

УДК 004.85:539.1.074.8:681.7

doi: 10.32620/aktt.2025.5.07

А. Г. КОРОБОВ, Ю. В. МОСКАЛЕНКО,
М. О. ВІНОГРАДОВ, В. Ю. БАБИЧ

Сумський державний університет, Суми, Україна

МЕТОД ПІДВИЩЕННЯ РОБАСТНОСТІ НЕЙРОМЕРЕЖ ДЛЯ СПІВСТАВЛЕННЯ АЕРОЗНІМКІВ

Предметом вивчення в статті є нейромережеві методи співставлення аерозображень, що широко використовуються у задачах навігації, локалізації та картографування. **Актуальною проблемою** є чутливість таких методів до візуальних завад та новизни, що можуть утворитися за рахунок тіней, зміни освітлення, варіабельності рельєфу, що обмежує їх робастність у реальних умовах, особливо в умовах обмежених обчислювальних ресурсів. У статті досліджується підхід до підвищення робастності та крос-доменної узагальнюваності обчислювально ефективних моделей співставлення аерозображень шляхом поєднання змагального процедурного шуму з модифікацією функції активації. **Метою статті** є створення методики навчання, яка одночасно підсилює стійкість (резильєнтність) моделей до збурень і покращує їхню переносимість між різними доменами спостережень. **Завдання:** (1) здійснити аналіз існуючих методів підвищення робастності нейронних мереж та визначити їх придатність для задач співставлення аерозображень; (2) розробити підхід до навчання, що включає синтез змагальних процедурних шумів (Перліна, Габора, Ворлі) та заміну стандартного ReLU на гібридну функцію активації LeakyReLU6, яка обмежує амплітуди активацій і зменшує чутливість до локальних збурень; (3) провести комплексне експериментальне дослідження ефективності детекторних архітектур (SuperPoint + LightGlue) та бездетекторних моделей (EfficientLoFTR) на еталонному наборі Aerial Image Matching Benchmark; (4) перевірити крос-доменну узагальнюваність на наборі HPatches; (5) здійснити абляційний аналіз для виокремлення внеску кожного з компонентів. **Отримані результати статті.** Запропонована методика забезпечила понад 4,2% абсолютного приросту AUC@1px співставлення на зашумлених тестових даних для обох класів моделей; абляційний аналіз показав синергетичний ефект поєднання процедурного шуму та LeakyReLU6 — зокрема, для комбінації SuperPoint+LightGlue приріст склав +3,0% AUC@1px і +2,7% AUC@3px, а для EfficientLoFTR — +2,2% і +2,6% відповідно. Додатково, тестування моделей на HPatches показало на 0,83% менше просідання якості порівняно з базовим навчанням, що підтверджує вищий рівень крос-доменної узагальнюваності. **Висновки.** Запропонований підхід підвищує шумостійкість і крос-доменну узагальнюваність моделей співставлення ознак та є легко розширюваним на різні нейромережеві архітектури. Подальші дослідження будуть спрямовані на вивчення впливу гіперпараметрів процедурного шуму, застосування мета-навчання на пошкоджених даних і архітектурні вдосконалення для додаткового посилення резильєнтності та робастності. **Наукова новизна** роботи полягає у першому поєднанні змагального навчання із процедурними шумами та обмежувальною функцією активації LeakyReLU6 (із застосуванням STE у зворотному проході), що дозволило досягти синергетичного ефекту підвищення робастності й узагальнюваності моделей співставлення аерозображень без значного зростання обчислювальної вартості.

Ключові слова: співставлення зображень; робастність; нейронні мережі; змагальні атаки; змагальне навчання.

1. Вступ

1.1. Мотивація дослідження

Співставлення аерофотознімків є важливим завданням у різних застосуваннях комп'ютерного зору, зокрема в навігації дронів, автономній інспекції, картографії та геопросторовому аналізі. Протягом тривалого часу в цих галузях широко використовувалися традиційні алгоритми детектування й співставлення локальних ознак, такі як

SIFT, SURF, ORB і FAST [1,2]. У класичних підходах детектування локальних ознак (keypoints detection), їх опис (description) і співставлення (matching) розглядаються як незалежні процеси та не оптимізувалися спільно. Внаслідок цього вони часто не враховують належним чином контекстну інформацію сцени та окремих ключових точок, що обмежує їхню точність і надійність порівняно з наскрізними методами на основі нейронних мереж.

Серед підходів на основі нейронних мереж для виявлення ключових точок (точок інтересу) і їх опису



[Creative Commons Attribution
NonCommercial 4.0 International](https://creativecommons.org/licenses/by-nc/4.0/)

широкого поширення набули моделі, такі як SuperPoint [3], R2D2 [4] та XFeat, завдяки їхній обчислювальній ефективності та високій надійності [5]. Для співставлення локальних ознак зазвичай використовуються SuperGlue та LightGlue. Крім того, бездетекторні методи щільного зіставлення ознак, такі як LoFTR, EfficientLoFTR [3], COTR і DGC-Net, також продемонстрували обнадійливі результати [6]. Однак продуктивність цих моделей помітно погіршується в реальних умовах, де поширені зміни текстури поверхні через нерівномірне освітлення, добові чи сезонні варіації освітленості, часткові оклюзії та цифрові артефакти.

Природні варіації освітлення й текстури, спотворення, зумовлені сенсорами, а також візуальний хаос сцени можуть інтерпретуватися як форма змагального шуму (Adversarial Attack). Це створює суттєві виклики для досягнення надійного співставлення аерознімків, де поширені змінні точки огляду, рельєфні структури та специфічний для сенсорів шум. Моделі процедурного шуму, такі як шум Габора, Перліна або Ворлі, можна використовувати під час навчання для імітації таких змагальних атак і підвищення робастності моделей співставлення зображень [8, 9].

Попри нещодавні досягнення, досі питання підвищення робастності моделей співставлення зображення є актуальним. Методи підвищення робастності моделей співставлення в умовах структурованого візуального шуму є недостатньо дослідженими. При цьому розв'язання даної задачі є перспективним напрямом досліджень, особливо для аерозастосувань, де стійка відповідність локальних ознак пари зображень є критично важливою для навігації та картографування.

1.2. Сучасний стан

Зіставлення зображень є однією з базових задачею комп'ютерного зору, що має важливе значення для безпілотних авіаційних систем [10]. Розв'язання даної задачі забезпечує ключові функції: автономну навігацію, візуальну локалізацію, картографування та моніторинг середовища [11]. Суть полягає у пошуку відповідностей між знімками з борту безпілотного літального апарату (БПЛА) та еталонними наборами (ортофото, супутникові зображення, дані попередніх польотів), що дозволяє виконувати геоприв'язку й відстежувати зміни середовища. Надійність цього процесу прямо визначає якість задач високого рівня — від SLAM до аналізу динаміки екосистем.

