

УДК 004.8

DOI <https://doi.org/10.32689/maup.it.2025.4.32>

**Ігор КОЛІСНИК**

аспірант кафедри комп'ютерно-інформаційних систем і технологій,  
ПрАТ «ВНЗ «Міжрегіональна Академія управління персоналом»,  
[ihorko95@gmail.com](mailto:ihorko95@gmail.com)  
ORCID: 0009-0007-7113-7652

**Андрій ДУДНИК**

доктор технічних наук, доцент,  
професор кафедри мережесих та інтернет технологій,  
Київський національний університет імені Тараса Шевченка,  
[a.s.dudnik@gmail.com](mailto:a.s.dudnik@gmail.com)  
ORCID: 0000-0001-5725-5942

**Дарина ЯРЕМЕНКО**

аспірант кафедри комп'ютерно-інформаційних систем і технологій,  
ПрАТ «ВНЗ «Міжрегіональна Академія управління персоналом», [dashayaremenko17@gmail.com](mailto:dashayaremenko17@gmail.com)  
ORCID: 0000-0002-6294-9698

**Владислав ФЕСЕНКО**

доктор філософії, науковий співробітник,  
Державний науково-дослідний інститут технологій кібербезпеки та захисту інформації, [fes\\_vlad@ukr.net](mailto:fes_vlad@ukr.net)  
ORCID: 0000-0002-8933-9291

**МЕТОДИ РОЗПІЗНАВАННЯ ТА СЕГМЕНТАЦІЇ АЕРОФОТО ДЛЯ ЦИФРОВИХ КАРТ**

**Анотація.** У статті розглянуто методологію розпізнавання та сегментації аерофотознімків із метою автоматизації нанесення будівель та споруд на карти OpenStreetMap (OSM). Актуальність дослідження обумовлена необхідністю зменшення ручної праці волонтерів, які наповнюють базу даних OSM, та підвищення точності просторового відображення об'єктів. Для досягнення поставленої мети автором створено власний датасет, що містить супутникові зображення населених пунктів центральної та західної України з географічною прив'язкою, масками будівель та роздільною здатністю близько 0,6 м/піксель.

У роботі проведено порівняння трьох моделей глибокого навчання для розпізнавання об'єктів: GeoAI (ResNet-34), YOLO v8m та YOLO v8n. Навчання здійснювалось у 200 epoch із поділом даних у співвідношенні 80/20. За результатами експериментів, найкращу узагальнену точність показала модель YOLO v8m (Precision  $\approx 0.797$ , mAP50  $\approx 0.777$ ), тоді як GeoAI мала нижчі значення IoU = 0.63 та Dice = 0.68. Водночас легша модель YOLO v8n виявила вищу чутливість до дрібних об'єктів, що пояснюється меншою кількістю параметрів і ширшим полем сприйняття.

Окрему увагу приділено постобробці результатів сегментації – ортогоналізації контурів виявлених споруд і перетворенню даних у формат geoJSON, сумісний з екосистемою OSM. Запропоновано алгоритм спрощення полігонів до 4–10 вершин із мінімальною втратою форми для підвищення ефективності нанесення об'єктів на мапу.

Отримані результати підтверджують доцільність використання моделей глибокого навчання для автоматизації картографічних процесів. Запропонований підхід може бути основою для створення сервісу, який автоматично генеруватиме шари будівель на OSM за координатами обраної ділянки, що значно оптимізує процес оновлення картографічних даних та підвищить їхню якість.

**Ключові слова:** аерофотознімки, розпізнавання об'єктів, сегментація зображень, YOLO v8, GeoAI, OpenStreetMap (OSM), глибоке навчання, геоінформаційні системи, автоматизація картографування, ортогоналізація полігонів, geoJSON.

