



<https://doi.org/10.36023/ujrs.2026.13.1.303>

УДК 621.3:681.34

## Вплив конфігурацій локальних бінарних шаблонів та XGBoost на якість класифікації супутникових зображень із шумом і стисненням: експериментальне дослідження

М. А. Рибницький\*, <https://orcid.org/0009-0000-1299-1604>

С. С. Кривенко, <https://orcid.org/0000-0001-6027-5442>

Національний аерокосмічний університет «Харківський авіаційний інститут», вул. Вадима Манька, 17, м. Харків, 61070, Україна

У роботі розв'язується актуальна задача попиксельної класифікації мультиспектральних супутникових зображень в умовах критичного зниження якості даних, спричиненого адитивним шумом сенсорів та артефактами стиснення із втратами. Розглядається метод виділення просторових ознак на основі локальних бінарних шаблонів (LBP) з використанням різних конфігурацій (1:8, 2:16, 3:24) та їх комбінацій для підвищення точності розділення класів. Експериментальне дослідження проведено на фрагментах знімків Sentinel-2 (Харківська область), спотворених адитивним гаусівським шумом з дисперсією  $\sigma^2 = 100$  та підданих поканальному стисненню кодером BPG. Як класифікатор використано ансамбль дерев рішень XGBoost. Результати моделювання підтвердили, що застосування номасштабних шаблонів LBP є недостатнім для надійної сегментації гетерогенних об'єктів в умовах сильного шуму. Доведено, що формування розширеного вектора ознак шляхом конкатенації мультимасштабних конфігурацій LBP (1:8, 2:16, 3:24) забезпечує підвищення метрики F1-міра до 0.9530, що більш ніж на 1% перевищує показники базових конфігурацій. Детальний аналіз динаміки метрик у розрізі класів виявив, що клас «Вода» демонструє найвищу стабільність ( $F1 > 0.99$ ) завдяки спектральній однорідності. Водночас для структурно складних класів «Урбанізація» та «Рослинність» критично важливим виявилось залучення ознак великого радіуса, що дало змогу мінімізувати вплив локальних флуктуацій яскравості та стабілізувати метрику AUC на рівні  $> 0.99$ . Важливим емпіричним результатом стало виявлення позитивного впливу стиснення на точність класифікації зашумлених зображень: квантування коефіцієнтів кодером BPG спрацювало як низькочастотний фільтр, частково компенсуючи високочастотну складову гаусівського шуму. Додаткове дослідження в околицях оптимальної робочої точки показало, що метод зберігає робастність при помірних змінах ( $Q = 31$ ), а також продовжує демонструвати високу стабільність та збереження точності сегментації навіть при значному посиленні артефактів стиснення ( $Q = 43$ ), що підтверджує надійність та ефективність алгоритму в усьому дослідженому діапазоні компресійних спотворень. Встановлено, що інтеграція текстурних ознак різного масштабу дає змогу моделі XGBoost формувати стійкі вирішальні правила, при цьому оптимальний баланс між обчислювальною складністю та точністю досягається при обмеженні параметрів ансамблю (дерева = 200, глибина = 8), оскільки подальше ускладнення моделі не призводить до статистично значущого приросту якості розпізнавання.

**Ключові слова:** дистанційне зондування Землі, супутникові зображення Sentinel-2, попиксельна класифікація, XGBoost, локальні бінарні шаблони (LBP), текстурний аналіз, стиснення зображень, BPG-кодер.

© М. А. Рибницький, С. С. Кривенко, 2026

### Вступ

Класифікація супутникових зображень є важливим завданням для вирішення широкого спектра прикладних проблем у моніторингу довкілля, плануванні будівництва та інших сферах (Li et al., 2024). Попиксельна класифікація може ускладнюватися наявністю шуму в отриманих зображеннях, схожістю ознак пікселів, які фактично належать різним класам, а також артефактами, спричиненими стисненням (Abramova et al., 2022; De Jong & Meer, 2007; West et al., 2019). Важливо, щоб алгоритми класифікації були стійкими до таких спотворень та враховували просторові взаємозв'язки

між пікселями, що може суттєво підвищити точність розмежування класів (Firat et al., 2022).

Ансамблеві методи, зокрема Random Forest (RF), широко застосовуються у класифікації даних дистанційного зондування. Вони показують високу стійкість до перенавчання, високу ефективність та низькі вимоги до обчислювальних ресурсів (Belgiu & Drăguț, 2016). RF дає змогу вирішувати задачі розпізнавання різноманітних класів на багатоканальних супутникових зображеннях, забезпечуючи баланс між точністю класифікації та швидкістю оброблення. Водночас, сучасні модифікації ансамблевих класифікаторів на базі дерев рішень, такі як XGBoost, демонструють

\*Corresponding author / Автор для кореспонденції: М. А. Rybnytskyi / М. А. Рибницький / [m.a.rybnytskyi@khai.edu](mailto:m.a.rybnytskyi@khai.edu)

This is an Open Access article under the CC BY licenses (<http://creativecommons.org/licenses/by/4.0/>)

Стаття опублікована на умовах відкритого доступу за ліцензією CC BY (<http://creativecommons.org/licenses/by/4.0/>)

високу продуктивність у складних задачах класифікації, зокрема завдяки можливості простого налаштування параметрів моделі та ефективній роботі з великими обсягами даних (Chen & Guestin, 2016).

Слід також зазначити, що сучасні класифікатори на базі глибоких нейронних мереж, хоча й демонструють високу точність у багатьох задачах, мають низку суттєвих обмежень. Зокрема, вони вимагають значних обчислювальних ресурсів, великого обсягу навчальних даних, складного налаштування архітектури та гіперпараметрів, а також часто характеризуються меншою інтерпретованістю результатів порівняно з ансамблевими методами (Belgiu & Drăguț, 2016).

XGBoost, як і RF є ансамблевим класифікатором, крім того, реалізує градієнтний бустинг (Shao et al., 2024). У попередньому дослідженні (Rybnytskyi et al., 2025) з використанням XGBoost та одного набору локальних бінарних шаблонів (LBP) (Pietikäinen et al., 2011) для попиксельної класифікації були отримані перспективні результати. У отриманих результатах переважали помилки класифікації між такими класами як “Вода” та “Рослинність”. Також підкреслено особливості роботи класифікатора в умовах стиснення та завад. Згідно з рекомендаціями у (Belgiu & Drăguț, 2016), для підвищення ефективності ансамблевих методів важливо оптимально підбирати глибину дерев, зокрема орієнтуватись на значення, що відповідає квадратному кореню з кількості параметрів, які використовуються в моделі. Автори (Pietikäinen et al., 2011) рекомендують використовувати різні конфігурації LBP, а також їх поєднання, для покращення точності класифікації.

## Мета дослідження

Полягає у комплексному оцінюванні впливу комбінованих спотворень (адитивного білого гаусівського шуму та артефактів стиснення з втратами кодером BPG) на точність попиксельної класифікації мультиспектральних супутникових зображень Sentinel-2. Крім того, дослідження виконується з метою визначення ефективності мультимасштабного текстурного аналізу як механізму компенсації втрати якості даних та дослідження поведінки класифікатора XGBoost в умовах деградації ознак.

Для досягнення поставленої мети сформульовано такі головні задачі:

- Провести порівняльний аналіз інформативності номасштабних (1:8, 2:16, 3:24) та комбінованих (1:8+2:16+3:24) конфігурацій локальних бінарних шаблонів (LBP) в умовах зашумлення та різних рівнів стиснення (в оптимальній робочій точці та її околицях).
- Дослідити динаміку метрик точності (макроусередненої F1-міри та AUC) залежно від зміни архітектурних параметрів класифікатора XGBoost (максимальної глибини та кількості дерев ансамблю).