У випадках, коли супутникові навігаційні сигнали недоступні чи деградовані — у так званих «мі-

ських каньйонах», густих лісових масивах або приміщеннях — БПЛА змушені покладатися на візуальне зіставлення. Хоча запропоновано широкий спектр алгоритмів, вони залишаються обмежено стійкими за складних умов [10, 11]. Збурення у вигляді змін освітлення, сезонних варіацій, часткових оклюзій чи розмиття від руху суттєво знижують точність.

Kim та ін. [12] представили метод локалізації БПЛА шляхом зіставлення з аерокартами, що працював у контрольованих умовах, проте втрачав точність на сценах із тінями та низьким контрастом. Liu та ін. [13] провели масштабний бенчмарк моделей зіставлення, відзначивши вразливість до змін ракурсу та освітлення. Подібні проблеми виявлено і в задачах моніторингу довкілля: Śledziowski та ін. [14] підкреслили падіння надійності під час спостережень за підводними спорудами через відблиски на воді та каламутність.

Традиційні конвеєри зіставлення включали три етапи: детектори ключових точок (Harris, FAST); дескриптори (SIFT, ORB); пошук відповідностей (наприклад, nearest neighbor matching) [1, 2]. Хоча вони заклали основу, їхня стійкість обмежена масштабом, ракурсом і освітленням.

Сучасні підходи на основі нейромереж дозволили спільне навчання детекторів і дескрипторів. SuperPoint [3] став першою масово застосованою моделлю для виявлення й опису ознак. R2D2 [4] інтегрував оцінку повторюваності та надійності ключових точок. XFeat [5] запропонував легку модульну архітектуру для реального часу. Особливу роль відіграють контекстно-усвідомлені моделі зіставлення: SuperGlue [6] застосовує графові нейронні мережі з само- та крос-увагою, LightGlue [7] оптимізує цей підхід для мобільних платформ. Альтернативою є бездетекторні методи, де ключові точки не виділяються явно. Найбільш відомий приклад — LoFTR [8], який виконує щільне зіставлення за допомогою трансформерних дескрипторів. Цей підхід демонструє стійкість на ділянках із низьким рівнем текстури (рослинність, дороги, поля), де класичні детектори зазнають невдач.

Жоден підхід не є універсально стійким до складних структурованих візуальних збурень (тіні, шум, сезонні зміни). У відповідь на виклики дослідниками запропоновано різноманітні стратегії навчання та виведення. У праці [15] розглядається попереднє шумозниження автоенкодерами, що дає приріст точності, але вимагає ресурсів і не справляється з комплексними спотвореннями. Інший підхід полягає в застосуванні змагального навчання [8, 16], що підвищує стійкість до атак, але часто погано узагальнюється на нові збурення. Більш простим але часто ефективним підходом є використання під час навчання ефектив-

ної аугментації даних (повороти, масштабування, кольорні зміни), проте вона не охоплює всього спектру реальних варіацій [17]. Деякі дослідники розглядають структуровані шуми (Габора, Перліна, Ворлі) [18], які добре моделюють природні умови для аугментації даних та змагального навчання. Проте їх застосування у сфері співставлення аерофотозображень залишається недостатньо дослідженим. При цьому, окрім аугментації даних шумами, в тому числі змагальними атаками, велика значення має мікроархітектура нейронної мережі. Наприклад, функції активації з обмеженим діапазоном (ReLU6) та трансформери з механізмами уваги [19] демонструють кращу робастність.

Нейронні мережі радикально змінили парадигму зіставлення зображень, зробивши можливим наскрізне навчання моделі, що одночасно здійснює детектування, опис та співставлення ознак. Однак у реальних умовах безпілотних авіаційних систем навіть найсучасніші моделі залишаються чутливими до: сезонних змін вигляду, шумів сенсорів, складних освітлювальних ефектів, оклюзій і повторюваних текстур. Жоден метод не довів універсальної ефективності. Оптимальні стратегії й надалі вимагають комбінації кількох підходів — від аугментації до архітектурних вдосконалень — із фокусом на умови реальних авіаційних місій.

1.3. Мета та підхід

Основна мета цього дослідження — підвищити робастність моделей нейронних мереж для співставлення аерозображень шляхом обчислювально ефективних модифікацій моделі та процедури навчання. Результатом має стати підвищення робастності навчених моделей нейромереж для співставлення аерозображень до реальних варіацій вигляду сцени, сенсорних артефактів і шумів середовища спостереження.

Під робастністю розуміється здатність системи витримувати певний рівень збурень, зберігаючи функціональність без значного погіршення або втрати ефективності. Під робастною ми розуміємо модель екстракції і співставлення дескрипторів аерозображень, яка реалізує механізми поглинання та протистояння певному рівню та типу деструктивних збурень. Чим менше знижується ефективність співставлення аерозображень під впливом збурення, тим більш робастним вважається екстрактор візуальних орієнтирів. Робастність можна визначати як залишкову функціональність після впливу екстремального деструктивного збурення. Ми будемо порівнювати робастність моделей на основі їх залишкового показника ефективності після впливу збурюючого фактора.

Запропонований метод має на меті підвищити стійкість дескрипторів ознак і механізмів зіставлення до реальних варіацій вигляду сцени, сенсорних артефактів і шумів середовища спостереження.

Ключові завдання такі:

- аналіз наявних методів підвищення робастності нейронних мереж із особливим акцентом на їхнє застосування до задач зіставлення зображень;

- розроблення підходу до навчання, що покращує робастність моделі співставлення зображень шляхом її модифікації та модифікації процесу навчання шляхом включення структурованого синтетичного шуму у процес аугментації даних;

- порівняльна оцінка моделей, навчених запропонованим методом, порівняно зі звичайними процедурами навчання.

Структурно стаття організована так. У розділі 2 подано огляд і аналіз дотичних робіт у галузі зіставлення зображень. У розділі 3 представлено запропонований метод навчання. Розділ 4 містить деталі організації експериментів та їх результати, порівняння результатів детекторних та бездетекторних моделей співставлення. У розділі 5 виконано обговорення результатів експериментів та порівняння з результатами інших дослідників. Нарешті, розділ 6 підсумовує роботу та окреслює потенційні напрями майбутніх досліджень.

2. Моделі співставлення аерознімків

У підрозділі коротко розглянуто основні принципи сучасних підходів до зіставлення аерозображень [3] — моделі SuperPoint, LightGlue та EfficientLoFTR [7]. Спрощена ілюстрація цих моделей показана на рис. 1 (а, б, в).

