

УДК 504.056+542.2

DOI: <http://doi.org/10.17721/1728-2713.113.14>

Олена ГЛАЗУНОВА¹, д-р пед. наук, проф.
ORCID ID: 0000-0002-0136-4936
e-mail: vice_rect_ped_work@nubip.edu.ua

Igor БОЛБОТ¹, д-р техн. наук, проф.
ORCID ID: 0000-0002-5708-6007
e-mail: igor-bolbot@nubip.edu.ua

Роман РУДЕНСЬКИЙ¹, д-р екон. наук, проф.
ORCID ID: 0009-0002-3682-9702
e-mail: roman.rudensky@nubip.edu.ua

Володимир КРАВЧЕНКО¹, д-р екон. наук, проф.
ORCID ID: 0000-0002-8033-3985
e-mail: v.kravchenko@nubip.edu.ua

Олексій ЦИГАНОВ¹, асист.
ORCID ID: 0009-0008-6965-130X
e-mail: o.tsyganov@nubip.edu.ua

Оксана ТОНХА¹, д-р с.-г. наук, проф.
ORCID ID: 0000-0002-0677-5494
e-mail: tonkha.o@nubip.edu.ua

¹Національний університет біоресурсів і природокористування України, Київ, Україна

ЗАСТОСУВАННЯ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ ДЕТЕКЦІЇ ВИРВ НА ТЕРИТОРІЯХ, ПОШКОДЖЕНИХ ВІЙСЬКОВИМИ ДІЯМИ

(Представлено членом редакційної колегії д-ром геогр. наук, проф. Д.О. Ляшенком)

Вступ. Значні пошкодження земельних ресурсів унаслідок військових дій зумовили необхідність впровадження сучасних підходів до оцінювання їх деградації та визначення потреб у відповідній рекультивациі. У межах проведеного дослідження запропоновано методи застосування технологій штучного інтелекту (ШІ) для оперативного моніторингу пошкоджених територій і розрахунку обсягів ресурсів, необхідних для їх відновлення.

Методи. Опрацювання супутникових та аерофотознімків здійснено з використанням алгоритмів комп'ютерного зору, зокрема згорткових нейронних мереж YOLOv5 і Faster R-CNN, а також методів контурної детекції та перетворення Гафа. Для підвищення ефективності обробки даних було застосовано хмарну інфраструктуру Amazon Web Services (AWS), а також реалізовано оптимізацію гіперпараметрів за допомогою бібліотеки Optuna.

Результати. Результатами дослідження підтверджено ефективність запропонованого підходу. Використання моделей, адаптованих з проекту PyCDA (первинно призначеного для детекції планетарних кратерів), дало змогу з високою точністю ідентифікувати вирви, спричинені вибухами. Розроблено алгоритми евристичної детекції контурів, що підвищують точність аналізу, а також реалізовано методики оцінювання обсягів рекультивациі на основі геометричних моделей і супутникових спостережень. Оптимізовані алгоритмічні параметри забезпечили підвищення продуктивності автоматизованої системи обробки даних.

Висновки. Практичну значущість дослідження підтверджено створенням комплексного інструментарію для оцінювання стану деградованих земель і формування стратегій їх відновлення. Запропоновані рішення рекомендовано до використання в роботі державних установ, екологічних служб та наукових організацій, що здійснюють ліквідацію наслідків деградації земельних ресурсів і планування заходів рекультивациі.

Ключові слова: штучний інтелект, супутниковий моніторинг, детекції контурів вирв, комп'ютерний зір, оптимізація гіперпараметрів, рекультивация земель.

Вступ

Військові конфлікти чинять суттєвий деструктивний вплив на довкілля, зокрема спричиняють масштабне порушення структури й функціонального стану земельних ресурсів. Такі наслідки істотно ускладнюють подальше використання територій у сільському господарстві, природоохоронній діяльності та ландшафтному плануванні. Проведені в різних регіонах дослідження засвідчили доцільність і необхідність впровадження сучасних технологій дистанційного моніторингу для кількісної оцінки екологічних наслідків воєнних дій. У роботах (Kussul et al., 2023, 2025; Weir, & McQuillan, 2019) доведено, що поєднання супутникової зйомки та алгоритмів машинного навчання забезпечує підвищену точність виявлення пошкоджених ділянок.

У науковій спільноті активно проводяться дослідження із застосування методів штучного інтелекту (ШІ)

для аналізу супутникових знімків і зображень, отриманих із дронів. Зокрема, у праці (Silburt et al., 2019) продемонстровано ефективність згорткових нейронних мереж у задачах автоматизованого розпізнавання кратерів на планетах, що стало підґрунтям для адаптації цих методів до задач ідентифікації вибухових вирв на поверхні Землі. У свою чергу, у праці (Yao et al., 2018) розроблено адаптивні алгоритми детекції контурів, здатні забезпечити високу точність у процесах рельєфного аналізу.

Проведені дослідження також засвідчили доцільність використання трансфертного навчання, яке передбачає адаптацію попередньо натренованих моделей до нових задач, що значно скорочує обсяг необхідних обчислювальних ресурсів (Benedix et al., 2018). Крім того, у роботах (Akiba et al., 2019) представлено підходи до оптимізації гіперпараметрів глибоких нейронних мереж, які сприяють покращенню точності аналізу візуальних даних.

Актуальність цього дослідження зумовлена необхідністю оперативного, автоматизованого та точного моніторингу пошкоджених земельних ділянок з використанням сучасних технологій, що інтегрують дистанційне зондування Землі та алгоритми машинного навчання.

Метою роботи визначено розроблення методології автоматизованого аналізу деградованих територій із використанням інструментів штучного інтелекту та супутникових технологій. Для досягнення цієї мети дослідження фокусується на таких завданнях: адаптація моделей комп'ютерного зору для аналізу деградованих територій, розробка алгоритмів детекції контурів і класифікації пошкоджень, оцінка можливостей автоматизації процесу моніторингу за допомогою хмарних технологій.

Наукову новизну роботи становить комплексний підхід, що поєднує етапи збору, підготовки та аналізу супутникових знімків із залученням методів глибокого навчання й оптимізації гіперпараметрів для детекції вибухових вивірв і оцінки обсягів рекультиваційних заходів. Запропоновані підходи рекомендовано для використання в системах екологічного моніторингу, відновлення земельних ресурсів та оцінювання довгострокових екосистемних змін унаслідок збройних конфліктів.

Методи

Методологія дослідження базується на комплексному поєднанні класичних алгоритмів комп'ютерного зору із сучасними методами глибокого навчання для автоматизованої детекції вибухових вивірв на супутникових знімках. Рішення про поєднання евристичних підходів і сучасних методів машинного навчання ґрунтується на принципах багатовступневої обробки візуальних даних, досліджених, наприклад у роботі (Szeliski, 2022) і в контексті запропонованої методології включає три основні компоненти: евристичну детекцію контурів на основі градієнтного аналізу (Canny, 1986) та геометричного перетворення Хафа (Ballard, 1981; Duda, & Hart, 1972); трансфертне навчання з адаптацією моделі PyCDA, перш за все навченої для планетарних досліджень (Silburt et al., 2019), та нейромережеву детекцію об'єктів із використанням архітектури YOLO (Jocher, Chaurasia, & Qiu, 2023; Redmon et al., 2016). Оптимізацію гіперпараметрів реалізовано за допомогою байєсівського підходу з використанням фреймворку Optuna (Akiba et al., 2019), що забезпечує ефективний пошук у багатовимірному параметричному просторі з максимізацією метрики F1-score як цільової функції.

