

4. КЛАСИФІКАЦІЇ ТИПІВ ЗЕМНОГО ПОКРИВУ ТА ЗЕМЛЕКОРИСТУВАННЯ НА ОСНОВІ СУПУТНИКОВИХ ДАНИХ З ВИКОРИСТАННЯМ TRANSFER LEARNING

Богдан Яйлимов, завідувач відділу космічних інформаційних
технологій і систем
Інститут космічних досліджень НАН України та ДКА України
yailymov@gmail.com

ВСТУП

Земельні ресурси та їх ефективне використання є ключовими факторами сталого розвитку. Оцінка стану земного покриву та землекористування є важливою для управління природними ресурсами, прогнозування екологічних змін та забезпечення раціонального землекористування. Одним із найважливіших інструментів для цього є супутникові дані, які дозволяють отримувати інформацію про стан земної поверхні на великих територіях з високою точністю.

З розвитком супутникових технологій, таких як Sentinel-1 і Sentinel-2, стало можливим отримувати регулярні дані про стан земного покриву в різних спектральних діапазонах. Це надає можливість виконувати класифікацію типів земного покриву та землекористування з урахуванням таких факторів, як стан рослинності, типи угідь тощо.

Однак однією з проблем при класифікації типів земного покриву є обмеженість наземних даних, які використовуються для навчання моделей. Зокрема, для деяких регіонів, зокрема для східних областей України, збір таких даних є неможливим через військові дії. Це створює проблему точності класифікації для цих регіонів.

Для вирішення цієї проблеми використовують підходи Transfer Learning [1]. Це дозволяє переносити моделі, навчені на даних для одних територій, на інші території з подібними характеристиками, де неможливо зібрати навчальні дані. Дослідження спрямоване на підвищення точності класифікації для територій, для яких відсутні наземні дані, шляхом використання навчальних даних з інших регіонів.

3.4. Класифікації типів земного покриття та землекористування на основі...

Метою даної роботи є побудова високоточних карт класифікації типів земного покриття та землекористування для всієї території України на основі супутникових даних Sentinel-1 та Sentinel-2, використовуючи підхід Transfer Learning для територій для яких відсутні навчальні дані.

4.1. АНАЛІЗ МЕТОДІВ TRANSFER LEARNING ДЛЯ КЛАСИФІКАЦІЇ ЗЕМНОГО ПОКРИВУ

Однією з найбільш поширених проблем при побудові карт класифікації є обмеженість навчальних даних для деяких регіонів. Наприклад, у регіонах, де збір наземних даних неможливий через геополітичні або природні обмеження, виникає проблема створення точних карт класифікації. В цьому контексті, методи Transfer Learning набувають особливого значення [2].

Останні дослідження свідчать про високу ефективність перенесення моделей, навчених на одних територіях, до інших регіонів із подібними характеристиками [3]. Зокрема, в роботі [4] автори використовують такий підхід для ідентифікації типів культур в інших регіонах, використовуючи навчену модель на території США. В якості даних використано 30-метрові 15-денні композити часових рядів NDVI на основі даних Landsat-8 та Sentinel-2 (Harmonized Landsat Sentinel-2 - HLS). Такий підхід є ефективним при невеликій кількості класів і у випадку, коли культура має однаковий схожий хід розвитку протягом вегетаційного сезону. В Україні, наприклад, соняшник може мати різні періоди посіву та цвітіння, тому такий підхід може мати певні складнощі.

Застосування Transfer Learning для побудови карт земного покриття стає все більш популярним, зокрема, у контексті супутникових даних [5, 6], де часто неможливо зібрати навчальні дані для кожного регіону. В [6] представлено комплексний огляд методів Transfer Learning в області дистанційного зондування навколишнього середовища. Дослідження охоплює декілька підходів до трансферного навчання, зокрема, методи перенесення на рівні функцій, екземплярів та параметрів. Автори продемонстрували ефективність цих методів у задачах класифікації земного покриття, оцінки біофізичних параметрів, а також інших характеристик моніторингу земної поверхні.

Існує кілька підходів до перенесення моделей, які використовуються для задач класифікації земного покриття. Одним

із них є тонке налаштування (Fine-tuning) попередньо навчених моделей. Fine-tuning - це процес адаптації попередньо навченої моделі до нових даних шляхом налаштування ваг моделі на новому наборі даних [7]. В [7] використана базова модель TransformerEncoder, і після її налаштування авторам вдалося покращити точність перенесеної моделі на територію Сербії.

Часто, під час перенесення моделей використовують вилучення ознак (feature extraction) [8]. Такий підхід дає можливість використовувати попередньо навчені моделі як екстрактори ознак, зберігаючи ваги нижніх шарів та замінюючи або перенавчаючи лише верхні шари. У праці [9] досліджено використання попередньо навчених моделей глибоких згорткових нейронних мереж (Deep Convolutional Neural Networks, DCNN) для класифікації оптичних супутникових зображень. Автори застосували метод виділення ознак (feature extraction), що полягає у вилученні корисної інформації з попередньо навченої моделі, що дозволяє підвищити точність класифікації, адаптуючи моделі, навчені на ImageNet [9].

Автори праці [10] запропонували метод змагальної адаптації домену (adversarial domain adaptation), який використовує змагальні алгоритми для покращення точності класифікації земного покриття в різних географічних регіонах, що дозволило підвищити точність з 0.83 до 0.92.

Застосування Transfer Learning, яке використовує знання з вихідних доменів для покращення продуктивності моделей у цільовому домені, значно зросло. Однак, традиційні методи часто передбачають ідентичні простори ознак і міток у обох доменах, що є непрактичним у багатьох випадках. Гетерогенне Transfer Learning (HTL) вирішує ці розбіжності, ставши важливою стратегією у різних завданнях. У статті [11] представлено всебічний огляд понад 60 методів HTL, включаючи останні досягнення, такі як впровадження моделей на основі трансформерів та технік мультимодального навчання.

У статті [12] автори пропонують використання глибоких нейронних мереж (CNN) для класифікації зображень земного покриття з високим просторовим розрізненням використовуючи метод псевдо-маркування для покращення ефективності перенесення моделей, що дозволяє класифікувати зображення без розмітки. Експерименти проведені на різних наборах даних показали обнадійливі результати, підтверджуючи застосовність запропонованої методології.

3.4. Класифікації типів земного покриття та землекористування на основі...

Авторами праці [13] проведено оцінку тридцяти дев'яти моделей глибокого трансферного навчання для класифікації змін земного покриття, зокрема ResNet50, EfficientNetV2B0 та ResNet152, які показали найкращі результати за показниками каппа та загальної точності.

Існує ще багато методів глибинного навчання, що використовуються для класифікації супутникових даних, зокрема методи трансферного навчання [14]. Проте навіть ці передові підходи стикаються з труднощами через сезонні та географічні відмінності даних, що значно ускладнює процес створення універсальних моделей для різних територій. Як зазначено у [15], попередньо навчені нейронні мережі не завжди підходять для безпосереднього використання в нових умовах. Однак, перенавчання моделей з використанням вже існуючих ваг або заморожування початкових шарів може значно підвищити точність класифікації порівняно з тренуванням моделі з нуля.

