

М. А. РИБНИЦЬКИЙ, С. С. КРИВЕНКО, В. В. ЛУКІН

Національний аерокосмічний університет «Харківський авіаційний інститут», Харків, Україна

УДОСКОНАЛЕННЯ МЕТОДУ ПОПІКСЕЛЬНОЇ КЛАСИФІКАЦІЇ ДАНИХ ДИСТАНЦІЙНОГО ЗОНДУВАННЯ В УМОВАХ СПОТВОРЕНЬ НА ОСНОВІ КОМБІНОВАНИХ LBP-ОЗНАК

Предметом дослідження є процеси попиксельної класифікації супутникових зображень за наявності спотворень, зумовлених компресією даних з втратами та адитивним білим гаусівським шумом. **Актуальність роботи** обумовлена тим, що попередні дослідження з використанням методу локальних бінарних шаблонів (LBP) продемонстрували перспективні результати, проте виявили високу чутливість базових конфігурацій з малим радіусом збору ознак до адитивного піксельного шуму та артефактів стиснення (таких як розмиття меж і формування блокових ефектів). Це в деяких випадках призводить до помилкової класифікації на однорідних ділянках, спотворених стисненням (зокрема, розпізнавання водних поверхонь як рослинності). **Метою роботи** є підвищення точності попиксельної класифікації супутникових зображень в умовах спотворень шляхом розробки стійкого підходу на основі комбінованого простору ознак, який об'єднує спектральну інтенсивність і текстурну інформацію різних масштабів. Для досягнення поставленої мети вирішено такі **завдання**: експериментальний аналіз проведено на 4-х різнопланових супутникових сценах, змодельованих у 4-х станах (еталонне, зашумлене та зашумлене зображення в умовах двох рівнів стиснення); сформовано розширений простір ознак із застосуванням комбінованого LBP (шляхом інтеграції радіусів 1, 2 та 3 пікселів); проведено налаштування та оптимізацію гіперпараметрів ансамблевого класифікатора XGBoost. **Методи дослідження** базуються на інструментах текстурного аналізу, алгоритмах машинного навчання на основі дерев рішень і методах статистичної оцінки точності. **Результати дослідження** експериментально підтверджують, що поєднання LBP дескрипторів із різними радіусами дозволяє частково нівелювати вплив втрати мікротекстур при стисненні. **Висновки** підтверджують, що запропонований алгоритм ефективно компенсує недоліки окремих текстурних дескрипторів LBP в умовах спотворень зображень. **Практичне значення** отриманих результатів полягає в формуванні надійного базового рівня (baseline) для розробки стійких систем автоматизованого моніторингу та аналізу даних дистанційного зондування Землі (ДДЗ).

Ключові слова: попиксельна класифікація; ДДЗ; LBP; комбінований LBP; XGBoost; спотворення зображень; адитивний білий гаусівський шум; стиснення даних.

1. Вступ

1.1. Мотивація

Стрімке зростання обсягів даних дистанційного зондування Землі (ДДЗ), які мають значну кількість спектральних каналів і високу роздільну здатність, створює критичне навантаження на канали передачі та системи зберігання, перетворюючи обробку супутникових знімків на проблему великих даних [1]. Це робить застосування алгоритмів стиснення з втратами необхідним етапом для оптимізації використання ресурсів при передачі та довготривалому зберіганні інформації [2]. Проте для подальшого використання даних, які пройшли стиснення для передачі чи зберігання, виникає складність: методи компресії вносять специфічні спотворення (блокові артефакти, розмиття меж), що негативно впливають на точність

класифікації [3]. Як зазначається в порівняльних дослідженнях впливу кодерів [4], стабільність результатів розпізнавання (тобто здатність моделі забезпечувати мінімальний розкид точності на різних просторових ділянках сцени) критично залежить від здатності алгоритму нівелювати спотворення, внесені на етапі стиснення з втратами. Ситуацію може ускладнити наявність шуму від сенсорів ДДЗ, що в поєднанні з артефактами стиснення призводить до втрати дрібних деталей і спотворення текстурних ознак, важливих для ідентифікації об'єктів [5]. В умовах необхідності потокової обробки великого об'єму даних, попри популярність глибокого навчання (ГН), традиційні методи машинного навчання (МН) часто залишаються більш практичним рішенням. Вони дозволяють створювати швидкі та енергоефективні наземні комплекси автоматичного моніторингу, забезпечуючи високу точність класифікації даних без потреби в надпотужних обчислювальних засобах [6].



Розробка методів, що демонструють стійкість (здатність алгоритму втримувати високий загальний рівень точності в умовах спотворення даних) при класифікації стиснених зашумлених зображень, та при цьому мають низку обчислювальну складність, є одним із напрямків досліджень [7].

1.2. Сучасний стан досліджень

Класичні методи виділення інформативних ознак із зображень, зокрема локальні бінарні шаблони (LBP) [8], досить широко застосовуються в задачах аналізу текстур і розпізнавання образів завдяки своїй обчислювальній ефективності та інваріантності до монотонних змін яскравості [9], [10]. Дослідження показують, що LBP демонструє відносно високу стійкість до адитивного шуму, що підтверджується метрикою F1-score [11]. Математична простота й низька обчислювальна складність алгоритму LBP роблять його ефективним рішенням для високопродуктивних наземних систем автоматизованої обробки великих масивів ДДЗ. Це дозволяє суттєво знизити вимоги до апаратних ресурсів і енергоспоживання центрів обробки даних при проведенні глобального моніторингу територій [12].

Тут варто згадати про обчислення, які відбуваються в різних блоках систем дистанційного зондування. Хоча сучасні архітектури периферійних обчислень дозволяють розгортати глибокі згорткові мережі (CNN), їх використання залишається енергетично витратним і часто потребує застосування складних методів квантування та спрощення моделей. Натомість класичні методи здатні забезпечити непогані характеристики та достатню стабільність роботи при задовільному навантаженні на обчислювальні ресурси та підсистему живлення приладу [13].

Застосування алгоритмів стиснення з втратами для передачі ДДЗ вносить специфічні спотворення, які можуть впливати на роботу текстурних дескрипторів [14]. Відносно складна проблема виникає на однорідних поверхнях, таких як водні об'єкти або сільськогосподарські угіддя. В умовах сильної компресії на таких ділянках виникають блокові артефакти та шум квантування [7], [15], які алгоритм LBP помилково інтерпретує як значущу мікроструктуру [16]. Це призводить до генерації хибних ознак, унаслідок чого класифікатор не може розрізнити спотворену водну поверхню від текстурованої суші. У контексті сучасних автоматизованих систем підтримки прийняття рішень для моніторингу повеней, просторова точність виявлення меж водойм є надзвичайно важливою. Помилкова класифікація через текстурні або компресійні артефакти призводить до хибних оцінок

масштабів затоплення, що є неприпустимим при оперативному управлінні ліквідацією наслідків стихійних лих [17].

1.3. Мета, завдання та підхід до дослідження

Виходячи з означеної проблематики, головною метою даного дослідження є покращення точності класифікації супутникових зображень в умовах спотворень, спричинених компресією та шумом, шляхом розробки та перевірки ефективного пайплайну, який поєднує інформацію про колір, комбіновані LBP ознаки та їх поєднання з використанням класичних методів машинного навчання.

Для досягнення поставленої мети в роботі вирішуються наступні завдання:

1. Оцінка траєкторії зміни інформативності ознак: дослідити динаміку падіння загальної точності класифікації під впливом шуму та стиснення з втратами (на прикладі кодеру BPG (better portable graphics) [18]).
2. Аналіз різних підходів до побудови вектора ознак: порівняти ефективність окремих LBP конфігурацій із запропонованим комбінованим підходом (Combined LBP).
3. Аналіз стабільності розпізнавання класів: дослідити варіативність отриманих значень F1-метрики для базових типів поверхонь («Вода», «Рослинність», «Ґрунт», «Забудова»).
4. Адаптація ансамблевої моделі: дослідити різні конфігурації класифікатора XGBoost [19] (кількість дерев та їх глибину) для визначення оптимальної конфігурації, здатної максимізувати точність класифікації стиснених зображень, що спотворені шумом.