SuperPoint — це компактна нейромережа «детектор+дескриптор» із єдиним згортковим бекбоном і двома вихідними головами: одна формує карту ймовірностей точок інтересу, інша — поле дескрипторів, з якого знімаються вектори для вибраних ключових точок [3]. Типове навчання поєднує самонавчальні етапи (на кшталт гомографічної адаптації) та кероване донавчання, що забезпечує стабільні ключові точки і сумісні дескриптори для подальшого матчингу в бортових умовах.

LightGlue (рис. 1б) виконує саме зіставлення наборів ключових точок, отриманих, зокрема, SuperPoint-ом [7]. Модель використовує механізми самоуваги та крос-уваги для врахування контексту усередині та між зображеннями, що підвищує стійкість відповідей за оклюзій, повторюваних текстур і змін ракурсу. Завдяки інженерним спрощенням (динамічне обрізання, ранній вихід) LightGlue зменшує обчислювальні витрати порівняно

з попередниками, видаючи пари відповідностей із мірою довіри для подальшої геометричної валідації (наприклад, RANSAC із H/F-матрицями).

EfficientLoFTR (рис. 1в) реалізує бездетекторний підхід: відповідності будуються без явного пошуку ключових точок [7]. Архітектура працює у грубо-точному режимі: спершу формується глобальне узгодження ознак на зменшеній роздільності, далі — локальне уточнення в околах кандидатів. Такий дизайн забезпечує щільніше

покриття сцени й особливо корисний на малотекстурних ділянках аерознімків (поля, дороги, дахи), хоч і вимагає більше пам'яті та обчислень. На практиці розріджений конвеєр SuperPoint→LightGlue забезпечує високу ефективність на борту, тоді як EfficientLoFTR доречний там, де потрібне ширше покриття та робастність до втрати локальних ознак; у всіх випадках критичною залишається геометрична перевірка знайдених відповідностей




Рис. 1. Структура неймереж для співставлення зображень: а – модель детектора точок інтересу SuperPoint; б – модель співставлення точок інтересу LightGlue; в – модель бездетекторного співставлення зображень EfficientLoFTR

3. Метод навчання

Щоб підвищити стійкість моделі в умовах структурованих змагальних шумових впливів, ми пропонуємо замінити всі активації типу ReLU в мережі на гібридну функцію LeakyReLU6 [19]. Це вдосконалення поєднує переваги двох добре досліджених рішень у проєктуванні активацій для підвищення стійкості до змагальних атак.

Leaky ReLU запроваджує ненульовий градієнт у від’ємній області, що покращує проходження градієнта під час змагального навчання та зменшує ймовірність «мертвих» нейронів [21]. Такий гладкий профіль градієнта сприяє кращій збіжності та стабільнішим ландшафтам функції втрат під час змагального донавчання (fine-tuning).

ReLU6 – обмежений варіант ReLU, обрізає вихід активації до фіксованої верхньої межі (зазвичай 6), що зменшує вплив піків активації, спричинених збуреннями на вході під час інференсу [19]. Обмежуючи динамічний діапазон активацій, ReLU6 допомагає стримувати підсилення структурованого шуму на глибших шарах, сприяючи кращому узагальненню в умовах візуальної деградації.

Запропонована формулювання LeakyReLU6 покликане поєднати обидва ефекти — зберегти гладкість для надійної оптимізації та водночас підтримувати обмежену реакцію для підвищеної стабільності за перцептивних збурень, таких як шуми Перліна, Габора та Ворлі.

Під час адаптації попередньо натренованої моделі для підвищення робастності шляхом заміни функцій активації рекомендується замінювати активації, подібні до ReLU, на LeakyReLU6 передусім у глибоких згорткових шарах і блоках виділення ознак. В цих шарах покращений потік градієнта та обмежені за амплітудою вихідні значення активацій допомагають пригнічувати підсилення шуму й уникати «мертвих» нейронів. Не рекомендується змінювати активації у фінальних шарах, де зміни можуть порушити розподіли виходів, а також у блоках уваги трансформерного типу, які зазвичай використовують GELU або подібні гладкі активації, розроблені для стабільності. Також не рекомендується замінювати функцію активації у початкових шарах, що безпосередньо йдуть після входу, оскільки вони можуть діяти як неявні фільтри шуму. Якщо застосовується пакетна нормалізація (Batch Normalization), заміна припустима лише тоді, коли активація розташована після нормалізації (тобто $BN \rightarrow ReLU$), щоб зберегти очікувані розподіли активацій.

Для узгодження процесів навчання та виведення (inference) застосовано так званий “оцінювач прямого проходу” (straight-through estimator, STE)

для функції LeakyReLU6 [22]. У прямому проході використовується жорстко обмежена активація $y_{hard} = \min(\max(\alpha x, x), c)$ з $c = 6$, тоді як у зворотному проході градієнт береться від “м’якої” версії з плавним обмеженням

$$y_{soft} = c \tanh(\text{leaky_relu}(x) / c) \quad (1)$$

Реалізація STE задається як $y = y_{hard} + \text{stopgrad}(y_{soft} - y_{hard})$, що зберігає квантувально-дружній і стабільний за діапазоном forward та забезпечує гладкі, інформативні градієнти без ефектів маскування градієнту (gradient masking).

Рисунок 1 ілюструє етапи запропонованого методу, де процедурний шум може генеруватися у вигляді шумів Габора, Перліна, Simplex, Вороного, Ворлі або інших варіантів.




Рис. 2. Етапи запропонованого методу підвищення робастності моделей зіставлення зображень на основі нейронних мереж

Щоб змодельовати природні, але змагальні візуальні спотворення, які зазвичай погіршують продуктивність систем співставлення зображень, пропонується вводити структурований процедурний шум під час навчання. Зокрема, ми використовуємо патерни шуму Габора, Перліна та Ворлі для збурення вхідних даних у спосіб, що наближує реальні умови, такі як тіні, поверхневі текстури, оклюзії та непостійність освітлення. На відміну від неструктурованого білого чи гаусівського шуму, ці патерни вносять семантично правдоподібні збурення, що імітують природну варіативність сигналу. Завдяки цьому модель змушена зосереджуватися на стійких, семантично

значущих ознаках, а не на текстурно-зумовлених або нестійких ключових точках.