Наведені дослідження демонструють широкий спектр підходів до Transfer Learning у контексті класифікації типів земного покриття та підкреслюють важливість адаптації моделей до нових регіонів та умов. Вони також вказують на потенціал для подальшого вдосконалення методів Transfer Learning для вирішення проблем, пов'язаних з обмеженістю даних у певних регіонах.

У контексті класифікації земного покриття особливо ефективними є ансамблеві методи. Дослідження [16] вказує на те, що об'єднання кількох моделей через голосування або інші методи ансамблювання дозволяє підвищити загальну точність класифікації, зменшуючи невизначеність для окремих територій. Наприклад, коли моделі показують різні результати для тих самих територій, метод голосування дозволяє обрати найбільш ймовірний клас на основі ймовірнісних оцінок кожної моделі.

У даному дослідженні використовується один із подібних підходів для побудови карт класифікації для території України. Специфічною проблемою є відсутність наземних даних для східної України. Однак, використовуючи методи Transfer Learning, можна перенести моделі, навчені на даних центральної та західної частини України, до цих регіонів. Крім того, методи ансамблювання, зокрема голосування між кількома моделями, дозволяють підвищити точність кінцевих карт класифікації.

4.2. ПОСТАНОВКА ЗАДАЧІ

Основна задача, яка поставлена в даному розділі, полягає в побудові карт земного покриття для території України на основі супутникових даних Sentinel-1 і Sentinel-2 з використанням методів Transfer Learning. Через складнощі з отриманням наземних даних на певних територіях України, особливо у зонах активних військових дій на сході країни, традиційні методи класифікації не забезпечують необхідної точності для всіх регіонів. Використання наземних досліджень потребує значних людських і фінансових ресурсів та займає багато часу, що не завжди ефективно для оперативної побудови карт великого масштабу. Це призводить до необхідності використання перенесення моделей між регіонами з метою підвищення точності класифікації в тих зонах, де наземні дані відсутні.

Тому запропоновано дослідити різні підходи до перенесення моделей, навчання яких здійснено на регіонах із наявними даними, на регіони, де збір наземних даних є неможливим або неефективним. Основна увага приділяється дослідженню можливостей перенесення моделей, створених для центральних і західних регіонів України, на східні регіони, де відсутні наземні дані. Оцінка ефективності цих підходів здійснюється шляхом перевірки моделей на територіях з різними характеристиками земного покриття.

Запропоновані підходи повинні забезпечити підвищення точності класифікації земного покриття на основі супутникових даних при умові обмеженого доступу до наземних даних або його повної відсутності. Особлива увага приділяється використанню підходів до комбінованого навчання моделей, перенесення навчання між різними регіонами, а також методам інтеграції результатів кількох моделей для досягнення високої точності класифікації.

4.3. ДАНІ ТА ТЕРИТОРІЯ ДОСЛІДЖЕНЬ

Для проведення дослідження було використано супутникові дані Sentinel-1 та Sentinel-2, які охоплюють територію України. Основною метою є побудова карт класифікації для всієї країни, зокрема для регіонів, де відсутні наземні дані.

Супутникові знімки Sentinel-1, що містять радіолокаційні дані, використовуються для отримання інформації про структуру

3.4. Класифікації типів земного покриття та землекористування на основі...

поверхні та стан земного покриття незалежно від погодних умов і освітленості. Знімки Sentinel-2 містять дані оптичного спектру, які забезпечують більш детальну інформацію про рослинність, ґрунти та інші елементи земного покриття. Використання обох типів даних дозволяє створювати більш точні класифікаційні карти земного покриття [17].

Україна покрита 9 смугами Sentinel-1, що забезпечують повне охоплення території країни. Для кожної смуги підготовлено по 15 радарних знімків, які охоплюють період з березня по серпень 2024 року. Для цього дослідження було здійснено підготовку композитних зображень Sentinel-2, які були територіально підлаштовані під смуги даних Sentinel-1 для подальшої обробки. Для центральних і західних регіонів було створено по 4 композити на основі наявних оптичних даних. Для найзахіднішої 80-ї смуги було створено лише 3 оптичних композити через високу частоту хмарності в цьому регіоні. Використання композитів дозволяє зменшити вплив тимчасових погодних умов і отримати більш точну карту земного покриття. Попередня обробка супутникових даних здійснена згідно методології описаної у праці [18].

При побудові карти, зазвичай виникає проблема зі східними областями, де через військові дії збір наземних даних є ускладненим або неможливим. Ці регіони вимагають застосування методів перенесення моделей, що дозволяють використовувати дані з інших частин країни для класифікації.

Щоб перевірити достовірність методів Transfer Learning для території України, в даному розділі пропонується перенести моделі з центральних на західні території (зокрема 80 та 7 смуги), на яких зібрані дані наземних досліджень. Це дозволить провести тестування отриманих результатів. Навчання моделей здійснювалось на центральних 109 та 36 смугах (рис. 1).

Навчальні дані були зібрані у центральній і західній частинах України вздовж доріг в 2024 році. Ці дані були перетворені у векторні полігони з класами земного покриття. Використані наземні дані для проведення дослідження представлено у таблиці 1. Для побудови карти зібрані наземні дані були розподілені на навчальну та тестову вибірки по областях у співвідношенні 80% на 20%. Такий підхід дозволяє забезпечити рівномірний розподіл даних для навчання моделі, а також гарантує, що тестові дані, використані для перевірки якості класифікації, не перетинаються з навчальними. Розподіл по областях допомагає зберегти регіональні особливості та врахувати можливі географічні

Частина 3. Прикладні задачі супутникового інтелекту на ...

відмінності, що важливо для побудови точної карти в умовах неоднорідності даних.




Рис. 1. Територія України поділена смугами відповідно до траєкторії супутника Sentinel-1 та маршрутом збору даних у 2024 році

Таблиця 1 Дані наземних досліджень, використані для експериментів

Наземні дані	Тестові				Навчальні			
	80	7	109	36	80	7	109	36
Клас/смуга	80	7	109	36	80	7	109	36
Штучні об'єкти	7	33	27	24	40	142	114	112
Пшениця	42	136	57	107	189	543	250	438
Ріпак	11	32	17	15	51	123	57	75
Гречка	5	4			23	26	6	5
Кукурудза	25	57	49	125	99	240	187	508
Цукровий буряк	3	6	2	3	15	34	14	23
Соняшник	7	37	33	111	42	161	175	485
Соя	66	228	134	100	245	920	539	441
Інші культури	4	9	6	6	7	34	22	22
Ліс	30	35	31	44	170	220	170	267
Луг	74	87	51	101	292	347	248	434
Відкритий ґрунт	4	3	2	10	23	21	18	55
Водні об'єкти	18	30	37	31	85	144	159	169
Болотна	8	7	7	18	44	50	41	95
Ячмінь	4	39	19	19	30	165	89	97
Горох		3		1	2	15	1	16

3.4. Класифікації типів земного покриття та землекористування на основі...

