

Державна установа “Науковий центр аерокосмічних досліджень Землі
Інституту геологічних наук Національної академії наук України”

Кваліфікаційна наукова
праця на правах рукопису
УДК 528.854.4:519.237.8(043)

САПРИКІН ЄВГЕН ЮРІЙОВИЧ

ДИСЕРТАЦІЯ

**МЕТОДИКА ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ’ЄКТІВ
НА ОСНОВІ КОМПЛЕКСУВАННЯ ДАНИХ АЕРОЗНІМАННЯ РІЗНОЇ
ФІЗИЧНОЇ ПРИРОДИ**

172 – Електронні комунікації та радіотехніка
17 – Електроніка, автоматизація та електронні комунікації

Подається на здобуття ступеня доктора філософії
Дисертація містить результати власних досліджень. Використання ідей,
результатів і текстів інших авторів мають посилання на відповідне джерело



_____ Саприкін Є.Ю.

Науковий керівник Станкевич Сергій Арсенійович, доктор технічних наук,
професор

Київ – 2026

АНОТАЦІЯ

Саприкін Є.Ю. Методика виявлення малорозмірних компактних об'єктів на основі комплексування даних аерознімання різної фізичної природи.

Дисертація на здобуття ступеня доктора філософії за спеціальністю 172 – Електронні комунікації та радіотехніка (17 – Електроніка, автоматизація та електронні комунікації). Державна установа “Науковий центр аерокосмічних досліджень Землі Інституту геологічних наук Національної академії наук України”, м. Київ, 2026.

Мета дослідження: підвищення достовірності виявлення і класифікації малорозмірних компактних об'єктів, а саме поверхневих мін, на земній поверхні за матеріалами знімання з БПЛА.

В дисертаційному дослідженні розглянуто сукупність методів, які застосовувалися дослідниками з різних країн протягом останніх років для виявлення мін. Спираючись на твердження, що стовідсоткове надійне виявлення мін неможливе з використанням лише одного фізичного принципу, застосованого в камерах чи сенсорах, продемонстровано підхід до підбору сенсорів і комплексування ймовірнісних результатів виявлення у застосуванні до поверхневих мін. Використано диференційований підхід до роботи з даними сенсорів різної фізичної природи залежно від ступеня розвитку сенсорів, методів роботи з даними та доступності навчальних даних для машинного навчання.

Розроблено цілісну методику виявлення компактних об'єктів на основі комплексування даних аерознімання різної фізичної природи з урахуванням поточного стану розвитку сенсорів і методів виявлення та класифікації об'єктів, а також умов їх розміщення в середовищі. Запропоновано низку

критеріїв вибору сенсорів та їх пріоритизації в межах системи виявлення. Обґрунтовано доцільність застосування методів глибокого навчання для різних типів даних.

Користуючись розробленими критеріями, обрано три типи даних за фізичним принципом – аерозображення з камер видимого діапазону, аерозображення з інфрачервоних камер теплового діапазону та дані магнітометрії. Розроблено і продемонстровано метод комплексування ймовірнісних результатів нейронних мереж і статистичних методів через байєсівське злиття ймовірностей.

Розроблено підхід до мінімізації необхідного обсягу навчальних даних і часу навчання для забезпечення можливості подолання дефіциту навчальних даних та швидкого ітеративного покращення можливостей детектора, зокрема під час розширення набору класів. Для досягнення цієї мети використано передавальне навчання (тонке налаштування) на базі великих наборів даних загального користування з акцентом на досягненні оптимальних гіперпараметрів передавального навчання для базового та цільового наборів даних і конкретної моделі нейронної мережі, а саме кількості навчальних епох і глибини фіксації шарів.

Здійснено збір навчальних даних для глибокого навчання та створено навчальні й тестові датасети RGB- та теплових зображень реальних об'єктів, одержаних із БПЛА. Проведені експерименти з пошуку оптимальної методики навчання згорткової нейронної мережі для розглянутого типу об'єктів, тобто поверхневих протитанкових та протипіхотних мін. Здійснено кількісну оцінку точності у режимах як класифікації мін, так і виключно виявлення. Продemonстровано доцільність комплексування результатів різної фізичної природи на прикладі аерозображень видимого діапазону, теплових аерозображень і магнітометричних даних. Усі кроки поєднано в єдиний

робочий процес — від постановки завдання й планування аерозйомки БПЛА в різних погодних умовах до зберігання та відображення результатів на єдиній геоінформаційній платформі. Для вирішення всіх задач підібрано й адаптовано вільно розповсюджуване програмне забезпечення з відкритим кодом.

Оцінено необхідну кількість навчальних даних і епох навчання нейромережі на цільовому датасеті. Кількість аерозображень у датасеті склала 1000 зображень для шести типів протитанкових мін та одного типу з варіаціями — протитанкових мін. Для такого набору середня кількість необхідних епох навчання склала 23, що є дуже низьким значенням, з огляду на те, що універсальна рекомендована тривалість становить 100 епох. Це дозволяє говорити про реалізацію концепції пришвидшеного навчання (*few-shot learning*) та наближення до безперервного навчання (*continuous learning*).

Зокрема, для виявлення всіх типів мін, включно з найменшою з розглянутих — ПФМ1 “Пелюстка” (розмір 18×10 пікселів), за просторової розрізненності аерозображення 6 мм/піксель, при висоті аерознімання 10 м, для моделі *medium* нейромережі YOLOv11 знадобилося 23 епохи навчання з 10 фіксованими шарами. На тепловому аерозображенні продемонстровано впевнене виявлення протитанкової міни ТМ розмірами 20×20 пікселів.

Досягнуто показника **повноти** (*recall*), рівного 1 (що власне і є основним досягненням розробки методики) для моделі *medium* нейромережі YOLOv11 в режимі єдиного класу, базового датасету Microsoft COCO, кількістю епох 25, фіксації 8 шарів, при цьому показники *mAP50* та *mAP50-95* дорівнюють відповідно 0,878 та 0,702, у той час як *mAP50* для базової нейромережі YOLOv11, тренуваної на датасеті Microsoft COCO, складає 0,515, таким чином цей показник у отриманої донавченої мережі краще у 1,36 разів. Для моделі *medium* нейромережі YOLOv11 у режимі виявлення і

класифікації від початку процесу оптимізації значення $mAP50$ змінюється від 0,274 (20 епох) та 0,316 (25 епох) до 0,983, що доводить ефективність обраного підходу.

Водночас продемонстровано здатність нейромережі до навчання з нуля, без застосування трансферного навчання, на прикладі теплових аерозображень, для яких відсутній базовий датасет. На обмеженому наборі теплових аерозображень протитанкових мін ТМ досягнуто значення $R = 0,829$ та $mAP50 = 0,456$ за 75 епох навчання.

Комплексування результатів виявлення мін через байєсівське злиття ймовірностей дозволяє покращити результати невпевненого виявлення мін нейромережею у проблемних умовах в деяких випадках з 0,15 до 0,8 за умови отримання оптичних аерозображень з висоти польоту від 10 м і магнітометричних вимірювань з висоти до 2 м.

Наукова новизна

Вперше розроблено методику виявлення малорозмірних компактних об'єктів на основі комплексування даних аерознімання різної фізичної природи. Методика використовує раціональний набір сучасних методів машинного та глибокого навчання для виявлення мін, розташованих на земній поверхні, за даними звичайного RGB-аерознімання, аерознімання в інфрачервоному тепловому діапазоні та авіаційної магнітометрії. Передбачається, що всі датчики, залучені в межах методики, розташовуються на борту кількох легких БПЛА коптерного типу. Видові дані аерознімання аналізуються адаптованими до їх різновидів нейромережами, а магнітометричні вимірювання – шляхом статистичного виявлення аномалії сигналу магнітометра над магнітним фоном. Виконується статистичне злиття ймовірностей виявлення цільових об'єктів, що забезпечує підвищення

результуючої достовірності їх виявлення. Взаємодія всіх задіяних апаратних і програмних засобів здійснюється в межах єдиної геоінформаційної платформи, архітектуру якої обґрунтовано. Застосування розробленої методики забезпечує можливість виявлення мін на аерозображеннях видимого діапазону за допомогою згорткових нейромереж із показниками повноти $R = 1$ та $mAP50 = 0,983$, та впевнене підвищення достовірності у складних умовах виявлення до 0,8 при комплексуванні результатів сенсорів різної фізичної природи.

Удосконалено модель донавчання згорткової нейромережі з урахуванням особливостей мін як об'єктів виявлення, а саме: з урахуванням ступеня представлення розпізнавальних ознак цільових об'єктів у шарах основи базової пренавченої нейромережі (що залежить від вибору базового датасету), трансферне навчання пренавченої нейромережі відбувається із попередньо підібраними оптимальними значеннями таких гіперпараметрів, як кількість незмінних шарів основи та кількість епох донавчання. Таке удосконалення моделі донавчання дозволило покращити достовірність виявлення мін на аерозображеннях, що характеризується збільшенням показника $mAP50$ з 0,316 до 0,983 за тих самих базового та цільового датасетів.

Подальшого розвитку набуло статистичне виявлення об'єктів на аерокосмічних зображеннях. Експериментальним шляхом визначено кількість пікселів, достатню для впевненого виявлення компактного об'єкта нейромережею архітектури YOLO. Результат адаптовано для виявлення поверхневих мін різної форми. Визначення потрібної піксельної розрізненності дозволяє більш ґрунтовно визначати параметри польоту БПЛА під час виявлення поверхневих мін за допомогою різних бортових

сенсорів і тим самим підвищити загальну продуктивність аерознімання за збереження достовірності.

Практичне значення отриманих результатів

За результатами експериментальних досліджень розроблена методика продемонструвала можливість досягнення для нейромережі архітектури YOLO показника **повноти** (*recall*) виявлення мін, рівного 1, для аерозображень, отриманих з висоти польоту БПЛА 10 м, і показника *mAP50* 0,994 для виявлення і класифікації мін. Для комплексування результатів різних сенсорів, а саме — аерозображень видимого діапазону, теплових аерозображень і магнітометричних даних, продемонстровано можливість підвищення достовірності в складних випадках у середньому з 0,2 до 0,8. Досягнуто можливості донавчання детектора із середньою кількістю навчальних епох 23, що дає змогу швидко розширити набір об'єктів виявлення і класифікації. Обґрунтовано архітектуру єдиної геоінформаційної платформи для підтримки наскрізного процесу виявлення мін з БПЛА. Створено власні датасети RGB та теплових аерозображень реальних мін, натреновано набір нейромереж із широкими варіаціями кількості епох та фіксації шарів.

Ключові слова: безпілотні літальні апарати (БПЛА), аерознімання, дистанційне зондування, авіаційна магнітометрія, малорозмірні компактні об'єкти, наземні міни, виявлення і класифікація, штучний інтелект (ШІ), машинне навчання, глибоке навчання, згорткові нейронні мережі, передавальне навчання, комплексування даних різної фізичної природи.

За результатами досліджень опубліковано **13** наукових праць, у тому числі **1** глава у монографії; у закордонних фахових виданнях – **2** статті (з них

2 проіндексовані в базі даних Scopus); статті у наукових виданнях, включених на дату опублікування до переліку наукових фахових видань України категорія *A* – 1 стаття; категорія *B* – 4 статті; 5 публікацій у збірниках та матеріалах тез доповідей вітчизняних та міжнародних конференціях, з яких 3 проіндексовані в базі даних Scopus.