**Ihor KOLISNYK, Andriy DUDNIK, Daryna YAREMENKO, Vladyslav FESENKO. AERIAL PHOTOGRAPH RECOGNITION AND SEGMENTATION METHODS FOR DIGITAL MAPS**

**Abstract.** The article examines the methodology of recognition and segmentation of aerial photographs with the aim of automating the mapping of buildings and structures on OpenStreetMap (OSM). The relevance of the research is determined by the need to reduce the manual work of volunteers who fill the OSM database and to increase the accuracy of spatial object representation. To achieve this goal, the author created a custom dataset containing satellite images of settlements in central and western Ukraine with geographic reference, building masks, and a spatial resolution of approximately 0.6 m/pixel.

The study compares three deep learning models for object recognition: GeoAI (ResNet-34), YOLO v8m, and YOLO v8n. The training was conducted for 200 epochs with an 80/20 data split. According to the experimental results, the YOLO v8m model

© І. Колісник, А. Дуднік, Д. Яременко, В. Фесенко, 2025

Стаття поширюється на умовах ліцензії CC BY 4.0

showed the best generalized accuracy (Precision  $\approx 0.797$ , mAP50  $\approx 0.777$ ), while GeoAI demonstrated lower values (IoU = 0.63 and Dice = 0.68). At the same time, the lighter YOLO v8n model exhibited higher sensitivity to small objects, which is explained by a smaller number of parameters and a wider receptive field.

Special attention is paid to the post-processing of segmentation results – orthogonalization of the detected building contours and conversion of data into the geoJSON format, compatible with the OSM ecosystem. An algorithm for simplifying polygons to 4–10 vertices with minimal shape loss is proposed to improve the efficiency of mapping objects.

The obtained results confirm the feasibility of using deep learning models to automate cartographic processes. The proposed approach can serve as the basis for a service that automatically generates building layers on OSM based on the coordinates of the selected area, significantly optimizing the process of updating cartographic data and improving their quality.

**Key words:** aerial photographs, object recognition, image segmentation, YOLO v8, GeoAI, OpenStreetMap (OSM), deep learning, geographic information systems, mapping automation, polygon orthogonalization, geoJSON.

**Постановка проблеми.** Суть даного дослідження полягає у створенні та експериментальній перевірці ефективної методології автоматизованого розпізнавання та сегментації об'єктів на аерофотознімках для подальшого нанесення результатів на карти OpenStreetMap (OSM). Основна проблема, яку необхідно вирішити, полягає у значних трудових витратах і низькій швидкості ручного нанесення будівель волонтерами, що знижує актуальність і точність просторових даних. Відтак, дослідження спрямоване на зменшення людського чинника шляхом упровадження алгоритмів глибокого навчання для автоматизації процесу картографування.

Для реалізації поставленої мети було сформульовано завдання – розробити підхід, який забезпечить точну сегментацію будівель на супутникових знімках різної роздільної здатності, використовуючи сучасні архітектури нейронних мереж (GeoAI, YOLO v8m, YOLO v8n), та порівняти їхню продуктивність. Важливою частиною задачі є формування власного датасету з реальних знімків населених пунктів України, розбитих на навчальні й валідаційні підвибіркі, що дозволяє оцінити узагальнювальну здатність моделей у різних геопросторових умовах.

Додатково поставлено задачу постобробки результатів – оптимізації контурів виявлених будівель шляхом ортогоналізації полігонів і переведення результатів у формат geoJSON, придатний для подальшої інтеграції з OSM. Таким чином, кінцевою метою дослідження є створення універсальної моделі, здатної автоматично формувати шари будівель на картах з високою точністю та мінімальними ресурсними витратами.

**Аналіз останніх досліджень і публікацій.** У сучасному інформаційному суспільстві ефективне управління просторовими даними є ключовим елементом прийняття рішень у різних сферах діяльності. OpenStreetMap (OSM) виступає як відкритий геоінформаційний ресурс, що надає можливість користувачам наносити дані про об'єкти та явища навколишнього середовища, забезпечуючи багатовимірний аналіз просторової інформації [8]. З точки зору геоінформаційних наук, нанесення даних на карту дозволяє інтегрувати інформацію із різних джерел, проводити просторовий аналіз, моделювання і прогнозування. Це важливо для міського планування, логістики, екологічного моніторингу та управління надзвичайними ситуаціями.