- Виконати детальний покласовий аналіз (“Вода”, “Рослинність”, “Відкритий ґрунт”, “Урбанізація”) для виявлення специфіки впливу артефактів стиснення на структурно різні об’єкти та визначення критичних меж робастності моделі.

- Сформулювати науково обґрунтовані рекомендації щодо підбору оптимальних гіперпараметрів моделі та просторових ознак, які забезпечують найкращий компроміс між точністю сегментації деградованих даних та обчислювальною складністю.

## Матеріали та методи дослідження


Для дослідження було обрано підготовлені зображення Sentinel-2, які було використано в роботі (Rybnytskyi et al., 2025). Оригінальне зображення охоплює територію Харківської області (Україна). Вибір цієї ділянки обумовлений відсутністю атмосферних перешкод (хмарності) та різноманітністю ландшафту, що містить усі необхідні класи об’єктів (вода, рослинність, забудова, ґрунт). Знання особливостей цієї території дало змогу виконати коректну розмітку навчальної вибірки та сформувати маски класів для тренування моделі.

Для моделювання спотворень, що виникають у процесі реєстрації сигналу сенсорами (зокрема теплового шуму), застосовано модель адитивного білого гаусівського шуму (АБГШ). Використання такої моделі з фіксованою дисперсією  $\sigma^2 = 100$  є загальноприйнятою практикою для первинного аналізу та базової оцінки робастності алгоритмів оброблення даних дистанційного зондування. Такий підхід свідомо обрано для того, щоб зберегти спадкоємність експериментальних умов і забезпечити можливість прямого та коректного порівняння отриманих результатів із попередніми базовими дослідженнями.

Щодо етапу стиснення, то базовим сценарієм є використання ефективного BPG кодера (*BPG Image format*, б. д.) безпосередньо в оптимальній робочій точці (OPT), якій відповідає коефіцієнт якості  $Q = 35$  (Kovalenko et al., 2022). Проте, оскільки на практиці можуть виникати сценарії, що вимагають налаштування параметрів для забезпечення більшого коефіцієнта стиснення або вищої візуальної якості, це дослідження було розширено. Для більш повного аналізу додатково розглянуто випадки в околицях OPT. Зокрема, було обрано два додаткових значення коефіцієнта якості:  $Q = 31$  та  $Q = 43$ . Як свідчить візуальний аналіз графіка залежності PSNR для зображення SS1 (Рис. 1), ці дві точки характеризуються близькими значеннями метрики PSNR для відповідних каналів, але знаходяться по різні боки від максимуму в OPT. Це дає змогу всебічно та об’єктивно оцінити поведінку запропонованої моделі класифікації при відхиленнях від оптимальних умов стиснення.

Варто зазначити, що процедура стиснення виконувалася поканально: кожен спектральний канал оброблявся кодером незалежно, після чого декодовані компоненти об’єднувалися у результуюче

триканальне RGB-зображення. Отримані зображення мають розмір 512x512 пікселів.



**Рис. 1.** Криві залежності PSNR від  $Q$  для покомпонентного (поканального) стиснення зображення з використанням кодера BPG,  $\sigma^2 = 100$

Для побудови стенду дослідження використано мову програмування Python та такі ключові бібліотеки, як XGBoost, Scikit-Learn, Scikit-Image. Оцінку ефективності роботи різних конфігурацій класифікатора проведено за допомогою метрик F-міра (Punia, 2023) та AUC (Yang & Berdine, 2017).

### Результати дослідження

Для експерименту було обрано чотири зображення SS1:

а) з адитивним гаусівським шумом без стиснення (Рис. 2);

б) з адитивним гаусівським шумом та стиснене за допомогою ефективного кодера BPG з коефіцієнтом якості  $Q = 31$  (Рис. 3а);

в) з адитивним гаусівським шумом та стиснене за допомогою ефективного кодера BPG з коефіцієнтом якості  $Q = 35$  (ОПТ) (Рис. 3б);

г) з адитивним гаусівським шумом та стиснене за допомогою ефективного кодера BPG з коефіцієнтом якості  $Q = 43$  (Рис. 3в).




**Рис. 2.** Зображення SS1 із доданим гаусівським шумом ( $\sigma^2 = 100$ )

У ході експерименту було перевірено вплив кількості використаних дерев ( $n\_estimators$ ) та глибину моделі ( $max\_depth$ ) на точність класифікації обраних зображень.



а)



б)



в)

**Рис. 3.** Зображення SS1 із доданим гаусівським шумом ( $\sigma^2 = 100$ ) після стиснення кодером BPG із коефіцієнтом якості: а)  $Q = 31$ ; б)  $Q = 35$ ; в)  $Q = 43$

Вибір цих значень обумовлений практикою згаданих раніше досліджень та рекомендаціями з офіційної документації XGBoost (XGBoost Documentation – *xgboost 3.0.2 documentation*, б. д.), діапазон  $n\_estimators$  дає змогу дослідити, як збільшення кількості дерев впливає на якість моделі та перенавчання, значення  $max\_depth$  обрані для балансу між здатністю моделі вловлювати складні залежності (більша глибина) та ризиком перенавчання (надто велика глибина).

Такі діапазони параметрів часто використовуються в роботах, присвячених

оптимізації XGBoost для задач класифікації зображень (Chen & Guestrin, 2016). Крім того, параметр  $\eta = 0.3$  є типовим стартовим значенням для швидкої збіжності моделі, а використання `eval_metric='mlogloss'` та `objective='multi:softmax'` відповідає задачі багатокласової класифікації.

На Рис. 4 наведені результати, що характеризують точність класифікації для зображення SS1 з адитивним гаусівським шумом з  $\sigma^2 = 100$  з використанням макроусередненої F1-міри ( $F1\_score$ , б. д.).




Рис. 4. F1-міра (макроусереднення) для різних конфігурацій LBP

Зі збільшенням глибини та кількості дерев точність класифікації підвищується. Починаючи з кількості дерев рівної 200 та більше, а також після глибини 8 приріст точності класифікації незначний, і криві виходять на плато. Суттєвим фактором підвищення точності стало збільшення області аналізу текстур. Використання LBP з більшим радіусом та поєднання декількох наборів ознак покращило результати. Для 200 дерев та глибини 8 при використанні LBP (1:8) значення становить 0.9314, тоді як для тієї ж конфігурації XGBoost але з використанням поєднаних конфігурацій LBP (1:8; 2:16; 3:24) значення становило 0.9494. Тобто приріст становить більше 1%.


На Рис. 5 наведено метрику F1-міра для кожного класу окремо. Загальний тренд щодо покращення класифікації зі збільшенням кількості дерев та глибини зберігається для всіх класів, виходячи на плато (незначний приріст) і починаючи зі значення 200 дерев та глибини 8. Детальний аналіз графіків дає змогу виділити відмінності у розпізнаванні об'єктів. Найкращі показники демонструє клас “Вода”: завдяки високій спектральній однорідності він стабільно розпізнається з точністю  $F1 > 0.99$  навіть при мінімальній складності моделі.

Натомість класи “Урбанізація” та “Рослинність” виявилися складнішими для класифікації на початкових етапах (мала глибина дерев), що пояснюється їхньою текстурною гетерогенністю. Проте, саме ці класи демонструють найбільший приріст точності при збільшенні параметрів моделі та використанні комбінованих LBP, що підтверджує необхідність мультимасштабного аналізу для складних ландшафтів.

Для оцінювання дискримінаційної здатності моделі XGBoost використано метрику AUC. Вона дає змогу визначити, наскільки добре модель розрізняє класи незалежно від вибраного порога класифікації.