ABSTRACT

Saprykin I.Y. Technique for detection of small-sized compact objects based on data fusion from airborne survey of various physical nature.

Dissertation for the Doctor of Philosophy (PhD) degree in 172 – Electronic Communications and Radio Engineering (17 – Electronics and Telecommunications). State Institution “Scientific Centre for Aerospace Research of the Earth of the Institute of Geological Sciences of the National Academy of Sciences of Ukraine”, Kyiv, 2026.

The aim of the study was to increase the reliability of detection and classification of small-sized compact objects, namely surface landmines, on the land surface using UAV data acquisition.

The dissertation study examines methods used in recent years by researchers from different countries to detect landmines. Based on the statement that completely reliable landmine detection is impossible using only a single physical principle of the cameras or sensors engaged, an approach to sensor selection and the integration of detection probability for surface landmines is demonstrated. A differentiated approach to processing sensor data of different physical natures is used, depending on the sensors’ possibilities, data processing methods, and the availability of training data for machine learning.

A cut-through technique for compact object detection based on remote sensing data fusion of various physical natures has been developed, taking into account the sensors’ capabilities, methods for object detection and classification, and environmental conditions. A number of criteria for sensor selection and prioritization within the detection system have been proposed. The feasibility of deep learning methods for different types of data has been substantiated.

Using the proposed criteria, three types of data were selected based on the physical principle: aerial images from visible-band cameras, aerial images from thermal infrared cameras, and magnetometry data. A combination of the probabilistic outputs of neural networks and statistical methods through Bayesian probability fusion has been proposed and demonstrated.

An approach to minimizing the required amount of training data and training time has been developed to overcome the training data shortage and rapidly improve object detection capabilities, including by expanding the set of classes. To achieve this goal, transfer learning (fine-tuning) was used for large public datasets with an emphasis on achieving optimal transfer learning hyperparameters for the basic and target datasets and a specific neural network model, specifically the number of training epochs and the depth of layer freezing.

Training data for deep learning were collected, and training and test datasets of RGB and thermal images of real-world objects captured by UAVs were created. Experiments were conducted to identify the optimal training technique for a convolutional neural network for the object type under consideration, i.e., anti-tank and anti-personnel surface landmines. A quantitative assessment of accuracy was performed for both landmine classification and detection. The reason for combining data of different physical natures was illustrated by examples of visible-band aerial imagery, thermal aerial imagery, and magnetometry data. All operations are integrated into an end-to-end workflow, from task setting and UAV mission planning under different weather conditions to storing and displaying landmine detection results on a unified geoinformation platform. The free, open-source software was selected and adapted for implementing the proposed technique.

The required number of training samples and the number of training epochs for the neural network on the target dataset were estimated. The dataset contained

1,000 aerial images across six types of anti-personnel landmines and one type of anti-tank, with variations. For such a set, the average number of required training epochs was 23, which is very low, given that the universally recommended duration is 100 epochs. This implements both the few-shot learning concept and the continuous learning.

In particular, to detect all types of landmines, including the smallest of the considered ones – PFM1 “Petal” when its size is 18×10 pixels, under aerial image spatial resolution of 6 mm/pixel at an altitude of 10 m, the medium model of the YOLOv11 neural network required 23 training epochs with ten frozen layers. The thermal aerial image demonstrated the confident detection of the TM anti-tank landmine when its size is 20×20 pixels.

A *recall* metric of 1.0 (which is the primary performance of the developed technique) was achieved for the medium model of the YOLOv11 neural network in the single-class mode, the base Microsoft COCO dataset, the number of epochs 25, and freezing of 8 layers, while the mAP50 and mAP50-95 metrics are 0.878 and 0.702, respectively, while the mAP50 for the base YOLOv11 neural network trained on the Microsoft COCO dataset is 0.515, thus the performance obtained of pre-trained network is 1.36 times better. For the medium model of the YOLOv11 neural network in detection and classification mode, from the start of the optimization process, the mAP50 value increases from 0.274 (20 epochs) to 0.316 (25 epochs) and then to 0.983, demonstrating the efficiency of the chosen approach.

At the same time, the ability to train a neural network from scratch, without transfer learning, is demonstrated on thermal aerial images for which no base dataset is available. On a limited set of thermal aerial images of TM anti-tank landmines, $R = 0.829$ and $mAP50 = 0.456$ were achieved after 75 training epochs.

Combining landmine detection results via Bayesian probability fusion improves the uncertain landmine detection performance of a neural network under challenging conditions, in some cases increasing it from 0.15 to 0.8, using aerial images obtained at a flight altitude of 10 m and magnetometric measurements at altitudes below 2 m.

Scientific novelty

A novel technique for detecting small, compact objects based on data fusion of various physical phenomena has been developed. The technique involves a rational set of modern machine learning and deep learning methods for surface landmine detection by conventional RGB aerial imaging, thermal infrared aerial imaging, and airborne magnetometry. It is assumed that all sensors involved can be installed on several light copter-type UAVs. Imaging data are analyzed by neural networks according to their types, while magnetometric measurements are analyzed by statistical anomaly detection inside the magnetometer signal. A Bayesian fusion of the target detection probabilities is performed, enhancing detection confidence. The interaction among all involved hardware and software tools is carried out within a unified geoinformation platform, whose architecture is justified. The application of the developed technique enables landmine detection in visible-band aerial images using convolutional neural networks, achieving a recall of $R = 1$ and $mAP50 = 0.983$, as well as a significant confidence enhancement under difficult conditions, up to 0.8, through sensor fusion of different physical natures.

The convolutional neural network fine-tuning model *has been improved* based on the specificity of mines as detection objects, namely: taking into account the amount of representation of the recognition features of target objects in the layers of the backbone of the basic pretrained neural network (which depends on the choice of the basic dataset), the transfer learning of the pretrained neural network

takes place with previously found optimal values of such hyperparameters as the number of frozen base layers and the number of fine-tuning epochs. Such an improvement in the fine-tuning model enhances the reliability of mine detection on aerial images, as evidenced by an increase in the mAP50 metric from 0.316 to 0.983 for the same basic and target datasets.

Statistical detection of objects in aerospace images *has been further developed*. The number of pixels required for a neural network based on the YOLO architecture to confidently detect a compact object has been experimentally determined. The result is adapted for detecting surface landmines of various shapes. Determining the required pixel resolution provides a more thorough assessment of UAV flight parameters for surface landmine detection using various onboard sensors, thereby enhancing the overall productivity of aerial imaging while preserving reliability.

Practical significance of the results obtained

According to experimental results, the developed technique achieved a surface landmine detection recall of 1 for the YOLO neural network in aerial images obtained at a UAV flight altitude of 10 m, and an mAP50 of 0.994 for landmine detection and classification. The fusion of data from various sensors, namely visible-band aerial images, thermal infrared aerial images, and magnetometric data, demonstrated an improvement in landmine detection reliability in challenging cases from 0.2 to 0.8 on average. Neural network fine-tuning with 23 training epochs was achieved, enabling rapid expansion of detection and classification object types. The architecture of a unified geoinformation platform was substantiated to support the end-to-end landmine detection workflow with UAVs. New datasets of RGB and thermal aerial images of actual landmines were created, and a set of neural networks with wide variations in the number of epochs and layer freezing were trained.

Keywords: unmanned aerial vehicle (UAV), aerial imaging, remote sensing, airborne magnetometry, small-sized compact objects, surface landmine, detection and classification, artificial intelligence (AI), machine learning, deep learning, convolutional neural networks, transfer learning, data fusion of various physical natures.

Based on the results of the research, 13 scientific works were published, including 1 chapter in monograph; in foreign specialized publications – 2 articles (of which 2 is indexed in the Scopus database); articles in scientific publications included on the date of publication in the list of specialized scientific publications of Ukraine category A - 1 article; category B – 4 articles; 5 in collections and abstracts of reports at Ukrainian and international conferences of which 3 are indexed in the Scopus database.

Список публікацій за темою дисертації

Публікації у монографіях

1. Ковтун, С. І., Мосов, С. П., Назаренко, О. О., Нероба, В. Р., Сєлюков, О. В., Станкевич, С. А., & Чубіна, Т. Д. (2025). Розвідка наземних мін з безпілотних літальних апаратів (видимий діапазон довжин хвиль): колективна монографія (В. П. Бабак, Ред.). Видавничий дім «Вініченко». (особистий внесок – розділ, присвячений виявленню мін за допомогою нейронних мереж)

Матеріали, опубліковані в періодичних виданнях:

2. Saprykin, I. Y. (2024). Optical deep learning landmine detection based on limited dataset of aerial imagery. *Science-Based Technologies*, 62(2), 107–115. <https://doi.org/10.18372/2310-5461.62.18708> (Індексація: фахове видання України категорії «Б»)
3. Popov, M. O., Stankevich, S. A., Mosov, S. P., Dugin, S. S., Golubov, S. I., Andreiev, A. A., Lysenko, A. R., & Saprykin, I. Y. (2024). The concept of a geoinformational platform for landmines and other explosive objects detection and mapping with UAV. *Радіоелектронні і комп'ютерні системи*, (4). <https://doi.org/10.32620/reks.2024.4.17> (Індексація: Scopus; особистий внесок: удосконалення модуля планування місій БПЛА для урахування додаткових умов середовища, інтеграція навчених нейронних мереж у платформу)
4. Stankevich, S. A., & Saprykin, I. Y. (2024). Optical and magnetometric data integration for landmine detection with UAV. *WSEAS Transactions on Environment and Development*, 20, 1059–1066. <https://doi.org/10.37394/232015.2024.20.96> (Індексація: Scopus; особистий

внесок: розробка методики обробки оптичних даних, здійснення розрахунків, аналіз, візуалізація, валідація)

5. Станкевич, С. А., Урусський, О. С., Мосов, С. П., & Саприкін, Є. Ю. (2024). Використання непрямих ознак для виявлення наземних мін з використанням безпілотних літальних апаратів. *Збірник наукових праць Центру воєнно-стратегічних досліджень Національного університету оборони України*, (2), 98–105. <https://doi.org/10.33099/2304-2745/2024-2-81/98-105> (Індексація: фахове видання України категорії «Б»; особистий внесок – адаптація методів глибокого навчання із застосуванням нейронних мереж до врахування непрямих ознак наземних мін, обробка даних)

6. Ментус, І. Е., Ясько, В. А., & Саприкін, Є. Ю. (2024). Методи виявлення мін для гуманітарного розмінування. *Український журнал дистанційного зондування Землі*, 11(3). <https://doi.org/10.36023/ujrs.2024.11.3.271> (Індексація: фахове видання України категорії «Б»; особистий внесок – адаптація методів глибокого навчання із застосуванням нейронних мереж для виявлення ряду типів наземних мін)

7. Stankevich, S., Kondratov, O., Herda, M., & Saprykin, I. (2024). Infrared image iterative enhancement in frequency domain. *Radioelectronics and Communications Systems*, 67, 277–286. <https://doi.org/10.3103/S0735272724070045> (Індексація: Scopus; особистий внесок – калібрування та обробка теплових аерозображень, підготовка даних)