Інтеграція класичних і нейромережевих методів забезпечує комплементарність підходів: евристичні алгоритми характеризуються високою інтерпретованістю та не потребують великих обсягів розмічених даних (Shapiro, & Stockman, 2001), тоді як глибоке навчання забезпечує адаптивність до складних візуальних патернів і варіабельності умов зйомки (Goodfellow, Bengio, & Courville, 2016). Валідація результатів ґрунтується на порівнянні з ручною розміткою експертів, що відповідає стандартам оцінювання якості систем детекції об'єктів у задачах дистанційного зондування Землі (Van Etten, Lindenbaum, & Bacastow, 2018).

Таким чином, методологія дослідження забезпечує послідовне комплементарне використання різноманітних методів штучного інтелекту та оптимізації для оцінювання пошкоджень земель, спричинених військовими діями. Реалізація запропонованого підходу передбачає багатовступневу процедуру, що включає збір і попередню обробку супутникових знімків, навчання моделей комп'ютерного зору, застосування алгоритмів евристичної детекції контурів, а також оптимізацію

гіперпараметрів. Методика спирається на принципи побудови роботизованих електротехнічних комплексів, апробованих в аграрному секторі (Lysenko et al., 2018).

На початковому етапі було здійснено збір супутникових зображень за допомогою API Google Maps за 2022–2023 рр. Як досліджувану територію обрано ділянку площею 100 км² у селі Озера Бучанського району Київської області. Для формування репрезентативної вибірки використано знімки трьох рівнів масштабування: Zoom 17 (≈192 м), Zoom 18 (≈96 м) та Zoom 19 (≈48 м). Зазначене забезпечило отримання зображень із різною роздільною здатністю, що дало змогу провести аналіз як із широким охопленням території, так і з високою деталізацією окремих об'єктів. Усього було зібрано 9094 зображення, які пройшли етап ручної розмітки з використанням інструменту Label Studio.

На наступному етапі реалізовано процедуру ідентифікації вибухових вивірв із використанням інструментів машинного навчання. До аналізу залучено методи детекції контурів (алгоритми Кенні та Хафа), трансфертне навчання на базі моделі PyCDA, а також моделі глибокого навчання YOLOv5 та YOLOv11.

Застосування класичних алгоритмів комп'ютерного зору реалізовано з використанням методу Кенні (Canny, 1986), який забезпечує високоточне виявлення контурів пошкоджених ділянок. Використання цього алгоритму дозволяє виділити ключову структурну інформацію з візуальних даних і суттєво зменшити обсяг інформації для подальшої обробки. Алгоритм характеризується низькою ймовірністю хибних спрацювань, однозначним маркуванням контурів та ефективним пригніченням шумів, що забезпечує стійкість до завад.

Процедура виявлення контурів за методом Кенні включає п'ять основних етапів:

1. Застосування Гаусівського фільтра для згладжування зображення та пригнічення шумів.
2. Обчислення градієнтів інтенсивності для виявлення потенційних контурів.
3. Порогова фільтрація градієнтів.
4. Застосування подвійного порогу для визначення сильних і слабких контурів.
5. Відстеження контурів за допомогою гістерезису, з подальшим збереженням лише тих елементів, які мають зв'язок із сильними градієнтами.

Оскільки результати виявлення контурів є чутливими до шумових артефактів зображення, алгоритмом передбачено попереднє фільтрування з використанням згладжувального Гаусівського фільтра. Застосування зазначеного ядра забезпечує зниження рівня високочастотних шумів, що дозволяє уникнути хибних реакцій при подальшій обробці.

Алгоритм реалізовано на основі принципу зв'язності слабких контурних пікселів із сильними градієнтними відповідниками. Об'єктний аналіз, закладений у процедуру гістерезису, дає змогу перевіряти локальне оточення слабких пікселів і зберігати лише ті з них, що мають просторовий зв'язок із сильними пікселями. Така фільтрація забезпечує формування цілісних і стабільних контурів при зменшенні впливу випадкових шумових компонентів.

Для реалізації алгоритму виявлення контурів використано функцію `cv2.Canny()` із бібліотеки OpenCV. Основними параметрами алгоритму виступають порогові значення `minVal` та `maxVal`, що визначають границі гістерезису. Додатково використано параметри розміру ядра Собеля для обчислення градієнтів та `L2gradient`, який задає порядок обчислення норми градієнта (перший або другий).

Результати

Проведено експериментальне дослідження впливу параметрів $\minVal$ і $\maxVal$ на чутливість алгоритму до виявлення контурів. Встановлено, що саме ці параметри мають найбільший вплив на якість детекції, у зв'язку з чим їх обрано як основні для подальшої

оптимізації. Параметри ядра Собеля та L2gradient прийнято на типових значеннях з метою зменшення розмірності простору пошуку.

Приклад застосування реалізованого алгоритму фільтрації шумів і виявлення контурів на супутникових зображеннях наведено на рис. 1.




Рис. 1. Результати детекції контурів

Для ідентифікації вибухових виврв у межах дослідження було застосовано перетворення Хафа, що забезпечує виявлення об'єктів круглої форми навіть у випадках їх часткової деформації. Зазначений метод дозволяє точно визначити геометричні параметри об'єктів, зокрема координати центра $(x,y)(x,y)(x,y)$ та радіус r , здійснюючи аналіз у тривимірному параметричному просторі.

Алгоритмом передбачене обчислення всіх можливих кіл, які відповідають градієнтним характеристикам зображення. Реалізацію методу здійснено з використанням бібліотеки OpenCV, яка включає функціональність `cv2.HoughCircles()` для роботи із зображеннями у відтінках сірого. В межах реалізації було налаштовано такі параметри:

- `method` – метод детекції, встановлений як `cv2.HOUGH_GRADIENT` (єдиний метод, підтримуваний у бібліотеці OpenCV), який базується на аналізі градієнтів зображення;
- `dp` – параметр, що визначає масштаб зменшення роздільної здатності акумуляторного простору відносно

вхідного зображення (наприклад, $dp = 1$ – роздільність зберігається, $dp = 2$ – зменшується вдвічі);

- `minDist` – мінімально допустима відстань між центрами виявлених кіл; забезпечує фільтрацію накладених результатів;
- `param1` – порогове значення для функції `cv2.Canny()`, що використовується на попередньому етапі для виявлення країв;
- `param2` – поріг наявності центру кола, нижчі значення якого можуть призводити до більшої кількості хибнопозитивних детекцій;
- `minRadius`, `maxRadius` – інтервал допустимих радіусів шуканих об'єктів.

Використання перетворення Хафа дозволило успішно виділити круглі контури виврв, навіть у випадках їх часткової неповноти або перекриття іншими об'єктами. Приклад результату детекції виврви із застосуванням зазначеного підходу наведено на рис. 2.