Люцерна		7	6	8	3	34	24	41
Сади, парки	3	33	40	7	25	159	174	53
Виноград	12	1	1	21	49	7	7	87
Картопля	4	9	1	1	22	55	19	11
Всього	327	796	520	752	1456	3440	2314	3434

4.4. ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ

У даному підрозділі представлено результати експериментів, спрямованих на оцінку ефективності методів перенесення навчання (Transfer Learning) для класифікації супутникових зображень Sentinel-1 і Sentinel-2 в регіонах з обмеженими або відсутніми наземними даними. Проведені п'ять експериментів були спрямовані на вивчення різних підходів до використання моделей перенесення, а також на оцінку ефективності комбінування даних для підвищення точності класифікації. В якості методу класифікації використано ансамбль MLP (multi-layer perceptron). Ефективність його використання для класифікації сільськогосподарських культур практично доведена в праці [19].

Перед початком проведення експерименту для кожної смуги (109 та 36) побудовано окрему модель на основі супутникових даних та даних наземних досліджень, яка потім використовувалася для подальших експериментів з перенесенням навчання. Результатом класифікації є карта класифікації земного покриття та карта ймовірності для кожного пікселя.

Карта класифікації земного покриття представляє собою растрове зображення, яке містить інформацію про клас земної поверхні який може представляти тип культур, земельне використання або інші характеристики земного покриття.

Растрова карта ймовірності для кожного пікселя - містить інформацію про ймовірність належності кожного пікселя до певного класу. Це дозволяє врахувати неточність класифікації, надаючи можливість оцінити, до якого класу піксель відноситься з найбільшою ймовірністю.

Результати класифікації показали, що загальна точність для 109 смуги склала 94.9%, а для 36 смуги – 95% на тестових незалежних даних. Для тестування моделей використовувалися 7 та 80 супутникові смуги з західних регіонів України, де наявні наземні дані для тренування та тестування моделей.

Розглянемо результати експериментів з побудови карт класифікації земного покриву на території України, з використанням різних методів, включаючи перенесення моделей та комбіноване навчання.

Експеримент 1: Перенесення моделі з центральної на західну частину України

Метою даного експерименту було оцінити, наскільки ефективним є перенесення моделі, навченої на даних центральної України, для класифікації територій, де наземні дані відсутні (наприклад, західна Україна). Модель була навчена на даних 36 та 109 смуг і перевірена на даних 7 та 80 смуг (західні регіони).

Результати показали, що точність класифікації для 7 смуги на основі 36 смуги склала 82.1%, а на основі моделі із 109 смуги – 83.8%. Для 80 смуги – 76.4% на основі 36 смуги, та 84.2% на основі 109 смуги. Перевага точності на основі моделі із 109 смуги, ймовірно через більш близькі значення у спектральних каналах, через схожість території та її кліматичних умов. Отримані загальні точності наведені у таблиці 2.

Експеримент 2: Комбіноване навчання моделей

Другий експеримент передбачав навчання моделі на основі даних зі смуг 36 і 109 одночасно. Навчена одна модель використовувалася для класифікації смуг 7 та 80. Результати показали помітне покращення точності в порівнянні з першим експериментом, що демонструє переваги використання комбінованих даних із різних територій для підвищення адаптивності моделей до різних регіонів. Для 7 смуги точність склала 87.4%, а для 80 смуги – 82.2%. Це демонструє, що комбінування даних з різних регіонів допомагає покращити адаптацію моделі та її здатність класифікувати нові території.

Експеримент 3: Метод голосування для покращення класифікації

Третій експеримент включав застосування методу голосування для вибору найбільш імовірного класу на основі результатів класифікації з двох різних моделей (36 та 109 смуги).

Цей підхід забезпечив підвищення точності класифікації, що свідчить про ефективність методу голосування для зменшення невизначеності і поліпшення загальних результатів.

Метод голосування показав точність для 7 смуги – 84.8%, і для 80 смуги – 78.1%. Це підтверджує, що об'єднання кількох моделей може суттєво покращити якість класифікації, особливо у складних умовах, таких як західна Україна.

3.4. Класифікації типів земного покриття та землекористування на основі...

Експеримент 4: Використання перетинів смуг для створення навчальних вибірок

У цьому експерименті було досліджено можливість використання перетинів між смугами супутникових зображень, а отже і карт класифікації для створення додаткових навчальних вибірок зі смуг 109 і 7, а також 7 та 80 (рис. 2).




Рис. 2. Перетин між смугами, на основі якого буде сформовано навчальні дані (виділено штриховою лінією)

Для формування навчальної вибірки були використані векторні межі полів, що сформовані та надані для території України компанією Sinergise, та карти класифікації із ймовірністю кожного класу. Всі полігони були попередньо оброблені, зокрема видалялися геометрично недійсні та порожні об'єкти. Для фільтрації полів із надто малою площею (менше ніж 100 м²) використовувалась процедура буферизації з наступним видаленням порожніх результатів. Це дозволило зосередитися на об'єктах, які містять достатню кількість інформації для точного навчання моделей класифікації.

Для кожного поля визначався унікальний клас, а також перевірялося, чи є даний полігон «однорідним», тобто чи містить він лише один клас пікселів. У вибірку були включені лише ті полігони, середня ймовірність яких перевищувала поріг 0.95, щоб забезпечити високу точність навчальних даних. Для уникнення переважання класів із великою кількістю зразків, вибірка для кожного класу була обмежена до 500 полів. Для цього з даного класу обиралися зразки з найвищою середньою ймовірністю.

Таким чином, було забезпечено, що кожен клас буде представленим у вибірці пропорційно та рівномірно.

В результаті сформована вибірка містила лише полігони, які відповідають зазначеним критеріям. Для кожного об'єкта зберігалася інформація про клас та середню ймовірність. Це дозволило отримати збалансовану навчальну вибірку, яка сприяє поліпшенню точності та надійності результатів класифікації.

Модель, що отримана на основі навчальних даних з перетину між 109 і 7 смугами, показала загальну точність отриманої карти для 7 смуги на тестових незалежних даних 88.8%.

Для отримання карти для 80 смуги, використано перетин між 7 та 80 смугами. Точність класифікації для 80 смуги склала 91.2%, що демонструє ефективність використання перетинів смуг для генерації нових навчальних даних.

Експеримент 5: Побудова карт на основі наземних даних

Останній експеримент передбачав порівняння точності класифікації на основі наземних даних з результатами, отриманими за допомогою методів перенесення моделей.

Побудовані карти класифікації для смуг 7 і 80 на основі наземних досліджень демонструють найвищу точність класифікації. Точність класифікації 94.5% для 7 смуги та 96.1 % для 80 смуги. Це вказує на те, що наземні дані, є найбільш точним джерелом для навчання моделей.