8. Мосов, С. П., Станкевич, С. А., Нероба, В. Р., & Саприкін, Є. Ю. (2026). Класифікація наземних мін як об'єктів повітряної розвідки в системі цивільного захисту. *Збірник наукових праць Національної академії Державної прикордонної служби України. Серія: військові та технічні науки*, 102(1), 70–80. <https://doi.org/10.32453/3.v102i1.2133> (Індексація: фахове

видання України категорії «Б»; *особистий внесок* – аналіз класифікації мін в контексті глибокого навчання, підготовка даних та ілюстрацій)

Апробація матеріалів дисертації

9. Popov M., Stankevich S., Mosov S., Saprykin I. Drone-based landmine detection by image and signal fusion. Proceedings of the TIEMS Hybrid Annual Conference. Port Alfred: TIEMS, 2023, p. 24. URL: https://www.tiems.info/images/pdf/TIEMS_2023_Hybrid_Annual_Conference_Preliminary_Program_ver_5.pdf (*особистий внесок*: підготовка та обробка зображень наземних мін, підготовка презентації, доповідь)

10. Popov, M. O., Stankevich, S. A., Mosov, S. P., Dugin, S. S., & Saprykin, I. Y. (2023). Drone-based landmine detection mission planning. In *Proceedings of the 7th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)* (pp. 151–154). IEEE. <https://doi.org/10.1109/MSNMC61017.2023.10329129> (Індексація: Scopus; *особистий внесок*: удосконалення програмного модуля ГІС до планування місій із урахуванням додаткових умов аерознімання, підготовка презентації і тез, доповідь)

11. Stankevich, S. A., Mosov, S. P., & Saprykin, I. Y. (2023). Landmine detection in farmlands using optical/radar small drones. In *Proceedings of the International Research and Practice Conference “Sustainable Restoration of Agricultural Landscapes affected by Military Activities”* (p. 71). Talkom. <https://doi.org/10.36994/978-966-388-681-7-2023-71> (*особистий внесок*: підготовка та обробка даних з виявлення наземних мін за допомогою глибокого навчання)

12. Stankevich, S. A., Dugin, S. S., Golubov, S. I., & Saprykin, I. Y. (2024). Workflow for landmine detection in aerial imagery with YOLO-based deep

learning. In *Proceedings of the 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Developments (APUAVD)*. IEEE. <https://doi.org/10.1109/APUAVD64488.2024.10765896> (Індексація: Scopus; особистий внесок: участь у аерозйомці реальних мін, підготовка наборів навчальних даних, тренування і тестування нейронних мереж, інтеграція з ГІС, обробка аерозображень для виявлення мін, підготовка презентації і тез, доповідь)

13. Stankevich, S. A., Saprykin, I. Y., Dugin, S. S., & Golubov, S. I. (2025). Transfer learning in YOLO-based landmine detection in aerial imagery. In *Proceedings of the 2025 IEEE 8th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/MSNMC61130.2025.11399716> (Індексація: Scopus; особистий внесок: розробка механізму передавального навчання і тонкого налаштуванням нейромереж, підготовка даних, навчання, тестування виявлення реальних наземних мін на аерозображеннях, узагальнення результатів, підготовка презентації і тез, доповідь)

Свідоцтво про реєстрацію авторського права

14. Станкевич, С. А., Титаренко, О. В., Дугін, С. С., Голубов, С. І., Андреев, А. А., Лисенко, А. Р., Саприкін, Є. Ю., Дьомін, Д. В., Юзефович, В. В., Цибульська, Є. О., та Додонов, Є. О. (2025). *Комп'ютерна програма Геоінформаційна платформа для виявлення і картографування наземних мін та інших вибухонебезпечних предметів за допомогою безпілотних літальних апаратів* [Свідоцтво про реєстрацію авторського права на твір № 133879]. Міністерство економіки України.

Заявка на патент України на винахід

15. Попов, М. О., Станкевич, С. А., Мосов, С. П., Чорний, С. В., Дугін, С. С., Голубов, С. І., Андреев, А. А., та Саприкін, Є. Ю. (2025). *Спосіб*

дистанційного виявлення металевих об'єктів за допомогою магнітометра
(Ukrainian Patent Application No. а202404889). Український інститут
інтелектуальної власності.

ЗМІСТ

ВСТУП	23
Розділ 1	34
АНАЛІЗ МЕТОДІВ ТА ЗАСОБІВ ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ ДАНИХ АЕРОЗНІМАННЯ	34
1.1. Огляд існуючих сенсорів для виявлення малорозмірних компактних об'єктів	34
1.1.1. Оптичні цифрові камери	35
1.1.2. Інфрачервоні камери теплового діапазону	35
1.1.3. Бортові магнітометри БПЛА	37
1.1.4. Георадари та інші сенсори	37
1.2. Огляд існуючих методів виявлення малорозмірних компактних об'єктів	38
1.2.1. Статистичні піксельноорієнтовані методи	38
1.2.2. Згорткові нейромережі	39
1.2.3. Виявлення аномалій	40
1.3. Постановка задачі дослідження	41
Висновки до першого розділу	45
Список використаних джерел	46
Розділ 2	50
РОЗРОБКА МЕТОДІВ ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ КОМПЛЕКСУВАННЯ ДАНИХ АЕРОЗНІМАННЯ РІЗНОЇ ФІЗИЧНОЇ ПРИРОДИ	50
2.1. Використання зображень оптичного діапазону для виявлення компактних об'єктів	51
2.1.1. Згорткові нейронні мережі для виявлення і класифікації об'єктів ..	52
2.1.2. Особливості архітектури згорткових нейронних мереж	53
2.1.3. Застосування трансферного (передавального) навчання (тонкого налаштування)	54
2.2. Використання теплових зображень для виявлення компактних об'єктів методами машинного навчання	57

2.3. Використання даних магнітометрії для виявлення компактних об'єктів	57
2.4. Поєднання даних від сенсорів різної фізичної природи.....	59
Висновки до другого розділу.....	61
Список використаних джерел.....	62
Розділ 3.....	66
РОЗРОБКА МЕТОДИКИ ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ КОМПЛЕКСУВАННЯ ДАНИХ АЕРОЗНІМАННЯ РІЗНОЇ ФІЗИЧНОЇ ПРИРОДИ	66
3.1. Модульна структура методики.....	67
3.2. Аналіз доцільності застосування сенсорів.....	71
3.3. Збір навчальних даних і формування датасетів.....	73
3.4. Трансферне (передавальне) навчання.....	75
3.5. Використання магнітометрії.....	79
3.7. Геоінформаційна платформа	82
Висновки до третього розділу	84
Список використаних джерел.....	85
Розділ 4.....	87
ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ РОЗРОБЛЕНОЇ МЕТОДИКИ ВИЯВЛЕННЯ КОМПАКТНИХ ОБ'ЄКТІВ	87
4.1. Застосування розробленої методики для виявлення мін на аерозображеннях за допомогою згорткових нейронних мереж	87
4.1.1. Навчальний та тестовий датасети	88
4.1.2. Досліджувані архітектури та моделі нейромереж.....	89
4.1.3. Підбір базових датасетів	91
4.1.4. Пошук оптимальних гіперпараметрів і результати тестування на базовому датасеті.....	93
4.1.5. Зміна базового датасету	99
4.1.6. Порівняння результатів виявлення мін	102
4.2. Тестування розробленої методики на реальних аерозображеннях	107

4.2.1. Тестування розробленої методики на RGB аерозображеннях з визначенням класів мін	107
4.2.2. Тестування розробленої методики на RGB аерозображеннях в режимі єдиного класу.....	111
4.3.1. Особливості теплових аерозображень при виявленні мін	113
4.3.2. Результати навчання нейромережі та виявлення мін на теплових зображеннях	114
4.3.3. Комплексування RGB та теплових аерозображень при виявленні мін.....	117
4.3.4. Визначення мінімально прийнятної просторової розрізненності аерознімання для виявлення мін заданих класів	119
4.4. Тестування розробленої методики на реальних магнітометричних даних	121
4.4.1. Особливості виявлення мін за допомогою авіаційної магнітометрії	122
4.4.2. Комплексування магнітометричної та оптичної аерозйомки при виявленні мін.....	124
4.5. Рекомендації щодо впровадження розробленої методики	129
Висновки до четвертого розділу	130
Використані джерела.....	133
ВИСНОВКИ	136
Додаток А.....	141
Додаток Б	142
Додаток В.....	146
Додаток Г	151

ВСТУП

Актуальність теми дослідження. Виявлення і класифікація малорозмірних компактних об'єктів на основі даних аерознімання включають у себе клас актуальних задач, серед яких дедалі більшу роль відіграє виявлення об'єктів засобами БПЛА. Зокрема, в останні роки відбувається розвиток засобів і методів дистанційного виявлення мін та нерозірваних боєприпасів. При цьому актуальними є задачі виявлення як поверхневих, видимих мін, так і підповерхневих, але частка перших збільшується завдяки використанню наземних роботизованих платформ мінування і мінування з БПЛА (Корольов, 2026). Не можна не зазначити, що проблема розмінування останніми роками змінила свій статус – із подолання наслідків давно минулих конфліктів, хоча й жахливих, але локалізованих здебільшого в країнах третього світу, ця проблема перемістилася в центр Європи і набула сучасної загрозливої динаміки. Яскравим прикладом кардинальної зміни ситуації є вихід цілого ряду європейських країн з конвенції про нерозповсюдження протипіхотних мін (Іванова, 2025). Дистанційне виявлення поверхневих і підповерхневих мін завжди вимагало різних підходів, але традиційно у гуманітарному розмінуванні обидві задачі мали бути виконані обов'язково. Тепер же можна вести мову і про сценарії, у яких достатньо детального обстеження поверхні, наприклад, у випадку території, яка ніколи не була під окупацією чи у зоні бойових дій, але могла бути дистанційно мінуваною. Таким чином, постановка задачі окремого виявлення та класифікації поверхневих мін стала ще більш доцільною.

Для виявлення мін у дослідженнях останніх років застосовується цілий спектр різноманітних сенсорів (Baur et al., 2026), що виокремлює їх з-поміж інших об'єктів і зумовлено значною небезпекою та непересічним масштабом

проблеми, зокрема й для України. Насамперед ці сенсори відрізняються фізичним принципом, що лежить в їх основі. Також вони відрізняються станом розвитку, детальністю та інформативністю отриманих даних, доступністю і вибором модифікацій. Що складнішою і актуальнішою є проблема виявлення певного типу об'єктів, то більше різноманіття засобів залучається для її розв'язання, і з'являється більше досліджень. Зокрема, для виявлення мін традиційно застосовується ряд камер і сенсорів, і що важливо – їх комбінацій, через те що жоден сенсор сам по собі не забезпечує стовідсоткової гарантії виявлення.

Оптичні цифрові камери є, без сумніву, найрозвиненішою та найбільш розповсюдженою технологією дистанційного зондування, що використовується з БПЛА (*Baur & Nitsche, 2025*). Оптичні камери наразі можуть забезпечити розрізненність, достатню і навіть інколи надлишкову для виявлення малорозмірних компактних поверхневих об'єктів методами машинного навчання, і вимоги до пошукових задач БПЛА диктуються компромісом між інформативністю та економічною доцільністю. Методи виявлення об'єктів із застосуванням глибокого навчання переважно використовують саме зображення з оптичних камер у видимому діапазоні.