2. Методи та матеріали дослідження

2.1. Формування й обробка набору даних

Експериментальна база дослідження сформована на основі чотирьох різнопланових супутникових сцен (позначених як SS1–SS4) розміром 512×512 пікселів, що охоплюють територію Харківської області (Україна). Фрагменти з мультиспектральних даних Sentinel-2 обиралися за критерієм мінімальної наявності шуму. Зображення були сформовані з трьох спектральних каналів видимого діапазону; приклади цих зображень наведено на рис. 1.

Вибір саме цього регіону та виокремлення чотирьох специфічних підсцен обумовлені кількома факторами. По-перше, знімки характеризуються відсутністю атмосферних перешкод (хмарності). По-друге, територія репрезентує різноманітний ландшафт, що

містить основні цільові класи: «Вода», «Рослинність», «Забудова» та «Ґрунт». Розділення загального масиву на 4 сцени дозволило ізольовано протестувати алгоритм на ділянках із різним рівнем складності — від відносно гомогенних (великі, однорідні об'єкти з чіткими межами) до гетерогенних (складне переплетіння класів). Крім того, знання особливостей даної місцевості авторами статті дозволило з високою точністю побудувати еталонні маски класів для подальшого тренування та валідації алгоритмів.



Рис. 1. Супутникові сцени (SS1, SS2, SS3, SS4, відповідно)

Для комплексного дослідження впливу спотворень, викликаних шумом та стисненням, для кожної з 4-х сцен було підготовлено по 4 варіанти зображень (загалом сформовано 16 зображень), що моделюють різні умови експлуатації систем дистанційного зондування:

Original: Вихідне зображення.

Noisy: Зображення з додаванням штучного адитивного білого гаусівського шуму (АБГШ) з дисперсією $\sigma^2 = 100$ (середньоквадратичне відхилення $\sigma=10$), що імітує вплив сенсорних завад. Такий рівень шуму є типовим стандартом в експериментальних дослідженнях і моделює реалістичну амплітуду теплових і електронних шумів, що виникають унаслідок експлуатаційної деградації оптико-електронних систем супутника (наприклад, радіаційного старіння матриці) або під час зйомки в умовах низького відношення сигнал/шум [20].

Compressed Q31: Зашумлене зображення, що пройшло процедуру каналного стиснення з втратами за допомогою кодера BPG із параметром квантування $Q=31$.

Compressed Q35: Зашумлене зображення, що пройшло процедуру каналного стиснення з втратами за допомогою кодера BPG із параметром квантування $Q=35$.

Вибір параметрів квантування не є випадковим. Згідно з дослідженнями [21], для зашумлених зображень, що стискаються кодером BPG, може існувати оптимальна робоча точка (ОРТ) — стан, де досягається найкращий компроміс між ступенем стиснення та збереженням корисної інформації з одночасним придушенням шуму. Для згаданих зображень ОРТ знаходиться саме в околах обраних значень.

Стратегія дослідження передбачає навчання та тестування класифікатора на даних з однаковим типом спотворень, що дозволяє ізольовано оцінити адаптивність моделі до конкретного середовища.

Для забезпечення чистоти експерименту та уникнення витоку даних [22] через просторову автокореляцію [23], процедуру формування навчальної та тестової вибірок було модифіковано. На відміну від класичного підходу рівномірного випадкового відбору окремих пікселів по всьому зображенню, який штучно завищує метрики точності, в цьому дослідженні застосовано метод просторового блочного розділення (Spatial Block Splitting) [24], [25].

Із еталонної маски випадковим чином виокремлювалися суцільні просторові вікна (блоки розміром 70×70 пікселів) доти, доки обсяг навчальної вибірки не досяг 70% від загальної кількості розмічених даних. Решта 30% пікселів сформували повністю ізольовану тестову маску. Вибір розміру вікна 70×70 пікселів для сцен формату 512×512 був визначений емпіричним шляхом як оптимальний компроміс між просторовою незалежністю та репрезентативністю класів. Менші вікна (наприклад, 30×30) не здатні ефективно мінімізувати вплив просторової автокореляції сусідніх пікселів, тоді як занадто великі блоки (100×100 і більше) призводили до критичного дисбалансу навчальної вибірки через нерівномірний розподіл класів на сцені. Обраний розмір дозволяє формувати достатньо великі суцільні полігони, співставні з типовими розмірами ландшафтних об'єктів на знімках Sentinel-2 (лісові масиви, водойми), забезпечуючи при цьому охоплення всіх наявних класів із різних частин зображення. Такий підхід максимально наближений до реальних сценаріїв машинного навчання в сфері ДДЗ: на практиці навчальні дані зазвичай збираються у вигляді суцільних полігонів (ground truth polygons) під час польових досліджень або ручної розмітки локальних ділянок. Отримані розмічені області використовуються для навчання моделі, щоб у подальшому використати її для класифікації невідомих частин зображень, або зображень у цілому. Щоб наочно продемонструвати відсутність перетину вибірок, для кожної аналізованої сцени

в роботі представлено вихідне зображення в зіставленні з відокремленими навчальною та тестовою масками (рис. 2а та рис. 2б).




Рис. 2. Маски (SS1, SS2, SS3, SS4 відповідно), використанні для перевірки моделі:
а – тренувальні; б – перевірочні

2.2. Інженерія ознак

Базовий підхід до попиксельної класифікації, що спирається на поєднання спектральної інформації (інтенсивності пікселів у кожному каналі) та класичного текстурного дескриптора LBP, є загалом достатнім для

роботи з якісними даними [26]. Однак в умовах структурної невизначеності, спричиненої шумом і артефактами стиснення, виділення текстурних ознак лише на одному фіксованому масштабі (радіусі LBP) не дозволяє досягти бажаної точності класифікації.

Зокрема, стандартний дескриптор малого радіуса (наприклад, LBP1:8, що означає радіус 1 піксель і 8 точок вибірки) добре захоплює мікротекстури, але є вкрай чутливим до високочастотного шуму. Натомість дескриптори більших радіусів (такі як LBP2:16 і LBP3:24) аналізують ширший просторовий контекст. Вони фіксують макротекстури та глобальні межі об'єктів, що робить їх менш вразливими до дрібних локальних спотворень. У рамках даного дослідження проводиться порівняльна оцінка ефективності використання спектральної інформації з різними конфігураціями дескриптора LBP, які відрізняються виключно масштабом збору текстурних даних. Для ефективної компенсації втрати дрібних деталей запропоновано новий комбінований метод (Combined LBP). Його суть полягає в формуванні розширеного простору ознак, який об'єднує інформацію про інтенсивність яскравості пікселя в кожному каналі з результатами обчислення LBP для кожного каналу одночасно на кількох різних радіусах (а саме: інтеграція ознак LBP1:8, LBP2:16 та LBP3:24). Це дозволяє інтегрувати як мікро, так і макротекстурні характеристики деградованого зображення в один вектор ознак для кожного пікселя.

2.3. Класифікація та оптимізація

Основним інструментом класифікації, який використовується нами в рамках цієї статті, є бібліотека XGBoost, яка традиційно демонструє досить високу узагальнюючу здатність і стійкість до перенавчання на табличних даних (якими в контексті даного дослідження виступає сформований вектор ознак, що базується на поєднанні спектральної інтенсивності каналів і текстурних дескрипторів LBP).