AUC відображає загальну впевненість моделі у прийнятті рішень та є стійкою до дисбалансу класів, що особливо важливо для задач класифікації даних дистанційного зондування, через присутність значних однорідних частин на зображеннях. Для багатокласової класифікації використовується метрика AUC у підході “Один проти всіх” (“One-vs-Rest”). Це означає, що для кожного класу модель оцінює здатність відрізняти цей клас від усіх інших, розглядаючи задачу як набір бінарних класифікацій.

Набір бінарних класифікацій – це підхід, при якому багатокласову задачу розбивають на кілька окремих задач, де кожна з них має лише два класи: “цільовий клас” проти “всі інші”. Для кожного класу створюється окрема модель або оцінка, яка визначає, чи належить об'єкт до цього класу, чи ні. Таким чином, замість однієї багатокласової класифікації, аналіз проводиться як сукупність простих бінарних (двокласових) задач, що дає змогу детальніше оцінити якість розпізнавання кожного класу окремо. Завдяки такому підходу можна детально проаналізувати якість розпізнавання кожного окремого класу, що важливо для комплексного оцінювання моделі на даних дистанційного зондування.




**Рис. 5.** F1-міра для кожного класу окремо:  
а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

На Рис. 6 наведено результати оцінювання моделі за метрикою AUC. Відповідно до отриманих результатів значення метрики AUC зростають зі збільшенням площі, яку покриває LBP, а найвищі значення отримані для комбінації різних конфігурацій LBP.


Приріст для LBP (1:8; 2:16; 3:24) у порівнянні з LBP (1:8) для 200 дерев та глибини 8 становив 0.0046. Також варто відзначити, що значення метрики AUC для кожного окремого випадку LBP

конфігурації залишається майже незмінним, починаючи з глибини 10, лише конфігурація з 10 деревами показує зміни для усіх випадків глибини.



**Рис. 6.** AUC (макроусереднення, один проти всіх) для різних конфігурацій LBP

На Рис. 7 деталізовано значення метрики AUC для кожного класу. Аналіз кривих виявляє суттєву розбіжність у стійкості розпізнавання різних типів поверхонь залежно від конфігурації LBP. Для текстурно однорідного класу “Вода” при використанні шаблону малого радіуса (LBP 1:8) зафіксовано аномальну поведінку: зі збільшенням складності моделі (глибини та кількості дерев) дискримінаційна здатність не зростає, а демонструє тенденцію до зниження.



**Рис. 7.** AUC для кожного класу окремо:  
а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

Це свідчить про ефект перенавчання на високочастотному шумі: малий радіус LBP “сприймає” піксельний шум як текстурні ознаки води, що призводить до помилок при формуванні складних вирішальних правил. Схожа, хоч і менш виражена динаміка, спостерігається для класу “Рослинність”. Водночас, перехід до комбінованих мультимасштабних конфігурацій (нижній ряд графіків) повністю нівелює цей недолік. Залучення ознак з більшим радіусом (2:16, 3:24) дає змогу ефективно фільтрувати локальні шумові артефакти, забезпечуючи стабільне зростання AUC до рівня  $>0.99$  для всіх класів, включаючи складний для сегментації клас “Урбанізація”.

На Рис. 8 деталізовано маски класифікації для зображення з інтенсивним гаусівським шумом ( $\sigma^2 = 100$ ) при використанні комбінованої конфігурації LBP.

Хоча візуально результати дуже схожі, мультимасштабний підхід успішно нівелює шум, формуючи суцільні регіони (найкраще це помітно на однорідному класі “Вода”). Збільшення кількості дерев (від 10 до 100) та глибини (від 5 до 8) очікувано зменшує ефект “солі та перцю” на межах складних класів і точніше окреслює контури об’єктів. Проте подальше нарощування параметрів (аж до 500 дерев та глибини 15) вже не приносить жодних видимих візуальних змін. Саме ця ідентичність масок на етапі насичення моделі доводить, що експертної оцінки “на око” недостатньо. Це беззаперечно підтверджує критичну необхідність покладатися на кількісні метрики (F1, AUC) для точного вибору оптимальної архітектури.

На Рис. 9 наведені результати точності класифікації (за метрикою F1-міра, макроусереднення) для

зображення SS1 зі штучно доданим шумом та стисненням у лівому околі оптимальної робочої точки (з коефіцієнтом якості  $Q = 31$ ).

Візуально динаміка кривих демонструє класичну залежність якості сегментації від складності ансамблю. Насичення точності (вихід на плато) чітко спостерігається починаючи з глибини 8–10 та кількості дерев від 100 до 200.

Аналіз графіків показує, що для базової конфігурації LBP (1:8) при 200 деревах та глибині 8 значення F1-міри становить близько 0.925. Натомість перехід до використання поєднаних конфігурацій LBP (1:8+2:16+3:24) за тих самих гіперпараметрів XGBoost (200 дерев, глибина 8) дає змогу суттєво підвищити точність – показник наближається до позначки 0.948–0.950.

На Рис. 10 деталізовано динаміку метрики F1-score у розрізі окремих класів (“Вода”, “Рослинність”, “Відкритий ґрунт”, “Урбанізація”) для зображення зі стисненням при коефіцієнті якості  $Q = 31$ .

Аналіз отриманих залежностей свідчить, що загальні тенденції зростання точності зі збільшенням складності моделі зберігаються і після застосування компресії. Клас “Вода” підтверджує свій статус найбільш стабільного (робастного) об’єкта класифікації: завдяки високій гомогенності текстури, метрика F1 виходить на плато з дуже високими значеннями (понад 0.98–0.99) вже при мінімальній складності моделі, демонструючи низьку чутливість до появи специфічних артефактів стиснення кодера BPG. Натомість класи зі складною просторовою структурою – “Відкритий ґрунт”, “Рослинність” та “Урбанізація” – виявляють суттєву залежність від радіуса аналізу LBP. На графіках для базової одинарної конфігурації (LBP 1:8) криві точності для

цих класів стартують з порівняно низьких значень (наприклад, для відкритого ґрунту та урбанізації

близько 0.72–0.80 при глибині 4) і характеризуються пологою динамікою зростання.

LBP 1:8+2:16+3:24




Рис. 8. Маски класифікованого зображення SS1 з адитивним білим гаусівським шумом  $\sigma^2 = 100$

Перехід до використання розширеного вектора ознак, сформованого шляхом конкатенації масштабів (LBP 1:8+2:16+3:24), забезпечує значний приріст точності та суттєве збільшення крутизни кривих для цих класів вже на початкових етапах налаштування моделі (глибина 4–6).


Такі результати емпірично підтверджують, що застосування мультимасштабного текстурного аналізу є критично важливим для коректної сегментації структурно складних об'єктів. Більш того, цей підхід доводить свою ефективність, як надійний компенсаторний механізм, даючи змогу моделі витягувати достатньо інформативних ознак навіть

при складному комбінованому впливі адитивного шуму та артефактів стиснення з втратами.

На Рис. 11 подано результати за метрикою AUC (макроусереднення) для різних конфігурацій LBP при стисненні з коефіцієнтом якості  $Q = 31$ .

Аналіз графіків свідчить, що незважаючи на появу нових специфічних спотворень у вигляді артефактів компресії кодера BPG, значення AUC залишаються стабільно високими. Для найкращих конфігурацій вони наближаються до позначки 0.9970, що підтверджує виняткову здатність моделі XGBoost до безпомилкового розрізнення класів


навіть в умовах такого комплексного (шум та стиснення) рівня завад.



**Рис. 9.** F1-міра (макроусереднення) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 31$ )

Графіки демонструють чітку ієрархію інформативності ознак: мономасштабний LBP 1:8 дає найнижчий AUC (0.9930), тоді як комбінований вектор (LBP 1:8+2:16+3:24) максимізує цей показник. Крім того, для комбінованого LBP різниця між 100–500 деревами нівелюється вже на глибині 6–8.