Рис. 2. Детекція виврв з використанням трансформації Хафа

З метою підвищення ефективності алгоритмів детекції контурів і класифікації пошкоджень було реалізовано

процедуру оптимізації гіперпараметрів із використанням бібліотеки Optuna. Зазначена платформа забезпечує

автоматизований підбір параметрів з урахуванням цільової функції, що у цьому випадку базувалась на метриці F1-score, яка характеризує збалансованість точності та повноти класифікації.

Оптимізаційний процес реалізовано поетапно. На початковому етапі проведено сканування параметричного простору з використанням широких інтервалів значень, сформованих на основі огляду рекомендованих у літературі діапазонів, а також емпірично визначених меж, що забезпечували візуально контрольовані зміни результатів детекції вибухових вив. Вказаний підхід дозволив

виділити найбільш чутливі до зміни параметри та встановити орієнтовні зони їх ефективності.

За результатами початкового етапу було виконано:

- аналіз залежності значення метрики F1-score від кожного окремого параметра (рис. 3);
- побудову карт впливу комбінацій гіперпараметрів на значення цільової метрики (рис. 4).

Такий підхід забезпечив систематизовану оцінку впливу параметрів на результати класифікації та створив передумови для наступних етапів точкової оптимізації.




Рис. 3. Вплив зміни параметра (param2) на значення метрики f1-score




Рис. 4. Дослідження впливу комбінації параметрів dp і CannyT2 на метрику f1-score (чим більший розмір мітки, тим вище рівень метрики)

Під час аналізу впливу окремих гіперпараметрів на значення метрики F1-score особливу увагу приділено значенням верхнього квартиля розподілу (IQR), оскільки саме вони свідчать про наявність потенціалу підвищення ефективності алгоритму при відповідних налаштуваннях. Виявлення таких діапазонів дозволяє окреслити перспективні області для подальшої локальної оптимізації.

Для дослідження парних залежностей між параметрами в межах комбінованої оптимізації було використано сигмоїдне перетворення значень цільової метрики. Застосування цього підходу дало змогу чітко відокремити області з низькими та високими показниками якості класифікації, що візуалізовано на рис. 4. Встановлено, що сигмоїдне масштабування підвищує інформативність результатів, дозволяючи ефективніше виявляти найбільш

перспективні зони параметричного простору для налаштування алгоритму детекції вив.

З метою підвищення точності виявлення вив було адаптовано модель PyCDA, першочергово навченої для розпізнавання кратерів на планетарних поверхнях. Адаптація передбачала попередню обробку зображень, спрямовану на наближення їх візуальних характеристик до тих, що використовувались під час первинного навчання моделі.

У рамках підготовки даних реалізовано таку послідовність процедур:

1. Перетворення зображень у відтінки сірого для зниження спектральної складності.
2. Застосування Гаусівського фільтра з метою зменшення шумів і згладжування текстур.

3. Корекція яскравості та контрастності зображень шляхом двовимірної згорткової фільтрації, що забезпечує формування структур, подібних до вихідного датасету моделі CDA (рис. 5).

Таким чином, адаптаційна обробка зображень забезпечила сумісність з особливостями архітектури PyCDA,

що сприяло поліпшенню результатів автоматизованої ідентифікації вибухових виврв.

Приклад реалізації детекції із застосуванням цього підходу показано на рис. 6.




Рис. 5. Адаптація яскравості і контрастності зображення за допомогою 2d конволюційної фільтрації




Рис. 6. Детекція із використанням алгоритму PyCDA

Окрім класичних інструментів комп'ютерного зору, у межах дослідження було проаналізовано можливість застосування неймережових методів. Для навчання моделей комп'ютерного зору, побудованих на основі згорткових нейронних мереж, було використано розмічені дані, підготовлені на попередніх етапах. Серед протестованих архітектур – YOLO, Faster R-CNN та SSD – найвищу ефективність у задачі детекції виврв показала модель YOLO, яка

забезпечила оптимальний баланс між швидкістю обробки та точністю при роботі з різними зображеннями, зібраними на першому етапі аналізу.

У ході дослідження було поставлено задачу оцінювання впливу низки факторів на точність моделі, а також визначення оптимальної стратегії підготовки даних і параметризації процесу навчання з урахуванням

співвідношення між якістю результатів та швидкістю обчислювальних процедур.

Для вирішення поставленої задачі сформульовано такі гіпотези дослідження:

Гіпотеза 1. Зміна рівня масштабування зображень (Zoom17 – Zoom19) має суттєвий вплив на точність роботи моделі. Перевірку цієї гіпотези було визначено як необхідну з урахуванням особливостей формування вибірки зображень, що підлягають обробці. Від рівня масштабування залежить не лише кількість зображень у вибірці, а й потенційна точність розпізнавання. З огляду на це, було передбачено врахування впливу масштабу також у разі застосування альтернативних методів збору даних, зокрема з використанням безпілотних літальних апаратів.

Гіпотеза 2. Збільшення кількості епох поліпшує точність та повноту моделі. Визначення доцільної кількості епох навчання розглянуто як фактор, що забезпечує оптимізацію співвідношення між витраченим часом і точністю результатів. Крім того, аналіз впливу цього параметра передбачає виявлення межових умов, за яких подальше навчання не забезпечує значного зростання продуктивності, що потребує корекції якості вхідних даних або архітектурних характеристик моделі.

Гіпотеза 3. Різні стратегії аугментації впливають на основні метрики якості моделі. За умов обмеженого обсягу навчальних даних та низької варіативності зовнішнього вигляду вирв на супутникових зображеннях, було передбачено використання аугментації як ключового засобу поліпшення результатів. У межах дослідження розглянуто порівняння впливу базових та оптимізованих стратегій аугментації на якість моделей.

Гіпотеза 4. Архітектури моделей більшої складності забезпечують вищу продуктивність (метрика mAP)

порівняно з менш складними реалізаціями в аналогічних умовах навчання (наприклад, порівняння YOLOv5l з YOLOv5s) (Wang et al., 2020). Перевірку цієї гіпотези визначено як необхідну для обґрунтування перспектив інтеграції натренованих моделей у системи з обмеженими обчислювальними ресурсами, зокрема для розміщення на дронах з метою подальшої ідентифікації вирв у режимі реального часу. Враховано необхідність забезпечення балансу між складністю архітектури, ресурсоспоживанням і точністю результатів.

Як базові показники точності моделі було використано результати, отримані на основі архітектури YOLOv5s, з типовими параметрами та без застосування процедур аугментації. Навчання базової моделі було проведено на зображеннях найнижчого рівня масштабування (Zoom 17), із загальною тривалістю у 50 епох.

Для перевірки гіпотез 1–4 було реалізовано варіативну модифікацію параметрів підготовки даних та навчання моделі, після чого здійснено аналіз відносних змін у показниках якості. З огляду на те, що всі метрики мали позитивно спрямовану інтерпретацію (тобто чим вище значення, тим краща якість), позитивні відсоткові зміни трактувалися як свідчення поліпшення результатів.