Процедура навчання включає повний перебір гіперпараметрів (Grid Search) для пошуку оптимальної конфігурації моделі:

- кількість дерев ($n_estimators$): 10, 30, 50, 100, 200, 300, 500;
- максимальна глибина дерева (max_depth): 4, 5, 6, 8, 10, 12, 15.

Важливою умовою експерименту є те, що для тренування та фінальної класифікації використовувалися набори даних з ідентичними рівнями шуму та стиснення. Цей підхід ґрунтується на фундаментальному принципі машинного навчання: модель досягає максимальної прогностичної ефективності тоді, коли статистичні розподіли тренувальної та тестової вибірок збігаються. Як було доведено в дослідженні [26],

попереднє узгодження характеристик якості (зокрема, інтенсивності шуму та ступеня стиснення) між еталонними та робочими зображеннями дозволяє класифікатору адаптуватися до специфічних артефактів. Це запобігає проблемі, пов'язаній із виникненням невідомих алгоритму типів спотворень, і, як наслідок, гарантує високі та стабільні результати класифікації.

Усі обчислювальні експерименти, включаючи генерацію ознак, моделювання спотворень і навчання моделей, реалізовані мовою програмування Python із використанням відповідних спеціалізованих бібліотек для обробки зображень і машинного навчання (scikit-learn, xgboost, skimage та ін.). Для забезпечення відтворюваності результатів і об'єктивної оцінки обчислювальної складності (часу інференсу), тестування алгоритмів проводилося на базі локальної робочої станції з процесором Apple M3 Pro та 36 ГБ об'єднаної оперативної пам'яті.

3. Результати дослідження

Під час експерименту було навчено та провалідовано 3136 унікальних конфігурацій моделей: 4 зображення $\times$ 4 стани $\times$ 4 LBP варіації $\times$ 7 варіантів глибини $\times$ 7 варіантів кількості дерев. Оскільки супутникові сцени характеризуються природним просторовим дисбалансом (наприклад, домінуванням значних суцільних водних поверхонь), під час навчання XGBoost штучне зважування класів (class weights) не застосовувалося, щоб оцінити об'єктивну роздільну здатність згенерованого простору ознак. Натомість вплив дисбалансу було компенсовано на етапі оцінки шляхом використання макро-усереднених метрик: F1-score (F1-macro) та AUC (macro-AUC) [27]. Ці метрики обчислюють результати незалежно для кожного класу з подальшим їх рівноцінним усередненням. Це гарантує, що малопредставлені класи мають таку ж вагу в підсумковій оцінці, як і домінуючі, запобігаючи хибно-високим результатам за рахунок великих однорідних зон.

3.1. Аналіз змін вектора ознак у залежності від спотворень

Для оцінки загальної стійкості запропонованого методу класифікації було досліджено динаміку зміни точності класифікації при переході від еталонних зображень до зображень із різним рівнем спотворень. На рис. 3 представлено траєкторії максимального значення метрики F1-macro для кожної з 4-х досліджуваних сцен (SS1–SS4) та усереднений тренд залежно від типу спотворення (Original, Noisy, Compressed_Q31, Compressed_Q35) при використанні комбінованого LBP.

Аналіз усередненого тренду (жирна чорна лінія) демонструє логічне падіння загальної точності класифікації внаслідок впливу адитивного білого гаусівського шуму (зниження F1-macro з 0.920 до 0.905). Проте ключовим результатом є поведінка моделі на етапах застосування стиснення: при значенні $Q=31$ (значення, при якому емпірично зафіксовано початок зростання поканальної метрики PSNR після початкового плато) до околу оптимальної робочої точки $Q=35$ (де досягаються найвищі значення PSNR), середній тренд розпізнавання демонструє впевнене зростання. Це підтверджує стійкість комбінованого підходу до спотворень, спричинених стисненням: втрата мікротекстур унаслідок квантування ефективно компенсується наявністю у векторі ознак дескрипторів більшого радіуса (LBP3:24). Оскільки вони охоплюють ширшу ділянку навколо пікселя, ці дескриптори здатні боротися із дрібними блоковими артефактами компресії та спиратися на збережені макроструктури об'єктів.




Рис. 3. Траєкторія зміни максимального значення точності (F1-macro) при використанні комбінованого LBP для зображень SS1–SS4:
1 – SS1; 2 – SS2; 3 – SS3; 4 – SS4;
5 – загальний середній тренд

Аналіз траєкторій зміни максимального значення точності дозволяє виокремити три особливості поведінки алгоритму:

1. Модель, навчена та протестована на сцені з рівномірно розподіленими класами (SS3), демонструє найвищу точність класифікації. Цей знімок характеризується наявністю великих, збалансованих за площею масивів різних класів: наприклад, чверть кадру займає суцільна водна поверхня, ще близько 20% — масиви рослинності, а центральна частина утворює змішану мозаїку з полів, ґрунту та урбанізованих територій. Завдяки такому розподілу (наявність як великих суцільних зон, так і мозаїчних переходів) тренувальні блоки захоплюють максимально повну та збалансовану кількість різноманітних текстурних ознак. Це дозволяє системі ефективно генералізувати

дані, нівелювати локальні особливості місцевості та безпомилково розрізняти пікселі.

2. При роботі з високо-однорідною сценою (SS1) алгоритм показує найнижчий базовий результат (~ 0.88). На цьому зображенні домінують значні суцільні зони двох класів (вода та рослинність), тоді як ґрунт і забудова займають незначну площу, формуючи дрібну структуру з великою кількістю переходів. Головний чинник погіршення класифікації – екстремальна спектральна близькість домінуючих масивів (темно-зеленої рослинності та темної води), що призводить до їх взаємного плутання. Через геометричний розподіл сцени система не отримує достатньої варіативності ознак: замість узагальнення, модель перенавчається на локальній одноманітності масивних блоків лісу чи води й втрачає здатність чітко розпізнавати міноритарні класи.

3. Результати класифікації високо-різнорідних сцен (SS2, SS4) демонструють стабільну та передбачувану поведінку моделі в умовах високої структурної складності. Ці зображення поєднують у собі значні масиви окремих класів (великі шматки ґрунту для SS2 або монотонної зелені для SS4) зі щільною, складною мозаїкою, де тісно перетинаються урбанізація, водна поверхня, ґрунт і рослинність. Хоча наявність великої кількості дрібних перехідних зон ускладнює піпиксельне розпізнавання (що дещо знижує загальну точність порівняно з SS3), алгоритм демонструє достатньо високу точність класифікації.

Важливо, що, незалежно від початкової складності сцени, коливання точності класифікації між різними станами спотворень зображень для кожної лінії залишається мінімальним.

Розгляд траєкторій зміни максимальної точності класифікації узгоджується з висновками, отриманими в попередніх дослідженнях [28]. Зокрема, практично підтверджується ефект існування ОПТ, у межах якої застосування компресії до зашумлених даних призводить до стабілізації або навіть зростання точності класифікації. Наочно цей феномен ілюструє поведінка моделі на сцені SS2 (блакитна пунктирна лінія).

3.2. Порівняння ефективності просторів LBP-дескрипторів

Для перевірки гіпотези про доцільність використання комбінованого вектору ознак було проведено порівняння трьох окремих просторів ознак (LBP1:8, LBP2:16, LBP3:24) та запропонованого інтегрованого підходу (Combined LBP). На Рис. 4 представлено порівняльний аналіз ефективності різних конфігурацій LBP. Висота кольорових стовпчиків відображає максимальне значення метрики F1-масго, усереднене по чотирьох тестових сценах для кожного стану даних (Original, Noisy, Compressed_Q31,

Compressed_Q35). Тонкі чорні вертикальні лінії показують розмах значень (від мінімального до максимального), а фігурні маркери деталізують точні результати класифікації для кожної окремої сцени (SS1–SS4).