Інфрачервоні камери теплового діапазону є одним із основних типів сенсорів, що використовуються для виявлення мін, і це однаково стосується як поверхневих, так і підповерхневих мін. Для поверхневих мін застосовується весь спектр методів виявлення, включно з методами глибокого навчання; для прихованих мін основними є статистичні методи виявлення аномалій. Для прихованих мін теплові зображення є головним універсальним джерелом інформації; для поверхневих мін вони є допоміжними до зображень видимого діапазону, хоча можуть використовуватися і незалежно (*Nikulin et al., 2018, de Smet et al., 2018, Popov*

et al., 2022, Forero-Ramírez et al., 2022, Bajic & Potocnik, 2023, Шкляр та ін., 2025).

Поточний стан розвитку засобів магнітометрії, що використовуються з БПЛА для виявлення об'єктів, перебуває на стадії, коли ще не затверджені єдині стандарти для зберігання, відображення та обробки магнітометричних даних. Загальні підходи вже визначені, але деталі залежать від виробника магнітометра та розробника методу. Виявлення мін за допомогою бортових магнітометрів БПЛА на сьогодні залишається актуальною дослідницькою задачею, виконання якої, незважаючи на певні успіхи, ще не поставлено на потік. Загалом можна стверджувати, що магнітометри, встановлені на БПЛА, добре зарекомендували себе як засіб виявлення великих мін, що містять значну кількість феромагнетиків, таких як ТМ-62. Водночас дрібні міни або міни з широким застосуванням полімерів та інших немагнітних матеріалів потребують такої відстані до приладу, що умови аерознімання з БПЛА практично неможливі. Отже, бортовий магнітометр БПЛА — корисний, але не універсальний засіб для виявлення мін (Poliachenko et al., 2023; Чорний та ін., 2024).

Значна кількість публікацій присвячена окремим методам виявлення (Popov et al., 2022; Shklyar et al., 2025; Poliachenko et al., 2023; Chorny et al., 2024), але поки що бракує цілісних описів методики, яка була б заснована на комплексуванні результатів аналізу даних різної фізичної природи і включала б організацію процесу машинного (глибокого) навчання.

Окремої уваги заслуговує тема доступності навчальних даних у публічному просторі – вони вже наявні (Binghamton, 2025), однак все ще проблема подолання їх нестачі є актуальною. Дані різних камер і сенсорів представлені нерівномірно. Проблема недостатності публічних наборів даних має два виміри. По-перше, даних бракує для навчання нейронних

мереж, що підвищує поріг входу для нових дослідників, які не мають доступу до даних. По-друге, обмежується можливість порівняння методів виявлення, адже коли публікуються певні показники результативності, але не публікуються набори даних, на яких вони були досягнуті (через те, що дані часто мають статус «для службового використання» у державних установах, і «інтелектуальна власність» у приватних), цінність таких показників для інших дослідників є досить умовною.

Поточний стан галузі дистанційного виявлення мін має таку тенденцію, що після стадії переважно відкритих досліджень наукових установ та ентузіастів (*Demining Research Community, 2020*) відбувається певна комерціалізація, створюються стартапи та приватні компанії (*Safe Pro Group, 2025, UADAMAGE, 2025*), які спеціалізуються на дистанційному виявленні, що лише частково публікують свої досягнення, а деталі реалізації часто стають комерційною таємницею.

Щодо методологічного підходу, одну з новацій можна знайти в статті (*Baur & Nitsche, 2025*), де запропоновано градації дистанційного виявлення об'єкта: *видима аномалія, розпізнавана аномалія та унікальна розпізнавана аномалія*. Підкреслюється, що різні типи даних відрізняються своєю здатністю забезпечувати відповідні градації виявлення об'єктів. У статті (*Baur et al., 2026*) наведено градацію сенсорів у балах за рівнем технологічної готовності: зображенню RGB відповідає бал 9, тепловим зображенням — 8–9, а магнітометрії — 7–8.

Можна констатувати, що серед дослідників вкоренився підхід, за якого сенсори різних фізичних принципів порівнюються й ранжуються за ефективністю за результатами дослідів у певному штучно створеному середовищі. Визнається необхідність поділу задач виявлення поверхневих і прихованих мін, і у той же час вказується на розмитість меж між ними.

Отже, *актуальним науковим завданням* є розробка методики виявлення компактних об'єктів, заснованої на використанні даних різної фізичної природи, одержуваних із БПЛА, а також на методах машинного навчання, адаптованих до відповідних типів даних.

Зв'язок роботи з науковими програмами, планами, темами

Дисертаційна робота виконана в рамках наукових досліджень, що проводились у Державній установі “Науковий центр аерокосмічних досліджень Землі ІГН НАН України” за такою темою:

Розроблення програмно-апаратних засобів дистанційного виявлення вибухонебезпечних предметів за допомогою сенсорів різної фізичної природи та створення прототипу комплексу для картування замінованих територій на основі БПЛА коптерного типу. Шифр НЦАДЗ-2024/1 (№ 0121U000075д) за Цільовою науково-технічною програмою оборонних досліджень НАН України на 2020-2024 рр.

Мета і завдання дослідження. Мета дослідження – підвищення достовірності виявлення і класифікації малорозмірних компактних об'єктів, а саме поверхневих мін, на земній поверхні за матеріалами знімання з БПЛА.

Основним завданням дослідження є розробка методики виявлення компактних об'єктів, заснованої на використанні даних різної фізичної природи, одержуваних із БПЛА, та на методах машинного навчання. Для цього в дослідженні необхідно обґрунтувати вибір набору бортових сенсорів БПЛА, розв'язати проблему недостатності даних для глибокого навчання, забезпечити можливість швидкого донавчання (тонкого налаштування) нейромережі під час розширення навчального набору, реалізувати

комплексування даних різної фізичної природи та кількісно оцінити досягнуте підвищення достовірності.

Для досягнення мети було вирішено низку *часткових наукових завдань дослідження*, а саме:

1) Проведено аналіз методів виявлення і класифікування компактних об'єктів на аерозображеннях, їхніх переваг та недоліків.

2) Проведено аналіз властивостей архітектур нейромереж, що застосовуються для виявлення і класифікування компактних об'єктів, здійснено вибір архітектури.

3) Проведено аналіз властивостей доступних навчальних наборів зображень (датасетів) загального користування та цільових.

4) Оцінено можливості використання попередньо навчених нейромереж разом з донавчанням на обмежених наборах даних.

5) Створено дослідні набори даних різної фізичної природи – оптичні, теплові, магнітометричні.

6) Розроблено методику, що використовує згорткові нейромережі сучасної архітектури, набори даних загального користування, обмежені цільові набори даних і комплексні ймовірнісні результати обробки даних різної фізичної природи.

7) Експериментально перевірено розроблену методику, порівняно досягнуту достовірність виявлення малорозмірних компактних об'єктів з відомими методами.

8) Надано рекомендації щодо можливостей і сфер подальшого використання розробленої методики.

Методи дослідження. Для вирішення поставлених завдань використовувалися:

- геометрична оптика та теорія переносу електромагнітного випромінювання – для визначення необхідних параметрів польоту БПЛА.
- методи глибокого навчання із застосуванням згорткових нейронних мереж архітектури YOLO – для навчання на базі власноруч створених датасетів RGB та теплових зображень мін;
- методи передавального навчання (*transfer learning*) і тонкого налаштування (*fine tuning*) – для донавчання (тонкого налаштування) нейромереж, навчених на базі великих датасетів загального користування;
- методи прискореного навчання (*few-shot learning*) – для оптимізації часу донавчання, яке має виконуватись періодично при поповненні навчальних даних;
- методи статистичного виявлення аномалій – для виявлення компактних об'єктів на теплових аерозображеннях і за результатами обробки магнітометричних даних;
- Байєсівське злиття ймовірностей – для комбінування ймовірнісних результатів виявлення компактних об'єктів.
- математична статистика – для обробки результатів експериментальних вимірювань і оцінки показників достовірності виявлення компактних об'єктів.

Наукова новизна одержаних результатів полягає у наступному:

Вперше розроблено методику виявлення малорозмірних компактних об'єктів на основі комплексування даних аерознімання різної фізичної природи. Методика використовує раціональний набір сучасних методів машинного та глибокого навчання для виявлення мін, розташованих на

земній поверхні, за даними звичайного RGB-аерознімання, аерознімання в інфрачервоному тепловому діапазоні та авіаційної магнітометрії. Передбачається, що всі датчики, залучені в межах методики, розташовуються на борту кількох легких БПЛА коптерного типу. Видові дані аерознімання аналізуються адаптованими до їх різновидів нейромережами, а магнітометричні вимірювання – шляхом статистичного виявлення аномалії сигналу магнітометра над магнітним фоном. Виконується статистичне злиття ймовірностей виявлення цільових об'єктів, що забезпечує підвищення результуючої достовірності їх виявлення. Взаємодія всіх задіяних апаратних і програмних засобів здійснюється в межах єдиної геоінформаційної платформи, архітектуру якої обґрунтовано. Застосування розробленої методики забезпечує можливість виявлення мін на аерозображеннях видимого діапазону за допомогою згорткових нейромереж із показниками повноти $R = 1$ та $mAP50 = 0,983$, та впевнене підвищення достовірності у складних умовах виявлення до 0,8 при комплексуванні результатів сенсорів різної фізичної природи.

Удосконалено модель донавчання згорткової нейромережі з урахуванням особливостей мін як об'єктів виявлення, а саме: з урахуванням ступеня представлення розпізнавальних ознак цільових об'єктів у шарах основи базової пренавченої нейромережі (що залежить від вибору базового датасету), трансферне навчання пренавченої нейромережі відбувається із попередньо підібраними оптимальними значеннями таких гіперпараметрів, як кількість незмінних шарів основи та кількість епох донавчання. Таке удосконалення моделі донавчання дозволило покращити достовірність виявлення мін на аерозображеннях, що характеризується збільшенням показника $mAP50$ з 0,316 до 0,983 за тих самих базового та цільового датасетів.

Подальшого розвитку набуло статистичне виявлення об'єктів на аерокосмічних зображеннях. Експериментальним шляхом визначено кількість пікселів, достатню для впевненого виявлення компактного об'єкта нейромережею архітектури YOLO. Результат адаптовано для виявлення поверхневих мін різної форми. Визначення потрібної піксельної розрізненності дозволяє більш ґрунтовно визначати параметри польоту БПЛА при виявленні поверхневих мін за допомогою різних бортових сенсорів, і тим самим підвищити загальну продуктивність аерознімання при збереженні достовірності.

Практичне значення отриманих результатів.

За результатами експериментальних досліджень розроблена методика продемонструвала можливість досягнення для нейромережі архітектури YOLO показника **повноти** (*recall*) виявлення мін, рівного 1, для аерозображень, отриманих з висоти польоту БПЛА 10 м, і показника *mAP50* 0,994 для виявлення і класифікації мін. Для комплексування результатів різних сенсорів, а саме – аерозображень видимого діапазону, теплових аерозображень і магнітометричних даних, продемонстровано можливість покращення достовірності в складних випадках у середньому з 0,2 до 0,8. Досягнуто можливості донавчання детектора із середньою кількістю навчальних епох 23, що дає змогу швидко розширити набір об'єктів виявлення і класифікації. Обґрунтовано архітектуру єдиної геоінформаційної платформи для підтримки наскрізного процесу виявлення мін з БПЛА. Створено власні датасети RGB та теплових аерозображень реальних мін, натреновано набір нейромереж із широким спектром варіацій кількості епох і фіксації шарів.