Отримані результати дозволили порівняти точність різних підходів до Transfer Learning та визначити найбільш ефективні методи для побудови карт класифікації для територій із відсутніми даними (табл. 2).

Таблиця 2 Точність класифікації для різних експериментів на незалежних тестових наземних даних

Експеримент	Смуга 7 (точність, %)	Смуга 80 (точність, %)
Експеримент 1: Перенесення моделі з центральної на західну частину України	82.1 (на основі моделі з 36 смуги) 83.8 (на основі моделі з 109 смуги)	76.4 (на основі моделі з 36 смуги) 84.2 (на основі моделі з 109 смуги)
Експеримент 2: Комбіноване навчання моделей	87.4	82.2

3.4. Класифікації типів земного покриття та землекористування на основі...

Експеримент 3: Метод голосування для покращення класифікації	84.8	78.1
Експеримент 4: Використання перетинів смуг для створення навчальних вибірок	88.8	91.2
Експеримент 5: Побудова карт на основі наземних даних	94.5	96.1

Аналіз результатів проведених експериментів демонструє, що побудова карт на основі наземних даних демонструє найвищу точність класифікації. Це очікуваний результат, оскільки використання наземних даних зазвичай забезпечує найвищу точність, однак, як було зазначено раніше, такий підхід є ресурсовитратним і не завжди можливим на великих територіях.

Найгірші показники отримані при перенесенні моделі із центральної України на західні регіони. Як показано на рис. 3, фрагменти 80 смуги, перші три експерименти мають невеликий шум на картах. Кращим рішенням для перенесення моделей виявилось використання даних з перетину смуг для створення навчальних вибірок (експеримент 4). Такий підхід має свої обмеження. На нашому прикладі, не можливо побудувати карту для 80 смуги, поки не буде отримано карти, що перетинається (у даному випадку це 7 смуга). Також, від точності попередньої карти залежить точність наступної.

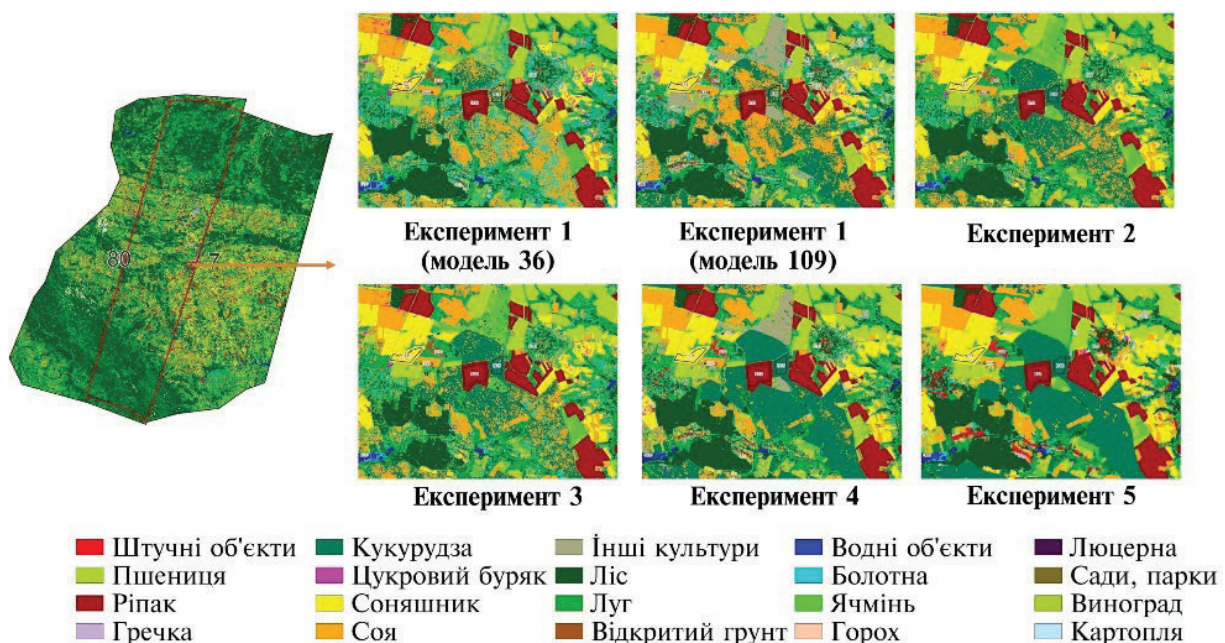


Рис. 3. Приклад результатів класифікації для 80 смуги

Для детальнішого аналізу точності класифікації основних класів (рис. 4-5) було обчислено значення F1-score, яке дозволяє оцінити точність моделі для кожного окремого класу [19]. Результати експериментів показують різну ефективність методів перенесення моделей та комбінованого навчання залежно від класу культури та смуги, на яку було перенесено модель.

Загалом, ріпак демонструє стабільно високу точність для всіх методів і смуг. Це пов'язано з особливостями спектральних характеристик ріпаку, особливо під час його цвітіння, коли він добре виділяється на знімках завдяки яскравим кольорам, що спрощує ідентифікацію незалежно від методу або смуги. Незначні коливання F1-score для ріпаку в різних експериментах вказують на його стійкість до перенесення моделей, навіть за умови різниці в умовах між смугами.




Рис. 4. F1-score основних культур для 7 смуги

Для пшениці спостерігається також висока точність класифікації незалежно від методу, що пояснюється тим, що більшість площ засіяні озимими зерновими. Під час початку вегетаційного сезону пшениця вже має високу вегетацію відносно інших культур, що робить її ідентифікацію відносно простою. Комбіноване навчання моделей і метод голосування покращили результати для пшениці, але навіть при перенесенні моделей з інших смуг точність залишалася на високому рівні, що вказує на високу узгодженість спектральних характеристик цієї культури.

3.4. Класифікації типів земного покриття та землекористування на основі...

Основні проблеми виникають із класифікацією кукурудзи та сої. Їхні спектральні характеристики досить схожі, особливо на початку вегетаційного сезону, що ускладнює точну класифікацію. Експерименти показують, що точність для кукурудзи та сої значно знижується, особливо при перенесенні моделі на 80 смугу. Наприклад, в експерименті 1 при перенесенні моделей із 36 смуги на 80 смугу F1-score для кукурудзи впав до 61.2%, а для сої — до 64.3%. Це свідчить про те, що класифікація цих культур є чутливою до змін спектральних характеристик і умов регіону.