Рис. 4. Порівняння ефективності LBP конфігурацій

Аналіз вразливості окремих LBP. Результати на еталонних даних (Original) показують, що для базового дескриптора з найменшим радіусом (LBP1:8) значення F1-метрики класифікації становить близько 0.900. При внесенні адитивного білого гаусівського шуму (Noisy) фіксується зниження F1-метрики до 0.860, оскільки малий радіус ($R=1$) підвищує чутливість до локальних змін яскравості пікселів. Аналогічна поведінка метрики простежується при стисненні (Compressed_Q31, Compressed_Q35), коли стиснення кодером BPG призводить до втрати дрібних деталей і зниження інформативності ознак. При цьому розкид значень F1-метрики між чотирма тестовими зображеннями (відображений на графіку тонкими вертикальними лініями) ілюструє розкид значень точності класифікації. Разом з тим, дескриптор LBP3:24 зберігає вищі показники F1-метрики в спотворених станах завдяки орієнтації на макроструктуру поверхонь, що робить його стійкішим до впливу шуму та артефактів стиснення.

Перевага комбінованого підходу (Combined LBP). Комбінований LBP стабільно перевершує будь-яку конфігурацію з одним фіксованим радіусом у всіх станах спотворень. Головна перевага комбінованого LBP полягає у взаємодоповнюваності просторових ознак: в умовах, коли ознаки малого радіуса стають ненадійними, ансамблевий класифікатор автоматично перерозподіляє ваги на користь стабільних патернів більшого радіуса (3:24), компенсуючи втрату інформації.

З метою визначення типів поверхонь, для яких застосування комбінованого простору ознак є найбільш ефективним, було проаналізовано метрику Area Under Curve (AUC) для кожного класу окремо за

підходом «один проти всіх». Слід зазначити, що стабільно високі значення AUC (понад 0.90) у цій задачі зумовлені специфікою попиксельної класифікації дистанційних даних: при виділенні одного цільового класу всі інші утворюють масивний фон (велику кількість True Negatives), що математично мінімізує рівень хибнопозитивних спрацювань (False Positive Rate) при побудові ROC-кривої. На рис. 5 показано порівняння усереднених значень AUC в умовах шуму та двох рівнів компресії.

Висота стовпчиків відображає середнє значення метрики по чотирьох тестових сценах, а чорні верти-

кальні лінії вказують на розмах значень. Різна ширина цього розмаху пояснюється тим, що для одних класів (наприклад, «Вода») просторові ознаки залишаються стабільними незалежно від сцени, тоді як для інших (наприклад, «Ґрунт») якість класифікації сильно залежить від геометрії об'єктів на конкретному зображенні. Загальна тенденція на графіках свідчить, що використання комбінованого LBP підвищує метрику (позитивний приріст порівняно з базовим LBP1:8) для всіх каналів у всіх станах спотворень.




Рис. 5. Зведені значення метрики AUC для кожного класу поверхонь за різних умов спотворень зображень

Найбільший ефект від комбінованого підходу спостерігається для класів «Забудова» та «Рослинність». В умовах шуму приріст метрики AUC для цих класів становить +0.010 та +0.011 відповідно. Шум зазвичай руйнує складну геометрію міської забудови та специфічну текстуру рослинності. Комбінований LBP, дозволяє алгоритму XGBoost зберігати здатність до класифікації цих об'єктів в умовах інтенсивних завад на високому рівні.

При сильному стисненні (Compressed_Q35) помітний стабілізуючий ефект також фіксується для класу «Забудова» (+0.01 до AUC). Оскільки стиснення кодером BPG згладжує прямі кути будівель і дрібні дороги, саме інтегрований простір ознак не дозволяє системі помилково класифікувати ці згладжені ділянки як відкритий «Ґрунт» або «Вода». Клас «Ґрунт» демонструє найвищу варіативність результатів (найдовші вертикальні чорні лінії), що пояснюється згаданою раніше колірною схожістю з забудовою на певних локаціях (наприклад, SS1). Проте навіть у таких складних умовах комбінований LBP забезпечує найкраще розрізнення цих класів порівняно з окремими LBP дескрипторами.

Клас «Вода» демонструє найвищі показники AUC (>0.98), проте навіть для нього комбінований LBP покращує класифікацію, нівелюючи хибні текс-

тури, що виникають від артефактів стиснення на великих однорідних площах.

3.3. Оцінка стабільності класифікації зображень за класами

Підвищення точності моделі є лише одним із критеріїв її ефективності. Для практичного застосування в системах аналізу ДДЗ критично важливою є стабільність алгоритму — його здатність демонструвати передбачувані результати з мінімальним розкидом помилок при зміні гіперпараметрів або обробці різних сцен. Для оцінки цієї властивості було проаналізовано стандартні відхилення метрики F1-масго для кожного класу.

Важливо зазначити, що розрахунок статистичних показників та побудова розподілів здійснювалися на основі повного масиву експериментальних результатів (тисячі ітерацій навчання класифікатора XGBoost), що охоплює всі досліджені комбінації гіперпараметрів для всіх тестових зображень. Візуалізацію розподілу результатів наведено на діаграмах розмаху (Boxplots) на рис. 6.

Аналіз діаграм для всіх станів спотворень (Noisy, Compressed_Q31, Compressed_Q35) виявляє більш складну закономірність: при переході від базових окремих дескрипторів до інтегрованого простору

комбінованого LBP (світло-зелені блоки), медіана показника точності стабільно зміщується вгору для всіх без винятку класів. Водночас вплив на дисперсію (ширину «блоку») має виражену класову специфіку:

Клас «Вода»: Аналіз відповідних діаграм (рис. 6) демонструє, що комбінований LBP виступає стабілізатором саме в умовах спотворень. Якщо для LBP1:8 характерний широкий розкид значень (особливо у стані Noisy, де нижня межа «вуса» опускається до ~ 0.70), то комбінований LBP підтягує нижню межу розподілу вгору (до ~ 0.74 для Noisy зображення та ~ 0.77 для Compressed_Q35), а медіану – до

0.96-0.97. При сильному стисненні (Q35) комбінований метод забезпечує найвищу концентрацію результатів у верхньому діапазоні (0.90–0.99), ігноруючи блочні артефакти стиснення, які погіршують роботу вузько спрямованого LBP1:8.

Клас «Забудова»: Урбанізовані території є одним із найскладніших класів і мають велику різницю між найкращими значеннями та найнижчими. Значний загальний розкид значень для цього класу пояснюється згаданою раніше спектральною «конфузією»: на певних сценах пікселі відкритого ґрунту та бетонних покриттів мають надзвичайно близькі кольорні характеристики.




Рис. 6. Вохплотс. Стабільність розпізнання класів

Характерною особливістю для стану Compressed_Q35 є те, що нижні межі для базового LBP1:8 та комбінованого LBP знаходяться приблизно на одному рівні (~0.76-0.77), використання комбінованого підходу дозволяє суттєво підняти медіану. Для комбінованого LBP медіана фіксується на рівні ~0.93 (порівняно з 0.89 для LBP1:8). Це свідчить про високу здатність алгоритму зберігати стабільність класифікації забудови, підтягуючи загальну точність більшості вибірок вгору, незважаючи на агресивне стиснення та складність ландшафту.

Клас «Рослинність»: На розподілах метрик для цього класу (рис. 6) чітко фіксується поява значної кількості поодиноких викидів для всіх конфігурацій LBP. Для стану Noisy ці аномалії опускаються до мінімуму близько ~0.43, а для стану Compressed_Q35 – до ~0.60. Детальний аналіз цих аномалій показав, що вони з'являються переважно через специфічні масиви рослинності, які суттєво відрізняються від наявних у навчальній вибірках. Проте комбінований LBP демонструє найвищу «щільність» результатів у верхній частині графіка (медіана стійко тримається вище ~0.96-0.97 для всіх станів), що вказує на здатність моделі успішно класифікувати «Рослинність» навіть за наявності складних локальних аномалій.

