаючий інтерес до фундаментальних моделей нового покоління, здатних забезпечити високу ефективність навіть за незначної кількості розмічених даних та різномірності вхідної інформації. У відповідь на виклики у галузі супутникового інтелекту, такі як великі об'єми, спектральна складність, мінливість сенсорів і погодних умов, почали з'являтися спеціалізовані фундаментальні моделі. Серед них як класичні Vision Transformers із адаптаціями для різно-розмірних і різно-орієнтованих об'єктів [6, 7], так і генеративні моделі, наприклад, RingMo, які використовують самонавчання на масивних датасетах для формування універсальних представлень [8]. Розробляються також спектральні трансформери (SpectralGPT) для обробки гіперспектральних та часових даних [9], мультисенсорні генератори (MetaEarth) для синтезу зображень [10], а також мультизадачні vision-language моделі на зразок RemoteCLIP, що дозволяють класифікувати чи сегментувати об'єкти без навчання на конкретному завданні [11]. Високий рівень універсальності, масштабованості й навченості робить ці моделі привабливими як практичний інструмент для реальних задач моніторингу.

Попри активний розвиток фундаментальних моделей для дистанційного зондування, їх застосування для виявлення нафтових плям залишається на ранньому етапі. Загальноприйнятий підхід відсутній, а PRITHVI [12], хоч і має широкі можливості, ще не тестувалася для цього завдання. Водночас PRITHVI 2.0 має великий потенціал завдяки здатності адаптуватися до різних типів даних і переносити знання на нові регіони.

Крім того, проведення даного дослідження безпосередньо сприяє реалізації проекту «DT4LC – Developing Scalable Digital Twin Models for Land Cover Change Detection Using Machine Learning», в рамках якого передбачено створення масштабованого цифрового двійника для моніторингу змін земного покриву з використанням фундаментальних моделей. Таким чином, тестування можливостей PRITHVI 2.0 у складних задачах виявлення нафтових плям стане цінним кроком на шляху до досягнення цілей цього проекту.

1. Дані та методи

1.1. Датасет

Першочергово вивчалась можливість використання відкритих даних сервісу CleanSeaNet, який забезпечує супутниковий моніторинг розливів нафти над європейськими водами. Цей сервіс, що працює під егідою EMSA, ґрунтується на SAR-зйомці та забезпечує високу якість виявлення, зокрема інформацію про координати плями, площу та рівень довіри до

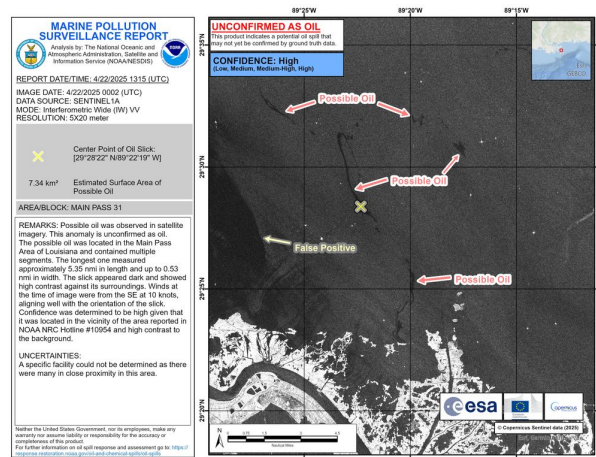


Рис. 2. Приклад SAR-зображення з розливом нафти, отриманого з програми Marine Pollution Surveillance Program NOAA/NESDIS.

виявлення. Проте для наукових цілей CleanSeaNet надає лише щорічні точкові дані без часової прив'язки до супутникових зображень, що унеможливило їх пряме використання для навчання моделей машинного навчання.

Тому основним джерелом даних для цього дослідження стали відкриті звіти програми Marine Pollution Surveillance Program, яку реалізує NOAA/NESDIS (приклад зображень на рис. 1). Ця програма забезпечує цілодобовий моніторинг забруднень у водах США із застосуванням SAR та мультиспектральної супутникової зйомки. Доступні через їхній веб-ресурс дані поінти містять векторні позначки нафтових розливів із 2011 по 2025 рік, охоплюючи акваторії Мексиканської затоки, Атлантичного та Тихого океанів, а також Великих озер та Міжнародних вод. В останній ітерації оновлення датасету було також включено нові події та території, класифіковані NOAA як «international waters», що дало змогу трохи розширити географічне покриття.