Апробація матеріалів дисертації. Попередні результати дисертаційного дослідження та основні теоретичні і методичні аспекти були представлені та обговорені на наступних конференціях: конференції «TIEMS 2023 Annual Conference» Порт-Алфред, Південна Африка, вересень 2023 р. (онлайн); міжнародній науковій конференції «IEEE 7th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)», Київ, жовтень 2023; конференції “Sustainable Restoration of Agricultural Landscapes affected by Military Activities” Київ, вересень-жовтень 2023, online; міжнародній науковій конференції «2024 IEEE 7th International Conference on actual problems of unmanned aerial vehicles developments (APUAVD)», Київ, жовтень 2024; міжнародній науковій конференції «2025 IEEE 8th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)», Київ, жовтень 2025.

Особистий внесок здобувача. Основні результати роботи одержано автором особисто. Результати співпраці з колегами та спеціалістами інших наукових галузей відображено в спільних наукових публікаціях.

В Додатку Б представлено публікації, на яких базується розроблена методика виявлення малорозмірних компактних об’єктів на основі комплексування даних аерознімання різної фізичної природи.

За результатами досліджень опубліковано 7 статей, з них 4 – статті у наукових виданнях, включених на дату опублікування до переліку наукових фахових видань України категорій А і Б, і 3 у міжнародних виданнях, індексованих Scopus, 4 тези міжнародних конференцій, з них 3 індексовані Scopus.

Проведені автором аналіз існуючих методів виявлення об’єктів, методів глибокого навчання, подолання недостатності навчальних даних,

комплексування результатів різних методів, планування дослідних польотів БПЛА, розглянуто в роботах, перелічених у Додатку Б.

Зокрема, методи глибокого навчання, передавального навчання, подолання дефіциту навчальних даних і оптимізації процесу навчання мереж розглянуто у Б2, Б9, Б13, Б14. Методи злиття результатів сенсорів різної фізичної природи розглянуто у Б4, Б13, Б14. Планування дослідних польотів БПЛА та інтеграція з ГІС описані у Б3, Б11, Б12. Особливості використання оптичних зображень описано у Б1, Б2, Б5, Б6, Б8, Б11, Б12, Б13, Б14; особливості використання теплових зображень описано у Б7, Б9, Б13, Б14, особливості використання магнітометричних даних описано у Б4, Б9, Б14.

Структура і обсяг дисертації

Дисертація складається зі вступу, чотирьох розділів, висновків, переліку використаних джерел (76 найменувань на 10 сторінках) та 4 додатків на 11 сторінках. Робота викладена на 140 сторінках, що містять 90 сторінок основного тексту, 36 рисунків і 11 таблиць.

РОЗДІЛ 1

АНАЛІЗ МЕТОДІВ ТА ЗАСОБІВ ВІЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ ДАНИХ АЕРОЗНІМАННЯ

Виявлення і класифікація малорозмірних компактних об'єктів на основі даних аерознімання включають у себе цілий клас актуальних задач, серед яких дедалі більшу роль відіграє виявлення об'єктів засобами БПЛА. Зокрема, в останні роки відбувається розвиток засобів і методів дистанційного виявлення мін і нерозірваних боєприпасів. При цьому актуальними є задачі виявлення як поверхневих, видимих мін, так і підповерхневих, але частка перших збільшується завдяки використанню роботизованих платформ для мінування. Також регулярно з'являються нові різновиди мін та інших боєприпасів. Для виявлення мін традиційно застосовується цілий спектр різноманітних сенсорів, що робить їх унікальними з-поміж інших об'єктів і зумовлено значною небезпекою та непересічним масштабом проблеми, зокрема для України.

1.1. Огляд існуючих сенсорів для виявлення малорозмірних компактних об'єктів

Останнім часом набули стрімкого розвитку найрізноманітніші сенсори, що використовуються з БПЛА. Насамперед вони відрізняються фізичним принципом, що лежить в основі. Також вони відрізняються станом розвитку, детальністю та інформативністю отриманих даних, доступністю і вибором модифікацій. Що складнішою і актуальнішою є проблема виявлення певного типу об'єктів, то більше різноманіття засобів залучається для її розв'язання, і з'являється більше досліджень. Зокрема, для виявлення мін традиційно

застосовується ряд камер і сенсорів, і що важливо – їх комбінацій, через те що жоден сенсор сам по собі не забезпечує стовідсоткової гарантії виявлення.

1.1.1. Оптичні цифрові камери

Оптичні цифрові камери є, без сумніву, найрозвиненішою та найбільш розповсюдженою технологією дистанційного зондування, що використовується з БПЛА. Оптичні камери наразі можуть забезпечити розрізненість, достатню і навіть інколи надлишкову для виявлення малорозмірних компактних поверхневих об'єктів методами машинного навчання, і вимоги до пошукових задач БПЛА диктуються компромісом між інформативністю та економічною доцільністю.

Методи виявлення об'єктів із застосуванням глибокого навчання переважно використовують саме зображення, отримані з оптичних камер у видимому діапазоні.

1.1.2. Інфрачервоні камери теплового діапазону

Інфрачервоні камери теплового діапазону є одним із основних типів сенсорів, що використовуються для виявлення мін, і це однаково стосується як поверхневих, так і підповерхневих мін. Для поверхневих мін застосовується весь спектр методів виявлення, включно з методами глибокого навчання; для прихованих мін основними є статистичні методи виявлення аномалій. Для прихованих мін теплові зображення є головним універсальним джерелом інформації; для поверхневих мін вони є допоміжним джерелом інформації до зображень у видимому діапазоні, хоча можуть використовуватися й самостійно.

На початку досліджень щодо використання теплових зображень, одержуваних з БПЛА, фокус був на визначенні меж можливості виявлення

малорозмірних компактних об'єктів, на режимі знімання і фізичних параметрах польоту БПЛА у таких дослідженнях (Nikulin et al., 2018, de Smet et al., 2018), згодом стали розглядатися і застосовуватися методи виявлення та класифікації об'єктів на таких зображеннях (Popov et al., 2022, Forero-Ramírez et al., 2022).

Існують дослідження, які стверджують, що теплові зображення мають меншу інформаційну цінність пікселя (*value per pixel*) для задачі виявлення об'єктів на прикладі мін та нерозірваних боєприпасів (Baur & Nitsche, 2025). Ці результати відображають загальну тенденцію, не враховуючи можливих умов середовища, що погіршують виявлення об'єктів, таких як заглиблення, часткове покриття рослинністю, камуфлювання, маскування або використання муляжів. Якщо додати до цих аргументів широке розповсюдження недорогих інфрачервоних камер на мікроболометричних фотоприймачах, то використання теплових зображень як додаткового джерела інформації стає цілком виправданим.

Як і у випадку із зображеннями видимого діапазону, з тепловими зображеннями можуть бути використані як піксельно-орієнтовані, так і об'єктно-орієнтовані методи виявлення та класифікації об'єктів. Хоча для більш наочної візуалізації використовуються різні схеми колоризації, фактично пікселі каліброваних теплових зображень містять вимірювання температури. Відповідно, піксельно-орієнтовані методи виявлення зводяться до пошуку аномалій, що є цілком робочим методом у випадку, коли класифікація не так важлива (Shklyar et al., 2025). Водночас і методи глибокого навчання показують задовільний результат як для класифікації, так і для виявлення в режимі єдиного класу (Bajic & Potocnik, 2023).

1.1.3. Бортові магнітометри БПЛА

Поточний стан розвитку засобів магнітометрії, що використовуються з БПЛА для виявлення об'єктів, перебуває на стадії, коли ще не затверджені єдині стандарти для зберігання, відображення та обробки магнітометричних даних. Загальні підходи вже визначені, але деталі залежать від виробника магнітометра та розробника методу. Виявлення мін за допомогою бортових магнітометрів БПЛА на сьогоднішній день залишається актуальною дослідницькою задачею, виконання якої, незважаючи на певні успіхи, ще не поставлене на потік.

Поширеною на сьогоднішній день є ситуація, коли виробник магнітометра реалізує лише генерацію потоку даних вимірювань без прив'язки до координат і часу, а задача збереження та синхронізації даних покладається на користувачів приладу (Чорний та ін., 2024). Більш досконалі моделі мають вбудовану пам'ять для збереження вимірів із прив'язкою до координат (Poliachenko et al., 2023).

Загалом можна стверджувати, що магнітометри, встановлені на БПЛА, добре зарекомендували себе як засіб виявлення великих мін, що містять значну кількість феромагнетиків, таких як ТМ-62. Водночас дрібні міни або міни з широким застосуванням полімерів та інших немагнітних матеріалів потребують такої відстані до приладу, що умови аерознімання з БПЛА практично неможливі. Отже, бортовий магнітометр БПЛА – корисний, але не універсальний засіб для виявлення мін.

1.1.4. Георадари та інші сенсори

Для комбінованої задачі виявлення поверхневих і підповерхневих мін є сенс розглядати ширший набір сенсорів, у тому числі активних, таких як георадар. Однак якщо йдеться про поверхневі міни, то решта сенсорів поступається RGB, тепловому зображенню та магнітометрії (Baur et al., 2026)

за абсолютними показниками і значно — за співвідношенням ціна-користь, тому в цьому дослідженні вони не розглядаються.

1.2. Огляд існуючих методів виявлення малорозмірних компактних об'єктів

Сучасні методи виявлення пройшли значний шлях розвитку й варіюються в межах від статистичного виявлення аномалій до визначення конкретного унікального підвиду об'єктів за допомогою методів глибокого навчання (Hutsul et al., 2024; Baur et al., 2026). Можливість застосування тих чи інших методів суттєво варіюється залежно від типу даних і фізичного принципу їх отримання. Наявність впізнаваних сигнатур робить можливим застосування глибокого навчання із використанням нейромереж не тільки для виявлення, а й для класифікації. Втім, що складніший і вибагливіший до ресурсів метод, то більш обґрунтованим має бути його вибір порівняно з простішими методами.

1.2.1. Статистичні піксельно-орієнтовані методи

Піксельно-орієнтований підхід успішно застосовувався для виявлення мін (Porov et al., 2022), як поверхневих, так і прихованих. Універсальність і простота є його перевагами, але його інформативність нижча, оскільки він не виявляє рис об'єктів, а використовує лише інформацію про колір і яскравість пікселів. Навчальні дані для цих методів також обмежуються значеннями пікселів. Можливості цих методів зростають у разі використання багатоспектральних або гіперспектральних даних завдяки визначенню більш впізнаваних спектральних сигнатур.

Застосування гіперспектральних даних є доволі перспективним (Sineglazov & Lesohorskyi, 2024) – безперервний набір значень у широкому діапазоні довжин хвиль безперечно містить більше характерних ознак, ніж

три RGB-канали звичайних кольорових зображень чи 4–6 робочих каналів багатоспектральних камер, що встановлюються на БПЛА. Але натомість зменшується просторова розрізненість гіперспектрального аерознімання, а система обробки та аналізу даних дорожчає. Проблемою є також відсутність навчальних датасетів гіперспектральних даних для нішевих завдань, як-от виявлення мін.