Клас «Ґрунт»: Як і у випадку з «Забудовою», для класу «Ґрунт» спостерігається стабільне зростання медіани (до ~0.85) при використанні комбінованого LBP. У стані Compressed_Q35 нижній «вус» на діаграмі для комбінованого LBP починається від ~0.60, тоді як у LBP1:8 він опускається відчутно нижче – до 0.56. Це вказує на зменшення кількості грубих помилок класифікації на відкритих ділянках місцевості при застосуванні комплексного простору ознак.

Таким чином, аналіз діаграм розмаху (рис. 6) підтверджує, що головна цінність комбінованого LBP полягає в комплексному підвищенні надійності класифікації. Цей метод забезпечує стабільне медіанного значення точності та ефективно підтягує «нижні» показники складних сцен до прийняттого рівня. Така здатність мінімізувати кількість критичних помилок є надзвичайно важливою для надійної роботи систем автоматизованого моніторингу в умовах спотворених ДДЗ.

3.4. Оптимізація гіперпараметрів ансамблевої моделі (Ensemble Model Optimization)

Ефективність запропонованого методу щодо класифікації спотворених ДДЗ залежить не лише від стійкості самого простору ознак, а й від здатності класифікаційної моделі на основі XGBoost знаходити приховані нелінійні закономірності в спотворених

даних. Для дослідження цього аспекту було проаналізовано гіперпараметричний простір моделі. На рис. 7 наведено теплову карту (Heatmap) — візуальну матрицю, що демонструє залежність усередненої метрики F1-масо від двох ключових гіперпараметрів: кількості дерев (вісь X) та їхньої максимальної глибини (вісь Y). У цій візуалізації колірна шкала відіграє роль індикатора ефективності: перехід від світло-жовтих до темно-синіх відтінків чітко відображає зростання точності моделі. Ця теплова карта побудована для найскладнішого випадку спотворень у межах нашого дослідження — комбінованого впливу адитивного білого гаусівського шуму та подальшого стиснення з параметром Q=35. Оскільки цей параметр визначає найвищий рівень квантування в рамках нашого експерименту, його застосування призводить до значної втрати високочастотних деталей. У поєднанні з наявністю шумової компоненти це генерує виражені артефакти компресії та створює екстремальні умови, що є серйозним викликом для стабільної роботи алгоритму класифікації.

Аналіз розподілу значень на Heatmap (рис. 7) демонструє, що прості моделі з низькою репрезентативною здатністю не можуть впоратися з артефактами компресії. Мінімальна конфігурація (кількість дерев Trees=10, глибина Depth=4) показує найнижчий результат (0.8581, що відповідає найсвітлішій жовтій зоні на графіку), оскільки не здатна побудувати достатньо складні правила прийняття рішень на основі спотворених текстур.




Рис.7. Теплова карта (Heatmap)

Водночас матриця дозволяє наочно ідентифікувати зону «насичення» (темно-синій регіон), де подальше збільшення складності ансамблю вже не дає суттєвого приросту точності, а лише збільшує обчислювальне навантаження.

Однак, класифікатор на базі XGBoost демонструє високу здатність витягувати інформацію зі спотворених LBP ознак за рахунок нарощування кількості дерев. Особливо помітною є роль глибини дерева при малій кількості ітерацій: при $Trees=10$ збільшення глибини дозволяє підняти точність з 0.858 до 0.896. Це пояснюється тим, що за умови малого розміру ансамблю класифікатор змушений компенсувати нестачу базових моделей за рахунок збільшення складності (глибини) кожного окремого дерева, щоб успішно виявити приховані закономірності в даних.

Важливим спостереженням є наявність чітко вираженої «точки насичення», після якої ускладнення моделі перестає бути ефективним. Теплова карта показує, що при досягненні кількості дерев $Trees = 100 - 200$ та глибини $Depth = 6 - 8$, метрика F1-масо стабілізується на рівні 0.907–0.908. Більше того, за умов суворого просторового розділення 70/30, детальний аналіз виявляє ознаки мікро-деградації результатів при подальшому ускладненні. Наприклад, при фіксованій глибині $Depth=6$ збільшення кількості дерев з 100 до 500 призводить до незначного зниження точності (з 0.9087 до 0.9051). Це вказує на те, що надмірно великі ансамблі починають підлаштовуватися під специфічні артефакти кодера BPG на тренувальних блоках, втрачаючи здатність до генералізації на тестових ділянках ландшафту.

Для наочної демонстрації практичної ефективності знайденої оптимальної конфігурації на рис. 8 наведено маски класифікації для тестових сцен SS1–SS4. Візуалізація виконана для найбільш критичних умов спотворень шумом та при високому значенні коефіцієнта стиснення BPG ($Q=35$) – з використанням простору ознак комбінованого LBP та оптимізованих гіперпараметрів класифікатора XGBoost. Як свідчить візуальний аналіз, навіть в умовах інтенсивних спотворень запропонований підхід забезпечує формування візуально однорідних ділянок для кожного з класів.

Алгоритм успішно розрізняє складно-роздільні класи з високою точністю класифікації та збереженням чітких меж між об'єктами.

Таким чином, експериментально підтверджено, що для класифікації супутникових зображень в умовах компресійних спотворень оптимальною є конфігурація XGBoost з параметрами $max_depth = 6...8$ та $n_estimators = 100...200$. Саме цей діапазон забезпечує найкращий компроміс: модель уже має достатню кількість "слабких" класифікаторів для формування стійкого консенсусу, але ще не починає завчати специфічні артефакти стиснення.




Рис. 8. Маски класифікації для тестових сцен:
а – SS1; б – SS2; в – SS3; г – SS4

Згадана конфігурація забезпечує максимальну стійкість і точність (понад 90%), одночасно мінімізуючи ризик перенавчання та суттєво заощаджуючи обчислювальні ресурси порівняно з надмірно глибокими або великими ансамблями.

4. Дискусія

Аналіз отриманих результатів дозволив виявити та пояснити низку ключових закономірностей у поведінці моделей класифікації за умов спотворень ДДЗ.

У даному дослідженні було свідомо застосовано стратегію просторової ізоляції вибірок (розділення 70/30 за допомогою суцільних макроблоків) для мінімізації ризиків просторової автокореляції та запобігання витоку даних. Такий дизайн експерименту оцінює реальну здатність моделі узагальнювати знання на нові, раніше небачені ділянки ландшафту. Варто наголосити, що, незважаючи на ці жорсткі, максимально наближені до практичних умови тестування, запропонований алгоритм на основі комбінованих LBP продемонстрував стабільно високий рівень точності. Це доводить, що досягнута якість класифікації є наслідком високої розрізняювальної здатності згенерованого простору ознак, а не результатом банального перенавчання моделі на спектрально схожих сусідніх пікселях.

Експериментально доведено, що окремі дескриптори малого радіуса (LBP1:8) є найбільш вразливими до шуму та втрати мікротекстур при стисненні. Натомість інтеграція різномасштабних ознак у комбінований простір забезпечує їхню ефективну взаємодоповнюваність. Це пояснюється тим, що модель здатна автоматично перерозподіляти ваги на користь стабільних макроструктур (LBP3:24), ігноруючи локальні артефакти.

Зокрема, було виявлено ефект спектрально-текстурної схожості: зниження точності на високо-однорідних сценах обумовлене екстремальною близькістю ознак темно-зеленої рослинності та водної поверхні, а також ґрунту та забудови. Проте здатність комбінованого LBP аналізувати ширший кон

текст дозволяє надійно розмежовувати класи (AUC > 0.98) навіть там, де суто спектральна інформація є неоднозначною. Ефект стабілізації має яскраво виражений класово-залежний характер: найбільше він проявляється для гетерогенного класу «Забудова» та класу «Вода» при високих значеннях стиснення ($Q=35$), тоді як для складних ландшафтів («Рослинність») залишається ризик помилкової класифікації окремих ділянок.