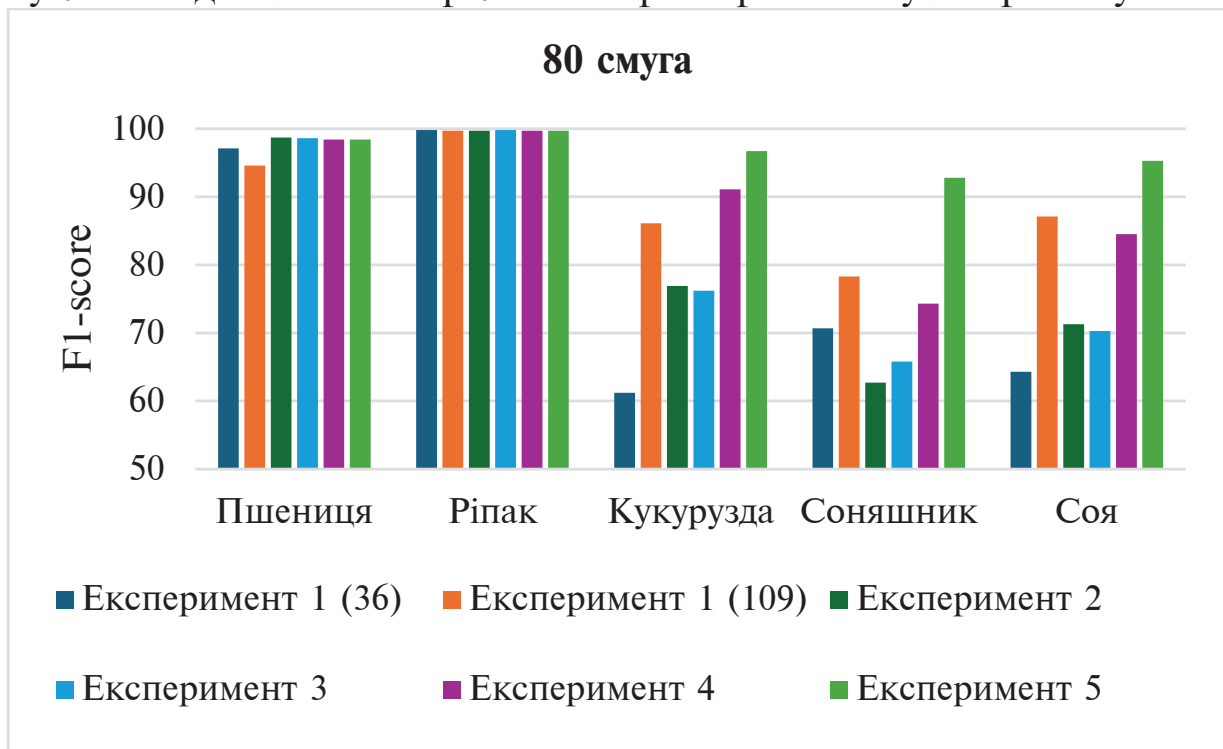


Рис. 5. F1-score основних культур для 80 смуги

Важливо відзначити, що експеримент 4, де використовувалися перетини смуг для створення навчальних вибірок, показав значно менший спад точності на 80 смугі порівняно з іншими методами. Це свідчить про те, що такий підхід дозволяє моделі краще адаптуватися до нових умов, враховувати регіональні відмінності, а також немає залежності від кількості вхідних ознак відносно інших смуг. Для кукурудзи та сої цей підхід дав помітно кращі результати, ніж інші методи перенесення моделей.

Найвищі результати для всіх культур показав експеримент 5 з використанням наземних даних. Це підтверджує важливість використання наземних даних для побудови точних моделей

класифікації, особливо для культур із подібними спектральними характеристиками.

Варто підкреслити результати другого експерименту, коли використовувалися всі дані (моделі) для побудови карти. Перевагою такого підходу є те, що результуюча модель може добре навчитися завдяки великій кількості навчальних даних, і як наслідок отримати хороший результат при перенесенні для інших територій. Основним недоліком такого підходу є те, що кількість знімків та період їхньої зйомки може значно відрізнятись, що може негативно вплинути на результат. Для приведення даних до однакового розміру, необхідно або зменшувати кількість даних щоб вирівняти їх кількість або додавати штучно нові дані. Такі підходи не гарантують отримання точних результатів.

Саме тому, підхід описаний в четвертому експерименті було використано для побудови карти для всієї території України. Так як мають достатню кількість даних для західних та центральних територій стає можливим отримання карт для сходу із високою точністю.

Для оперативного створення карти класифікації України та її оновлення із появою нових даних розроблено сценарії із використання хмарної платформи AWS (Amazon Web Services).

4.5. ІМПЛЕМЕНТАЦІЯ МОДЕЛІ МАШИННОГО НАВЧАННЯ З БАГАТОВИМІРНИМ ВЕКТОРНИМ ВИХОДОМ НА ОСНОВІ TRANSFER LEARNING НА ХМАРНІЙ ПЛАТФОРМІ AWS

Побудова карт класифікації земного покриття з використанням оптичних та радарних супутникових даних для території України з просторовим розрізненням 10 м є важливим завданням для моніторингу та аналізу аграрної діяльності та землекористування [20]. Для великої території найкраще виконувати побудову таких карт із використанням хмарних платформ [21] або високопродуктивних обчислень [22, 23]. Це може бути реалізовано на різних платформах, таких як AWS, Creodias та інші, оскільки супутникові дані Sentinel-1 і Sentinel-2 доступні на цих платформах. У подальшому дослідженні розглядатиметься приклад реалізації на AWS, хоча в загальному випадку вибір хмарної платформи не є критичним і може бути замінений іншими рішеннями.

3.4. Класифікації типів земного покриття та землекористування на основі...

Україна, розташована в Східній Європі, має велику територію та різноманітні типи культур, що робить її ідеальним об'єктом для дослідження з використанням супутникових даних. Для території України супутникові дані Sentinel-1 та Sentinel-2 є зручними завдяки їх доступності та можливості отримання інформації з різних спектральних і радарних діапазонів.

Якщо розглянути як відбувається зйомка України супутниками Sentinel-1, то щоб покрити країну необхідно 9 смуг (рис. 6). Для 6 (або 5 залежно від року) з них наявні дані наземних спостережень, які використовуються для навчання та тестування моделей класифікації. Для інших смуг (східних у всіх роках та для західних територій у 2017 році) дані відсутні, що потребує перенесення моделей для отримання карти класифікації всієї країни.