Шум Перліна моделює органічні варіації, подібні до градієнтів освітлення чи природних поверхонь. Він генерується шляхом інтерполяції градієнтів у вузлових точках сітки та зазвичай реалізується рекурсивно для створення фрактальної поведінки. Шум Перліна будується як фрактальна сума згладжених співчастот у частотному просторі [18]:

$$S_{\text{per}}(x, y) = \sum_{n=1}^{\Omega} p \left(x \frac{2^{n-1}}{\lambda_x}, y \frac{2^{n-1}}{\lambda_y} \right), \quad (2)$$

λ_x, λ_y – параметри довжини хвилі вздовж відповідних осей;

Ω – кількість октав (тобто рівнів деталізації);

$p(\bullet)$ – класична 2D функція шуму Перліна.

Для підвищення візуального контрасту дослідники часто застосовують синусоїдальне перетворення:

$$G_{\text{per}}(x, y) = \sin(2\pi \cdot \phi_{\text{sin}} \cdot S_{\text{per}}(x, y)), \quad (3)$$

де ϕ_{sin} – параметр синусоїдальної частоти.

Шум Габора імітує напрямлені структури, такі як відкинуті тіні або повторювані візерунки (наприклад, паркани, дахові покриття). Шум Габора визначається як згортка розрідженого білого шуму з ядром Габора [8]:

$$g(x, y) = e^{-\pi\sigma^2(x^2+y^2)} * \cos\left(\frac{2\pi}{\lambda}(x \cdot \cos(\omega) + y \cdot \sin(\omega))\right), \quad (4)$$

де σ – ширина гауссової обвідної;

λ – довжина хвилі (період гармоніки)

ω – орієнтація.

Отриманий шум Габора генерується як сума згорток:

$$S_{\text{gab}}(x, y) = \frac{1}{\xi} \sum_{n=1}^{\xi} \sum_i g(x - x_i, y - y_i; \sigma, \lambda, \omega + \frac{n\pi}{\xi}) \quad (5)$$

де ξ – число орієнтацій (ступінь ізотропності);

(x_i, y_i) – координати випадково вибраних точок розміщення ядра.

Шум Ворлі (cellular noise) моделює структурні нерегулярності, такі як кам'яні візерунки, потріскані поверхні чи нерівний ґрунт. Він визначається через

обчислення відстані до найближчої точки у сітці псевдовипадкових опорних точок [9]:

$$W(x, y) = \min_{p_i \in F} \|(x, y) - p_i\| \quad (6)$$

де F – набір випадкових контрольних точок (характерних точок), які зазвичай генеруються в кількості 1-2 на кожну комірку регулярної сітки;

(x, y) – координати пікселя або точки в просторі.

Для забезпечення узагальнення під час змагального навчання параметри патернів процедурного шуму (орієнтація, частота, фаза, відстань між елементами тощо) рандомізуються на кожній ітерації або для кожного міні-паketу. При цьому амплітуда збурень обмежується невеликим діапазоном (наприклад, 3–8% динамічного діапазону), аби зберегти візуальну правдоподібність. Результуюче зображення формується шляхом адитивної суперпозиції шуму:

$$I_{\text{noisy}} = I + \epsilon \cdot N(x, y), \quad (7)$$

де ϵ – параметр амплітуди шуму, $\epsilon \in [0.03, 0.08]$.

У результаті утворюються малопомітні для ока, але семантично руйнівні збурення, що робить їх ідеальними кандидатами для структурованого змагального навчання. Завдяки впливу таких спотворень ми підвищуємо стійкість моделі до типів візуальної варіативності, з якими зазвичай стикаються в реальних аерознімках.

Для оцінювання ефективності запропонованого методу було вирішено розглянути як моделі на основі виявлення ключових точок, так і бездетекторні підходи. Найпоширенішими моделями для виявлення та опису ключових точок є нейромережеві комбінації SuperPoint і LightGlue [3, 7]. Однією з найбільш відомих та ефективних бездетекторних моделей є нейронна мережа EfficientLoFTR [7].

4. Експерименти

Ми генеруємо пари зображень шляхом вибірки випадкових гомографій та застосування випадкових фотометричних спотворень до аерознімків. Базові зображення походять із набору даних для бенчмарку зіставлення аерозображень (Aerial Image Matching Benchmark Dataset [23]), який поділено на навчальну, валідаційну та тестову вибірки. При цьому відома гомографія між кожним оригінальним зображенням та трансформованою версією. Як валідаційна метрика коректності зіставлення аерозображень використовується AUC RANSAC з точністю K пікселів, що обчислюється за формулою [24]

$$AUC_k = \frac{1}{KN} \sum_{i=1}^N \max(0, K - e_i), \quad (8)$$

де e_i – середня L2 -похибка репроекції 4х кутів зображення (у пікселях) між оціненою (H) на результатах матчингу зображень за алгоритмом RANSAC і достовірною H_{gt} гомографіями, тобто

$$e_i = \frac{1}{4} \sum_{p \in \{(0,0), (w,0), (0,h), (w,h)\}} \|H^{(i)}p - H_{gt}^{(i)}p\|_2 \quad (9)$$

K – поріг похибки в пікселях (px), де $K = 1$ px є строгим критерієм субпіксельної точності, а $K = 3.5$ px є м'якшим критерієм;

N – кількість пар зображень.

Для підвищення стійкості моделей до структурованих спотворень, змодельованих за допомогою процедурного шуму (Габова, Перліна, Ворлі), було проведено додаткове навчання із використанням модифікованої активаційної функції LeakyReLU6. Результати, отримані під час тестування навчених моделей на тестових даних із застосуванням того ж типу процедурного шуму, наведено в Таблиці 1.

Таблиця 1

Результати на наборі даних Aerial Image Matching Benchmark

Модель детектора орієнтирів	Модель співставлення	AUC @1px	AUC @3px
SuperPoint	LightGlue	42,1 %	73,9 %
EfficientLoFTR	EfficientLoFTR	49,5 %	79,2 %
SuperPoint з LeakyReLU6, навчена з процедурним шумом	LightGlue з LeakyReLU6, навчена з процедурним шумом	47,3 %	78,9 %
EfficientLoFTR з LeakyReLU6, навчена з процедурним шумом	EfficientLoFTR з LeakyReLU6, навчена з процедурним шумом	53,7 %	83,6 %

Аналіз Таблиці 1 показує, що запропонований метод підвищує AUC @1px співставлення зашумлених зображень як для детекторних моделей (на 5,2 %), так і бездетекторних моделей (на 4,2 %). Проте окремий внесок процедурного шуму та модифікації активаційної функції у кінцевий результат залишається неочевидним. Тому було проведено абляційне

дослідження, в якому процедурний шум збережено як частину аугментації пар даних під час навчання, але функцію активації LeakyReLU не застосовувано (див. Таблицю 2).