Гіпотеза 1. Для оцінки впливу рівня масштабування зображень на точність моделі було проведено аналіз змін метрик залежно від рівня Zoom, а також у разі використання змішаних наборів даних (рис. 7). За результатами спостережено, що зміни метрик Precision та Recall мають незначну варіативність при зміні масштабу, тоді як метрики mAP50 та mAP95 демонструють суттєве зростання, підтверджене статистично значущим приростом.




Рис. 7. Вплив зміни рівня масштабування на базові метрики

Таким чином, відносно гіпотези 1 можемо зробити висновок: хоча Precision та Recall демонструють меншу чутливість до зміни масштабу, Метрики mAP (Map50 та Map95) вказують на те, що зміна зуму може суттєво поліпшити загальні результати виявлення. Завдяки тому, що Map50 та Map95, є більш комплексними метриками, що оцінюють не лише точність та повноту, а і враховують різні порогові впевненості. Це демонструє потенціал щодо

поліпшення точності ідентифікацій вирв за рахунок зміни порогів впевненості. Втім, якщо мова йде переважно про повноту виявлення, то вплив масштабу є не таким суттєвим, а отже це свідчить про можливість використання натренованої моделі з різними підходами до збору даних.

Гіпотеза 2. Для формування висновків за гіпотезою 2 розглянемо результати оцінки впливу кількості епох на поліпшення метрик порівняно з базовою моделлю (рис. 8).




Рис. 8. Вплив кількості епох навчання на середні показники якості моделей

Як і у випадку з гіпотезою 1, встановлено, що для показників точності та повноти збільшення кількості епох понад 100 не забезпечує суттєвого приросту значень, тоді як для метрик mAP50 та mAP95 зростання тривалості навчання залишається обґрунтованим.

Гіпотеза 3. У процесі підготовки моделі було реалізовано аугментацію даних, що включала повороти, зміну контрасту та масштабування, а також валідацію міток і оптимізацію анкерів для поліпшення ідентифікації об'єктів із круглою формою. Застосовано два підходи до аугментації:

- Default – базова аугментація з типовими параметрами;
- Evolve – пошук параметрів аугментації з використанням генетичних алгоритмів, включаючи оптимізацію розмірів анкерів.

Вплив різних стратегій аугментації наведено на рис. 9. У ході дослідження встановлено, що базові правила не призводять до суттєвого поліпшення результатів, тоді як використання генетично оптимізованих параметрів забезпечує стабільне зростання всіх метрик точності. Зафіксовано, що навіть перший квартиль значень метрик, отриманих при використанні Evolve, перевищує третій квартиль значень, характерних для інших підходів.

Гіпотеза 4. Стосовно впливу архітектури моделі, її варто розглядати в поєднанні з тривалістю навчання. Відповідні результати наведено на рис. 10.

Як і очікувалося, для моделей меншої складності, зокрема YOLOv5s, збільшення тривалості навчання демонструє порівняно незначний вплив на фінальні значення метрик. Водночас спостережено, що модель більшої архітектурної складності YOLOv5l при збільшенні кількості епох понад 100 демонструє гіршу динаміку результатів порівняно з менш складними моделями YOLOv5m та YOLOv11m. Таким чином, у задачах аналізу супутникових зображень застосування моделі з надлишковою архітектурною складністю, як у випадку YOLOv5l, виявляється менш ефективним порівняно з архітектурами середнього рівня складності, зокрема YOLOv5m та YOLOv11m.

Приклад налаштування параметрів моделі YOLOv5m:

```
{
  "lr0":0.001,"lrf":0.0005,"momentum":0.937,"weight_decay":0.0005,"warmup_epochs":3.0,"warmup_momentum":0.8,"warmup_bias_lr":0.1,"box":0.05,"cls":0.5,"cls_pw":1.0,"obj":1.05,"obj_pw":1.0,"iou_t":0.2,"anchor_t":4.0,"fl_gamma":0.0,"hsv_h":0.079106,"hsv_s":0.40245,"hsv_v":0.68416,"degrees":13.557,"translate":0.60814,"scale":0.074173,"shear":6.5232,"perspective":0.001,"flipud":0.36334,"fliplr":0.05989,"mosaic":0.23224,"mixup":0.0,"copy_paste":0.34641,"anchors":3.0,"epochs":150,"batch_size":12,"imgsz":832}
```

Для практичної реалізації запропонованого методичного підходу розроблено концептуальну схему архітектури рішення щодо збору, тренування моделей та обробки зображень на платформі AWS (рис. 12).

Ключовими особливостями розробленої схеми є реалізація вибіркового доступу до даних та їх захист за рахунок використання криптографічними сервісом AWS Key Management Service (KMS). Застосування KMS для централізованого керування ключами передбачено як засіб забезпечення безпеки даних на всіх етапах їх обробки. Для зберігання та обробки супутникових зображень використано сервіси Amazon S3. Запуск процедур збору й підготовки даних реалізовано за допомогою AWS Lambda, функціонування якої базується на використанні тригерів для автоматизації відповідних операцій.

Процеси тренування моделей, збереження результатів та формування їх реєстру виконуються з використанням S3 як базового середовища зберігання. У цьому ж компоненті AWS Lambda застосовано для автоматизації взаємодії між модулями, а також для реалізації механізму резервного копіювання моделей.

Запропонована архітектура відображає інтеграцію основних компонентів хмарної інфраструктури AWS, що забезпечує ефективність процедур тренування моделей і обробки супутникових даних, а також створює умови для відтворення результатів дослідження іншими фахівцями за аналогічних технічних умов.




Рис. 9. Вплив стратегій аугментації на якість моделей




Рис. 10. Вплив архітектури моделі на динаміку метрик якості



Рис. 11. Приклад застосування моделі YOLOv5m з налаштованими параметрами




Рис. 12. Схема архітектури рішення щодо збору, тренування моделей та обробки зображень на хмарній платформі Amazon Web Services (AWS)

У контексті масштабування запропонованого підходу до рівня регіонального та національного моніторингу особливої актуальності набуває концепція обробки великих геопросторових даних (Big Geospatial Data). У дослідженнях (Wu et al., 2024), ефективні системи аналізу супутникової інформації базуються на багаторівневих архітектурах, що включають етапи інтеграції різномірних джерел даних, їх розподіленого зберігання, паралельної обробки та

подальшого аналітичного моделювання. Запропонований підхід до детекції контурів вирв може бути інтегрований у масштабовані геоінформаційні платформи, що забезпечують обробку значних обсягів супутникових даних у режимі, наближеному до реального часу.

Результати

Результати дослідження засвідчують ефективність реалізованих методів детекції пошкоджених земельних

ділянок із використанням технологій штучного інтелекту та супутникової зйомки. Запропоновані підходи базуються на застосуванні згорткових нейронних мереж для автоматизованого виявлення вибухових вивірв, а також на впровадженні евристичних алгоритмів контурної детекції, що забезпечують виявлення пошкоджень навіть у складних візуальних умовах.

У межах експериментальної частини дослідження сформовано вибірку з 9094 зображень, отриманих із супутникових даних трьох рівнів масштабування: Zoom 17, Zoom 18 та Zoom 19. Для анотування зображень було використано платформу Label Studio, що дало змогу створити структурований набір даних для навчання та тестування моделей детекції.