Це підтверджує можливість суттєвої оптимізації обчислень: для надійної сегментації стиснених даних цілком достатньо ансамблю зі 100–200 дерев при глибині 8 без втрати дискримінаційної здатності.



**Рис. 10.** F1-міра для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 31$ ):

а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24




Рис. 11. AUC (макроусереднення, один проти всіх) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 31$ )

На Рис. 12 деталізовано показники AUC для окремих класів при стисненні з коефіцієнтом якості  $Q = 31$ .

Аналіз графіків виявляє вразливість дрібномасштабних ознак на прикладі класу “Вода”. Зокрема, використання базового шаблону LBP 1:8 призводить до виражених флуктуацій метрики у глибоких моделях. Це зумовлено специфічними блоковими артефактами стиснення, які порушують

гомогенну текстуру води та роблять дрібний радіус LBP надмірно чутливим до локальних збурень.




Рис. 12. AUC для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 31$ ):

а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

Натомість перехід до комбінованого вектора ознак (LBP 1:8+2:16+3:24) ефективно працює як компенсаційний механізм. Залучення більших радіусів нівелює вплив артефактів, стабілізуючи криві для “Води” на рівні понад 0.997. Для

структурно складного класу “Урбанізація” абсолютні значення AUC дещо знижуються через втрату високочастотних деталей при компресії. Проте мультимасштабний підхід і тут забезпечує максимальний приріст якості порівняно з мономасштабним. Загальний поріг оптимізації

залишається незмінним: для всіх класів насичення стабільно фіксується при глибині 8–10 та 100–200 деревих, що підтверджує високу робастність методу.

На Рис. 13 наведено маски класифікації для комбінованого LBP (1:8+2:16+3:24) при стисненні  $Q = 31$ .

LBP 1:8+2:16+3:24




Рис. 13. Маски класифікованого зображення SS1 із шумом з  $\sigma^2 = 100$  та стиснені кодером BPG з коефіцієнтом якості  $Q = 31$

Аналіз підтверджує, що й після компресії якість сегментації стабільно покращується зі зростанням складності ансамблю. Збільшення глибини (від 5 до 15) та кількості дерев (від 10 до 100) мінімізує ефект “солі та перцю”, формуючи цілісні класифіковані області. Відсутність візуальної різниці між 100 і 500 деревами наочно підтверджує вихід метрик на плато. Головне, що попри артефакти стиснення BPG, розширений вектор ознак зберігає чіткі межі об’єктів (берегові лінії, антропогенні структури).

Це доводить здатність мультимасштабного підходу ефективно компенсувати втрату високочастотних деталей і забезпечувати робастну сегментацію за умов комбінованих спотворень.

На Рис. 14 наведені результати точності класифікації для зображення SS1 із штучно доданим адитивним білим гаусівським шумом з  $\sigma^2 = 100$  та стиснене за допомогою ефективного BPG-кодера у ОРТ з використанням коефіцієнта якості  $Q = 35$ . Динаміка кривих зберігається (плато при 200 деревах

і глибині 8). Стиснення з втратами частково придушило шум, підвищивши загальну точність на ~1%. Перевага комбінованого LBP (0.9530) над базовим (0.9418) також стабільно перевищує 1%.




Рис. 14. F1-міра (макроусереднення) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 35$ )

На Рис. 15 деталізовано динаміку метрики F1-score у розрізі окремих класів.

Клас “Вода” є найстабільнішим: завдяки гомогенній текстурі F1-міра сягає  $> 0.99$  вже за мінімальної складності (10 дерев, глибина 4). Натомість структурно складні класи (“Рослинність”,

“Урбанізація”) суттєво залежать від радіуса LBP. Базова конфігурація (1:8) дає повільне зростання точності, тоді як розширений мультимасштабний вектор (1:8+2:16+3:24) забезпечує різкий приріст уже на глибині 4–6. Це підтверджує критичну необхідність мультимасштабного аналізу для складних об’єктів.





Рис. 15. F1-міра для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 35$ ):


а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

На Рис. 16 значення AUC стабільно високі (0.9920–0.9980), що підтверджує стійкість моделі XGBoost до спотворень. Базовий шаблон LBP 1:8 демонструє найнижчі показники, тоді як комбінація радіусів (1:8+2:16+3:24) максимізує точність. Оскільки для комбінованого LBP різниця між 100 і 500 деревами нівелюється вже на глибині 8, обчислення можна суттєво оптимізувати: для надійного розпізнавання цілком достатньо 100–200 дерев при глибині 8.



**Рис. 16.** AUC (макроусереднення, один проти всіх) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 35$ )

На Рис. 17 деталізовано метрику AUC для кожного класу.



**Рис. 17.** AUC для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 35$ ):

а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

Аналіз графіків дав змогу виявити специфічну динаміку для класу “Вода”: при використанні мономасштабного шаблону LBP (1:8) спостерігаються помітні флуктуації (нестабільність) значень AUC при зміні глибини дерева, що свідчить про чутливість цієї конфігурації до локальних шумових артефактів.

Однак, при переході до розширеного вектора ознак (комбінація 1:8, 2:16, 3:24) криві стабілізуються, демонструючи стійке зростання якості. Для класу “Урбанізація”, який традиційно є найбільш складним для сегментації через високу спектральну варіативність, зафіксовано найбільш суттєвий приріст дискримінаційної здатності при переході від простого LBP до мультимасштабного.

Це підтверджує гіпотезу, що текстурні ознаки великого радіуса є критично важливими для ефективного відокремлення структурно складних антропогенних об’єктів від природного фону, особливо в умовах втрати деталізації внаслідок стиснення.

На Рис. 18 наведено візуалізацію отриманих масок для комбінованого набору LBP.

LBP 1:8+2:16+3:24




Рис. 18. Маски класифікованого зображення SS1 з шумом з  $\sigma^2 = 100$  та стиснені кодером BPG з коефіцієнтом якості  $Q = 35$

На Рис. 19 наведено результати точності класифікації за метрикою F1-міри (макроусереднення) для зображення зі стисненням у правій точці околу OPT (коефіцієнт якості  $Q = 43$ ).

Аналіз графіків свідчить, що навіть при такому значному рівні стиснення загальна поведінка моделі залишається стабільною та відповідає тенденціям, виявленим для оптимальної робочої точки ( $Q = 35$ ) та лівого околу ( $Q = 31$ ). Насамперед варто відзначити збереження високої загальної точності:

максимальні значення F1-міри впевнено сягають позначки 0.955 (для комбінованої конфігурації). Це переконливо свідчить про те, що інформативні текстурні ознаки класів не руйнуються остаточно, незважаючи на більш агресивний характер спотворень, притаманних стисненню з  $Q = 43$ . Динаміка кривих демонструє класичне зростання з подальшим виходом на плато (насиченням). Найвищі показники точності досягаються при середній складності моделі (глибина 8–10, кількість дерев

100–200), після чого збільшення параметрів не призводить до суттєвого приросту метрики.




Рис. 19. F1-міра (макроусереднення) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 43$ )

Це вказує на те, що ансамбль дерев ефективно моделює корисну структуру класів, успішно адаптуючись до домінуючих артефактів компресії без ризику перенавчання. Варто також відзначити стабільну ефективність комбінованих конфігурацій LBP. Як і в попередніх експериментах, мультимасштабний підхід гарантує приріст якості: за умов  $Q = 43$  найкращий абсолютний результат демонструє саме комбінований набір (LBP 1:8+2:16+3:24), який стабільно перевершує базову конфігурацію LBP 1:8 на всіх етапах. Такий результат емпірично підтверджує: навіть при досягненні високого рівня компресії макроструктура об'єктів залишається розпізнаваною, а залучення текстурних ознак великого радіуса (2:16, 3:24) забезпечує необхідну дискримінаційну здатність класифікатора.