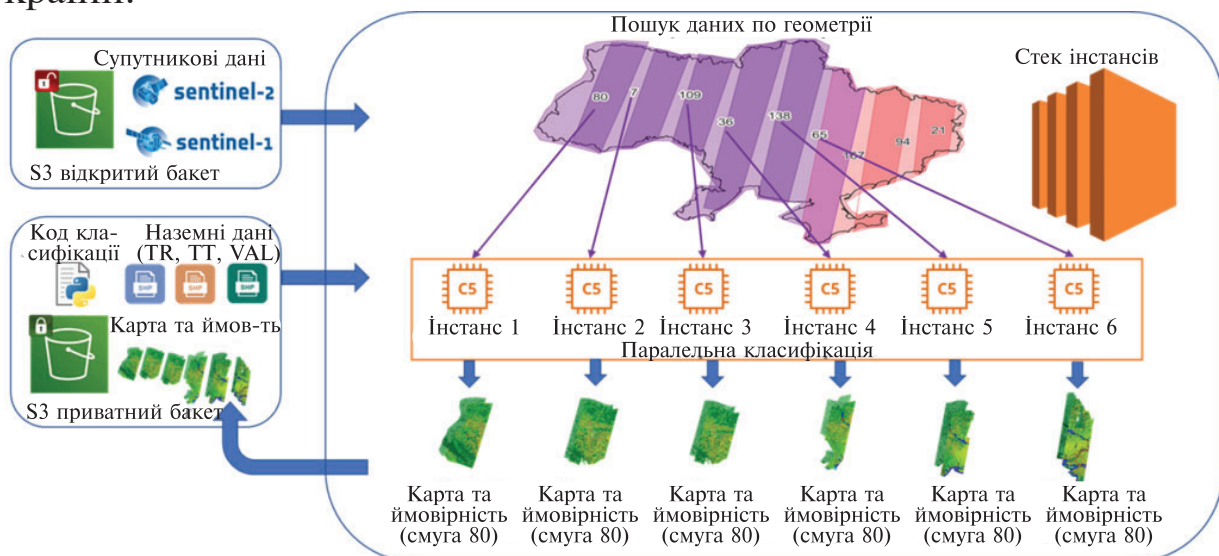


Рис. 6. Загальна схема побудови карт класифікації земного покриття в хмарній платформі AWS

Завдяки використанню хмарних платформ супутникові дані доступні безпосередньо на бакетах, що забезпечує можливість прямого доступу до них і значно скорочує час обробки. Для попередньої обробки даних Sentinel-1 використовуються інстанси, на яких встановлено програмний пакет SNAP (Sentinel Application Platform). SNAP дозволяє виконувати різноманітні операції, включаючи калібрування, геометричну корекцію, фільтрацію та інші операції над радарними даними.

При необхідності виконання атмосферної корекції для оптичних даних Sentinel-2, використовується інструмент Sen2Cor. Sen2Cor дозволяє виправляти атмосферний вплив на оптичні

зображення, враховуючи різні атмосферні умови та ефекти, такі як розсіювання світла атмосферою. Цей інструмент допомагає отримати більш точні та коректні дані, що можуть бути використані для аналізу та класифікації земного покриву. Велика частина обробки автоматизована за допомогою скриптів на мові програмування Python.

Навчальні, тестові та валідаційні дані, необхідні для навчання та тестування моделей класифікації, зберігаються на закритому бакеті AWS. Крім того, на бакеті AWS збережений код, який використовується для класифікації та обробки даних. Це дозволяє забезпечити централізований та надійний доступ до програмного забезпечення та алгоритмів, які використовуються в процесі створення карт класифікації земного покриву. Такий підхід сприяє збереженню даних та програмного забезпечення в безпечному та контрольованому середовищі, що є важливим аспектом при роботі з великими обсягами даних та конфіденційною інформацією.

Для досягнення ефективності та швидкості обробки великих обсягів даних для побудови карт класифікації земного покриву для України, використовується паралельний підхід. Попередня обробка та класифікація виконуються одночасно для кожної зі смуг, на які поділена територія України, і це відбувається на окремих обчислювальних інстансах.

Паралельна обробка даних для кожної смуги дозволяє оптимізувати використання ресурсів і швидкість обробки, а також підвищує продуктивність із врахуванням великих масштабів. Такий підхід обробки даних є особливо важливим при обробці великого обсягу супутникових даних для аналізу земного покриву на великій території. В результаті використання паралельного обчислення вдається зменшити час обробки та підвищити продуктивність завдяки розподіленню завдань на декілька незалежних інстансів.

Результатом виконання коду на кожному інстансі є: карта класифікації земного покриву та ймовірність належності кожного пікселя до визначеного класу.

Обидва растри зберігаються у форматі Geotiff на закритому бакеті AWS. Збереження цих даних на серверах AWS забезпечує їх доступність та зберігання в безпечному середовищі для подальшого аналізу та використання.

Для смуг супутникових даних, де відсутні навчальні дані, застосовується підхід перенесення моделей. Оскільки смуги перекриваються між собою, це дає можливість використовувати інформацію з попередньої смуги (рис. 7). Процес перенесення

3.4. Класифікації типів земного покриття та землекористування на основі...

навчання базується не на навченій моделі, а на результатах класифікації моделі. Тобто, щоб побудувати карту класифікації для наступної смуги створюються навчальні дані у місці перетину двох сусідніх смуг. Навчальні дані з попередньої смуги формуються на основі вибору пікселів з високою ймовірністю належності до різних класів земного покриття (обираються пікселі із ймовірністю не менші за 0.95). Кількість пікселів обирається рівномірно, з метою забезпечення балансу в навчальних даних. Після створення навчальних даних проводиться процес класифікації супутникових даних для смуги, для якої не було навчальних даних. Результати класифікації зберігаються на бакеті. Отримавши навчальні дані з попередньої смуги, аналогічний процес створення навчальної вибірки та класифікації виконується для всіх наступних смуг. Цей процес повторюється для кожної смуги без наявних навчальних даних до завершення побудови карт класифікації для всіх смуг. Такий підхід дозволяє ефективно побудувати карти класифікації для території України, навіть якщо не всі смуги мають навчальні дані.