Таблиця 2

Абляційне дослідження: точність зіставлення без активації LeakyReLU6

Модель детектора орієнтирів	Модель співставлення	AUC @1px	AUC @3px
SuperPoint, навчена з процедурним шумом	LightGlue, навчена з процедурним шумом	44,3 %	76,2 %
EfficientLoFTR, навчена з процедурним шумом	EfficientLoFTR, навчена з процедурним шумом	51,5 %	81,0 %

Таблиці 1 та 2 демонструють, що використання модифікованої активаційної функції LeakyReLU6 у поєднанні з процедурним шумом забезпечило підвищення AUC @1px на 3,0 % та AUC @3px на 2,7 % для моделі SuperPoint+LightGlue. Для моделі EfficientLoFTR застосування LeakyReLU6 призвело до зростання AUC @1px співставлення на 2,2 % та AUC @3px на 2,6 %.

Таким чином, експериментально підтверджено ефективність запропонованого методу підвищення стійкості — зокрема, покращення AUC @1px та AUC @3px на зашумлених тестових даних — як для моделей на основі ознак, так і для бездетекторних нейромережових моделей співставлення.

5. Обговорення

Отримані результати залежать не лише від моделі та методу навчання, але й від навчальних і тестових наборів даних. Тому важливо оцінити ефективність запропонованого методу також на інших загальнодоступних наборах даних. У цьому контексті доцільно порівняти результати, досягнуті із використанням запропонованого підходу, з результатами, отриманими за допомогою традиційного методу. У Таблиці 3 наведено результати, представлені в [25] для моделі SuperPoint + LightGlue, поряд із результатами, отриманими із застосуванням запропонованого методу на наборі даних HPatches.

Аналіз Таблиці 3 показує, що відомий набір даних HPatches також демонструє підвищення AUC @1px та AUC @3px на порівняно з базовим результатом, наведеним у [25].

Таблиця 3

Результати на наборі даних HPatches для нейронних мереж, попередньо натренованих на наборі даних HPatches

Модель детектора орієнтирів	Модель співставлення	AUC @1px	AUC @3px
SuperPoint	LightGlue	34,87 %	56,36 %
SuperPoint з LeakyReLU6 і навчена з процедурним шумом	LightGlue з LeakyReLU6 і навчена з процедурним шумом	37,9 %	59,3 %

Запропонований метод має багато спільного з попередніми дослідженнями у сфері аугментації даних та адвесаріального навчання, спрямованими на підвищення здатності нейронних мереж до узагальнення та їхньої стійкості до варіативності спостережень [16]. Тому доцільно дослідити здатність до узагальнення нейронних мереж, натренованих на наборі даних Aerial Image Matching Benchmark, під час тестування на «чистих» (безшумних) даних із набору HPatches (див. Таблицю 4).

Таблиця 4

Результати на наборі даних HPatches для нейронних мереж, попередньо натренованих на наборі даних Aerial Image Matching Benchmark

Модель детектора орієнтирів	Модель співставлення	AUC @1px	AUC @3px
SuperPoint	LightGlue	31,2 %	51,0 %
SuperPoint з LeakyReLU6 і навчена з процедурним шумом	LightGlue з LeakyReLU6 і навчена з процедурним шумом	33,4 %	54,1 %

Аналіз Таблиці 4 показує, що моделі SuperPoint+LightGlue, навчені на наборі даних Aerial Image Matching Benchmark, під час тестування на HPatches демонструють зниження AUC @1px та 3,67% та AUC @3px на 3,1%, порівняно з моделями, натренованими на HPatches. Натомість моделі, навчені із застосуванням запропонованого методу, показують лише 4,5% зниження AUC @1px та 5,2% зниження AUC @3px. Це підтверджує підвищену здатність до узагальнення моделей, навчених за допомогою запропонованого підходу.

Таким чином, запропонований метод підвищення стійкості нейронних мереж для зіставлення

зображень є придатним як для моделей на основі ознак, так і для бездетекторних моделей. Більше того, покращення показників точності було досягнуто як під час навчання, так і під час тестування на різних наборах даних.

6. Висновки

Уперше було розроблено метод підвищення стійкості нейронних мережових моделей для зіставлення аерозображень шляхом заміни активаційних функцій типу ReLU на LeakyReLU6 та донавчання моделей на даних, аугментованих процедурним шумом (таким як Перліна, Габора чи Ворлі).

Експериментально доведено, що запропонований метод підвищує як стійкість, так і здатність до узагальнення нейронних мережових моделей для зіставлення аерозображень. Зокрема, нейронні мережі SuperPoint+LightGlue та EfficientLoFTR, навчені із застосуванням запропонованого підходу, досягли більш ніж на 4,2% вищих показників AUC @1px порівняно з традиційними методами під час навчання й тестування на зашумлених даних набору Aerial Image Matching Benchmark Dataset. Ба більше, навіть під час оцінювання на «чистому» наборі HPatches з іншої предметної області моделі продемонстрували кращі показники точності порівняно з тими, що були навчені класичними методами.

Обмеженням цього дослідження є те, що не було проаналізовано вплив параметрів генерації синтетичного процедурного шуму та кількості ітерацій навчання на точність роботи зіставлявача зображень за різних умов. Крім того, експериментальне дослідження було обмежене лише двома нейронними зіставлявачами: SuperPoint+LightGlue та EfficientLoFTR. Проте ці моделі є репрезентативними прикладами популярних підходів відповідно з використанням і без використання виявлення ключових точок.

Подальші дослідження будуть спрямовані на застосування мета-навчання, регуляризаційних методів та архітектурних удосконалень для підвищення стійкості й резильєнтності нейронних зіставлявачів аерозображень.

Внесок авторів: розроблення концептуальних положень та методології дослідження, формулювання висновків – **Артем Коробов**; розроблення методу навчання моделей нейромереж, аналіз результатів дослідження – **Юрій Москаленко**; огляд та аналіз джерел, порівняння отриманих результатів з результатами інших дослідників – **Владислав Бабич**; розроблення програмного забезпечення – **Максим Виноградов**.

Конфлікт інтересів

Автори заявляють, що не мають конфлікту інтересів щодо цього дослідження, будь то фінансовий, особистий, авторський або інший, що могло б вплинути на дослідження та його результати, представлені в цій статті.

Фінансування

Робота виконана в рамках проекту «Виконання завдань перспективного плану розвитку наукового напрямку “Технічні науки” Сумського державного університету» (№ держреєстрації 0121U112684), що фінансується Міністерством освіти і науки України.