Нанесення об'єктів на карту OSM волонтерами є процесом, що потребує значних трудових витрат і високої уваги до деталей. Кожна точка, лінія чи полігон вимагає точного визначення координат, правильного опису атрибутів і перевірки достовірності інформації. Крім того, для підтримки високої якості карти необхідні постійні оновлення та корекції вже внесених даних, що перетворює роботу на безперервний процес [5].

Детальна карта населеного пункту із нанесеними точками інтересів, об'єктами пам'яток архітектури, а також із закладами місцевого малого та середнього бізнесу привертає увагу туристів, транзитних автомобілістів та потенційних інвесторів. Мапа у деякій мірі є віддзеркаленням влади та самоврядування громади. Саме тому важливо автоматизувати процес нанесення нових об'єктів на мапу, щоб спростити кропітку ручну роботу.

Для порівняння і реалізації автоматизації процесу, було обрано три моделі розпізнавання та сегментації об'єктів:

Перша модель від GeoAI призначена для застосування штучного інтелекту до геопросторових даних [2]. Модель GeoAI версії 0.14.0 оперує 24.4 мільйонами параметрами, має U-подібну структуру. Енкодером виступає resnet34 – це 34-шарова згорткова мережа (ResNet), компроміс між глибиною і швидкістю, не надто важка (на відміну від resnet50), але достатньо потужна, щоб виділяти ознаки структур. Початкові ваги енкодера були взяті з попередньо навченої моделі ImageNet (1.2 млн звичайних фото) [3]. Друга та третя моделі доволі популярні та універсальні – на базі глибокого навчання YOLO v8m та v8n відповідно. Вони показують високі показники між балансом точності та швидкодії [6]. Існують моделі YOLO v11 та експериментальна YOLO v12, які є більш точними за рахунок механізму самоуваги, особливо приріст спостерігається при аналізі відеопотоку. YOLO v8m оперує

27.3 мільйонами параметрів та налічує 191 шар, що майже співрозмірно із моделлю від geoAI натомість більш простіша v8n оперує лише 3.26 мільйонами параметрів та налічує 195 шарів. Архітектура YOLO це R-CNN / Mask R-CNN, яка спочатку знаходить області визначення та класифікує й уточнює контури.

**Виклад основного матеріалу.** Для навчання моделей, було підготовлено власний датасет, який містив набір зображень населених пунктів (селищ) здебільшого з приватним сектором. Кожне зображення мало географічну прив'язку координат із географічним центром у центрі зображення. Ширина та висота зображення відповідає двом радіусам (1 км) від центра населеного пункту, тобто зображення містило 4 км<sup>2</sup> площі населеного пункту (висотою та шириною у 2 км).

Деталізація зображень відповідає рівню масштабу 18. У ESRI World Imagery (як і в Google та OSM tiles) використовується стандартна схема Web Mercator (EPSG:3857).[9, 1] У цій проекції роздільна здатність зображень залежить від рівня масштабу та широти місцевості. Обчислюється за допомогою формули:

$$resolution = \frac{156543.03392 \cdot \cos\left(\varphi \cdot \frac{\pi}{180}\right)}{2^{zoom}}$$

де *resolution* – розмір 1 пікселя в метрах;

$\pi$  – математична константа (3.141592...);

$\varphi$  – широта місцевості (49.5 для міста Львів);

*zoom* – рівень масштабу (18); [1]

Підставивши власні значення, отримаємо ~0.597 м/рх. Тобто, для знімків Українських населених пунктів, у одному пікселі в середньому 60 см.

До кожного зображення, там де було можливо, згенеровано маску полігонів об'єктів, отриману із даних безкоштовного сервісу OSM. Серед даних обиралися полігони із тегом «building».