Дослідження гіперпараметричного простору XGBoost виявило чітку "точку насичення". Подальше нарощування глибини або кількості дерев (понад 200) не призводить до значного підвищення точності класифікації. При цьому, аналіз обчислювальної складності засвідчив, що, хоча збільшення ансамблю до оптимальних 100–200 дерев закономірно призводить до лінійного зростання часу інференсу порівняно з базовою моделлю (10 дерев та глибина 4), швидкість обробки залишається надзвичайно високою та становить усього близько 0.1–0.25 секунди. Цей результат ідеально замикає компроміс між швидкістю та точністю, підтверджуючи загальну енергоефективність класичних методів машинного навчання.

Попри високу ефективність запропонованого підходу, варто відзначити його обмеження. У даному дослідженні для експериментів цілеспрямовано відбиралися оптичні знімки Sentinel-2 за критерієм відсутності хмарності. У реальних умовах експлуатації наявність щільних хмар або їхніх напівпрозорих тіней суттєво змінює як спектральні, так і текстурні сигнатури поверхні. Оскільки в межах цієї роботи алгоритм не тестувався на знімках, спотворених хмарами, його поведінка в таких умовах наразі залишається невідомою. Відповідно, дослідження впливу хмар та їхніх тіней на точність класифікації є перспективним напрямком подальших досліджень.

5. Висновки

У роботі вирішено актуальне науково-прикладне завдання підвищення точності систем автоматичної попиксельної класифікації супутникових зображень в умовах спотворень, викликаних адитивним гаусівським шумом та стисненням BPG кодером. Експериментально доведено, що інтеграція дескрипторів LBP різних радіусів у комбінований текстурний простір забезпечує утримання загальної точності (F1-масо) на стабільному рівні (понад 0.91) навіть за умов високого рівня стиснення ($Q=35$), ефективно компенсуючи деградацію мікроструктур. Також встановлено оптимальні параметри класифікатора для роботи з деградованими даними: конфігурація ансамблю XGBoost із $\text{max_depth} \in [6, 8]$ та $\text{n_estimators} \in [100, 200]$ успішно запобігає перенавантаженню на артефактах спотворень. Разом із тим підтверджено високу обчислювальну ефективність підходу: запропонована модель мінімізує навантаження, забезпечуючи час інференсу на рівні 0.1–0.25 секунди, що робить її придатною для розгортання на наземних системах прийому даних ДДЗ із обмеженими ресурсами. У підсумку, інтеграція простору ознак LBP і методів ансамблевого навчання формує надійний базовий рівень (baseline) для розробки стійких систем дистанційного зондування Землі, гарантуючи високий рівень точності класифікації різних класів земної поверхні в умовах експлуатації даних, спотворених при їх зберіганні та передачі.

Внесок авторів: концептуалізація, методологія – Максим Рибницький, Сергій Кривенко; формулювання завдань, аналіз – Максим Рибницький, Сергій Кривенко, Володимир Лукін; розробка моделі, програмного забезпечення, верифікація – Максим Рибницький; аналіз результатів, візуалізація – Максим Рибницький; підготовка оригінальної чернетки – Максим Рибницький, написання – рецензування та редагування – Максим Рибницький, Сергій Кривенко, Володимир Лукін.

Конфлікт інтересів

Автори заявляють, що в них немає конфлікту інтересів щодо цього дослідження, фінансового, особистого, авторського чи іншого, який міг би вплинути на дослідження та його результати, представлені в цій статті.

Фінансування

Роботу виконано за підтримки Національного Фонду досліджень України в рамках теми "Розробка ефективних методів та засобів видобування корисної інформації з даних спостереження земної поверхні з літальних апаратів" ("Передова наука в Україні 2026-

2028", 2025.07/0253).

Доступність даних

Дані буде надано за обґрунтованим запитом.

Використання штучного інтелекту

Під час підготовки початкової чернетки рукопису були використані генеративні інструменти штучного інтелекту для допоміжного мовного редагування та структуризації тексту; перевірка фактів, інтерпретація результатів і фінальне наукове редагування мають бути виконані автором перед поданням.

Усі автори прочитали та погодили остаточну версію рукопису.

Література

1. Dritsas, E. *Remote Sensing and Geospatial Analysis in the Big Data Era: A Survey* / E. Dritsas, M. Trigka // *Remote Sensing*. – 2025. – Vol. 17, no. 3. – 30 p. DOI: 10.3390/rs17030550.
2. Review of compression approaches for optical remote-sensing images from post-processing perspective / X. Chen, H. Zhou, Y. Li et al. // *Geocarto International*. – 2026. – Vol. 41, iss. 1. – 23 p. DOI: 10.1080/10106049.2026.2647547.
3. Effects of Lossy Compression on Remote Sensing Image Classification Based on Convolutional Sparse Coding / J. Wei, L. Mi, Y. Hu et al. // *IEEE Geoscience and Remote Sensing Letters*. – 2021. – Vol. 19. – P. 1–5. DOI: 10.1109/LGRS.2020.3047789.
4. On classifier performance for remote sensing images compressed by different coders / G. Proskura, O. Rubel, S. Kryvenko, V. Lukin // *Aerospace Technic and Technology*. – 2023. – №. 1 (185). – P. 67–77. DOI: 10.32620/aktt.2023.1.07.
5. Noise Reduction in Hyperspectral Imagery: Overview and Application / B. Rasti, P. Scheunders, P. Ghamisi et al. // *Remote Sensing*. – 2018. – Vol. 10, iss. 3. – 28 p. DOI: 10.3390/rs10030482.
6. Maxwell, A. E. Implementation of machine-learning classification in remote sensing: an applied review / A. E. Maxwell, T. A. Warner, F. Fang // *International Journal of Remote Sensing*. – 2018. – Vol. 39, iss. 9. – P. 2784–2817 DOI: 10.1080/01431161.2018.1433343.
7. Robustness of Lossy Multispectral Compression to Simulated Instrumental Noise: A Comparative Study / J. González-de-Regàs, S. Mijares, J. Bartrina-Rapesta, J. Serra-Sagristà // *IEEE Geoscience and Remote Sensing Letters*. – 2025. – Vol. 22. – P. 1–5. DOI: 10.1109/LGRS.2025.3623314.
8. Computer Vision Using Local Binary Patterns / M. Pietikäinen, A. Hadid, G. Zhao, T. Ahonen // *Springer*. – 2011. – Vol. 40. – 228 p. DOI: 10.1007/978-0-85729-748-8.
9. Zhao, Z. Adjacent paired LBP and enhanced HOG for improved facial expression recognition /

Z. Zhao, N. Zheng // *SPIE International Conference on Computer Vision, Robotics and Automation Engineering*. – 2025. – Vol. 13790. – 6 p. DOI: 10.1117/12.3082520.

10. Ojala, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns / T. Ojala, M. Pietikainen, T. Maenpää // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2002. – Vol. 24, iss. 7. – P. 971–987. DOI: 10.1109/TPAMI.2002.1017623.

11. Liao, S. Dominant Local Binary Patterns for Texture Classification / S. Liao, M. Law, A. Chung // *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*. – 2009. – Vol. 18, iss. 5. – P. 1107–1118. DOI: 10.1109/TIP.2009.2015682.

12. Adaptive random forests for evolving data stream classification / H. M. Gomes, A. Bifet, J. Read et al. // *Mach Learn*. – 2017. – Vol. 106, iss. 9–10. – P. 1469–1495. DOI: 10.1007/s10994-017-5642-8.

13. A Lightweight Detection Method for Remote Sensing Images and Its Energy-Efficient Accelerator on Edge Devices / R. Yang, Z. Chen, B. Wang et al. // *Sensors*. – 2023. – Vol. 23, iss. 14. – 27 p. DOI: 10.3390/s23146497.