Отже, доходимо висновку, що, вивчаючи можливість використання зображень оптичного діапазону, слід насамперед зосередитись на використанні RGB-зображень і, після досягнення задовільного результату, за потреби вдаватись до використання інших типів зображень.

1.2.2. Згорткові нейромережі

Для виявлення компактних об'єктів, яким притаманні роздільні впізнавані ознаки, а не аморфний набір пікселів, все ж слід віддати перевагу об'єктно-орієнтованим методам, що виявляють ці ознаки. На початкових стадіях розвитку для цього використовувалися методи, які у деяких джерелах згадуються як методи *першого покоління комп'ютерного зору* (Chris et al., 2025). Наразі в цій царині домінують методи глибокого навчання, що застосовують згорткові нейронні мережі.

Історично першою архітектурою нейромереж, застосованою для задачі виявлення мін на зображеннях з БПЛА, була *R-CNN*, зокрема її варіації *Fast R-CNN* та *Faster R-CNN* (Ren et al., 2017). Вона була застосована для виявлення протипіхотних мін ПФМ1 “Пелюсток” (Baur et al., 2023). На момент проведення згаданого дослідження ця архітектура продемонструвала найкращі показники точності. Особливістю її є виявлення аналізу зображення у два етапи: спершу — формування потенційних ділянок знаходження об'єкта, а в подальшому — класифікація відповідних фрагментів зображення.

Досить швидко конкуренцію R-CNN склала архітектура YOLO (Redmon et al., 2016). Її перевага в тому, що задача розпізнавання зображення виконується за один етап, що значно підвищує швидкість роботи та знижує вимоги до обчислювальних ресурсів. Щоправда, у ранніх версіях архітектура YOLO поступалася R-CNN у точності, що й відображено у згаданому дослідженні щодо ПФМ1. У подальших версіях недоліки було подолано (Jegham et al., 2024), і на сьогоднішній день YOLO є де-факто стандартом для виявлення і класифікації об'єктів на зображеннях оптичного діапазону. Останнім часом найбільше різноманітних рішень розробляється на базі версій YOLOv8 (Jocher, 2023) та YOLOv11 (Jocher & Qiu, 2024).

1.2.3. Виявлення аномалій

Використання згорткових нейромереж для виявлення об'єктів на кольоровій мапі візуалізації магнітного поля (Barnawi et al., 2023) є перспективним, але очевидно, що на даний час ті самі або близькі результати можуть бути досягнуті статистичним виявленням аномалій із суттєво меншими обчислювальними витратами. Теоретично, є потенціал для виявлення впізнаваних сигнатур конкретних об'єктів, але, беручи до уваги стан розвитку тих технічних засобів, які доступні для широкого використання, доцільність застосування глибокого навчання для аналізу магнітометричних даних поки що викликає сумніви.

Отже, можна констатувати, що для магнітометричних даних доцільним є застосування статистичних методів виявлення аномалій (Rousseeuw & Hubert, 2018). Наприклад, RX-алгоритм (Kwon & Nasrabadi, 2005)

1.3. Постановка задачі дослідження

Згідно з проведеним аналізом статистичних методів виявлення об'єктів на аерозображеннях, вони поділяються на попиксельні методи класифікування, результатом роботи яких є поділ усіх пікселів зображення на об'єкт і фон шляхом встановлення певної порогової ймовірності, і методи виявлення та/або сегментації, результатом роботи яких є оцінка ймовірності наявності цілісного (зв'язного) об'єкта у певній області, прямокутній чи складнішої форми. Є підстави вважати, що досягнуті результати у попиксельних методах зараз близькі до гранично можливих, і на даний час більш перспективними для виявлення компактних об'єктів на аерозображеннях є методи глибокого навчання із застосуванням нейронних мереж, що виконують такі задачі, як класифікація, виявлення об'єктів та сегментація. Серед відомих архітектур нейромереж для виявлення об'єктів на даний час оптимальними за співвідношенням обчислювальних ресурсів і показників якості є *згорткові* нейронні мережі (CNN), що одночасно виконують задачу виявлення і класифікації. Отже, доцільно вивчити можливість застосування цих методів для виявлення малорозмірних компактних об'єктів на основі аерознімання з БПЛА в умовах обмеження наявного обсягу навчальних даних для конкретних задач *на прикладі виявлення поверхневих наземних мін.*

Навчальними даними для цих методів є набори зображень зі сталим розміром із зазначеними координатами міток об'єктів. Результатом виявлення і класифікації є мітки із зазначенням класу об'єкта та оціночного ступеня вірогідності (правдоподібності) класифікації.

Сучасний розвиток засобів дистанційного зондування Землі (ДЗЗ) передбачає можливість використання даних від сенсорів різної фізичної природи – оптичних видимого діапазону, інфрачервоних, магнітометричних,

радіолокаційних тощо – і з огляду на це варто оцінити переваги комбінування даних цих сенсорів для виявлення компактних об'єктів на земній поверхні. Відомі методи аналізу даних різної фізичної природи також суттєво відрізняються між собою, що впливатиме на вибір підходу до обробки кожного із застосованих типів даних, а також на принцип їх інтеграції.

Доцільно розділити задачі виявлення поверхневих і прихованих під поверхнею об'єктів з огляду на те, що кардинально різною для цих типів задач є роль оптичних зображень (основна — для поверхневих і допоміжна — для прихованих), а відповідно — і доцільність застосування методів глибокого навчання. Тож у цій роботі вирішено зосередитися на виявленні поверхневих об'єктів.

Метою дисертаційного дослідження є підвищення достовірності виявлення і класифікації малорозмірних компактних об'єктів на земній поверхні за матеріалами знімання з БПЛА, а саме — покращення кількісних показників точності *та/або розширення умов, за яких таке виявлення можливе.*

Завданнями дослідження є розробка методики виявлення компактних об'єктів, заснованої на використанні даних різної фізичної природи, одержуваних з БПЛА, і методах машинного навчання. Для цього у дослідженні необхідно обґрунтувати обрання набору бортових сенсорів БПЛА, розв'язати проблему недостатності даних для глибокого навчання, забезпечити можливість швидкого донавчання (тонкого налаштування) нейромережі при розширенні навчального набору, реалізувати комплексування даних різної фізичної природи та кількісно оцінити досягнуте підвищення достовірності.

Для оцінювання достовірності виявлення доцільно використовувати загальноприйнятні показники (Naidu et al., 2023), такі як точність (*precision*)

P (1), чутливість (*recall*) R (2), узагальнена середня точність (*mean average precision*) mAP . Для різних задач значимість показників варіюється, зокрема показник чутливості (*recall*) є найголовнішим у випадку виявлення мін, оскільки ціна невиявленої міни незрівнянно вища за ціну хибної тривоги. Формули, за якими розраховуються показники, наступні:

$$P = \frac{TP}{FP+TP} \quad (1)$$

де TP (*true positives*) – кількість знайдених реально існуючих цілей, FP (*false positives*) – кількість помилкових визначень,

$$R = \frac{TP}{FN+TP} \quad (2)$$

де FN (*false negatives*) – кількість цілей, що не виявлено;

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

де AP розраховується як площа під кривою *precision–recall* для кожного класу об'єктів.

Ці показники доцільно визначати для кожного з класів об'єктів, що розглядаються, і для кожного діапазону просторової розрізненності, притаманного вирішуваним завданням. Для цього треба розробити підхід до оцінки ефективності виявлення об'єктів, що пов'язує наявний навчальний набір даних, гіперпараметри нейромережі і просторову розрізненність досліджуваного зображення, подаючи показники ефективності у вигляді багатовимірного масиву (куба), що має спростити і формалізувати оцінку меж застосування конкретної навченої нейромережі.

Діапазон просторової розрізненності має варіюватися від найкращого, за якого об'єкти легко розрізняються людським оком, до такого, що відповідає максимальній висоті аерознімання, з якої ще забезпечується потрібна достовірність виявлення.

У якості можливих шляхів *підвищення достовірності* виявлення малорозмірних компактних об'єктів розглядається:

1) Покращення ефективності використання нейромереж і методів глибокого навчання шляхом застосування методів *передавального навчання* (transfer learning), *тонкого налаштування* (fine tuning), *мінімального навчання* (few-shot learning), *нарощування даних* (data augmentation), і врахування спорідненості великих наборів даних загального користування (для попереднього навчання) і цільового сегменту обмеженого обсягу.

2) Комплексування результатів виявлення об'єктів на оптичних зображеннях видимого та теплого діапазонів із застосуванням нейромереж, а також їх комплексування із даними, отриманими з сенсорів інших фізичних принципів дії методами виявлення аномалій, результат роботи яких також має ймовірнісну природу, з представленням кінцевого результату як координат мітки із результируючою ймовірністю;

Для досягнення мети потрібно виконати низку *часткових наукових завдань дослідження*, а саме:

1) Провести аналіз методів виявлення й класифікації компактних об'єктів на аерозображеннях, а також їхніх переваг і недоліків.

2) Провести аналіз властивостей архітектур нейромереж, що застосовуються для виявлення і класифікування компактних об'єктів, здійснити вибір архітектури.

3) Провести аналіз властивостей доступних навчальних наборів зображень загального користування та цільових.

4) Оцінити можливості використання попередньо навчених мереж разом з донавчанням на обмежених наборах даних.

5) Створити дослідні набори даних різної фізичної природи – оптичні, теплові, магнітометричні.

6) Розробити методику, що використовує сучасні архітектури нейромереж, набори даних загального користування, обмежені цільові набори даних і комплексує ймовірнісний результат, отриманий з обробки даних різної фізичної природи.

7) Експериментально перевірити розроблену методику, порівнявши досягнуту достовірність виявлення малорозмірних компактних об'єктів з відомими методами.

8) Надати рекомендації щодо можливостей і сфер подальшого використання розробленої методики.

Висновки до першого розділу

1. Проведений аналіз методів виявлення мін показав, що жоден з методів, заснованих на одному фізичному принципі, не забезпечує задовільної достовірності виявлення поверхневих мін.
2. Бортові сенсори БПЛА, засновані на різних фізичних принципах, суттєво відрізняються типами та характеристиками одержуваних даних, тож варто обирати методи, найбільш пристосовані для обробки різних типів даних.
3. Дефіцит навчальних даних притаманний більшості спеціалізованих задач глибокого навчання, тому подолання цього дефіциту є невід'ємною частиною розробки методик виявлення та класифікації об'єктів за допомогою глибокого навчання.
4. Успіх технології виявлення мін залежить від здатності до масштабування, адже проблема виявлення мін має глобальний характер і повинна вирішуватися методами, здатними масштабуватися на рівень регіону чи країни. Для цього повинні

використовуватися стандартні комерційні апаратні засоби і, бажано, вільно розповсюджуване програмне забезпечення.