На Рис. 20 деталізовано динаміку метрики F1-score у розрізі окремих класів (“Вода”, “Рослинність”, “Відкритий ґрунт”, “Урбанізація”)

для зображення зі стисненням у правій точці околу ОРТ (коефіцієнт якості  $Q = 43$ ).




Рис. 20. F1-міра для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 43$ ):

а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

Аналіз графіків підтверджує збереження високої якості сегментації для всіх без винятку класів, що повністю узгоджується із зафіксованими раніше загальними метриками. Абсолютно аналогічно до результатів для оптимальної робочої точки ( $Q = 35$ ) та лівого околу ( $Q = 31$ ), при  $Q = 43$  для кожного

класу яскраво проявляється стабільний вихід на плато. Найвищі значення точності здебільшого фіксуються при достатній складності ансамблю (глибина 8–10), після чого збільшення глибини дерев не призводить до суттєвих коливань метрики. Це безперечно свідчить про те, що глибокі дерева продовжують успішно виділяти корисну просторову структуру класів, незважаючи на агресивні шумові патерни та артефакти стиснення, які при цьому значенні  $Q$  суттєво впливають на текстурну інформацію. Висока стабільність ознак підтверджується на прикладі найодноріднішого класу “Вода”: його максимальні значення впевнено тримаються на рівні понад 0.994, демонструючи абсолютну стійкість до артефактів. Структурно складні об’єкти, зокрема “Відкритий ґрунт” та “Урбанізація”, також уникають втрат якості, піднімаючись до значень F1 на рівні 0.92–0.93, що вказує на повне збереження їхніх дискримінаційних властивостей. Окремої уваги заслуговує поведінка моделі при застосуванні розширеного набору ознак LBP 1:8+2:16+3:24 (Рис. 20г). Як і в умовах більш помірних спотворень, мультимасштабний підхід продовжує діяти як ефективний компенсаційний механізм: при  $Q = 43$  він формує гладкі, стабільно зростаючі криві з вираженим насиченням (переважно після глибини 8) без глибоких спадів. Такий характер графіків доводить, що в умовах відчутної втрати високочастотних просторових деталей залучення текстурних ознак великих радіусів здатне надійно стабілізувати класифікацію, повністю нівелюючи додаткову невизначеність та забезпечуючи коректну покласову сегментацію.

На Рис. 21 наведено результати за метрикою AUC (макроусереднення) для зображення зі стисненням у правій точці околу OPT ( $Q = 43$ ).

Як і у випадку з F1-мірою, тут чітко фіксується стабільна динаміка: замість деградації показників спостерігається впевнений вихід на плато при збільшенні складності ансамблю. Максимальні значення досягаються на середніх глибинах (8–10), після чого метрика стабілізується. Це підтверджує відсутність перенавчання – глибокі дерева коректно фокусуються на інформативних ознаках, ігноруючи агресивні артефакти стиснення. При цьому саме мультимасштабний підхід (LBP 1:8+2:16+3:24) здатен принципово гарантувати цю високу узагальнюючу здатність моделі. Проте варто відзначити важливу особливість: на відміну від попередніх гіпотез про обвал загальної точності, абсолютні показники AUC є надзвичайно високими (в межах 0.994–0.998). Така узгодженість пояснюється коректною математичною оптимізацією. F1-міра доводить успішну жорстку класифікацію за фіксованим порогом, який виявився цілком оптимальним навіть через сильне спотворення ознак артефактами стиснення. Натомість AUC ідеально оцінює загальну здатність моделі коректно ранжувати ймовірності класів незалежно від порогу прийняття рішення. Це означає, що попри критичне візуальне погіршення вихідних даних (стиснення), модель повністю зберігає здатність розрізняти класи між собою на рівні відносних ймовірностей.





Рис. 21. AUC (макроусереднення, один проти всіх) для різних конфігурацій LBP для зображення SS1 зі стисненням ( $Q = 43$ )

На Рис. 22 деталізовано показники AUC для окремих класів при стисненні у правій точці околу OPT (коефіцієнт якості  $Q = 43$ ).

Аналіз покласових кривих наочно демонструє стійку тенденцію до зростання метрики зі збільшенням глибини дерев, що є характерною ознакою стабільності моделі в умовах сильних компресійних спотворень. Традиційно найстабільніший клас “Вода” зберігає тут лідерські позиції: його показники впевнено тримаються та зростають

(до 0.999), зберігаючи ідеальну гомогенність, притаманну оптимальній робочій точці. Високий і стабільний результат фіксується для структурно складних антропогенних та природних об'єктів – класів “Відкритий ґрунт” та “Урбанізація”. Для них збільшення складності моделі (особливо перехід від глибини 4 до 15) призводить до впевненого плато AUC.



**Рис. 22.** AUC для кожного класу окремо для зображення SS1 зі стисненням ( $Q = 43$ ):  
а) LBP 1:8; б) LBP 2:16; в) LBP 3:24; г) LBP 1:8+2:16+3:24

Наприклад, у базовій конфігурації LBP 1:8 при достатній кількості дерев метрика для цих класів піднімається до 0.994–0.996. Це підтверджує, що глибокі дерева успішно продовжують виділяти корисні ознаки, повністю ігноруючи агресивний вплив шумових патернів (блочних артефактів), згенерованих кодером BPG. Перехід до розширеного вектора ознак LBP 1:8+2:16+3:24 суттєво підвищує абсолютні значення метрики на початкових етапах (глибина 4–6), формуючи швидке насичення моделі, і він принципово здатний закріпити загальну позитивну тенденцію. Приріст якості зі збільшенням глибини залишається стабільним для всіх без винятку класів. Закономірно, завдяки специфіці метрики AUC (яка оцінює відносне ранжування ймовірностей, а не жорсткі пороги) її абсолютні значення виглядають максимально високими, повністю підтверджуючи відмінні показники F1-міри, а загальний характер кривих є ідентичним. Це остаточно доводить, що при  $Q = 43$  класифікатор зберігає відмінну загальну здатність до відділення класів один від одного, а жорстка сегментація залишається вкрай ефективною попри часткове руйнування високочастотних текстурних деталей.

На Рис. 23 наведено візуалізацію отриманих масок класифікації для комбінованого набору ознак LBP (1:8+2:16+3:24) при стисненні у правій точці околу OPT з коефіцієнтом якості  $Q = 43$ .

Візуальний аналіз цих масок слугує підтвердженням збереження якості сегментації, яке раніше було зафіксоване кількісними метриками (зокрема впевненим зростанням F1-міри). Абсолютно аналогічно до результатів для оптимальної робочої точки ( $Q = 35$ ) та лівого околу ( $Q = 31$ ), де об'єкти мали чіткі контури та високу цілісність, маски для  $Q = 43$  характеризуються максимальним рівнем гомогенізації.

Найбільш показовою є візуальна стабільність класу “Вода” (синій колір): область, яка традиційно вирізнялася найвищою гомогенністю і майже стовідсотковою точністю розпізнавання, залишається ідеально чистою без хибних класифікацій (повністю відсутній ефект “солі та перцю”). Це свідчить про те, що специфічні агресивні артефакти стиснення BPG-кодера зовсім не зруйнували первинну макротекстуру, завдяки чому модель зберегла здатність формувати суцільні регіони.