SAR-зображення були отримані з супутників Sentinel-1, які входять до сузір'я Європейського космічного агентства (ESA) та забезпечують глобальне покриття з високою просторовою (10 м) і часовою (до 6 днів) роздільною здатністю. Для аналізу використовувалися продукти типу GRD з VV-поляризацією, яка зарекомендувала себе як ефективна для виявлення нафтових плям на водній поверхні. Зображення були завантажені з платформ NASA EarthData та Alaska Satellite Facility (ASF), згідно з координатами, вказаними у звітах про розливи. Для забезпечення однорідності та якості даних було застосовано попередню обробку, що включала радіометричну калібровку, фільтрацію спекла та виправлення геометричних спотворень.

Поточний датасет включає 512 зображень розміром 640×640 пікселів, з яких 358 використано для тренування моделей, 77 – для валідації, та 77 – для тестування. Цей набір є розширенням попереднього дослідження [13], в якому використовувалися дані лише з акваторій Мексиканської затоки та Атланти-

чного океану за 2018-2023 роки. В останній ітерації оновлення датасету було також включено події з регіонів Тихого океану та міжнародних вод, а часовий горизонт продовжено на 2024-2025 роки. Таке розширення часового і географічного покриття має значно підвищити репрезентативність і різноманітність прикладів нафтових розливів.

1.2. Модель PRITHVI 2.0

Для цього дослідження обрано модель PRITHVI EO-2.0 (Pretrained Integrated Transformer for High-resolution Vision Intelligence – Earth Observation), розроблену NASA для супутникового моніторингу. Це фундаментальна модель на базі Vision Transformer, адаптована до геопросторових даних і попередньо навчена на понад мільйоні зображень із різних сенсорів (Sentinel-1/2, Landsat, MODIS). Вона ефективна для задач аналізу змін земного покриття, виявлення пожеж, повеней, вирубки лісу та урбанізації.

PRITHVI EO-2.0 використовує масковане автокодування, що дозволяє точно реконструювати просторові патерни навіть на зашумлених або часткових даних, зокрема SAR-знімках. Вона працює з мультиспектральними та радарними каналами, зокрема Sentinel-1 VV, що робить її придатною для виявлення нафтових розливів.

На відміну від CNN, які потребують великих мічених вибірок, PRITHVI EO-2.0 демонструє ефективність при донавчанні на обмежених даних. У цьому дослідженні вона виступає універсальним енкодером SAR-зображень із тонким донавчанням для сегментації нафтових плям.

Її застосування дозволяє перевірити ефективність фундаментальних підходів у виявленні складних об'єктів на супутникових даних, що є важливим етапом проекту DT4LC із розробки масштабованих цифрових двійників змін земного покриття. Модель відкриває перспективи не лише для виявлення нафтових плям, а й для ширшого екологічного моніторингу.

1.3. Попередня обробка SAR-зображень

Попри адаптованість PRITHVI EO-2.0 до Earth Observation-даних, її вхідні вимоги все ще передбачають використання щонайменше трьох каналів, що походить з архітектурної особливості ViT та дозволяє моделі ефективно використовувати просторово-каналну інформацію. Оскільки Sentinel-1 VV є одноканальними SAR-зображеннями, виникає необхідність узгодження формату вхідних даних з очікуваним трьохканальним вектором. У цьому дослідженні ми використали розроблений раніше метод формування псевдо-RGB представлення VV-поляризованих знімків, спеціально адаптований для задач виявлення нафтових розливів [13].

Основна ідея цієї передобробки полягає в перетворенні одиночного каналу VV у тривимірний тензор, де кожен канал (r, g, b) кодує різні аспекти яскравості водної поверхні. Такий підхід дозволяє моделі

фокусуватися на релевантних особливостях, пов'язаних із морфологією нафтових плям, і знижує ризик плутанини з іншими темними об'єктами на поверхні моря або артефактами.

Перший канал формується шляхом переведення SAR-інтенсивності у шкалу децибел з подальшим мінімаксімним нормуванням:

$$r = \log_{10} VV.$$

Однак у випадках, коли зображення не містить нафтових плям, така нормалізація призводить до штучного посилення контрасту між схожими за яскравістю областями, що збільшує кількість об'єктів-двійників. Щоб зменшити цей ефект, другий канал створюється через нормування VV до нормального розподілу, базуючись на гіпотезі, що більшість пікселів належать до класу води. Отримані значення обмежуються до [0, 1] за допомогою арктангенсового згладжування:

$$g = \frac{1}{\pi} \arctan \left(\frac{VV - \text{mean}(VV)}{\text{std}(VV)} \right) + 0.5.$$