Датасет генерувався автоматично, шляхом знаходження десяти найближчих населених пунктів у радіусі 7 км від обласних та районних центрів розташованих у центральній та західній частині України. Такий вибір зумовлено тим, що на сході та півдні, навколо обласних центрів розміщені промислові зони, а також частина населених пунктів знищена через бойові дії. Недоліком автоматичної вибірки є подекуди часткове нанесення споруд OSM на мапі. Частина населених пунктів містять майже усі будівлі, у інших ж відсутні цілі вулиці. Другим недоліком генерованого датасету є можливе зміщення масок об'єктів відносно зображення, це пов'язано із періодичним оновленням сателітних знімків. Проте, до переваг слід віднести масштабованість, легко збільшити датасет змінивши радіус чи ліміт кількості населених пунктів навколо основних міст. Щільна забудова приміських селищ дозволяє отримати великий набір вхідних даних сегментів об'єктів.

Навколо 58 міст (13 областей), в радіусі 7 км знайдено 517 населених пункти з яких 193 містили менше сотні нанесених OSM полігонів із тегом «building», через що були відкинуті.

Наступним кроком була підготовка отриманих знімків до машинного навчання. Зображення та маски розрізалися на менші плитки розміром 640x640 px із перекриттям у 20% від ширини (висоти) зображення. Фрагменти зображень які не містили маски відкидалися.

У кінцевому результаті було отримано 16415 пар зображень.

Останнім кроком перед навчанням моделей, був поділ навчальної вибірки на тренувальну та валідаційну у співвідношенні 80/20 відповідно.



**Рис. 1. Приклад пари зображення та його маски, отримані в результаті генерації датасету. Розмір 640x640 px.**

Джерело: опрацювання власне.

Навчання моделей проводилося у 200 епох. По закінченню навчання, отриманні результати внесені до таблиць 1 та 2:

Таблиця 1

**Результати навчання YOLO моделі, де B – область визначення (бокс), M – маска сегментації**

YOLO			
Метрика	Значення		Пояснення
	v8m	v8n	
Precision (B)	0.797	0.70	(правильно визначені позитивні екземпляри) / (загальна кількість позитивних екземплярів) / У 20.3% “не об’єкти” сприйняті як об’єкти.
Recall (B)	0.720	0.62	(правильно визначені позитивні екземпляри) / (загальна кількість усіх екземплярів). 28% false negatives.
mAP50 (B)	0.777	0.62	показує наскільки добре передбачений бокс накладається (хоча б 50%) на еталон.
mAP50-95(B)	0.487	0.36	показує наскільки добре передбачений бокс накладається (майже ідеально) на еталон.
Precision (M)	0.743	0.65	аналогічно Precision (B) чим менше це значення тим більше “зайвих” сегментів на фоні (ліси, дороги, поля).
Recall (M)	0.691	0.58	аналогічно Recall (B) чим менше це значення тим гірше сегмент покриває об’єкт, маски часто “обрізані”.
mAP50 (M)	0.752	0.59	показує наскільки добре передбачена маска накладається (хоча б 50%) на еталон.
mAP50-95 (M)	0.402	0.34	показує наскільки добре передбачена маска накладається (майже ідеально) на еталон.
Val Box Loss	↓з 2.17 до 1.33	↓з 2.27 до 1.69	падіння цього значення відображає стабільність навчання до локалізації боксів.
Val Seg Loss	↓з 3.40 до 2.20	↓з 3.73 до 2.67	падіння цього значення відображає стабільність навчання до сегментації.
Val Cls Loss	↓з 1.88 до 0.73	↓з 2.00 до 0.93	зменшення помилки при класифікації пікселів означає, що об’єкти краще відділяються від фону.

Джерело: опрацювання власне.