Крім того, на масках наочно ілюструється повна відсутність перенавчання. Збільшення складності моделі (особливо перехід від глибини 5 до 15) впевнено приводить до згладжування маски та покращення обрисів об'єктів. Закономірно, глибокі дерева починають ще детальніше відтворювати корисний патерн та ігнорувати блокову структуру компресії, генеруючи надзвичайно точну та придатну для практичного використання карту класифікації. Це остаточно доводить емпіричний висновок: при досягненні такого високого порогу спотворень ( $Q = 43$ ) саме застосування розширеного мультимасштабного текстурного аналізу виявляється здатним компенсувати втрату високочастотної інформації.

LBP 1:8+2:16+3:24




Рис. 23. Маски класифікованого зображення SS1 з шумом з  $\sigma^2 = 100$  та стиснені кодером BPG з коефіцієнтом якості  $Q = 43$

Збільшення глибини моделі демонструє зменшення ефекту “солі та перцю” (поодинокі помилково класифіковані пікселі). Маски стають більш цілісними. Збільшення дерев показує, що основний приріст якості візуалізації відбувається при переході від 10 до 100 дерев. Різниця між 100 та 500 деревами візуально майже непомітна, що корелює з графіками метрик, де спостерігається насичення. Варто відзначити високу якість формування меж об’єктів (наприклад, берегова лінія), яка залишається чіткою, незважаючи на застосування стиснення з втратами ( $Q = 35$ ) та в його лівому околі ( $Q = 31$ ). Більш того, навіть при значному посиленні стиснення у правій точці околу ( $Q = 43$ ), візуальна якість масок залишається стабільно високою: відсутня фрагментація, зберігається цілісність макротекстури, а мультимасштабний підхід успішно нівелює агресивні артефакти компресії.

Для порівняння розробленого підходу з наявними рішеннями проведено зіставлення отриманих результатів з показниками нейромережових моделей та базових конфігурацій, використаних у попередніх дослідженнях (Rebrov et al., 2025), де як референсний метод використовувався нейромережовий класифікатор на основі багатошарового персептрона (Multilayer Perceptron – MLP). У Табл. 1 наведено порівняльну характеристику точності класифікації для різних методів оброблення супутникових зображень в умовах аналогічних завад, спричинених шумом, та ступеня стиснення. На відміну від попередніх досліджень (Rebrov et al., 2025; Rybnytskyi et al., 2025), де основним показником виступала зважена F1-міра, у цій роботі пріоритет надано матриці макросередньої F1-міри. Це обумовлено значним дисбалансом класів у наборі даних: макросереднення розглядає кожен клас як

рівноцінний внесок у фінальну метрику, незалежно від його обсягу. Такий підхід дає змогу об'єктивно оцінити здатність моделі розпізнавати міnorитарні (рідкісні) класи, які часто є найбільш критичними для аналізу та можуть ігноруватися зваженими метриками. Водночас, для забезпечення можливості прямого порівняння отриманих результатів із показниками попередніх досліджень, ми додатково розраховуємо значення зваженої F1-міри для використання в Табл. 1.

**Таблиця 1.** Порівняльний аналіз точності класифікації спотворених зображень

| Зображення                                 | Метод класифікації | Ознаки/Конфігурація                                      | F1-міра | AUC    |
|--------------------------------------------|--------------------|----------------------------------------------------------|---------|--------|
| SS1 ( $\sigma^2 = 100$ )                   | HM                 | –                                                        | 0.9000  | –      |
|                                            | XGBoost            | дерева – 500<br>глибина – 4<br>LBP – (1:8)               | 0.9545  | 0.9923 |
|                                            | XGBoost            | дерева – 200<br>глибина – 8<br>LBP – (1:8 + 2:16 + 3:24) | 0.9746  | 0.9967 |
| SS1 ( $\sigma^2 = 100$ та $Q_{BPG} = 31$ ) | HM                 | –                                                        | 0.9700  | –      |
|                                            | XGBoost            | дерева – 500<br>глибина – 4<br>LBP – (1:8)               | 0.9579  | 0.9927 |
|                                            | XGBoost            | дерева – 200<br>глибина – 8<br>LBP – (1:8 + 2:16 + 3:24) | 0.9757  | 0.9967 |
| SS1 ( $\sigma^2 = 100$ та $Q_{BPG} = 35$ ) | HM                 | –                                                        | –       | –      |
|                                            | XGBoost            | дерева – 500<br>глибина – 4<br>LBP – (1:8)               | 0.9698  | 0.9959 |
|                                            | XGBoost            | дерева – 200<br>глибина – 8<br>LBP – (1:8 + 2:16 + 3:24) | 0.9803  | 0.9977 |
| SS1 ( $\sigma^2 = 100$ та $Q_{BPG} = 43$ ) | HM                 | –                                                        | –       | –      |
|                                            | XGBoost            | дерева – 500<br>глибина – 4<br>LBP – (1:8)               | 0.9312  | 0.9967 |
|                                            | XGBoost            | дерева – 200<br>глибина – 8<br>LBP – (1:8 + 2:16 + 3:24) | 0.9550  | 0.9976 |

Як свідчать дані таблиці, найкращі показники точності в умовах оптимальної робочої точки та її лівого околу продемонструвала конфігурація XGBoost з використанням 200 дерев та глибини 8 у поєднанні з комбінацією ознак LBP 1:8 + 2:16 + 3:24. При рівні шуму  $\sigma^2 = 100$ , використання комбінації ознак дало змогу досягти F1-score = 0.9746, що на 2.1 % вище, ніж при використанні XGBoost з 500 дерев та глибиною 4 у поєднанні з LBP 1:8. Максимальне значення F1-score 0.9803 та AUC 0.9977 зафіксовано при поєднанні шуму  $\sigma^2=100$  та стиснення з використанням коефіцієнта  $Q_{BPG} = 35$ . Сценарій сильного стиснення у правій точці околу ( $Q_{BPG} = 43$ ) демонструє аналогічну стабільну поведінку: висока загальна точність зберігається, а мультимасштабний підхід продовжує діяти як ефективний компенсаційний механізм. У цьому випадку складна комбінована модель (LBP 1:8+2:16+3:24, глибина 8, 200 дерев) показала

закономірно вищий результат ( $F1 = 0.9550$ ), ніж базова конфігурація LBP 1:8 ( $F1 = 0.9312$ ). Це повністю підтверджує здатність глибоких дерев виділяти корисні ознаки та уникати перенавчання навіть за посиленних шумових патернів кодера.

Запропонований метод на базі XGBoost демонструє перевагу над базовими нейронними мережами (HM) у більшості перевірених випадків. На вихідному наборі SS1 ( $\sigma^2 = 100$ ) приріст точності склав 8.2% порівняно з HM. Навіть у складних умовах ( $Q_{BPG} = 31$ ), де HM показує високий результат (0.9700), оптимізована модель XGBoost з комбінованими ознаками перевершує цей показник, забезпечуючи приріст в 0.6%.

Окрему увагу слід приділити показникам AUC, які в усіх експериментах із XGBoost стабільно перевищують поріг 0.99. На відміну від F1-міри, яка залежить від конкретного порогу ймовірності, високі значення AUC (максимальне 0.9977) свідчать про виняткову здатність моделі розрізняти класи.

Це підтверджує, що модель зберігає високу розпізнавальну здатність навіть при сильних спотвореннях ( $\sigma^2 = 100$ ). Стабільність AUC (з відхиленням лише на 0.005 в діапазоні від відсутності стиснення до  $Q_{BPG} = 31$ ) свідчить про те, що обрані ознаки LBP стійкі до змін рівня шуму та коефіцієнту Q. Навіть при досягненні сильного рівня спотворень ( $Q_{BPG} = 43$ ) значення AUC залишаються надзвичайно високими (0.9967 для базової та 0.9976 для комбінованої конфігурацій), що беззаперечно доводить надзвичайну робастність запропонованого алгоритму до всього досліджуваного діапазону компресійних артефактів.