Наявність даних

Набір даних Aerial Image Matching Benchmark, використаний у цьому дослідженні, можна отримати з двох джерел: порталу ISPRS-EuroSDR (<https://ifpwww.ifp.uni-stuttgart.de/ISPRS-EuroSDR/ImageMatching/default.aspx>) та та IEEE DataPort (<https://ieee-dataport.org/documents/aerial-image-matching-benchmark-dataset>). Зверніть увагу, що для завантаження з обох репозиторіїв потрібна безкоштовна реєстрація користувача. Набір даних містить пари аерозображень високої роздільної здатності, еталонні гомографії та офіційні скрипти для оцінювання. Набір даних HPatches [Balntas та ін., CVPR 2017] доступний без обмежень за адресою <https://hpatches.github.io> (GitHub: <https://github.com/uzh-rpg/hpatches-release>). Він включає планарні фрагменти зображень із контрольованими змінами ракурсу та освітлення разом із відповідними матрицями еталонних гомографій. Усі вихідні зображення, файли гомографій і код, використаний для обчислення точності (precision) та повноти (recall) зіставлення в цій роботі, можна отримати за цими посиланнями.

Використання штучного інтелекту

Автори використовували технології штучного інтелекту для надання перевірених результатів. Написання тексту статті було здійснено без використання технологій штучного інтелекту.

Подяки

Автори висловлюють подяку Міністерству освіти і науки України за підтримку Лабораторії Інтелектуальних Систем в рамках дослідницьких проектів «Виконання завдань перспективного плану розвитку наукового напрямку “Технічні науки” Сумського державного університету» та “Інформаційна технологія забезпечення резильєнтності інтелектуальної бортової системи малогабаритних літальних апаратів” (№ держреєстрації 0121U112684)".

Всі автори прочитали та погодилися з опублікованою версією рукопису.

Література

- 1 Budzan, S. Performance analysis of keypoints detection and description algorithms for stereo vision based odometry [Text] / S. Budzan, R. Wyzgolik, & M. Lysko // *Sensors*. – 2025. – Vol. 25, no. 19. – Article No. 6129. DOI: 10.3390/s25196129.
- 2 Hidalgo, F. Evaluation of several feature detectors/extractors on underwater images towards vSLAM [Text] / F. Hidalgo, & T. Bräunl // *Sensors*. – 2020. – Vol. 20, iss. 15. – Article No. 4343. DOI: 10.3390/s20154343.
- 3 Local feature matching using deep learning: A survey [Text] / S. Xu, S. Chen, R. Xu, C. Wang, P. Lu, & L. Guo // *Information Fusion*. – 2024. – Vol. 107. – Article No. 102344. DOI: 10.1016/j.inffus.2024.102344.
- 4 R2D2: Repeatable and reliable detector and descriptor [Text] / J. Revaud, P. Weinzaepfel, C. De Souza, N. Pion, G. Csurka, & Y. Cabon, M. Humenberger // *ArXiv*. – 2019. DOI: 10.48550/arXiv.1906.06195.
- 5 Fukushima, S. Decay rate of the eigenvalues of the Neumann–Poincaré operator [Text] / S. Fukushima, H. Kang, & Y. Miyanishi // *ArXiv*. – 2023. DOI: 10.48550/arXiv.2304.04772.
- 6 Sarlin, P.-E. SuperGlue: Learning feature matching with graph neural networks [Text] / P.-E. Sarlin, D. DeTone, T. Malisiewicz, & A. Rabinovich // *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. – IEEE, 2020. – P. 4937–4946. DOI: 10.1109/CVPR42600.2020.00499.
- 7 Lindenberger, P. LightGlue: Local feature matching at light speed [Text] / P. Lindenberger, P.-E. Sarlin, & M. Pollefeys // *ICCV 2023*. – 2023. DOI: 10.1109/ICCV51070.2023.01616.
- 8 On procedural adversarial noise attack and defense [Text] / J. Yan, X. Deng, H. Yin, W. Ge // *ArXiv*. – 2021. DOI: 10.48550/arXiv.2108.04409.
- 9 Exploring aesthetic procedural noise for crafting model-agnostic universal adversarial perturbations [Text] / J. Yan, H. Yin, W. Ge, & L. Liu // *Displays*. – 2023. – Vol. 79. – Article No. 102479. DOI: 10.1016/j.displa.2023.102479.
- 10 Kinnari, J. Season-invariant GNSS-denied visual localization for UAVs [Text] / J. Kinnari, F. Verdoja, & V. Kyrki // *IEEE Robotics and Automation Letters*. – 2022. – Vol. 7, iss. 4. – P. 10232–10239. DOI: 10.1109/LRA.2022.3191038.
- 11 GNSS-denied geolocalization of UAVs using terrain-weighted constraint optimization [Text] / F. Yao, C. Lan, L. Wang, H. Wan, T. Gao, & Z. Wei // *International Journal of Applied Earth Observation and*

Geoinformation. – 2024. – Vol. 135. – Article No. 104277. DOI: 10.1016/j.jag.2024.104277.

12 Kim, J. Urban localization based on aerial imagery by correcting projection distortion [Text] / J. Kim, Y. Cho, & J. Kim // *Autonomous Robots*. – 2022. – Vol. 47, iss. 3. – P. 299–312. DOI: 10.1007/s10514-022-10082-5.

13 Image matching across wide baselines: From paper to practice [Text] / Y. Jin, D. Mishkin, E. Mishchuk, J. Matas, P. Fua, K. M. Yi, & E. Trulls // *International Journal of Computer Vision*. – 2020. – Vol. 129, iss. 2. – P. 517–547. DOI: 10.1007/s11263-020-01385-0.

14 Application of unmanned aerial vehicles and image processing techniques in monitoring underwater coastal protection measures [Text] / J. Ślędzowski, P. Terefenko, A. Giza, P. Forczmański, A. Łysko, W. Maćków, G. Stępień, A. Tomczak, & A. Kurylczyk // *Remote Sensing*. – 2022. – Vol. 14, iss. 3. – Article No. 458. DOI: 10.3390/rs14030458.

15 Solovyeva, E. Dual autoencoder network with separable convolutional layers for denoising and deblurring images [Text] / E. Solovyeva, & A. Abdullah // *Journal of Imaging*. – 2022. – Vol. 8, iss. 9. – Article No. 250. DOI: 10.3390/jimaging8090250.

16 A survey of robust adversarial training in pattern recognition: Fundamental, theory, and methodologies [Text] / Z. Qian, K. Huang, Q.-F. Wang, & X.-Y. Zhang // *Pattern Recognition*. – 2022. – Vol. 131. – Article No. 108889. DOI: 10.1016/j.patcog.2022.108889.