Для третього (b) каналу ми враховуємо просторову нерівномірність яскравості водної поверхні, яка часто створює низькочастотні зміни, схожі на темні плями. Щоб мінімізувати хибні спрацьовування, ми використовуємо локальне згладження яскравості. Для цього спершу обчислюються усереднені значення та стандартне відхилення вікном 32×32 :

$$E_P = \text{pooling}^{avg} 32(VV), \quad D_P = \text{pooling}^{std} 32(VV).$$

Отримані карти згладжуються за допомогою гаусового фільтру з ядром 7×7 :

$$E_B = \text{blur}^{gaussian7}(E_P), \quad D_B = \text{blur}^{gaussian7}(D_P).$$

Далі ці значення ресайзяться до розміру оригінального зображення:

$$E_R = \text{resize}^{linear} VV(E_B), \quad D_R = \text{resize}^{linear} VV(D_B).$$

Синій канал отримується через локальне нормування VV значень на основі отриманих E_R та D_R , після чого також застосовується арктангенс:

$$b^* = \frac{VV - E_R}{D_R}, \quad b = \frac{1}{\pi} \arctan(b^*) + 0.5.$$

Завершальним етапом є масштабування кожного з трьох каналів до діапазону [0, 255], де r піддається мінімаксимумному нормуванню, а g і b – множаться на 255.

Таким чином, це представлення враховує як контраст із фоном, так і стабільність до варіацій природного освітлення води.

2. Експерименти і результати

Для оцінювання ефективності моделі було проведено експерименти шляхом навчання і подальшого тестування на підготовленому наборі даних із використанням попередньо натренованих ваг Prithvi-EO-2.0 та RGB-представлення SAR-даних, сформованого відповідно до запропонованого підходу попередньої обробки.

Моделю оцінювалась за двома основними метриками: середній показник Intersection over Union (mIoU), який обчислює середнє значення IoU між передбаченими і реальними сегментами для кожного класу та піксельна точність (Acc), яка визначає відсоток правильно класифікованих пікселів класу. Оцінки наводяться для класу плям, оскільки саме цей клас є основним у задачі виявлення розливів нафти.

У таблиці 1 представлено результати для двох конфігурацій моделі: Prithvi-EO-2.0-300M та Prithvi-EO-2.0-600M. Показані конфігурації відповідають найкращим досягненням на тестовому наборі. Як і очікувалося, модель з більшою кількістю параметрів (600M) продемонструвала кращі результати за всіма метриками на обох наборах даних.

Підвищення кількості параметрів покращило як здатність моделі виявляти плями на неоднорідному фоні, так і її загальну стабільність.

Крім кількісної оцінки, для кращої версії моделі якісні результати наведені на рис. 3. З результатів сегментації можна побачити, що модель навіть точніше окреслює контури плями порівняно з ground truth, хоча хвіст їй не вдалося відокремити від фону до кінця.

Враховуючи, що використана модель не була спеціально адаптована для роботи з супутниковими даними Sentinel-1, вона продемонструвала здатність до якісної сегментації нафтових розливів навіть у таких умовах. А застосований фічер-енжиніринг, запропонованого в нашій попередній роботі, виявився ефективним і з новою архітектурою.

Висновки

У цьому дослідженні ми вперше продемонстрували потенціал використання фундаментальної моделі PRITHVI 2.0 для виявлення нафтових плям на SAR-зображеннях. Основні результати свідчать про високу ефективність запропонованого підходу: модель PRITHVI-EO-2.0-600M досягла 55,2% mIoU та 75,3% піксельної точності на тестовому наборі даних, що є значним досягненням з огляду на складність завдання та обмеженість навчальних даних.

Ключовим елементом успіху виявився розроблений нами метод попередньої обробки SAR-зображень, який забезпечує формування інформативного RGB-представлення одноканальних VV-поляризованих знімків. Цей підхід дозволив ефективно адаптувати архітектуру PRITHVI 2.0 до специфіки виявлення нафтових плям без необхідності суттєвої модифікації самої моделі. Отримані результати переконливо свідчать про перспективність застосування фундаментальних моделей для моніторингу екологічних

катастроф.

Подальші дослідження можуть розвиватися в декількох напрямках. По-перше, доцільно розширити географічне охоплення даних, включивши більше регіонів світового океану для підвищення узагальнюючої здатності моделі. По-друге, варто дослідити можливості мультисенсорного підходу, інтегруючи дані оптичних сенсорів (Sentinel-2, Landsat) з радарними для підвищення надійності виявлення в різних погодних умовах. По-третє, перспективним є вдосконалення методів попередньої обробки для кращого розрізнення нафтових плям від подібних елементів моря.