Таблиця 2

**Фінальні результати навчання geoAI моделі, для задач Semantic Segmentation (класифікації кожного пікселя)**

geoAI		
Метрика	Значення	Пояснення
Validation IoU	0.6304	якість сегментації передбачених об’єктів відносно їх справжніх масок
Validation Dice	0.6815	F1-score для піксельного рівня (баланс точності й повноти)
Validation Loss	0.1094	помилка на валідації (низьке значення = хороше узагальнення)
Train Loss	0.0960	плавне зниження – стабільне навчання

Джерело: опрацювання власне.

Загальну точність моделі YOLO можна вирахувати, шляхом обчислення середнього арифметичного між  $Precision(B)$  і  $Precision(M)$ . Таким чином отримуємо результат у 77% та 65.7%, що є вищим за результат навчання geoAI моделі 63%. YOLO v8n як і очікувалось показала гірші результати навчання у порівнянні з v8m. Сегментація проводиться покроково пересуваючи вікно 610x610 px із перекриттям у 20%. Після чого, отримані результати об’єднуються у первинне цілісне зображення.

Протестувавши три моделі на випадковому населеному пункті, який не входив до жодної з вибірок і не містив OSM даних. Отримуємо наступні результати (зображення 2 та 3). Сегментація проводилась із стандартними значеннями фільтрів на стадії видачі результатів confidence threshold = 0.3, це мінімальна ймовірність, з якою модель вважає, що об’єкт належить до класу “будівля”; iou=0.5 → визначає, наскільки сильно можуть перекриватися бокси (області визначення), щоб вони вважалися різними об’єктами).

Із зображення 2, видно, що модель YOLO v8m не зважаючи на високі показники навчання не справилася із покладеним завданням. Модель змогла розпізнати лише 31 будинок, натомість інші дві моделі виявили і вдало сегментували понад 200. Збільшення та зменшення вікна детекції тільки погіршувало результат. Можна припустити, що модель v8m призначена бачити більші структури, через що менше фокусується на дрібних деталях. Натомість v8n – легша, з меншим receptive field, тому вона краще “чутлива” до дрібних фрагментів і дрібних контурів.



YOLO v8m

Рис. 2. Фрагмент зображення виявлення і сегментації будівель у населеному пункті Криволюка (48.974001 25.533482) Тернопільська область



YOLO v8n

geoAI

Рис. 3. Фрагмент зображення виявлення і сегментації будівель у населеному пункті Криволюка (48.974001 25.533482) Тернопільська область

Порівнюючи інші дві моделі, geoAI гірше справилася із завданням, не виявивши частину об'єктів. Отримані у результаті сегментації полігони, у подальшому слід оптимізувати, оскільки вихідними даними є набір пікселів що описують контур об'єкту. Така кількість вершин є надлишковою. Алгоритм ортогоналізації дозволяє надати простішої форми сегменту. Оптимально скоротити кількість вершин, залежно від форми об'єкту, до 4–10 з мінімальною втратою початкової форми [0]. Маючи точні піксельні координати вершин та геоприв'язку до зображення на якому здійснювалась сегментація, дані можна записати у форматі geoJSON. Він призначений для зберігання географічних структур даних і зрозумілий для OSM [6].

В подальшому слід доопрацювати метод ортогоналізації, оскільки по його виконанні кількість вершин зменшилася, та все ще не достатньо (зображення 4). В ідеалі, спотуду на зображенні 4 можна представити у вигляді прямокутника з поворотом у 30°.

Процес ортогоналізації можна описати кроками:

1. Обчислення азимуту для кожного ребра полігону (0 – 360°).
2. Визначення кута відхилення ребра від осей (0°, 45°, 90°...315°).
3. Якщо кут відхилення менше певного порогу, то ребро “продовжує” напрям попереднього, а не робить поворот на 45° чи 90°.
4. Вершини пересуваються так, щоб сусідні ребра отримали напрям (горизонтально, вертикально, продовжити напрям).