## Висновки

Отримані результати для зображення SS1, спотвореного адитивним білим гаусівським шумом ( $\sigma^2 = 100$ ) та стисненого кодером BPG ( $Q = 35$ ), підтверджують ефективність запропонованого підходу, де найкращі показники досягнуто при використанні комбінації LBP (1:8 + 2:16 + 3:24) та параметрів XGBoost: дерева  $\geq 200$  і глибина  $\geq 8$ . Зокрема, використання поєднаних конфігурацій LBP дало змогу отримати значення F1-міри на рівні 0.9530, що більш ніж на 1% перевищує результат для окремої конфігурації LBP (1:8). У контексті стійкості встановлено, що вибір конфігурації LBP є компромісом між чутливістю до дрібних деталей та стійкістю до артефактів: використання лише малого радіусу (1:8) призводить до помітних флуктуацій метрик для однорідних класів (зокрема “Вода”) в умовах шуму, тоді як інтеграція більших радіусів (2:16, 3:24) діє як згладжувальний фактор, стабілізуючи розпізнавання складних текстурних об'єктів (“Урбанізація”) та мінімізуючи дисперсію помилок. При цьому аналіз динаміки метрик показує, що подальше збільшення складності моделі (понад 200 дерев та глибину 8) не призводить до статистично значущого приросту якості, що дає змогу вважати ці параметри оптимальними з погляду балансу точності та обчислювальних витрат. Також варто відзначити, що результати класифікації після

стиснення виявилися вищими, ніж для зображення виключно з шумом; це пояснюється тим, що стиснення із втратами спрацювало як певний фільтр, придушивши складові, що переважно зумовлені шумом, та зробивши локальні текстурні патерни більш виразними для класифікатора. Загалом модель продемонструвала високу стійкість до спотворення даних, забезпечуючи значення  $AUC > 0.99$  для більшості класів в оптимальній робочій точці.

Додаткове дослідження в околицях оптимальної робочої точки дало змогу чітко окреслити межі цієї стійкості. Встановлено, що при відхиленні в бік сильнішого стиснення ( $Q = 31$ ) мультимасштабний підхід успішно діє як компенсаційний механізм проти блочних артефактів, зберігаючи високу дискримінаційну здатність алгоритму. Більше того, навіть при досягненні вищого рівня специфічних спотворень ( $Q = 43$ ) фіксується збереження високої якості сегментації: глибокі дерева коректно виділяють корисні ознаки, уникаючи перенавчання на агресивних шумових паттернах кодера, зберігаються стабільно високі показники F1-міри та AUC, а застосування комбінованих ознак великого радіуса й надалі доводить свою ефективність. Це практично свідчить про те, що розширений текстурний аналіз та ансамблеві моделі забезпечують суттєвий приріст якості та високу робастність у всьому дослідженому діапазоні втрат при стисненні, успішно розпізнаючи первинну макроструктуру класів навіть за умов сильної компресії.

**Внесок авторів:** Концептуалізація – М. А. Рибницький, С. С. Кривенко; методологія – М. А. Рибницький; формальний аналіз та оброблення даних – М. А. Рибницький; дослідження – М. А. Рибницький; підготовка тексту статті – М. А. Рибницький; рецензування та редагування – М. А. Рибницький, С. С. Кривенко. Всі автори прочитали та погодилися з опублікованою версією рукопису.

**Фінансування:** Це дослідження не отримало зовнішнього фінансування.

**Доступність даних:** Дані можуть бути надані авторами за обґрунтованим запитом.

**Подяки:** Автори висловлюють щирі подяку та вдячні рецензентам і редакторам за їхні цінні коментарі, рекомендації та увагу до роботи.

**Конфлікти інтересів:** Автори заявляють, що не мають конфлікту інтересів.

**Author Contributions:** Conceptualization – M. A. Rybnytskyi and S. S. Kryvenko; Methodology – M. A. Rybnytskyi; Formal Analysis and Data Processing – M. A. Rybnytskyi; Investigation – M. A. Rybnytskyi; Writing – Original Draft Preparation – M. A. Rybnytskyi; Writing – Review & Editing – M. A. Rybnytskyi and S. S. Kryvenko. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Data Availability Statement:** Data available on reasonable request from the authors.

**Acknowledgments:** The authors express sincere gratitude to the reviewers and editors for their valuable comments, recommendations, and attention to the work.

**Conflicts of Interest:** The authors declare no conflict of interest.

## Література

- Abramova, V., Lukin, V., Abramov, S., Abramov, K., & Bataeva, E. (2022). Analysis of Statistical and Spatial Spectral Characteristics of Distortions in Lossy Image Compression. *2022 IEEE 2nd Ukrainian Microwave Week (UkrMW)*, 644–649. <https://doi.org/10.1109/UkrMW58013.2022.10036949>.
- Belgiu, M., Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BPG Image format. (б. д.). Вилучено 2025. 13 лип., із <https://bellard.org/bpg/>.
- Chen, T., Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- De Jong, S., Meer, F. (2007). *Remote Sensing Image Analysis: Including The Spatial Domain*. Springer Dordrecht. <https://doi.org/10.1007/978-1-4020-2560-0>.
- F1\_score. (б. д.). Scikit-Learn. Вилучено 2025. 25 лист., із [https://scikit-learn/stable/modules/generated/sklearn.metrics.f1\\_score.html](https://scikit-learn/stable/modules/generated/sklearn.metrics.f1_score.html).
- Firat, H., Asker, M. E., Bayindir, M. İ., & Hanbay, D. (2022). Spatial-spectral classification of hyperspectral remote sensing images using 3D CNN based LeNet-5 architecture. *Infrared Physics & Technology*, 127. <https://doi.org/10.1016/j.infrared.2022.104470>.
- Kovalenko, B., Lukin, V., Kryvenko, S., Naumenko, V., Vozel, B. (2022). Prediction of parameters in optimal operation point for BPG-based lossy compression of noisy images. *Ukrainian journal of remote sensing*, 9(2), 4–12.
- Li, Z., Chen, B., Wu, S., Su, M., Chen, J. M., & Xu, B. (2024). Deep learning for urban land use category classification: A review and experimental assessment. *Remote Sensing of Environment*, 311. <https://doi.org/10.1016/j.rse.2024.114290>.
- Ojala, T., Pietikainen, M., Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. <https://doi.org/10.1109/TPAMI.2002.1017623>.
- Pietikainen, M., Hadid, A., Zhao, G., & Ahonen, T. (2011). *Computer Vision Using Local Binary Patterns* (T. 40). <https://doi.org/10.1007/978-0-85729-748-8>.
- Punia, R. (2023). *How to Measure the Performance of Your Machine Learning Models: Precision, Recall, Accuracy, and F1 score* [Post]. Medium. <https://rs-punia.medium.com/how-to-measure-the-performance-of-your-machine-learning-models-precision-recall-accuracy-and-f1-855702df048b>.
- Rebrov, V., Proskura, G., Lukin, V. (2025). Classification of Compressed Noisy Three-Channel Noisy Images: Comparison of Several Approaches. *Integrated Computer Technologies in Mechanical Engineering - 2024. ICTM 2024*.
- Rybnytskyi, M., Kryvenko, S., Lukin, V., Rebrov, V. (2025). A COMBINED APPROACH TO PIXEL-WISE CLASSIFICATION OF SATELLITE IMAGES BASED ON LBP, PSEUDOCOLOR FEATURES, AND XGBOOST. *Radioelectronic and Computer Systems*, 4, 206–219. <https://doi.org/10.32620/reks.2025.4.14>.
- Shao, Z., Ahmad, M., Javed, A. (2024). Comparison of Random Forest and XGBoost Classifiers Using Integrated Optical and SAR Features for Mapping Urban Impervious Surface. *Remote Sensing*, 665. <https://doi.org/10.3390/rs16040665>.
- West, H., Quinn, N., Horswell, M. (2019). Remote sensing for drought monitoring & impact assessment: Progress, past