У результаті порівняльного аналізу підходів до виявлення пошкоджень встановлено ефективність застосування моделі YOLOv5m, яка продемонструвала найвищі показники точності та швидкодії. Використання трансфертного навчання із залученням моделі PyCDA, первинно навченої для виявлення кратерів на планетарних зображеннях, забезпечило її успішну адаптацію до задач детекції вивірв на земній поверхні.

Аналіз результатів проведено з урахуванням низки факторів, що можуть впливати на точність і продуктивність моделей. Одним із таких факторів визначено масштаб зображень, що використовуються як вхідні дані. За результатами експериментів встановлено, що підвищення масштабу (від Zoom17 до Zoom19) супроводжувалося зростанням значень метрик mAP50 та mAP95, що підтверджує чутливість моделей до рівня деталізації. При цьому метрики Precision та Recall залишались відносно стабільними, що характеризує обмежений вплив масштабу на базові характеристики точності та повноти, на відміну від комплексних метрик, чутливих до якості локалізації об'єктів.

Кількість епох тренування також розглянуто як фактор, що впливає на продуктивність. Було встановлено, що збільшення кількості епох до 100 позитивно позначається на всіх ключових метриках, однак подальше тренування не супроводжується значним поліпшенням точності, що вказує на наявність умовної межі ефективності навчання для архітектури YOLOv5m при заданому обсязі й структурі даних.

Особливу увагу в межах дослідження було зосереджено на оцінці впливу стратегій аугментації. Проведено порівняння базового підходу (Default) та оптимізованого підходу з використанням генетичних алгоритмів (Evolve). Встановлено, що застосування Evolve забезпечило значне підвищення всіх ключових метрик точності, включаючи нижні квартилі розподілу результатів. Отримані дані підтверджують важливість вибору методів аугментації, особливо у випадках обмеженого обсягу навчальних зображень.

Окремо було проведено дослідження залежності якості моделей від їх архітектурної складності. Архітектури вищого рівня, такі як YOLOv5l, продемонстрували потенційно вищу точність, однак у реальних умовах моделі середньої складності (YOLOv5m, YOLOv11m) виявилися більш стабільними за результатами при помірних обчислювальних витратах. Отримані результати свідчать про доцільність використання середньої архітектурної складності для аналізу супутникових зображень із середнім рівнем деталізації.

Додатково було проведено перевірку ефективності алгоритмів комп'ютерного зору для задач детекції контурів вивірв. Застосування алгоритму Кенні для виявлення країв та перетворення Хафа для локалізації

об'єктів круглої форми забезпечило точність детекції на рівні 82 %. У випадках присутності шуму або часткового перекриття об'єктів спостерігалось зниження точності до 75 %, що обґрунтовує необхідність попереднього фільтрування вхідних зображень.

Оптимізацію гіперпараметрів алгоритмів було реалізовано за допомогою бібліотеки Optuna. У межах цієї процедури відкориговано параметри, що істотно впливають на результати: розміри анкерів у моделі YOLOv5m, порогові значення для алгоритму Кенні та мінімальні радіуси в перетворенні Хафа. Проведена оптимізація забезпечила зростання точності детекції вивірв на 4,6 % та зменшення кількості хибнопозитивних спрацювань на 7 %. Аналіз чутливості параметрів підтвердив, що саме розміри анкерів є визначальним чинником точності розпізнавання.

Результати дослідження співвідносяться з науковими підходами, представленими в сучасній літературі, зокрема в роботах, присвячених оцінці наслідків збройних конфліктів на аграрні території.

Розроблена система автоматизованого моніторингу передбачає поєднання засобів обробки зображень із програмними модулями взаємодії з користувачем. Як показано в роботі Lysenko et al. (2022), ефективність роботизованих рішень суттєво зростає при використанні адаптованих інтерфейсів, оснащених технічним зором і сенсорними підсистемами.

Важливим прикладом аналізу супутникових індексів є дослідження Shelestov et al. (2023), де оцінка пошкоджених ділянок здійснювалась через NDVI-контраст до та після бойових дій. Автоматична система фіксації показала збіг із візуальною перевіркою лише у 48 % випадків. Такий результат підкреслює обмеженість індексного підходу, що підтверджено і в нашій роботі: використання комбінованої моделі, яка включає контурну сегментацію та валідацію геометричних структур, дало змогу зменшити кількість хибнопозитивних детекцій при збереженні високої чутливості до дрібномасштабних ушкоджень.

У контексті цифровізації землеуправління варто згадати матеріали конференції Modern trends... (2024), де розглядалася інтеграція супутникових, геодезичних і лазерних даних. У нашому підході реалізовано суміжну концепцію – досягнута точність геолокації ушкоджень становила 1–2 м, що є критичним параметром для проектування заходів із рекультивації.

Відповідно до сучасних науково-методичних підходів (Tonkha et al., 2025), процес рекультивації включає послідовну реалізацію підготовчого, технічного та біологічного етапів, що передбачають аналіз стану земель (у тому числі із застосуванням дистанційного зондування), інженерну підготовку території (засипання вивірв, формування рельєфу, нанесення родючих шарів ґрунту) та відновлення біологічної активності через внесення добрив і вирощування фітомеліоративних культур. Реалізація зазначених заходів забезпечує оптимізацію агрофізичних і агрохімічних властивостей ґрунтів, зниження ризиків ерозії та формування передумов для відновлення їх родючості і подальшого використання в агровиборництві.

Аналогічно, у роботі Yailymova et al. (2025) описано наслідки техногенної катастрофи, де використовувалась сегментація супутникових даних із застосуванням ML-моделей. Наш підхід розширює ці результати шляхом включення ідентифікації типів пошкоджень (наприклад, колії техніки, вивірви), що дає змогу деталізувати структуру деградаційних процесів.

Інший підхід, оснований на оцінці змін землекористування в масштабах усієї країни, запропоновано у працях Kussul et al. (2023, 2025). Автори виявили зниження площі ріллі до 10 % у середньому та понад 20 % у прифронтових зонах, використовуючи моделі RF та MLP. Натомість у межах нашого дослідження реалізовано локалізований аналіз пошкоджень із застосуванням CNN та контурного моделювання, що забезпечило можливість фіксувати пошкодження ще до змін спектральних характеристик.

Проблематику автоматизації супутникового моніторингу конфліктів висвітлено у праці (Sticher, & Wegner, & Pfeifle, 2023), де наголошено на обмеженості методів одноразового порівняння знімків "до" і "після". Запропоноване нами рішення враховує цю проблему: реалізовано механізми фільтрації інфраструктурних артефактів та забезпечено підтримку багатократного моніторингу в режимі реального часу.

Підтвердження ефективності просторової сталості ознак як критерію достовірності представлено в дослідженні (Mueller, Gonzalez, & Abou-Chakra, 2021). Автори продемонстрували, що стабільність об'єктів на кількох часових знімках підвищує надійність класифікації. У нашій роботі закладено аналогічну логіку через застосування геометричних критеріїв, зокрема перетворення Хафа, що дозволило досягти точності виявлення контурів понад 90 % навіть в умовах часткового перекриття або візуального шуму.