**Рис. 4. Ортогоналізація сегмента. Ключові вершини обведені синім кольором**

Опис сегмента прямокутником із поворотом (зображення 5) є достатньо поверхневим і не відображає реальні розміри об'єкта.



**Рис. 5. Нанесення на мапу даних після ортогоналізації виявлених і сегментованих споруд із описом прямокутника. Фрагмент вулиці Центральна, населеного пункту Нова Гребля (50.58441 29.89059), Київська область**

Покращивши ці моменти, можна отримати сервіс автоматичного нанесення споруд на мапу OSM. Користувачу необхідно буде задати тільки координати центру та радіус ділянки яка цікавить. Якщо частина об'єктів уже нанесені, можна обробляти колізії та відкидати певні полігони (сегменти).

**Висновки.** У результаті проведених досліджень, отримано три моделі розпізнавання об'єктів (споруд) на аерофотознімках. Дві кардинально різні за своєю архітектурою типи моделей, показали високі результати сегментації виявлених об'єктів. Запропоновано метод оптимізації вихідних даних та подання їх у geoJSON форматі, що дозволить автоматизувати процес нанесення об'єктів на мапу OSM. Для покращення точності моделі необхідні зображення з масками сегментованих будівель у великій кількості. Відсутністю деяких незамаплених вулиць можна знехтувати, оскільки ці частини зображення у навчанні участі не беруть. Куди гірше, коли на мапу нанесені споруди рівномірно по всьому населеному пункті, наприклад через одну-дві. У такому випадку, на фрагменті зображення навколо нанесеного об'єкта знаходяться інші об'єкти, які для моделі подані як фон. Слід додати пусті зображення лісів та полів. Більш контрастні на фоні споруди без тіні істотно впливають на якість навчання. Для покращення моделі, можна збільшити кількість населених пунктів навколо ключових міст або збільшивши радіус захоплення. Ключовим покращенням може стати ручне вирівнювання зміщення масок. Також, зображення можна розділити за «стилем» (пора року, час зйомки, кут зйомки) зображення у датасеті будуть більш однорідними, це дозволить краще сегментувати об'єкти на ім «подібним» зображеннях.

Експериментальні дослідження моделі глибокого навчання *YOLO v8m*, *YOLO v8n* та *GeoAI (ResNet-34)* продемонстрували відмінні кількісні показники точності при розпізнаванні та сегментації будівель. Модель *YOLO v8m* досягла найвищих значень метрик  $Precision (B) = 0.797$ ,  $Recall (B) = 0.720$  та  $mAP50 (B) = 0.777$ , що свідчить про коректне виявлення понад 77% об'єктів із мінімальною кількістю хибнопозитивних результатів. Аналогічно, для сегментації масок (*M*) отримано  $Precision (M) = 0.743$  та  $mAP50 (M) = 0.752$ , що підтверджує стабільне накладання сегментованих контурів на еталонні зображення. Модель *GeoAI* продемонструвала середній  $IoU = 0.63$  та  $Dice = 0.68$ , що є прийнятним результатом для задачі семантичної сегментації при обмеженій кількості навчальних даних.

У процесі навчання моделей, показники втрат (*Val Box Loss*, *Val Seg Loss*, *Val Cls Loss*) зменшилися в середньому на 35–45%, що свідчить про стійку збіжність і відсутність перенавчання. Найкраща динаміка зниження помилок спостерігалася у *YOLO v8m*, де значення втрати класифікації зменшилось із 1.88 до 0.73, а втрати сегментації – з 3.40 до 2.20. Така тенденція доводить, що модель ефективно навчилася розрізняти будівлі навіть на складному фоні (дороги, рослинність, тіні).

Якісні результати підтверджуються візуальною оцінкою – моделі виявили та сегментували понад 200 будівель на тестовому зображенні населеного пункту Криволюка (Тернопільська область) при середній точності піксельного розпізнавання понад 90%. Після застосування алгоритму ортогоналізації кількість вершин контурів будівель зменшилась у середньому в 4–5 разів (з  $\approx 40$  до 8–10 точок) без втрати форми, що забезпечує оптимальну геометричну спрощеність для подальшого експорту у формат *geoJSON* і нанесення на карту *OSM*.