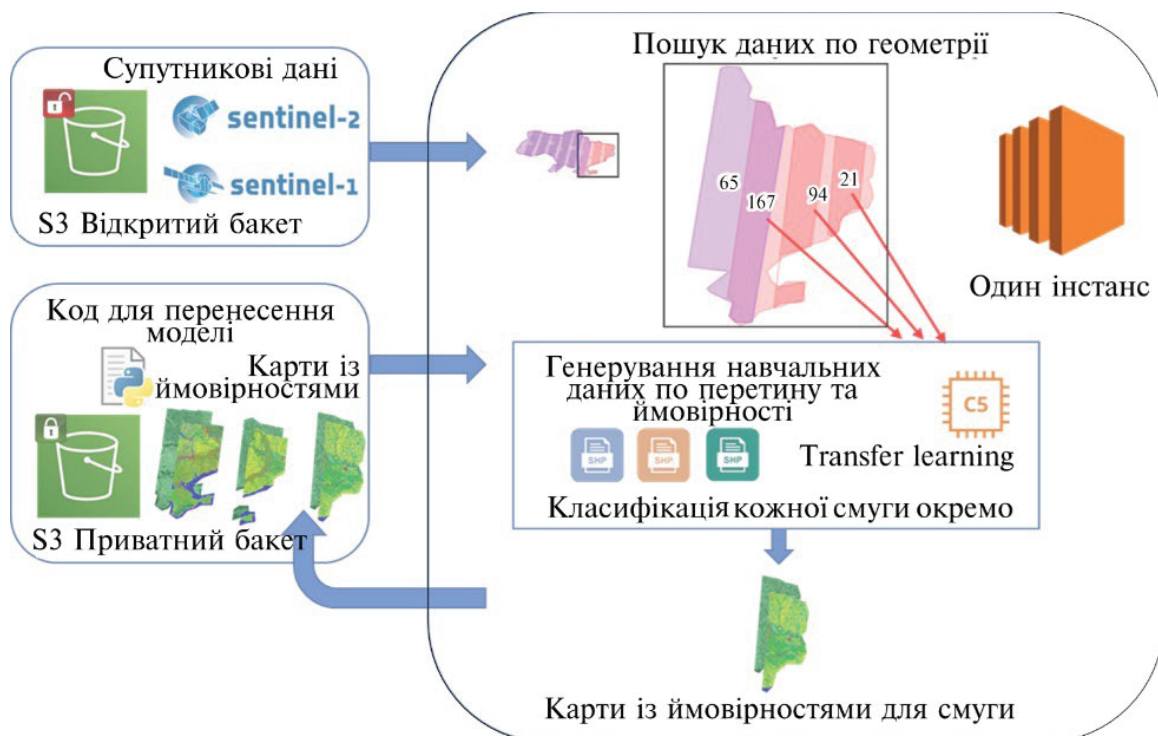


Рис. 7. Загальна схема побудови карт класифікації для територій із відсутніми навчальними даними в AWS

Недоліком такого підходу є те, що процес побудови карт класифікації для різних смуг супутникових даних є послідовним. Оскільки для створення наступної смуги потрібно використовувати попередню смугу, це означає, що робота над

класифікацією нових смуг не може розпочатися, поки не буде завершена попередня. Необхідність чекати завершення попередньої смуги може обмежувати продуктивністю та швидкістю класифікації супутникових даних, але з іншого боку, такий підхід дозволяє коректно виконувати класифікацію для різних смуг та забезпечити належну якість результатів.

Після успішної побудови та збереження усіх 9 смуг класифікації на вказаному бакеті, наступним кроком є об'єднання цих результатів, щоб отримати карту класифікації для всієї території України. Цей процес виконується на одному інстансі (рис. 8).

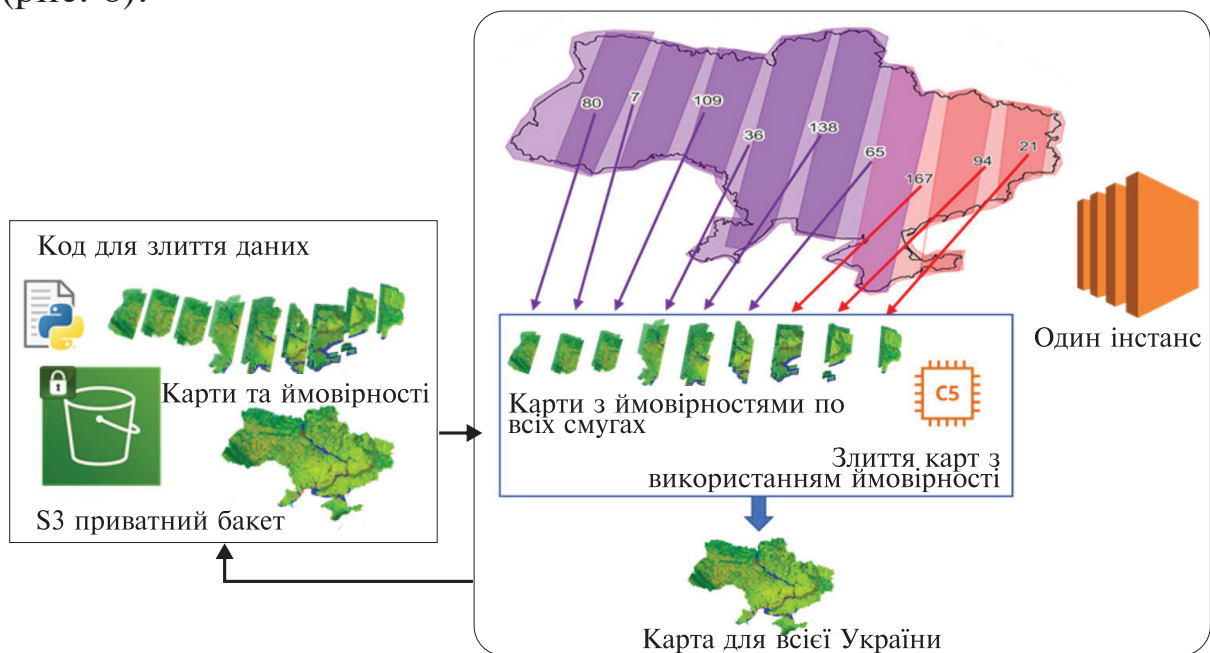


Рис. 8. Загальна схема злиття карт класифікації із врахуванням ймовірності кожного пікселя в AWS

Для об'єднання карт класифікації різних смуг супутникових даних в місцях перетину сусідніх смуг вибирається піксель, для якого ймовірність належності до певного класу земного покриття є найвищою. Це допомагає визначити клас земного покриття для кожного пікселя для території України. Обрані пікселі з високою ймовірністю належності до класів земного покриття об'єднуються, щоб сформувати кінцеву карту класифікації для всієї України.

Такий підхід дозволяє створити єдину карту класифікації земного покриття для України, яка враховує результати класифікації для кожної смуги супутникових даних та забезпечує належну точність та інтерпретацію результатів.

ВИСНОВКИ

У даному розділі розглянуто можливості побудови карти класифікації земного покриття в умовах відсутності даних для деяких регіонів, зокрема для території України. Результати експериментів показали, що методи Transfer Learning можуть бути успішно застосовані для класифікації типів земного покриття в регіонах з обмеженими або відсутніми наземними даними. Перенесення моделей, навчених на даних з центральних регіонів України, на західні регіони продемонструвало прийнятну точність класифікації від 76.4% до 84.2%. Подібні моделі трансферного навчання розроблено кафедрою математичного моделювання і аналізу даних НТУУ “КПІ” для розв’язання інших задач супутникового моніторингу [24].

Використання комбінованих даних з різних регіонів для навчання моделей показало покращення точності класифікації до 87.4% для смуги 7, що свідчить про ефективність цього підходу для підвищення адаптивності моделей до різних географічних умов. Застосування методу голосування для вибору найбільш імовірного класу на основі результатів кількох моделей дозволило досягти точності 84.8% для смуги 7, підтверджуючи ефективність цього методу для зменшення невизначеності при класифікації.

Найбільш ефективним підходом виявилось використання перетинів смуг супутникових зображень для створення додаткових навчальних вибірок (експеримент 4). Цей метод дозволив досягти точності 91.2% для смуги 80, що наближається до точності класифікації на основі наземних даних. Хоча побудова карт на основі наземних даних все ще забезпечує найвищу точність класифікації (94.5-96.1%), запропоновані методи Transfer Learning дозволяють отримати досить точні результати в умовах відсутності наземних даних.