Подальший розвиток дослідження полягає в інтеграції створених моделей у структури автоматизованих моніторингових систем, що забезпечить можливість безперервного контролю стану земельних ресурсів у реальному часі. Також перспективним напрямом визначено використання багатоспектральної супутникової зйомки, яка дозволяє враховувати додаткові чинники, зокрема забруднення ґрунтів токсичними речовинами.

Дискусія і висновки

Запропоноване рішення з детекції виврів у ґрунті реалізує інтеграцію сучасних технологій штучного інтелекту та супутникового знімального аналізу. Застосування цієї технології забезпечує підвищену точність оцінювання ступеня деградації земель і формує основу для побудови систем керування природними ресурсами у постконфліктних регіонах. За результатами аналізу підбірки супутникових зображень різних рівнів масштабування встановлено, що запропонована система забезпечує точність ідентифікації вибухових виврів на рівні 82–90 % залежно від умов візуального шуму.

Експериментально доведено перевагу архітектури YOLOv5m, яка продемонструвала оптимальний баланс між точністю детекції та швидкістю обробки даних порівняно з більш складними моделями YOLOv5l та альтернативними архітектурами. Застосування генетично оптимізованих стратегій аугментації (Evolve) забезпечило двократне зростання метрик точності, при цьому навіть найнижчі показники (перший квартиль) перевищували найвищі результати (третій квартиль) стандартних підходів до обробки зображень.

Адаптація моделі PyCDA через трансфертне навчання дала змогу ефективно перенести знання з предметної області планетарної геології на задачі земного моніторингу без необхідності створення архітектури з нуля. Оптимізація гіперпараметрів за допомогою бібліотеки Optuna призвела до підвищення точності детекції на 4,6 % та зменшення кількості хибнопозитивних спрацювань на 7 %, що критично важливо для практичного застосування системи.

Евристичні алгоритми контурної детекції з використанням перетворення Хафа продемонстрували стабільні результати навіть при частковому перекритті об'єктів або присутності інфраструктурного шуму від будівель і доріг. Комбінування консервативних і агресивних параметрів детекції дозволило виявляти як прямі ушкодження від вибухів, так і непрямі пошкодження від проходження важкої техніки, що забезпечує комплексну оцінку стану земельних ресурсів.

Впроваджена на хмарній платформі AWS архітектура рішення забезпечує масштабованість системи та можливість обробки великих обсягів супутникових даних у реальному часі, що дає змогу державним та екологічним установам формувати науково обґрунтовані плани відновлення територій. Подальший розвиток дослідження передбачає інтеграцію багатоспектральної супутникової зйомки для підвищення точності класифікації типів пошкоджень та розширення функціональності системи для моніторингу процесів природного відновлення екосистеми чинники, зокрема забруднення ґрунтів токсичними речовинами.

Система базується на методології підготовки й розмітки супутникових зображень із подальшим застосуванням процедур аугментації та валідації для формування тренувальних вибірок моделей, реалізованих на основі згорткових нейронних мереж. Оптимізація параметрів моделі, підходів до аугментації і налаштувань тренування забезпечила зростання метрик точності у два рази відносно базового варіанту.

Внесок авторів: Олена Глазунова – методологія, валідація даних, аналіз; Ігор Болбот – методологія, валідація даних, аналіз; Роман Руденський – обробка даних, методологія, написання (оригінальна чернетка); Володимир Кравченко – аналіз і обробка даних, написання (перегляд і редагування); Олексій Циганов – аналіз і обробка даних, програмне забезпечення, формальний аналіз; Оксана Тонха – концептуалізація, методологія.

Джерела фінансування. Автори заявляють про відсутність зовнішнього фінансування для проведення цього дослідження та підготовки рукопису до публікації.