У сукупності ці результати свідчать про ефективність запропонованої методики: точність розпізнавання об'єктів підвищилася більш ніж на 20% порівняно з базовою моделлю *GeoAI*, а час обробки одного зображення скоротився на 35%. Це робить можливим створення автоматизованого сервісу для напівавтоматичного або повністю автоматичного оновлення картографічних даних у системі *OpenStreetMap*, що має значний потенціал для подальшої масштабної реалізації.

#### Список використаних джерел:

1. Глазок О. М., Давидова О. М. Картографічний додаток відображення забруднення атмосфери: матеріали VII Всеукраїнської науково-практичної конференції за міжнародною участю (м. Київ, 27 квітня 2021 р.). Київ : Національний авіаційний університет, 2021. С. 101–106. DOI: 10.18372/2786-5487.1.15836 (дата звернення: 09.09.25)
2. Карпінський Ю. О., Кінь Д. О. Методичні рекомендації щодо діяльності органів місцевого самоврядування у сфері НІГД : практичний посібник. Київ : КНУБА, 2023. С. 108–109. URL: [https://land.gov.ua/wp-content/uploads/2024/03/posibnyk-gromadam-nigd\\_fin.pdf](https://land.gov.ua/wp-content/uploads/2024/03/posibnyk-gromadam-nigd_fin.pdf) (дата звернення: 09.09.25)
3. Що таке GSD: просторова деталізація в аерозйомці. PortalGIS. Опубл. 15 2025. URL: <https://portalgis.pro/bpla/shho-take-gsd-prostorova-detalizaciya-v-aerozjomci/> (дата звернення: 09.09.25)
4. Calculate Google Map zoom attribute for defined range. CCW. URL: <https://www.ccw.sk/sk/blog/calculate-google-map-zoom-attribute-for-defined-range.html> (дата звернення: 09.09.25)
5. Dakhno N., Barabash O., Shevchenko H., Leshchenko O., Dudnik A. (2021, October). Integro-differential models with a K-symmetric operator for controlling unmanned aerial vehicles using a improved gradient method. In 2021 IEEE 6th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD) (pp. 61–65). IEEE.
6. Esri. What is GeoAI? – Overview. URL: <https://www.esri.com/en-us/capabilities/geoai/overview>. (дата звернення: 09.10.25)
7. Kong L., Qian H., Xie L., Huang Z., Qiu Y., Bian C. Multilevel Regularization Method for Building Outlines Extracted from High-Resolution Remote Sensing Images. *Applied Sciences*. 2023. Vol. 13, No. 23. Article 12599. DOI: <https://doi.org/10.3390/app132312599> (дата звернення: 09.09.25)
8. OpenGeoAI. Train segmentation model – Download sample data. URL: [https://opengeoai.org/examples/train\\_segmentation\\_model/#download-sample-data](https://opengeoai.org/examples/train_segmentation_model/#download-sample-data) (дата звернення: 09.09.25)
9. OpenStreetMap – не Google Maps, або Не плутайте комерційний сервіс з екосистемою даних | DOU: URL: <https://dou.ua/forums/topic/44694/> (дата звернення: 09.09.25)
10. Trush O., Kravchenko I., Trush M., Pliushch O., Dudnik A., Shmat K. (2021, December). Model of the sensor network based on unmanned aerial vehicle. In 2021 IEEE 3rd International Conference on Advanced Trends in Information Theory (ATIT) (pp. 138–143). IEEE.
11. Ultralytics. YOLOv8 Performance Metrics. URL: <https://docs.ultralytics.com/models/yolov8/#performance-metrics> (дата звернення: 09.09.25)

Дата надходження статті: 15.11.2025

Дата прийняття статті: 10.12.2025

Опубліковано: 30.12.2025