В рамках дослідження продемонстровано можливості хмарної платформи для ефективної паралельної обробки великих масивів супутникових даних з використанням її гнучких ресурсів. Зокрема, розроблено та впроваджено інформаційну технологію класифікації земного покриття для всієї території України на основі машинного навчання з використанням даних супутників Sentinel-1 та Sentinel-2. Основною перевагою хмарних платформ є здатність масштабувати обчислювальні ресурси під потреби великих проєктів, що значно прискорює процес обробки та дозволяє виконувати класифікацію на великих територіях. Розподілена

паралельна обробка даних здійснюється по смугах зйомки на окремих інстансах.

Для забезпечення класифікації на всій території України, зокрема в регіонах, де відсутні наземні дані, запропоновано використовувати метод перенесення навчання із застосуванням перетинів смуг для створення навчальних вибірок, що продемонстрував одні з найкращих результатів під час експериментів. Процес перенесення ґрунтується не на самій навчальній моделі, а на результатах її класифікації, оскільки сусідні смуги перекриваються між собою, що дозволяє використовувати інформацію з попередньої смуги для наступної. Таким чином, продемонстровано ефективність сучасних інструментів машинного навчання та хмарних технологій для обробки великих масивів супутникових даних.

Запропоновані підходи можуть бути застосовані для моніторингу земного покриву для інших країн, де збір наземних даних є складним або неможливим. Подальші дослідження можуть бути спрямовані на вдосконалення методів Transfer Learning для підвищення точності класифікації та розробку нових методів геопросторового інтелекту [25].

ПЕРЕЛІК ПОСИЛАНЬ

1. Neyshabur, B., Sedghi, H., & Zhang, C. (2020). What is being transferred in transfer learning?. *Advances in neural information processing systems*, 33, 512-523.
2. Pandžić, M., Pavlović, D., Matavulj, P., Brdar, S., Marko, O., Crnojević, V., & Kilibarda, M. (2024). Interseasonal transfer learning for crop mapping using Sentinel-1 data. *International Journal of Applied Earth Observation and Geoinformation*, 128, 103718.
3. Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A review of deep transfer learning and recent advancements. *Technologies*, 11(2), 40.
4. Hao, P., Di, L., Zhang, C., & Guo, L. (2020). Transfer Learning for Crop classification with Cropland Data Layer data (CDL) as training samples. *Science of The Total Environment*, 733, 138869.
5. Papoutsis, I., Bountos, N. I., Zavras, A., Michail, D., & Tryfonopoulos, C. (2023). Benchmarking and scaling of deep learning models for land cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 195, 250-268.

3.4. Класифікації типів земного покриття та землекористування на основі...

6. Ma, Y., Chen, S., Ermon, S., & Lobell, D. B. (2024). Transfer learning in environmental remote sensing. *Remote Sensing of Environment*, 301, 113924.

7. Antonijević, O., Jelić, S., Bajat, B. et al. Transfer learning approach based on satellite image time series for the crop classification problem. *J Big Data* 10, 54 (2023). <https://doi.org/10.1186/s40537-023-00735-2>.

8. Dey, M., Prakash, P. S., & Aithal, B. H. (2024). UnetEdge: A transfer learning-based framework for road feature segmentation from high-resolution remote sensing images. *Remote Sensing Applications: Society and Environment*, 34, 101160.

9. Zou, M., Zhong, Y. Transfer Learning for Classification of Optical Satellite Image. *Sens Imaging* 19, 6 (2018). <https://doi.org/10.1007/s11220-018-0191-1>.

10. Wang, Y., Feng, L., Zhang, Z., & Tian, F. (2023). An unsupervised domain adaptation deep learning method for spatial and temporal transferable crop type mapping using Sentinel-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 199, 102-117.

11. Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.

12. Tong, X. Y., Xia, G. S., Lu, Q., Shen, H., Li, S., You, S., & Zhang, L. (2020). Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment*, 237, 111322.

13. Dastour, H., & Hassan, Q. K. (2023). A comparison of deep transfer learning methods for land use and land cover classification. *Sustainability*, 15(10), 7854.

14. Nowakowski, A., Mrziglod, J., Spiller, D., Bonifacio, R., Ferrari, I., Mathieu, P. P., ... & Kim, D. H. (2021). Crop type mapping by using transfer learning. *International Journal of Applied Earth Observation and Geoinformation*, 98, 102313.

15. Gadiraju, K. K., & Vatsavai, R. R. (2023). Remote sensing based crop type classification via deep transfer learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 4699-4712.

16. Benbriqa, H., Abnane, I., Idri, A., Tabiti, K. (2021). Deep and Ensemble Learning Based Land Use and Land Cover Classification. In: Gervasi, O., et al. *Computational Science and Its Applications – ICCSA 2021*. ICCSA 2021. Lecture Notes in Computer Science, vol 12951. Springer, Cham. https://doi.org/10.1007/978-3-030-86970-0_41.

17. Skakun, S., Kussul, N., Shelestov, A. Y., Lavreniuk, M., & Kussul, O. (2015). Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(8), 3712-3719.

18. Mikava, P., & Yailymov, B. (2024). Методи машинного навчання для моніторингу навколишнього середовища. *International Scientific Technical Journal "Problems of Control and Informatics"*, 69(2), 108-122.

19. Shelestov, A., Lavreniuk, M., Vasiliev, V., Shumilo, L., Kolotii, A., Yailymov, B., ... & Yailymova, H. (2019). Cloud approach to automated crop classification using Sentinel-1 imagery. *IEEE Transactions on Big Data*, 6(3), 572-582.

20. Lavreniuk, M., Kussul, N., & Novikov, A. (2018, July). Deep learning crop classification approach based on sparse coding of time series of satellite data. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4812-4815). IEEE.

21. Kussul, N., Shelestov, A., & Yailymov, B. (2022, November). Cloud Platforms and Technologies for Big Satellite Data Processing. In *International scientific and practical conference Information and communication technologies and sustainable development* (pp. 303-321). Cham: Springer Nature Switzerland.

22. Куcсуль Н. Н. Grid-системы для задач исследования Земли. Архитектура, модели и технологии / Н. Н. Куcсуль, А. Ю.Шелестов. — К. : Наукова думка, 2008. — 452 с.

23. G. M. Bakan and N. N. Kussul, "Fuzzy ellipsoidal filtering algorithm of static object state", *Problemy Upravleniya I Informatiki (Avtomatika)*, vol. 5, no. 5, pp. 77-92, 1996.

24. N. Kussul, V. Kuzin, Y. Sali, B. Yailymov and A. Shelestov, "Single-polarized SAR Image Preprocessing in Scope of Transfer Learning for Oil Spill Detection," *2024 IEEE 12th International Conference on Intelligent Systems (IS)*, Varna, Bulgaria, 2024, pp. 1-6, doi: 10.1109/IS61756.2024.10705228.

25. Kussul, N., Shelestov, A., Basarab, R., Skakun, S., Kussul, O., & Lavrenyuk, M. (2015). Geospatial Intelligence and Data Fusion Techniques for Sustainable Development Problems. *ICTERI*, 1356, 196-203.