- challenges and future opportunities. *Remote Sensing of Environment*, 232. <https://doi.org/10.1016/j.rse.2019.111291>.
- XGBoost Documentation–Xgboost 3.0.2 documentation. (б. д.). Вилучено 2025. 05 черв., із <https://xgboost.readthedocs.io/en/stable/>.
- Yang, S., Berdine, G. (2017). The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles*, 5, 34. <https://doi.org/10.12746/swrccc.v5i19.391>.
- ### References
- Abramova, V., Lukin, V., Abramov, S., Abramov, K., & Bataeva, E. (2022). Analysis of Statistical and Spatial Spectral Characteristics of Distortions in Lossy Image Compression. 2022 *IEEE 2nd Ukrainian Microwave Week (UkrMW)*, 644–649. <https://doi.org/10.1109/UkrMW58013.2022.10036949>.
- Belgiu, M., Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BPG Image format. Retrieved from <https://bellard.org/bpg/>.
- Chen, T., Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- De Jong, S., Meer, F. (2007). *Remote Sensing Image Analysis: Including The Spatial Domain*. Springer Dordrecht. <https://doi.org/10.1007/978-1-4020-2560-0>.
- F1\_score. (b. d.). Scikit-Learn. B Retrieved from [https://scikit-learn/stable/modules/generated/sklearn.metrics.f1\\_score.html](https://scikit-learn/stable/modules/generated/sklearn.metrics.f1_score.html).
- Firat, H., Asker, M. E., Bayindir, M. İ., & Hanbay, D. (2022). Spatial-spectral classification of hyperspectral remote sensing images using 3D CNN based LeNet-5 architecture. *Infrared Physics & Technology*, 127. <https://doi.org/10.1016/j.infrared.2022.104470>.
- Kovalenko, B., Lukin, V., Kryvenko, S., Naumenko, V., Vozel, B. (2022). Prediction of parameters in optimal operation point for BPG-based lossy compression of noisy images. *Ukrainian journal of remote sensing*, 9(2), 4–12.
- Li, Z., Chen, B., Wu, S., Su, M., Chen, J. M., & Xu, B. (2024). Deep learning for urban land use category classification: A review and experimental assessment. *Remote Sensing of Environment*, 311. <https://doi.org/10.1016/j.rse.2024.114290>.
- Ojala, T., Pietikainen, M., Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. <https://doi.org/10.1109/TPAMI.2002.1017623>.
- Pietikainen, M., Hadid, A., Zhao, G., & Ahonen, T. (2011). *Computer Vision Using Local Binary Patterns* (T. 40). <https://doi.org/10.1007/978-0-85729-748-8>.
- Punia, R. (2023). *How to Measure the Performance of Your Machine Learning Models: Precision, Recall, Accuracy, and F1 score* [Post]. Medium. <https://rs-punia.medium.com/how-to-measure-the-performance-of-your-machine-learning-models-precision-recall-accuracy-and-f1-855702df048b>.
- Rebrov, V., Proskura, G., Lukin, V. (2025). Classification of Compressed Noisy Three-Channel Noisy Images: Comparison of Several Approaches. *Integrated Computer Technologies in Mechanical Engineering - 2024. ICTM 2024*.
- Rybnytskyi, M., Kryvenko, S., Lukin, V., Rebrov, V. (2025). A COMBINED APPROACH TO PIXEL-WISE CLASSIFICATION OF SATELLITE IMAGES BASED ON LBP, PSEUDOCOLOR FEATURES, AND XGBOOST. *Radioelectronic and Computer Systems*, 4, 206–219. <https://doi.org/10.32620/reks.2025.4.14>.
- Shao, Z., Ahmad, M., Javed, A. (2024). Comparison of Random Forest and XGBoost Classifiers Using Integrated Optical and SAR Features for Mapping Urban Impervious Surface. *Remote Sensing*, 665. <https://doi.org/10.3390/rs16040665>.
- West, H., Quinn, N., Horswell, M. (2019). Remote sensing for drought monitoring & impact assessment: Progress, past challenges and future opportunities. *Remote Sensing of Environment*, 232. <https://doi.org/10.1016/j.rse.2019.111291>.
- XGBoost Documentation–Xgboost 3.0.2 documentation. (b. d.). Retrieved from <https://xgboost.readthedocs.io/en/stable/>.
- Yang, S., Berdine, G. (2017). The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles*, 5, 34. <https://doi.org/10.12746/swrccc.v5i19.391>.

## INFLUENCE OF LOCAL BINARY PATTERN CONFIGURATIONS AND XGBOOST ON THE QUALITY OF SATELLITE IMAGE CLASSIFICATION WITH NOISE AND COMPRESSION: EXPERIMENTAL STUDY

Rybnytskyi M. A., <https://orcid.org/0009-0000-1299-1604>

Kryvenko S. S., <https://orcid.org/0000-0001-6027-5442>

National Aerospace University "Kharkiv Aviation Institute", Vadym Manko str., 17, Kharkiv, 61070, Ukraine

The paper addresses the relevant task of pixel-wise classification of multispectral satellite images under conditions of critical data quality degradation caused by additive sensor noise and lossy compression artifacts. A method for spatial feature extraction based on Local Binary Patterns (LBP) using various configurations (1:8, 2:16, 3:24) and their combinations to improve class separation accuracy is considered. An experimental study was conducted on Sentinel-2 image fragments (Kharkiv region) distorted by additive Gaussian noise with a variance of  $\sigma^2 = 100$  and subjected to per-channel compression using the BPG encoder. The XGBoost decision tree ensemble was used as a classifier. Simulation results confirmed that the application of mono-scale LBP patterns is insufficient for reliable segmentation of heterogeneous objects under conditions of strong noise. It is proven that forming an extended feature vector by concatenating multi-scale LBP configurations (1:8, 2:16, 3:24) ensures an increase in the F1-score metric to 0.9530, which exceeds the indicators of basic configurations by more than 1%. A detailed analysis of metric dynamics by class revealed that the "Water" class demonstrates the highest stability ( $F1 > 0.99$ ) due to spectral homogeneity. At the same time, for structurally complex classes "Urbanization" and "Vegetation," incorporating large-radius features proved critically important, allowing to minimize the influence of local brightness fluctuations and stabilize the AUC metric at a level  $> 0.99$ . An important empirical result was the detection of a positive effect of compression on the classification accuracy of noisy images: coefficient quantization by the BPG encoder acted as a low-pass filter, partially compensating for the high-frequency component of Gaussian noise. Additional research around the optimal operating point revealed that the method remains robust under moderate changes ( $Q = 31$ ). Furthermore, it continues to exhibit high stability and maintain segmentation accuracy even with a substantial amplification of compression artifacts

( $Q = 43$ ), thereby confirming the reliability and efficiency of the algorithm throughout the entire evaluated range of compression distortions. It was established that the integration of texture features of different scales allows the XGBoost model to form robust decision rules, while the optimal balance between computational complexity and accuracy is achieved when limiting ensemble parameters ( $n\_estimators=200$ ,  $max\_depth=8$ ), as further model complexity does not lead to a statistically significant increase in recognition quality.

**Keywords:** remote sensing, Sentinel-2 satellite imagery, pixel-wise classification, XGBoost, Local Binary Patterns (LBP), texture analysis, image compression, BPG encoder.

*Рукопис статті отримано 07.02.2026*

*Надходження остаточної версії: 05.03.2026*

*Публікація статті: 30.03.2026*

*Received 07.02.2026*

*Revised 05.03.2026*

*Accepted 30.03.2026*