17 Xu, M. A comprehensive survey of image augmentation techniques for deep learning [Електронний ресурс] / M. Xu, S. Yoon, A. Fuentes, D. S. Park // *Pattern Recognition*. – 2023. – Vol. 137. – Article No. 109347. DOI: 10.1016/j.patcog.2023.109347.

18 Perlin noise improve adversarial robustness [Text] / C. Tang, K. Zhang, C. Xing, Y. Ding, & Z.-Q. J. Xu // *ArXiv*. – 2021. DOI: 10.48550/arXiv.2112.13408.

19 Sooksatra, K. Dynamic-max-value ReLU functions for adversarially robust machine learning models [Text] / K. Sooksatra, & P. Rivas // *Mathematics*. – 2024. – Vol. 12, iss. 22. – Article No. 3551. DOI: 10.3390/math12223551.

20 Paul, S. Vision transformers are robust learners [Текст] / S. Paul, & P.-Y. Chen // *Proceedings of the AAAI Conference on Artificial Intelligence*. – 2022. – Vol. 36, iss. 2. – P. 2071–2081. DOI: 10.1609/aaai.v36i2.20103.

21 Layton, O. W. ReLU, sparseness, and the encoding of optic flow in neural networks [Text] / O. W. Layton, S. Peng, & S. T. Steinmetz // *Sensors*. – 2024. – Vol. 24, iss. 23. – Article No. 7453. DOI: 10.3390/s24237453.

22 AdaSTE: An adaptive straight-through estimator to train binary neural networks [Text] / H. Le, R. K. Hoier, C.-T. Lin, & C. Zach // *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. – IEEE, 2022. – P. 460–469. DOI: 10.1109/CVPR52688.2022.00055.

23 Pogorzelski, T. P. Aerial Image Matching Benchmark Dataset [Dataset] / T. P. Pogorzelski // *IEEE DataPort*. – 2025. DOI: 10.21227/JD5S-AY89.

24 HPatches: A benchmark and evaluation of handcrafted and learned local descriptors [Text] / V. Balntas, K. Lenc, A. Vedaldi, T. Tuytelaars, J. Matas, & K. Mikolajczyk // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2019. – P. 1–1. DOI: 10.1109/TPAMI.2019.2915233.

25 Zhang, S. DiffGlue: Diffusion-aided image feature matching [Text] / S. Zhang, & J. Ma // *Proceedings of the 32nd ACM International Conference on Multimedia (MM '24)*. – ACM, 2024. – P. 8451–8460. DOI: 10.1145/3664647.3681069.

References

1. Budzan, S., Wyżgolik, R., & Łysko, M. Performance analysis of keypoints detection and description algorithms for stereo vision based odometry. *Sensors*, 2025, vol. 25, iss. 19, article no. 6129. DOI: 10.3390/s25196129.

2. Hidalgo, F., & Bräunl, T. Evaluation of several feature detectors/extractors on underwater images towards vSLAM. *Sensors*, 2020, vol. 20, iss. 15, article no. 4343. DOI: 10.3390/s20154343.

3. Xu, S., Chen, S., Xu, R., Wang, C., Lu, P., & Guo, L. Local feature matching using deep learning: A survey. *Information Fusion*, 2024, vol. 107, article no. 102344. DOI: 10.1016/j.inffus.2024.102344.

4. Revaud, J., Weinzaepfel, P., De Souza, C., Pion, N., Csurka, G., Cabon, Y., & Humenberger, M. R2D2: Repeatable and reliable detector and descriptor. *arXiv*, 2019. DOI: 10.48550/arXiv.1906.06195.

5. Fukushima, S., Kang, H., & Miyanishi, Y. Decay rate of the eigenvalues of the Neumann–Poincaré operator. *arXiv*, 2023. DOI: 10.48550/arXiv.2304.04772.

6. Sarlin, P.-E., DeTone, D., Malisiewicz, T., & Rabinovich, A. SuperGlue: Learning feature matching with graph neural networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2020)*, IEEE, 2020, pp. 4937–4946. DOI: 10.1109/CVPR42600.2020.00499.

7. Lindenberger, P., Sarlin, P.-E., & Pollefeys, M. LightGlue: Local feature matching at light speed. *Proceedings of the IEEE/CVF International Conference*

- on *Computer Vision (ICCV 2023)*. DOI: 10.1109/ICCV51070.2023.01616.
8. Yan, J., Deng, X., Yin, H., & Ge, W. On procedural adversarial noise attack and defense. *arXiv*, 2021. DOI: 10.48550/arXiv.2108.04409.
9. Yan, J., Yin, H., Ge, W., & Liu, L. Exploring aesthetic procedural noise for crafting model-agnostic universal adversarial perturbations. *Displays*, 2023, vol. 79, article no. 102479. DOI: 10.1016/j.displa.2023.102479.
10. Kinnari, J., Verdoja, F., & Kyrki, V. Season-invariant GNSS-denied visual localization for UAVs. *IEEE Robotics and Automation Letters*, 2022, vol. 7, iss. 4, pp. 10232–10239. DOI: 10.1109/LRA.2022.3191038.
11. Yao, F., Lan, C., Wang, L., Wan, H., Gao, T., & Wei, Z. GNSS-denied geolocalization of UAVs using terrain-weighted constraint optimization. *International Journal of Applied Earth Observation and Geoinformation*, 2024, vol. 135, article no. 104277. DOI: 10.1016/j.jag.2024.104277.
12. Kim, J., Cho, Y., & Kim, J.. Urban localization based on aerial imagery by correcting projection distortion. *Autonomous Robots*, 2022, vol. 47, iss. 3, pp. 299–312. DOI: 10.1007/s10514-022-10082-5.
13. Jin, Y., Mishkin, D., Mishchuk, E., Matas, J., Fua, P., Yi, K. M., & Trulls, E. Image matching across wide baselines: From paper to practice. *International Journal of Computer Vision*, 2020, vol. 129, iss. 2, pp. 517–547. DOI: 10.1007/s11263-020-01385-0.
14. Śledziowski, J., Terefenko, P., Giza, A., Forcmański, P., Łysko, A., Maćków, W., Stępień, G., Tomczak, A., & Kurylczuk, A. Application of unmanned aerial vehicles and image processing techniques in monitoring underwater coastal protection measures. *Remote Sensing*, 2022, vol. 14, iss. 3, article no. 458. DOI: 10.3390/rs14030458.
15. Solovyeva, E., & Abdullah, A. Dual autoencoder network with separable convolutional layers for denoising and deblurring images. *Journal of Imaging*, 2022, vol. 8, iss. 9, article no. 250. DOI: 10.3390/jimaging8090250.
16. Qian, Z., Huang, K., Wang, Q.-F., & Zhang, X.-Y. A survey of robust adversarial training in pattern recognition: Fundamental, theory, and methodologies. *Pattern Recognition*, 2022, vol. 131, article no. 108889. DOI: 10.1016/j.patcog.2022.108889.
17. Xu, M., Yoon, S., Fuentes, A., & Park, D. S. A comprehensive survey of image augmentation techniques for deep learning. *Pattern Recognition*, 2023, vol. 137, article no. 109347. DOI: 10.1016/j.patcog.2023.109347.
18. Tang, C., Zhang, K., Xing, C., Ding, Y., & Xu, Z.-Q.J. Perlin noise improve adversarial robustness. *arXiv*, 2021. DOI: 10.48550/arXiv.2112.13408.
19. Sooksatra, K., & Rivas, P. Dynamic-max-value ReLU functions for adversarially robust machine learning models. *Mathematics*, 2024, vol. 12, iss. 22, article no. 3551. DOI: 10.3390/math12223551.
20. Paul, S., & Chen, P.-Y. Vision transformers are robust learners. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, vol. 36, iss. 2, pp. 2071–2081. DOI: <https://doi.org/10.1609/aaai.v36i2.20103>
21. Layton, O. W., Peng, S., & Steinmetz, S. T. ReLU, sparseness, and the encoding of optic flow in neural networks. *Sensors*, 2024, vol. 24, iss. 23, article 7453. DOI: 10.3390/s24237453.
22. Le, H., Hoier, R.K., Lin, C.-T., & Zach, C. AdaSTE: An adaptive straight-through estimator to train binary neural networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2022)*, IEEE, 2022, pp. 460–469. DOI: 10.1109/CVPR52688.2022.00055.
23. Pogorzelski, T. P. Aerial image matching benchmark dataset [dataset]. *IEEE DataPort*, 2025. DOI: 10.21227/JD5S-AY89.
24. Balntas, V., Lenc, K., Vedaldi, A., Tuytelaars, T., Matas, J., & Mikolajczyk, K. HPatches: A benchmark and evaluation of handcrafted and learned local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019. pp. 1–1. DOI: 10.1109/TPAMI.2019.2915233.
25. Zhang, S., & Ma, J. DiffGlue: Diffusion-aided image feature matching. *Proceedings of the 32nd ACM International Conference on Multimedia (MM '24)*, ACM, 2024, pp. 8451–8460. DOI: 10.1145/3664647.3681069.