Таким чином, дане дослідження не лише робить внесок у розвиток методів автоматичного виявлення нафтових плям, але й закладає основу для створення масштабованих цифрових двійників у рамках проєкту DT4LC, демонструючи практичне застосування фундаментальних моделей для вирішення актуальних екологічних проблем.

Перелік використаних джерел

1. *Oceanic N., Administration A.* Largest Oil Spills Affecting U.S. Waters Since 1969. — 05/04/2024.
2. *Temitope Yekeen S., Balogun A.-L.* Advances in Remote Sensing Technology, Machine Learning and Deep Learning for Marine Oil Spill Detection, Prediction and Vulnerability Assessment // *Remote Sensing*. — 2020. — Жовт. — Т. 12, № 20. — С. 3416. — ISSN 2072-4292. — DOI: [10.3390/rs12203416](https://doi.org/10.3390/rs12203416). — URL: <http://dx.doi.org/10.3390/rs12203416>.
3. *Oil Spill Detection Using Machine Learning and Infrared Images / T. De Kerf, J. Gladines, S. Sels, S. Vanlanduit* // *Remote Sensing*. — 2020. — Груд. — Т. 12, № 24. — С. 4090. — ISSN 2072-4292. — DOI: [10.3390/rs12244090](https://doi.org/10.3390/rs12244090). — URL: <http://dx.doi.org/10.3390/rs12244090>.
4. *Dehghani-Dehcheshmeh S., Akhoondzadeh M., Homayouni S.* Oil spills detection from SAR Earth observations based on a hybrid CNN transformer networks // *Marine Pollution Bulletin*. — 2023. — Трав. — Т. 190. — С. 114834. — ISSN 0025-326X. — DOI: [10.1016/j.marpolbul.2023.114834](https://doi.org/10.1016/j.marpolbul.2023.114834). — URL: <http://dx.doi.org/10.1016/j.marpolbul.2023.114834>.
5. *Automated marine oil spill detection algorithm based on single-image generative adversarial network and YOLO-v8 under small samples / Y. Cai, L. Chen, X. Zhuang, B. Zhang* // *Marine Pollution Bulletin*. — 2024. — Черв. — Т. 203. — С. 116475. — ISSN 0025-326X. — DOI: [10.1016/j.marpolbul.2024.116475](https://doi.org/10.1016/j.marpolbul.2024.116475). — URL: <http://dx.doi.org/10.1016/j.marpolbul.2024.116475>.
6. *Advancing Plain Vision Transformer Toward Remote Sensing Foundation Model / D. Wang, Q. Zhang, Y. Xu, J. Zhang, B. Du, D. Tao, L. Zhang* // *IEEE Transactions on Geoscience and Remote Sensing*. — 2023. — Т. 61. — С. 1–15. —

Таблиця 1. Показники метрик моделей Prithvi-EO-2.0 на валідаційному та тестовому наборах для класу нафтових плям.

Набір даних	Модель	mIoU, %	Acc, %
Валідаційний	Prithvi-EO-2.0-300M	44	54.4
	Prithvi-EO-2.0-600M	52.6	72.3
Тестовий	Prithvi-EO-2.0-300M	48	59.1
	Prithvi-EO-2.0-600M	55.2	75.3