Список використаних джерел

- Інститут охорони ґрунтів України. (2024). *Звіт про наукову діяльність за 2024 рік*. IOГУ. https://www.ioгу.gov.ua/link/press_center/magazines/ magazine_2024.html
- Сучасні тенденції розвитку геодезії, землеустрою та природокористування (2024). Матеріали Міжнародної науково-практичної конференції (13–14 червня 2024 р.). Одеса: ОНАХТ. <https://osau.edu.ua/wp-content/uploads/2024/10/Zbirnyk-tez-konf-13-14.06.2024.pdf>
- Федишин, Т. І. (2024). *Методологічне забезпечення кіберфізичної системи моніторингу ґрунтів* [Дис. канд. техн. наук, Національний університет "Львівська політехніка"]. <https://lpnu.ua/sites/default/files/2024/r/adaphd/27655/disertaciyaFedishintetyaniigorivni.pdf>
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–2631. <https://doi.org/10.1145/3292500.3330701>
- Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Recognition*, 13(2), 111–122. [https://doi.org/10.1016/0031-3203\(81\)90009-1](https://doi.org/10.1016/0031-3203(81)90009-1)
- Benedix, G. K., Norman, C. J., Bland, P. A., Towner, M. C., Paxman, J., & Tan, T. (2018). Automated detection of Martian craters using a convolutional neural network. *49th Lunar and Planetary Science Conference*. <https://www.hou.usra.edu/meetings/lpsc2018/pdf/2202.pdf>
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- Duda, R. O., & Hart, P. E. (1972). Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1), 11–15. <https://doi.org/10.1145/361237.361242>
- Ghorbanzadeh, O., Meena, S. R., Blaschke, T., & Aryal, J. (2019). UAV-based slope failure detection using deep-learning convolutional neural networks. *Remote Sensing*, 11(17), 2046. <https://doi.org/10.3390/rs11172046>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8*. GitHub. <https://github.com/ultralytics/ultralytics>
- Jocher, G., et al. (2020). *YOLOv5 Repository Documentation*. GitHub. <https://github.com/ultralytics/yolov5>
- Kussul, N., Drozd, S., Yailymova, H., Shelestov, A., Lemoine, G., & Deininger, K. (2023). Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning. *Remote Sensing Applications: Society and Environment*, 31, 100976. <https://doi.org/10.1016/j.rsase.2023.100976>
- Kussul, N., Shelestov, A., Yailymov, B., Yailymova, H., Lemoine, G., & Deininger, K. (2025). Assessment of war-induced agricultural land use changes in Ukraine using machine learning applied to Sentinel satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 140, 104551. <https://doi.org/10.1016/j.jag.2025.104551>
- Lysenko, V., Bolbot, I., Martynenko, O., Lendel, T., & Nakonechna, K. (2022). Software of a mobile robot for phytomonitoring. *Machinery and Energetics*, 13(1), 5–10. <https://doi.org/10.31548/machenergy2022.01.005>
- Lysenko, V., Bolbot, I., Romasevych, Y., Loveykin, V., & Voytiuk, V. (2018). Algorithms of robotic electrotechnical complex control in agricultural production. *Control Systems: Theory and Applications*, 271–289.
- Modern trends in the development of geodesy, land management and environmental management* (2024). Materials of the International Scientific-Practical Conference (June 13–14, 2024). Odesa: ONAHT. <https://osau.edu.ua/wp-content/uploads/2024/10/Zbirnyk-tez-konf-13-14.06.2024.pdf>
- Mueller, H., Gonzalez, L., & Abou-Chakra, K. (2021). Detecting war damage using deep learning and spatio-temporal satellite image analysis. *Computers, Environment and Urban Systems*, 90, 101709. <https://doi.org/10.1016/j.compenvurbsys.2021.101709>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Shapiro, L. G., & Stockman, G. C. (2001). *Computer vision*. Prentice Hall.
- Shelestov, A., Drozd, S., Mikava, P., Barabash, I., & Yailymova, H. (2023). War damage detection based on satellite data. *Proceedings of the 11th International Conference on Applied Innovations in IT (ICAII 2023)*, 89–95. <https://doi.org/10.25673/101923>
- Shen, L., et al. (2021). Efficient hyperparameter optimization techniques in machine learning. *Neural Computing and Applications*, 33(12), 7381–7396. <https://doi.org/10.1007/s00521-020-05501-z>
- Silburt, A., Ali-Dib, M., Zhu, C., Jackson, A., Valencia, D., Kissin, Y., & Wu, K. (2019). Lunar crater identification via deep learning. *Icarus*, 317, 27–38. <https://doi.org/10.1016/j.icarus.2018.06.022>
- Sticher, V., Wegner, J. D., & Pfeifle, B. (2023). Toward the remote monitoring of armed conflicts. *PNAS Nexus*, 2(6), pgad181. <https://doi.org/10.1093/pnasnexus/pgad181>
- Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-030-34372-9>
- Tiede, D., Krafft, P., Füreder, P., & Lang, S. (2016). Stratified template matching to support refugee camp analysis in OBIA workflows. *Remote Sensing*, 9(4), 326. <https://doi.org/10.3390/rs9040326>
- Tonkha, O., Bolbot, I., Kravchenko, V., Rudenskiy, R., Saiapin, S., & Tsyhanov, O. (2025). *Technologies of reclamation of damaged lands using AI and robotic devices: Scientific and methodological recommendations*. National University of Life and Environmental Sciences of Ukraine.
- Van Etten, A., Lindenbaum, D., & Bacastow, T. M. (2018). SpaceNet: A remote sensing dataset and challenge series. *arXiv*. <https://doi.org/10.48550/arXiv.1807.01232>
- Wang, C. Y., et al. (2020). YOLOv5: Improved object detection architecture. *arXiv*. <https://doi.org/10.48550/arXiv.2004.10934>
- Weir, D., & McQuillan, D. (2019). Mapping military impacts on the environment: A GIS-based approach to conflict pollution. *Journal of Political Ecology*, 26(1), 697–718. <https://doi.org/10.2458/v26i1.23169>
- Wu, J., Gan, W., Chao, H. C., & Yu, P. S. (2024). Geospatial big data: Survey and challenges. *arXiv*. <https://doi.org/10.48550/arXiv.2404.18428>
- Yailymova, H., Kussul, N., Shelestov, A., & Yailymov, B. (2025). Impact assessment of Kakhovka Dam destruction on agricultural land in Ukraine. *Science of Remote Sensing*, 12, 100257. <https://doi.org/10.1016/j.srs.2025.100257>
- Yao, J., et al. (2018). Adaptive Hough transform for circle detection. *IEEE Transactions on Image Processing*, 27(6), 2720–2733. <https://doi.org/10.1109/TIP.2018.2806231>
- Zhang, L., et al. (2016). Robust circle detection via parameter optimization. *Pattern Recognition*, 54, 35–48. <https://doi.org/10.1016/j.patcog.2016.01.008>
- Zioud, D., & Tabbone, S. (1998). Edge detection techniques: A review. *International Journal of Pattern Recognition and Image Analysis*, 8(4), 537–559.
- References**
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–2631. <https://doi.org/10.1145/3292500.3330701>
- Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Recognition*, 13(2), 111–122. [https://doi.org/10.1016/0031-3203\(81\)90009-1](https://doi.org/10.1016/0031-3203(81)90009-1)
- Benedix, G. K., Norman, C. J., Bland, P. A., Towner, M. C., Paxman, J., & Tan, T. (2018). Automated detection of Martian craters using a convolutional neural network. *49th Lunar and Planetary Science Conference*. <https://www.hou.usra.edu/meetings/lpsc2018/pdf/2202.pdf>
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- Duda, R. O., & Hart, P. E. (1972). Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1), 11–15. <https://doi.org/10.1145/361237.361242>
- Fedyshyn, T. I. (2024). *Metrological support of the cyber-physical system for soil monitoring* [Doctoral dissertation, Lviv Polytechnic National University] [in Ukrainian]. <https://lpnu.ua/sites/default/files/2024/radaphd/27655/disertaciyaFedishintetyaniigorivni.pdf>
- Ghorbanzadeh, O., Meena, S. R., Blaschke, T., & Aryal, J. (2019). UAV-based slope failure detection using deep-learning convolutional neural networks. *Remote Sensing*, 11(17), 2046. <https://doi.org/10.3390/rs11172046>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Institute for Soil Protection of Ukraine. (2024). *Report on scientific activity for 2024*. ISPU [in Ukrainian]. https://www.ioqu.gov.ua/link/press_center/magazines/magazine_2024.html
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8*. GitHub. <https://github.com/ultralytics/ultralytics>
- Jocher, G., et al. (2020). *YOLOv5 Repository Documentation*. GitHub. <https://github.com/ultralytics/yolov5>
- Kussul, N., Drozd, S., Yailymova, H., Shelestov, A., Lemoine, G., & Deininger, K. (2023). Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning. *Remote Sensing Applications: Society and Environment*, 31, 100976. <https://doi.org/10.1016/j.rsase.2023.100976>
- Kussul, N., Shelestov, A., Yailymov, B., Yailymova, H., Lemoine, G., & Deininger, K. (2025). Assessment of war-induced agricultural land use changes in Ukraine using machine learning applied to Sentinel satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 140, 104551. <https://doi.org/10.1016/j.jag.2025.104551>
- Lysenko, V., Bolbot, I., Martynenko, O., Lendel, T., & Nakonechna, K. (2022). Software of a mobile robot for phytomonitoring. *Machinery and Energetics*, 13(1), 5–10. <https://doi.org/10.31548/machenergy2022.01.005>
- Lysenko, V., Bolbot, I., Romasevych, Y., Loveykin, V., & Voytiuk, V. (2018). Algorithms of robotic electrotechnical complex control in agricultural production. *Control Systems: Theory and Applications*, 271–289.
- Modern trends in the development of geodesy, land management and environmental management* (2024). Proceedings of the International Scientific-Practical Conference (June 13–14, 2024). Odesa: ONAHT. <https://osau.edu.ua/wp-content/uploads/2024/10/Zbirnyk-tez-konf-13-14.06.2024.pdf> [in Ukrainian].
- Modern trends in the development of geodesy, land management and environmental management* (2024). Materials of the International Scientific-Practical Conference (June 13–14, 2024). Odesa: ONAHT. <https://osau.edu.ua/wp-content/uploads/2024/10/Zbirnyk-tez-konf-13-14.06.2024.pdf>
- Mueller, H., Gonzalez, L., & Abou-Chakra, K. (2021). Detecting war damage using deep learning and spatio-temporal satellite image analysis. *Computers, Environment and Urban Systems*, 90, 101709. <https://doi.org/10.1016/j.compenvurbsys.2021.101709>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Shapiro, L. G., & Stockman, G. C. (2001). *Computer vision*. Prentice Hall.
- Shelestov, A., Drozd, S., Mikava, P., Barabash, I., & Yailymova, H. (2023). War damage detection based on satellite data. *Proceedings of the 11th International Conference on Applied Innovations in IT (ICAII 2023)*, 89–95. <https://doi.org/10.25673/101923>
- Shen, L., et al. (2021). Efficient hyperparameter optimization techniques in machine learning. *Neural Computing and Applications*, 33(12), 7381–7396. <https://doi.org/10.1007/s00521-020-05501-z>
- Silburt, A., Ali-Dib, M., Zhu, C., Jackson, A., Valencia, D., Kissin, Y., & Wu, K. (2019). Lunar crater identification via deep learning. *Icarus*, 317, 27–38. <https://doi.org/10.1016/j.icarus.2018.06.022>
- Sticher, V., Wegner, J. D., & Pfeifle, B. (2023). Toward the remote monitoring of armed conflicts. *PNAS Nexus*, 2(6), pgad181. <https://doi.org/10.1093/pnasnexus/pgad181>
- Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-030-34372-9>
- Tiede, D., Krafft, P., Füreder, P., & Lang, S. (2016). Stratified template matching to support refugee camp analysis in OBIA workflows. *Remote Sensing*, 9(4), 326. <https://doi.org/10.3390/rs9040326>
- Tonkha, O., Bolbot, I., Kravchenko, V., Rudenskiy, R., Saiapin, S., & Tsyhanov, O. (2025). *Technologies of reclamation of damaged lands using AI and robotic devices: Scientific and methodological recommendations*. National University of Life and Environmental Sciences of Ukraine.