Надійшла до редакції 15.09.2025 розглянута на редколегії 22.09.2025

A METHOD FOR IMPROVING THE ROBUSTNESS OF NEURAL NETWORK FOR AERIAL IMAGE MATCHING

Artem Korobov, Yuriy Moskalenko, Maksym Vynohradov, Vladyslav Babych

The **subject** of study in this article is neural network–based methods for aerial image matching, which are widely used in navigation, localization, and mapping tasks. A key challenge lies in the sensitivity of such methods to visual

disturbances and scene novelty caused by shadows, illumination changes, and terrain variability, which limits their robustness in real-world conditions—particularly under constrained computational resources. This paper investigates an approach to enhancing the robustness and cross-domain generalization of computationally efficient aerial image matching models by combining adversarial procedural noise with a modified activation function. The **goal** is to develop a training methodology that simultaneously increases the resilience of models to perturbations and improves their transferability across different observation domains. The **research objectives** are as follows: (1) to analyze existing methods for improving the robustness of neural networks and assess their applicability to aerial image matching tasks; (2) to develop a training approach incorporating the synthesis of adversarial procedural noises (Perlin, Gabor, Worley) and the replacement of the standard ReLU with a hybrid activation function, LeakyReLU6, which constrains activation amplitudes and reduces sensitivity to local disturbances; (3) to conduct a comprehensive experimental evaluation of detector-based architectures (SuperPoint + LightGlue) and detector-free models (EfficientLoFTR) using the Aerial Image Matching Benchmark dataset; (4) to verify cross-domain generalization on the HPatches dataset; and (5) to perform an ablation study to isolate the contribution of each component. **Results.** The proposed methodology achieved over a 4.2% absolute improvement in AUC@1px matching accuracy on noisy test data for both classes of models. The ablation study revealed a synergistic effect from combining procedural noise with LeakyReLU6 — in particular, for the SuperPoint + LightGlue combination, improvements reached +3.0% AUC@1px and +2.7% AUC@3px, while for EfficientLoFTR, gains of +2.2% and +2.6% were observed, respectively. Additionally, testing on HPatches showed a 0.83% smaller performance drop compared to baseline training, confirming a higher level of cross-domain generalization. **Conclusions.** The proposed approach enhances the noise robustness and cross-domain generalization of feature-matching models and can be easily extended to various neural network architectures. Future work will focus on investigating the influence of procedural noise hyperparameters, applying meta-learning on corrupted data, and introducing architectural improvements to further strengthen resilience and robustness. **Scientific novelty.** The novelty of this work lies in the *first integration* of adversarial learning with procedural noise and a bounded activation function (LeakyReLU6, using the Straight-Through Estimator (STE) in the backward pass), which produced a synergistic effect that improved the robustness and generalization of aerial image matching models *without a significant increase in computational cost*.

Keywords: image matching; robustness; neural networks; adversarial attacks; adversarial learning.

Коробов Артем Геннадійович – PhD, старш. викл. каф. комп’ютерних наук, Сумський державний університет, Суми, Україна.

Москаленко Юрій Васильович – асп. каф. комп’ютерних наук, Сумський державний університет, Суми, Україна.

Виноградов Максим Олексійович – асп. каф. комп’ютерних наук, Сумський державний університет, Суми, Україна.

Бабич Владислав Юрійович – асп. каф. комп’ютерних наук, Сумський державний університет, Суми, Україна.

Artem Korobov – PhD, Senior Lecturer of Computer Sciences Department of Sumy State University, Sumy, Ukraine, e-mail: a.korobov@cs.sumdu.edu.ua, ORCID: 0000-0003-3239-1977, Scopus Author ID: 57196299250.

Yuriy Moskalenko – PhD Student of Computer Science Department of Sumy State University, Sumy, Ukraine, e-mail: yuriy.mosk@gmail.com, ORCID: 0009-0002-3635-3337.

Maksym Vynogradov – PhD Student of Computer Science Department of Sumy State University, Sumy, Ukraine, e-mail: vinogradov.max97@gmail.com, ORCID: 0009-0009-1234-922X.

Vladyslav Babych – PhD Student of Computer Science Department of Sumy State University, Sumy, Ukraine, e-mail: vladuslav09@gmail.com, ORCID: 0009-0009-2521-0841.