14. Zhai, G. Perceptual image quality assessment: a survey / G. Zhai, X. Min // *Science China Information Sciences*. – 2020. – Vol. 63. – 52 p. DOI: 10.1007/s11432-019-2757-1.

15. On the Impact of Lossy Compression on Hyperspectral Image Classification and Unmixing / F. Garcia-Vilchez, J. Muñoz, M. Zortea et al. // *IEEE Geoscience and Remote Sensing Letters*. – 2011. – Vol. 8, iss. 2. – P. 253–257. DOI: 10.1109/LGRS.2010.2062484.

16. Bernacki, J. Algorithms and Methods for Individual Source Camera Identification: A Survey / J. Bernacki, R. Scherer // *Sensors*. – 2025. – Vol. 25, iss. 10. – 43 p. DOI: 10.3390/s25103027.

17. An Efficient Decision Support System for Flood Inundation Management Using Intermittent Remote-Sensing Data / H. Sun, X. Dai, W. Shou et al. // *Remote Sensing*. – 2021. – Vol. 13, iss. 14. – 26 p. DOI: 10.3390/rs13142818.

18. BPG Image format. Available et: <https://bellard.org/bpg/> (accessed: July 13, 2025)

19. Chen, T. XGBoost: A Scalable Tree Boosting System / T. Chen, C. Guestrin // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, in KDD '16*. New York, NY, USA: Association for Computing Machinery. – 2016. – P. 785–794. DOI: 10.1145/2939672.2939785.

20. Satellite Multispectral and Hyperspectral Image De-Noising with Enhanced Adaptive Generalized Gaussian Distribution Threshold in the Wavelet Domain / N. A. Golilarz, H. Gao, S. Pirasteh et al. // *Remote Sensing*. – 2021. – vol. 13, iss. 1. – 16 p. DOI: 10.3390/rs13010101.

21. Prediction of parameters in optimal operation point for BPG-based lossy compression of noisy images / B. Kovalenko, V. Lukin, S. Kryvenko et al. // *Ukrainian*

journal of remote sensing. – 2022. – Vol. 9, iss. 2. – P. 4–12.

22. Information Leakage in Deep Learning-Based Hyperspectral Image Classification: A Survey / H. Feng, Y. Wang, Z. Li et al. // *Remote Sensing*. – 2023. – Vol. 15, iss. 15. – 34 p. DOI: 10.3390/rs15153793.

23. Importance of spatial predictor variable selection in machine learning applications – Moving from data reproduction to spatial prediction / H. Meyer, C. Reudenbach, S. Wöllauer, T. Nauss // *Ecological Modelling*. – 2019. – Vol. 411. – 12 p. DOI: 10.1016/j.ecolmodel.2019.108815.

24. Abdi, A. M. Forest tree species classification and entropy-derived uncertainty mapping using extreme gradient boosting and Sentinel-1/2 satellite data / A. M. Abdi, F. Wang. – 2025. Available et: <https://api.semanticscholar.org/CorpusID:281496896>

25. Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure / D. R. Roberts, V. Bahn, S. Ciuti et al. // *Ecography*. – 2017. – Vol. 40, iss. 8. – P. 913–929. DOI: 10.1111/ecog.02881.

26. A combined approach to pixel-wise classification of satellite images based on LBP, pseudocolor features, and XGBoost / M. Rybnytskyi, S. Kryvenko, V. Lukin, V. Rebrov // *Radioelectronic and Computer Systems*. – 2025. – № 4 (116). – P. 206–219. DOI: 10.32620/reks.2025.4.14.

27. Yang, S. The receiver operating characteristic (ROC) curve / S. Yang, G. Berdine // *The Southwest Respiratory and Critical Care Chronicles*. – 2017. – Vol. 5, iss. 19. – p. 34–36. DOI: 10.12746/swrccc.v5i19.391.

28. BPG-Based Automatic Lossy Compression of Noisy Images with the Prediction of an Optimal Operation Existence and Its Parameters / B. Kovalenko, V. Lukin, S. Kryvenko et al. // *Applied Sciences*. – 2022. – Vol. 12, iss. 15. – 23 p. DOI: 10.3390/app12157555

References

1. Dritsas, E., Trigka, M. Remote Sensing and Geospatial Analysis in the Big Data Era: A Survey. *Remote Sensing*, 2025, vol. 17, no. 3. 30 p. DOI: 10.3390/rs17030550..

2. Chen, X., Zhou, H., Li, Y., Wang, Z., Shan, F., Lin, W., Da, H., Li, J. Review of compression approaches for optical remote-sensing images from post-processing perspective. *Geocarto International*, 2026, vol. 41, iss. 1. 23 p. DOI: 10.1080/10106049.2026.2647547.

3. Wei, J., Mi, L., Hu, Y., Ling, J., Li, Y., Chen, Z. Effects of Lossy Compression on Remote Sensing Image Classification Based on Convolutional Sparse Coding. *IEEE Geoscience and Remote Sensing Letters*, 2021, vol. 19, pp. 1–5. DOI: 10.1109/LGRS.2020.3047789.

4. Proskura, G., Rubel, O., Kryvenko, S., Lukin, V. On classifier performance for remote sensing images compressed by different coders. *Aerospace Technic and Technology*, 2023, no. 1 (185), pp. 67–77.

DOI: 10.32620/aktt.2023.1.07.

5. Rasti, B., Scheunders, P., Ghamisi, P., Licciardi, G., Chanussot, J. Noise Reduction in Hyperspectral Imagery: Overview and Application. *Remote Sensing*, 2018, vol. 10, iss. 3. 28 p. DOI: 10.3390/rs10030482.

6. Maxwell, A. E., Warner, T. A., Fang, F. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 2018, vol. 39, iss. 9, pp. 2784–2817. DOI: 10.1080/01431161.2018.1433343.

7. González-de-Regàs, J., Mijares, S., Bartrina-Rapesta, J., Serra-Sagristà, J. Robustness of Lossy Multispectral Compression to Simulated Instrumental Noise: A Comparative Study. *IEEE Geoscience and Remote Sensing Letters*, 2025, vol. 22, pp. 1–5. DOI: 10.1109/LGRS.2025.3623314.

8. Pietikäinen, M., Hadid, A., Zhao, G., Ahonen, T. Computer Vision Using Local Binary Patterns. *Springer*, 2011, vol. 40. 228 p. DOI: 10.1007/978-0-85729-748-8.

9. Zhao, Z., Zheng, N. Adjacent paired LBP and enhanced HOG for improved facial expression recognition. *SPIE International Conference on Computer Vision, Robotics and Automation Engineering*, 2025, vol. 13790. 6 p. DOI: 10.1117/12.3082520.

10. Ojala, T., Pietikainen, M., Maenpaa, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, vol. 24, no. 7, pp. 971–987. DOI: 10.1109/TPAMI.2002.1017623.

11. Liao, S., Law, M., Chung, A. Dominant Local Binary Patterns for Texture Classification. *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society*, 2009, vol. 18, iss. 5, pp. 1107–1118. DOI: 10.1109/TIP.2009.2015682.

12. Gomes, H. M., Bifet, A., Read, J., Barddal, J. P., Enembreck, F., Pfharinger, B., Holmes, G., Abdessalem, T. Adaptive random forests for evolving data stream classification. *Machine Learning*, 2017, vol. 106, iss. 9–10, pp. 1469–1495. DOI: 10.1007/s10994-017-5642-8.

13. Yang, R., Chen, Z., Wang, B., Guo, Y., Hu, L. A Lightweight Detection Method for Remote Sensing Images and Its Energy-Efficient Accelerator on Edge Devices. *Sensors*, 2023, vol. 23, iss. 14. 27 p. DOI: <https://doi.org/10.3390/s23146497>.