Список використаних джерел

- Bajić, M., Jr., & Potočnik, B. (2023). UAV thermal imaging for unexploded ordnance detection by using deep learning. *Remote Sensing*, 15(4), Article 967. <https://doi.org/10.3390/rs15040967>
- Barnawi, A., Kumar, K., Kumar, N., Alzahrani, B., & Almansour, A. (2024). A deep learning approach for landmines detection based on airborne magnetometry imaging and edge computing. *CMES-Computer Modeling in Engineering & Sciences*, 139(2), 2117–2137. <https://doi.org/10.32604/cmes.2023.044184>
- Baur, J., & Nitsche, F. (2025). A false-positive-centric framework for object detection disambiguation. *Remote Sensing*, 17, Article 2429. <https://doi.org/10.3390/rs17142429>
- Baur, J., Steinberg, G., Nikulin, A., Chiu, K., & Smet, T. (2020). Applying deep learning to automate UAV-based detection of scatterable landmines. *Remote Sensing*, 12(5), Article 859. <https://doi.org/10.3390/rs12050859>
- Chorny, S., Dugin, S., Stankevich, S., Popov, M., & Golubov, S. (2024). Prototype of a UAV-borne magnetometer for landmine detection. *Ukrainian Journal of Remote Sensing*, 11(3), 26–30. <https://doi.org/10.36023/ujrs.2024.11.3.269>
- Chris, E., Johnson, K., & Allison, J. (2025). *The evolution of computer vision: From pixels to perception*.
- De Smet, T., Nikulin, A., Frazer, W., Baur, J., Abramowitz, J., Finan, D., Denara, S., Aglietti, N., & Campos, G. (2018). Drones and "butterflies": A low-cost UAV system for rapid detection and identification of unconventional minefields. *The*

- Journal of Conventional Weapons Destruction*, 22(3), Article 10.
<https://commons.lib.jmu.edu/cisr-journal/vol22/iss3/10>
- Forero-Ramírez, J. C., García, B., Tenorio-Tamayo, H. A., Restrepo-Girón, A. D., Loaiza-Correa, H., Nope-Rodríguez, S. E., Barandica-López, A., & Buitrago-Molina, J. T. (2022). Detection of “legbreaker” antipersonnel landmines by analysis of aerial thermographic images of the soil. *Infrared Physics & Technology*, 125, Article 104307. <https://doi.org/10.1016/j.infrared.2022.104307>
- Jegham, N., Koh, C. Y., Abdelatti, M., & Hendawi, A. (2025). *YOLO evolution: A comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions* (arXiv:2411.00201). arXiv.
<https://doi.org/10.48550/arXiv.2411.00201>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *YOLO by Ultralytics* (Version 8.0) [Computer software]. GitHub. github.com
- Jocher, G., Qiu, J., & Chaurasia, A. (2024). Ultralytics YOLO11 (Version 11.0) [Computer software]. GitHub. github.com
- Kwon, H., & Nasrabadi, N. M. (2005). Kernel RX-algorithm: A nonlinear anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 43(2), 388–397. <https://doi.org/10.1109/TGRS.2004.841487>
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A review of evaluation metrics in machine learning algorithms. In R. Silhavy & P. Silhavy (Eds.), *Artificial intelligence application in networks and systems* (Vol. 724, pp. 15–25). Springer.
https://doi.org/10.1007/978-3-031-35314-7_2
- Nikulin, A., De Smet, T. S., Baur, J., Frazer, W. D., & Abramowitz, J. C. (2018). Detection and identification of remnant PFM-1 ‘Butterfly Mines’ with a UAV-based thermal-imaging protocol. *Remote Sensing*, 10(11), Article 1672.
<https://doi.org/10.3390/rs10111672>

- Poliachenko, I., Kozak, V., Bakhmutov, V., Cherkes, S., & Varava, I. (2023). Preliminary results of UAV magnetic surveys for unexploded ordnance detection in Ukraine: Effectiveness and challenges. *Geophysical Journal*, 45(5), 126–140. <https://doi.org/10.24028/gj.v45i5.289117>
- Popov, M. O., Stankevich, S. A., Mosov, S. P., Titarenko, O. V., Dugin, S. S., Golubov, S. I., & Andreiev, A. A. (2022). Method for minefields mapping by imagery from unmanned aerial vehicle. *Advances in Military Technology*, 17(2), 211–229. <https://doi.org/10.3849/aimt.01722>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *YOLO: You Only Look Once: Unified, real-time object detection* (arXiv:1506.02640). arXiv. <https://doi.org/10.48550/arXiv.1506.02640>
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Rousseeuw, P., & Hubert, M. (2018). Anomaly detection by robust statistics. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(2), Article e1236. <https://doi.org/10.1002/widm.1236>
- Shklyar, S., Andreiev, A., & Golubov, S. (2025). Accuracy assessment of landmine detection by infrared aerial imaging. *Ukrainian Journal of Remote Sensing*, 12(4), 16–20. <https://doi.org/10.36023/ujrs.2025.12.4.294>
- Sineglazov, V., & Lesohorskyi, K. (2024). Application of unmanned aerial vehicles for landmine detection and classification using hyperspectral imagery. In *Proceedings of the 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD)* (pp. 224–227). IEEE. <https://doi.org/10.1109/APUAVD64488.2024.10765909>

РОЗДІЛ 2

РОЗРОБКА МЕТОДІВ ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ КОМПЛЕКСУВАННЯ ДАНИХ АЕРОЗНІМАННЯ РІЗНОЇ ФІЗИЧНОЇ ПРИРОДИ

Задача автоматизованого виявлення об'єктів на основі даних аерознімання полягає у створенні карти ймовірностей наявності об'єктів. Дані різної фізичної природи потребують різного підходу – для частини кращий результат дає контрольоване класифікування, що дає змогу отримати з певною достовірністю інформацію про клас об'єкта; для деяких можливе лише виявлення аномалій, що свідчать про наявність об'єктів, не притаманних даному середовищу.

Під час вирішення конкретних практичних задач із виявлення зазвичай розробники мають справу з об'єктами, об'єднаними спільними фізичними властивостями і походженням, і у більшості випадків розташованими у певному середовищі, чим обумовлюється обмежений перелік сенсорів, які доцільно використовувати. До кожного з типів даних, отриманих від сенсорів, доцільно застосовувати певні методи виявлення та класифікування об'єктів, в залежності від стану розвитку методів обробки саме таких даних і якості доступних сенсорів. Визначення конкретного набору типів даних і методів їх обробки для цільових об'єктів із їхніми конкретними особливостями є першим завданням під час розробки комплексних методів виявлення. Враховуючи динаміку технічного прогресу, такий набір може змінюватися протягом років.

Для поверхневих об'єктів земної поверхні пріоритетним типом даних є зображення в оптичному діапазоні. До них можуть бути застосовані як методи класифікації, що працюють з окремими пікселями, так і методи, що

виявляють і аналізують певні розпізнавальні ознаки зображень. Такими, зокрема, є методи глибокого навчання, що використовують згорткові нейронні мережі (CNN) (Issaoui et al., 2024). Серед даних аерознімання вони передусім можуть бути застосовані до звичайних кольорових (RGB), багатоспектральних та інфрачервоних (теплових) зображень. Методи, що працюють з окремими пікселями, дозволяють створити карту ймовірностей знаходження об'єктів чи аномалій, методи глибокого навчання дозволяють визначати місцезнаходження об'єктів конкретних класів також з вказанням їх ймовірностей.

Стан розвитку методів глибокого навчання та комп'ютерного зору такий, що предметом дослідження виступає не сама можливість виявлення об'єктів, а вибір архітектур нейронних мереж, практичні питання організації навчання нейронних мереж за наявності обмежених обсягів навчальних даних у застосуванні до конкретної практичної задачі.

2.1. Використання зображень оптичного діапазону для виявлення компактних об'єктів

Методи класифікації зображень для визначення об'єктів базуються на двох основних підходах — піксельно-орієнтованому та об'єктно-орієнтованому. Перший полягає в незалежній класифікації окремих пікселів виключно за їх радіометричними властивостями і безпосередньо від них переходить до таких похідних задач, як виявлення (detection) і сегментація; другий же досліджує зображення як ієрархію розпізнавальних ознак.

Саме такий принцип реалізують CNN. Багато сучасних досліджень повідомляють про перевагу згорткових нейромереж у задачі виявлення компактних об'єктів складної форми (Xiao et al., 2025).

2.1.1. Згорткові нейронні мережі для виявлення і класифікації об'єктів

На сьогоднішній день згорткові нейронні мережі (*convolutional neural networks*, далі — *CNN*) є де-факто стандартом у класифікації об'єктів на зображеннях. Для цього також використовуються мережі на базі трансформерів і механізму уваги (Vaswani et al., 2017, Dosovitskiy et al., 2021), але їхньою сильною стороною є здатність розпізнавати загальний контекст зображення, а вимоги до кількості навчальних даних переважають вимоги до згорткових мереж (Deining et al., 2022). Саме для архітектур на базі CNN притаманний підхід, за якого розпізнавальні ознаки зображення “збираються” від найпростіших до більш складних. Тому для виявлення компактних об'єктів, до того ж із обмеженими навчальними даними, згорткові мережі підходять краще.

Згорткові нейромережі у роботі з двовимірними даними вигідно відрізняються своєю продуктивністю від повнозв'язних мереж завдяки використанню таких прийомів, як *розподіжені взаємодії* (*sparse interactions*), *спільне використання параметрів* (*parameter sharing*) та *еквіваріантні представлення* (*equivariant representations*) (Goodfellow et al., 2016). Не буде перебільшенням стверджувати, що саме згорткові нейромережі відкрили шлях до практичного застосування нейромереж у аналізі зображень.

Стосовно функцій, які можуть виконувати нейромережі щодо об'єктів на зображеннях, виділяють класифікацію, виявлення (*detection*) і сегментацію, семантичну (*semantic*) і пооб'єктну (*instance*) (Zhang et al., 2023). Значення термінів у цьому контексті відрізняються від відповідних, вживаних стосовно піксельно-орієнтованих методів. Класифікація означає тут не просто віднесення пікселів до певного класу, а віднесення до певних класів виділених фрагментів або всього зображення. Сегментація також означає

знаходження контурів, а не областей однотипних пікселів, тобто цілісних об'єктів відомого класу. Задача ж виявлення полягає в геометричному обмеженні області зображення та оцінці достовірності знаходження в ній об'єкта. Коли йдеться про виявлення малорозмірних компактних об'єктів, достатньо реалізувати задачу виявлення й класифікації — сегментація тут надлишкова.

2.1.2. Особливості архітектури згорткових нейронних мереж

Архітектура YOLO відрізняється серед інших згорткових архітектур виявлення об'єктів швидкістю та помірною вибагливістю до обчислювальних ресурсів. У новіших версіях її точність також досягла рівня кращих зразків. Отже, на даний час вона є першим вибором для виявлення компактних об'єктів (Redmon et al., 2016; Jegham et al., 2025).

Починаючи з третьої версії, в архітектурі YOLO виділяють три базові елементи – *backbone*, *neck* та *head* (Terven & Cordova-Esparza, 2023). Початковий елемент — *основа (backbone)* — складається з множини згорткових шарів і відповідає за виділення розпізнавальних ознак об'єктів – від простих до складних. На основі карти ознак, сформованої цими шарами, наступні елементи мережі, такі як *neck* та *head*, виконують операції класифікації, виявлення, сегментації тощо. Формування основи є найвибагливішою щодо ресурсів складовою навчання згорткової нейромережі.