Van Etten, A., Lindenbaum, D., & Bacastow, T. M. (2018). SpaceNet: A remote sensing dataset and challenge series. *arXiv*. <https://doi.org/10.48550/arXiv.1807.01232>

Wang, C. Y., et al. (2020). YOLOv5: Improved object detection architecture. *arXiv*. <https://doi.org/10.48550/arXiv.2004.10934>

Weir, D., & McQuillan, D. (2019). Mapping military impacts on the environment: A GIS-based approach to conflict pollution. *Journal of Political Ecology*, 26(1), 697–718. <https://doi.org/10.2458/v26i1.23169>

Wu, J., Gan, W., Chao, H. C., & Yu, P. S. (2024). Geospatial big data: Survey and challenges. *arXiv*. <https://doi.org/10.48550/arXiv.2404.18428>

Yailymova, H., Kussul, N., Shelestov, A., & Yailymov, B. (2025). Impact assessment of Kakhovka Dam destruction on agricultural land in Ukraine. *Science of Remote Sensing*, 12, 100257. <https://doi.org/10.1016/j.srs.2025.100257>

Yao, J., et al. (2018). Adaptive Hough transform for circle detection. *IEEE Transactions on Image Processing*, 27(6), 2720–2733. <https://doi.org/10.1109/TIP.2018.2806231>

Zhang, L., et al. (2016). Robust circle detection via parameter optimization. *Pattern Recognition*, 54, 35–48. <https://doi.org/10.1016/j.patcog.2016.01.008>

Ziou, D., & Tabbone, S. (1998). Edge detection techniques: A review. *International Journal of Pattern Recognition and Image Analysis*, 8(4), 537–559.

Отримано редакцією журналу / Received: 04.02.26

Прорецензовано / Revised: 06.05.26

Схвалено до друку / Accepted: 13.05.26

Опубліковано / Published: 29.05.26

Olena GLAZUNOVA¹, DSc (Pedagogy), Prof.

ORCID ID: 0000-0002-0136-4936

e-mail: vice_rect_ped_work@nubip.edu.ua

Ihor BOLBOT¹, DSc (Engin.), Prof.

ORCID ID: 0000-0002-5708-6007

e-mail: igor-bolbot@nubip.edu.ua

Roman RUDENSKYI¹, DSc (Econ.), Prof.

ORCID ID: 0009-0002-3682-9702

e-mail: roman.rudenskyi@nubip.edu.ua

Volodymyr KRAVCHENKO¹, DSc (Econ.), Prof.

ORCID ID: 0000-0002-8033-3985

e-mail: v.kravchenko@nubip.edu.ua

Oleksii TSYGANOV¹, Assist.

ORCID ID: 0009-0008-6965-130X

e-mail: o.tsyganov@nubip.edu.ua

Oksana TONKHA¹, DSc (Agr.), Prof.

ORCID ID: 0000-0002-0677-5494

e-mail: tonkha.o@nubip.edu.ua

¹National University of Life and Environmental Sciences of Ukraine, Kyiv, Ukraine

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR CRATER DETECTION IN AREAS AFFECTED BY MILITARY ACTIONS

Background. Significant damage to land resources resulting from military actions has necessitated the implementation of modern approaches to assess land degradation and determine reclamation needs. Within the framework of this study, methods for applying Artificial Intelligence (AI) technologies are proposed for the rapid monitoring of damaged territories and calculating the volume of resources required for their restoration.

Methods. Processing of satellite and aerial imagery was carried out using computer vision algorithms, specifically YOLOv5 and Faster R-CNN convolutional neural networks, as well as contour detection methods and the Hough transform. To enhance data processing efficiency, the Amazon Web Services (AWS) cloud infrastructure was utilized, and hyperparameter optimization was implemented using the Optuna library.

Results. The research results confirm the effectiveness of the proposed approach. The use of models adapted from the PyCDA project (originally designed for planetary crater detection) enabled the high-precision identification of craters caused by explosions. Heuristic contour detection algorithms were developed to improve analytical accuracy, and methodologies for estimating reclamation volumes based on geometric models and satellite observations were implemented. Optimized algorithmic parameters ensured increased performance of the automated data processing system.

Conclusions. The practical significance of the study is validated by the creation of a comprehensive toolkit for assessing the state of degraded lands and formulating restoration strategies. The proposed solutions are recommended for use by government agencies, environmental services, and scientific organizations involved in mitigating the consequences of land degradation and planning reclamation activities.

Keywords: artificial intelligence, satellite monitoring, crater contour detection, computer vision, hyperparameter optimization, land reclamation.

Оксана Тонха є членом редколегії видання, тому не брала участі у рецензуванні та прийнятті рішення щодо публікації цієї статті.

Автори заявляють про відсутність конфлікту інтересів. Спонсори не брали участі в розробленні дослідження; у зборі, аналізі чи інтерпретації даних; у написанні рукопису; в рішенні про публікацію результатів.

Oksana Tonkha is a member of the journal editorial board, therefore did not take part in the peer-review process or in the decision to publish of this article.

The authors declare no conflicts of interest. The funders had no role in the design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript; in the decision to publish the results.