14. Zhai, G., Min, X. Perceptual image quality assessment: a survey. *Science China Information Sciences*, 2020, vol. 63. 52 p. DOI: 10.1007/s11432-019-2757-1.

15. Garcia-Vilchez, F., Muñoz, J., Zortea, M., Blanes, I., Gonzalez-Ruiz, V., Camps-Valls, G., Plaza, A., Serra-Sagristà, J. On the Impact of Lossy Compression on Hyperspectral Image Classification and Unmixing. *Geoscience and Remote Sensing Letters*,

IEEE, 2011, vol. 8, iss. 2, pp. 253–257. DOI: 10.1109/LGRS.2010.2062484.

16. Bernacki, J., Scherer, R. Algorithms and Methods for Individual Source Camera Identification: A Survey. *Sensors*, 2025, vol. 25, iss. 10. 43 p. DOI: 10.3390/s25103027.

17. Sun, H., Dai, X., Shou, W., Wang, J., Ruan, X. An Efficient Decision Support System for Flood Inundation Management Using Intermittent Remote-Sensing Data. *Remote Sensing*, 2021, vol. 13, iss. 14. 26 p. DOI: 10.3390/rs13142818.

18. BPG Image format. Available et: <https://bellard.org/bpg/> (accessed: July 13, 2025).

19. Chen, T., Guestrin, C. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, in KDD '16. New York, NY, USA: Association for Computing Machinery*, 2016, pp. 785–794. DOI: 10.1145/2939672.2939785

20. Golilarz, N. A., Gao, H., Pirasteh, S., Yazdi, M., Zhou, J., Fu, Y. Satellite Multispectral and Hyperspectral Image De-Noising with Enhanced Adaptive Generalized Gaussian Distribution Threshold in the Wavelet Domain. *Remote Sensing*, 2021, vol. 13, iss. 1. 16 p. DOI: 10.3390/rs13010101.

21. Kovalenko, B., Lukin, V., Kryvenko, S., Naumenko, V., Vozel, B. Prediction of parameters in optimal operation point for BPG-based lossy compression of noisy images. *Ukrainian journal of remote sensing*, 2022, vol. 9, iss. 2, pp. 4–12.

22. Feng, H., Wang, Y., Li, Z., Zhang, N., Zhang, Y., Gao, Y. Information Leakage in Deep Learning-Based Hyperspectral Image Classification: A Survey. *Remote Sensing*, 2023, vol. 15, iss. 15. – 34 p. DOI: 10.3390/rs15153793.

23. Meyer, H., Reudenbach, C., Wöllauer, S.,

Nauss, T. Importance of spatial predictor variable selection in machine learning applications – Moving from data reproduction to spatial prediction. *Ecological Modelling*, 2019, vol. 411. 12 p. DOI: 10.1016/j.ecolmodel.2019.108815.

24. Abdi, A. M., Wang, F. *Forest tree species classification and entropy-derived uncertainty mapping using extreme gradient boosting and Sentinel-1/2 satellite data*, 2025. Available et: <https://api.semanticscholar.org/CorpusID:281496896>

25. Roberts, D. R., Bahn, V., Ciuti, S., Boyce, M. S., Elith, J., Guillera-Aroita, G., Hauenstein, S., Lahoz-Monfort, J. J., Schröder, B., Thuiller, W., Warton, D. I., Wintle, B. A., Hartig, F., Dormann, C. F. Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 2017, vol. 40, iss. 8, pp. 913–929. DOI: 10.1111/ecog.02881.

26. Rybnytskyi, M., Kryvenko, S., Lukin, V., Rebrov, V. A combined approach to pixel-wise classification of satellite images based on LBP, pseudocolor features, and XGBoost. *Radioelectronic and Computer Systems*, 2025, no. 4 (116), pp. 206–219. DOI: 10.32620/reks.2025.4.14.

27. Yang, S., Berdine, G. The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles*, 2017, vol. 5, iss. 19. p. 34–36. DOI: 10.12746/swrccc.v5i19.391.

28. Kovalenko B., Lukin V., Kryvenko S., Naumenko V., Vozel B. BPG-Based Automatic Lossy Compression of Noisy Images with the Prediction of an Optimal Operation Existence and Its Parameters. *Applied Sciences*, 2022, vol. 12, iss. 15. 23 p. DOI: 10.3390/app12157555.

Надійшла до редакції 12.05.2026, отримано в доопрацьованому вигляді 29.07.2026,
Дата ухвалення 17.08.2026, дата публікації 26.08.2026

IMPROVEMENT OF THE PIXEL-WISE CLASSIFICATION METHOD FOR REMOTE SENSING DATA UNDER DISTORTIONS BASED ON COMBINED LBP FEATURES

Maksym Rybnytskyi, Sergii Kryvenko, Volodymyr Lukin

The subject of this article is the process of pixel-wise classification of satellite images under distortions caused by lossy data compression and additive white Gaussian noise (AWGN). **The relevance of the work is driven by the fact that** while previous studies using the Local Binary Patterns (LBP) method have demonstrated promising results, they have also revealed the high sensitivity of baseline configurations with a small feature extraction radius to additive pixel noise and compression artifacts (such as boundary blurring and the formation of block effects). In certain cases, this leads to the misclassification of homogeneous areas distorted by compression (e.g., misidentifying water surfaces as vegetation). **The goal is** to improve the accuracy of pixel-wise classification of satellite images under distortions by developing a robust approach based on a combined feature space that integrates spectral intensity and texture information of different scales. **The tasks addressed are:** conducting an experimental analysis on 4 diverse satellite scenes modeled under 4 distortion states (reference image, noisy, and two levels of compression); forming an expanded feature space using the combined LBP (by integrating radii of 1, 2, and 3 pixels); and tuning and optimizing the hyperparameters of the XGBoost ensemble classifier. **The methods used** are based on texture analysis tools,

decision-tree-based machine learning algorithms, and statistical accuracy assessment techniques. **The study's results** experimentally confirm that combining LBP descriptors across different radii partially mitigates microtexture loss caused by compression. **Conclusions.** The findings confirm that the proposed algorithm effectively compensates for the shortcomings of individual LBP texture descriptors under image distortion conditions. The practical significance of the obtained results lies in establishing a reliable baseline for developing robust automated monitoring and analysis systems for Earth remote sensing (RS) data.

Keywords: pixel-wise classification; remote sensing data; LBP; combined LBP; XGBoost; image distortions; additive white Gaussian noise; data compression.

Рибницький Максим Анатолійович – асп. каф. інформаційно-комунікаційних технологій ім. О. О. Зеленського, Національний аерокосмічний університет «Харківський авіаційний інститут», Харків, Україна.

Кривенко Сергій Станіславович – д-р техн. наук, старш. наук. співроб каф. інформаційно-комунікаційних технологій ім. О. О. Зеленського, Національний аерокосмічний університет «Харківський авіаційний інститут», Харків, Україна.

Лукін Володимир Васильович – д-р техн. наук, проф., зав. каф. інформаційно-комунікаційних технологій ім. О. О. Зеленського, Національний аерокосмічний університет «Харківський авіаційний інститут», Харків, Україна.

Maksym Rybnytskyi – PhD Student of the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: m.a.rybnytskyi@khai.edu, ORCID: 0009-0000-1299-1604

Sergii Kryvenko – Doctor of Technical Sciences, Senior Research Scientist at the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: s.kryvevko@khai.edu, ORCID: 0000-0001-6027-5442.

Volodymyr Lukin – Doctor of Technical Sciences, Professor, Head of the Department of Information-Communication Technologies named after O. O. Zelensky, National Aerospace University "Kharkiv Aviation Institute", Kharkiv, Ukraine, e-mail: v.lukin@khai.edu, ORCID: 0000-0002-1443-9685.