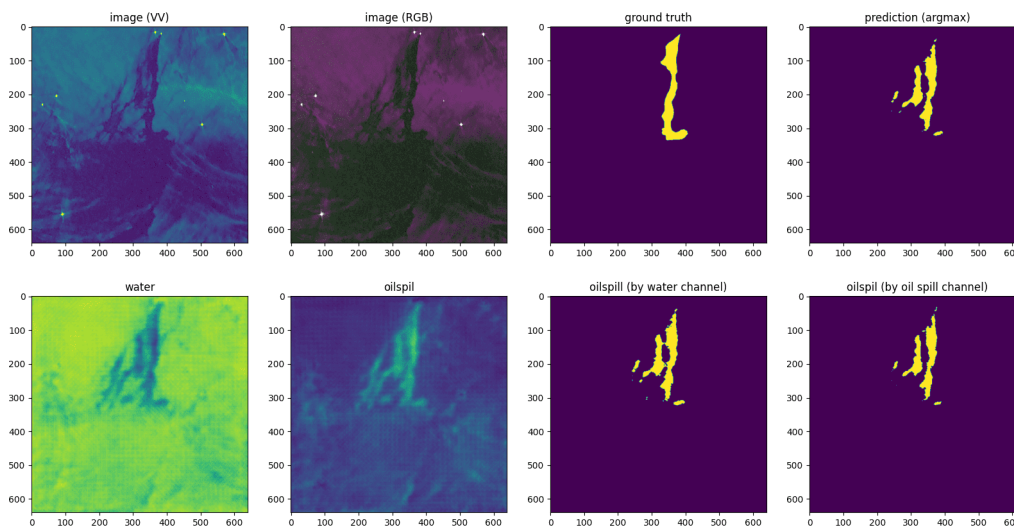


Рис. 3. Візуалізація результатів сегментації для одного зразка. Верхній ряд (зліва направо): SAR-зображення VV-поляризації, RGB представлення, істинна маска розливу (ground truth), передбачення моделі (argmax). Нижній ряд: ймовірність класу «вода», ймовірність класу «нафтова пляма», сегментація, отримана через порівняння з каналом «вода», сегментація, побудована за порогом каналу «нафтова пляма».

ISSN 1558-0644. — DOI: [10.1109/tgrs.2022.3222818](https://doi.org/10.1109/tgrs.2022.3222818). — URL: <http://dx.doi.org/10.1109/TGRS.2022.3222818>.

7. Cha K., Seo J., Lee T. A Billion-scale Foundation Model for Remote Sensing Images // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. — 2024. — С. 1—17. — ISSN 2151-1535. — DOI: [10.1109/jstars.2024.3401772](https://doi.org/10.1109/jstars.2024.3401772). — URL: <http://dx.doi.org/10.1109/JSTARS.2024.3401772>.
8. RingMo: A Remote Sensing Foundation Model With Masked Image Modeling / X. Sun [та ін.] // IEEE Transactions on Geoscience and Remote Sensing. — 2023. — Т. 61. — С. 1—22. — ISSN 1558-0644. — DOI: [10.1109/tgrs.2022.3194732](https://doi.org/10.1109/tgrs.2022.3194732). — URL: <http://dx.doi.org/10.1109/TGRS.2022.3194732>.
9. SpectralGPT: Spectral Remote Sensing Foundation Model / D. Hong [та ін.] // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2024. — Серп. — Т. 46, № 8. — С. 5227—5244. — ISSN 1939-3539. — DOI: [10.1109/tpami.2024.3362475](https://doi.org/10.1109/tpami.2024.3362475). — URL: <http://dx.doi.org/10.1109/TPAMI.2024.3362475>.
10. MetaEarth: A Generative Foundation Model for Global-Scale Remote Sensing Image Generation / Z. Yu, C. Liu, L. Liu, Z. Shi, Z. Zou // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2025. — Бер. — Т. 47, № 3. — С. 1764—1781. — ISSN 1939-3539. — DOI: [10.1109/tpami.2024.3507010](https://doi.org/10.1109/tpami.2024.3507010). — URL: <http://dx.doi.org/10.1109/TPAMI.2024.3507010>.
11. RemoteCLIP: A Vision Language Foundation Model for Remote Sensing / F. Liu, D. Chen, Z. Guan, X. Zhou, J. Zhu, Q. Ye, L. Fu, J. Zhou // IEEE Transactions on Geoscience and Remote Sensing. — 2024. — Т. 62. — С. 1—16. — ISSN 1558-0644. — DOI: [10.1109/tgrs.2024.3390838](https://doi.org/10.1109/tgrs.2024.3390838). — URL: <http://dx.doi.org/10.1109/TGRS.2024.3390838>.
12. Prithvi-EO-2.0: A Versatile Multi-Temporal Foundation Model for Earth Observation Applications / D. Szwarcman [та ін.]. — 2025. — arXiv: [2412.02732 \[cs.CV\]](https://arxiv.org/abs/2412.02732). — URL: <https://arxiv.org/abs/2412.02732>.
13. Transfer learning and single-polarized SAR image preprocessing for oil spill detection / N. Kussul, Y. Sali, V. Kuzin, B. Yailymov, A. Shelestov // ISPRS Open Journal of Photogrammetry and Remote Sensing. — 2025. — Jan. — Vol. 15. — P. 100081. — ISSN 2667-3932. — DOI: [10.1016/j.ophoto.2024.100081](https://doi.org/10.1016/j.ophoto.2024.100081). — URL: <http://dx.doi.org/10.1016/j.ophoto.2024.100081>.