Уявлення про розподіл інформації, що міститься в навченій нейромережі, має приблизний характер. Дещо покращити його можуть технології візуалізації згорткових мереж (Zeiler & Fergus, 2013), проте, як правило, у практичних розробках обмежуються схематичним уявленням про те, що у пізніших шарах основи міститься інформація, відповідальна за

складні риси, а початкові шари відповідають за базові риси. Цього уявлення достатньо для планування експериментів, що враховують розподіл інформації у мережі.

2.1.3. Застосування трансферного (передавального) навчання (тонкого налаштування)

Інформація, що міститься в шарах основи, у більшості випадків не є чітко розділеною між цільовими об'єктами. Початкові шари містять риси, спільні для багатьох об'єктів, що дає змогу використати шари мережі, навченої на одних об'єктах, для розпізнавання інших, споріднених із попередніми. На цьому заснований метод передавального навчання.

Виділяють три категорії передавального навчання: *трансдуктивне (transductive)*, *індуктивне (inductive)* та *некероване (unsupervised)*. У випадку трансдуктивного навчання лише зображення базового датасету розмічені, у некерованому — жоден із наборів не розмічений, а в індуктивному — розмічений цільовий датасет. Якщо обидва датасети — базовий і цільовий — розмічені, то навчання характеризується як *багатозадачне (multi-task learning)* (Zhuang et al., 2020). У сценарії, що розглядається у цій роботі, а саме — виявлення і класифікація компактних об'єктів в умовах дефіциту навчальних даних, маємо справу саме з *багатозадачним передавальним навчанням*.

Окремим випадком передавального навчання є *тонке налаштування (fine-tuning)*, що полягає у донавчанні попередньо повноцінно навченої на великому датасеті мережі за допомогою обмеженого датасету цільових класів.

Для багатьох практичних задач важливою є можливість адаптації до нових даних, що надходять у невеликих кількостях і розтягнуто у часі. Така

можливість забезпечується двома факторами – здатністю навченої мережі до *генералізації*, тобто виявлення об’єктів, схожих на наявні у цільовому датасеті, але не ідентичних, та можливістю додавати до цільового датасету нові дані (із додаванням нових класів та без), при цьому уникаючи надмірних витрат на перенавчання мережі. Така можливість описується терміном *послідовне навчання (continual learning)*. У ідеальному випадку донавчання має відбуватися лише з використанням нових, свіжоотриманих даних і не погіршувати результат для старих класів. Втім, на практиці цього важко досягти. Перешкодою як для трансферного, так і для послідовного навчання є явище *катастрофічного забування (catastrophic forgetting)* (Ven et al., 2024). В нашому випадку цей ефект полягає у тому, що при донавчанні мережі YOLO на обмеженому датасеті компактних об’єктів, замість очікуваної послідовної адаптації розпізнавальних ознак у шарах основи мережі до нового набору класів, відбувається суттєве погіршення якості інформації щодо цих ознак. Очевидно, корисна інформація у мережі руйнується значно швидше, ніж нова формується завдяки навчанню. Навчання на певному обмеженому датасеті за певну кількість епох часто буває недостатнім для повноцінної адаптації всіх шарів основи під нові дані, але це обмежене навчання частково або повністю руйнує наявну в шарах корисну інформацію з минулого сеансу навчання.

Тож у такому випадку вдаються до наступного прийому: під час донавчання на обмеженому цільовому датасеті залишають фіксованими базові шари основи, а інколи — всю основу. Тобто, нейромережа може виконувати функцію розпізнавання цільових класів, маючи у своєму складі базові ознаки, вивчені не безпосередньо з цих класів, а з класів базового датасету, формуючи лише пізніші шари на базі цільового датасету.

Коли йдеться про *фіксацію (freezing)* шарів згорткової нейромережі, то під шаром мають на увазі комбінацію згорткового шару, шару нелінійності та шару об'єднання (*pooling*), тобто будівельний блок, що повторюється в межах основи (*backbone*) мережі багато разів.

Очевидно, що успіх донавчання залежить від ступеня спорідненості цільових класів і класів базового датасету, і ця спорідненість може відрізнятися як між різними базовими датасетами, так і між різними класами цільового датасету. Різниця у межах цільового датасету не має бути значною, виходячи із зазначеної раніше спільності фізичних властивостей і походження об'єктів виявлення.

З вищенаведеного випливає, що для результативного донавчання мережі на базі обмеженого цільового датасету необхідно провести серію експериментів зі зміною кількості фіксованих шарів основи мережі, кількості епох навчання, і можливо, деяких інших гіперпараметрів. Не варто також обмежуватися єдиним базовим датасетом, якщо є можливість вибору. Якщо цільовий датасет достатньо однорідний, то ймовірним є отримання набору значень гіперпараметрів, оптимального для всіх класів, у загальному ж випадку результатом буде набір значень для певних груп класів.

Якщо виникне необхідність у розширенні цільового датасету, доведеться провести повторне донавчання базової мережі, використовуючи значення гіперпараметрів, оптимальні для класів, найближчих до нових. Такий порядок дій не відповідатиме визначенню послідовного навчання, але принаймні не потребуватиме значних обчислювальних ресурсів на кожній ітерації.

2.2. Використання теплових зображень для виявлення компактних об'єктів методами машинного навчання

Інфрачервоне аерознімання теплового діапазону – одне із найнадійніших джерел даних дистанційного зондування (Попов та ін., 2021). Можливість візуалізації результатів знімання робить сприйняття результатів зручнішим для людини. Щодо дистанційного виявлення поверхневих компактних об'єктів, теплові зображення можна впевнено поставити на друге місце за значенням після зображень у видимій частині оптичного діапазону. Відмінний фізичний принцип полягає у тому, що використовується не відбите світло, як у випадку видимого діапазону, а власне випромінювання фізичного тіла. Це зумовлює відповідні обмеження, про які далі буде йти мова у контексті природного середовища, що зумовлює різницю температур штучного об'єкта та його оточення. У природному середовищі протягом доби в певний час створюються найменш сприятливі та найбільш сприятливі умови для теплового знімання (Jordan et al., 2024). Цей фактор необхідно враховувати під час планування місії БПЛА.

Що стосується використання методів машинного навчання для виявлення компактних поверхневих об'єктів на теплових зображеннях, то відмінності від зображень видимого діапазону є радше кількісними, ніж якісними. Варіюючи просторову розрізненність, можна або виявляти лише температурні аномалії, або здійснювати виявлення й класифікацію об'єкта подібно до RGB-зображень.

2.3. Використання даних магнітометрії для виявлення компактних об'єктів

При підготовці до використання того чи іншого сенсора з БПЛА необхідно визначити етапи попередньої обробки, що приводять дані у

вигляд, придатний для виявлення, і можливо, класифікації об'єктів, визначитись безпосередньо із методом виявлення, і на основі вимог методу до якості даних визначити спосіб обчислення параметрів місії БПЛА.

Магнітометр чутливий до зовнішніх завад. Це лінії електропередач, електромагнітні передавачі, інфраструктура (комунікації), залишки побутових та промислових об'єктів, залізовмісні відходи, залишки сільськогосподарської та військової техніки тощо, а також залишки використаних боєприпасів (Poliachenko et al., 2023).

Магнітометр є трасовим приладом, але зону його чутливості можна спроектувати на поверхню землі. Радіус зони чутливості магнітометра r (див. рис. 2.1.) визначатиметься величиною магнітного поля міни M , фоновим магнітним шумом μ та законом зменшення сигналу магнітометра з відстанню $S(r)$ (Ram-Cohen et al., 2017; Macharet et al., 2016; Gavazzi et al., 2016; Munschy et al., 2007).

Відповідно до квадратичного зменшення сигналу магнітометра з відстанню $S(r) = \frac{G \cdot M}{h^2 + r^2}$, де h – це висота зйомки, G – коефіцієнт пропорційності, радіус чутливої зони магнітометра буде визначатись формулою

$$r = h \cdot \sqrt{\frac{M}{\mu \cdot \psi} - 1} \quad (1)$$

де ψ є відношенням “сигнал-шум”, за якого можливе надійне виявлення.




Рис. 2.1. Щодо визначення радіуса зони чутливості магнітометра

Маючи радіус зони чутливості магнітометра, можна визначити параметри польоту БПЛА з магнітометром для суцільного покриття всієї досліджуваної області магнітометричними слідами (Prouty & Tchernyshev, 2016; Butler, 2003; Nguyen et al., 2005). За цим слідом можна розрахувати ймовірність перебування міни шляхом статистичного виявлення аномалій там, де сигнал магнітометра перевищує фоновий рівень (Lee & Lee, 2024).

2.4. Поєднання даних від сенсорів різної фізичної природи

Сприйняття оточення живими істотами базується на використанні поєднаної інформації від сенсорів різної фізичної природи. Здатність до комбінування даних різних сенсорів розвинулася як результат еволюції та є необхідною умовою для побудови адекватної картини світу (Elmenreich, 2002).

Поєднання сенсорів (*sensor fusion*) може бути здійснене трьома способами – поєднання даних (*data fusion*), поєднання рис (*feature fusion*) та поєднання рішень (*decision fusion*). Перші два способи стосуються окремих

випадків; для універсального ж підходу, що поєднує сенсори різного фізичного принципу дії, перевагу слід віддати комплексуванню рішення або комплексуванню результату (Narkhede et al., 2022).

Важливо зазначити, що як більш традиційні статистичні методи, так і сучасні методи глибокого навчання формують результат у вигляді ймовірності наявності об'єкта або достовірності його віднесення до певного класу. Це дозволяє, використовуючи методи теорії ймовірності, в автоматичному режимі створювати узагальнену картину території дослідження ймовірнісної природи.

Байєсівський висновок, або байєсівське підсумовування ймовірностей, – метод статистичного аналізу, який дозволяє коригувати достовірність факту в міру надходження нових даних. У разі виявлення об'єкта кількома різними сенсорами, що діють за різними фізичними принципами, метод полягає в подачі процесу визначення ймовірності наявності цілі за результатами минулого виміру та теперішнього.

$$P(T|D) = \frac{P(D|T)P(T)}{P(D|T)P(T) + P(D|\bar{T})P(\bar{T})}$$

тобто ймовірність того, що ціль присутня, якщо детектор спрацював – $P(T|D)$, дорівнює добутку ймовірності спрацювання детектора за наявності цілі $P(D|T)$ на апіорну ймовірність наявності цілі $P(T)$, поділеному на суму першого добутку і добутку ймовірності спрацювання детектора за відсутності цілі $P(D|\bar{T})$ та апіорної ймовірності відсутності цілі $P(\bar{T})$ (Von der Linden et al., 2014; Narkhede et al., 2022).

У цьому контексті апіорна ймовірність — це ймовірність, отримана попереднім використанням сенсором. Формальна незалежність визначення сенсорів забезпечується тим, що всі вони засновані на різних фізичних принципах.

Висновки до другого розділу

1. Основним типом даних для виявлення малорозмірних компактних об'єктів у даній роботі визначено аерозображення видимого діапазону, що отримуються з БПЛА, а основним методом виявлення – глибоке навчання у формі згорткової нейромережі архітектури YOLO.
2. Розпізнавальні ознаки об'єктів, якими оперують згорткові нейронні мережі, є спільними для багатьох компактних об'єктів реального світу, тому розроблено підхід до компенсації дефіциту розмічених навчальних даних у задачі виявлення поверхневих мін за допомогою передавального (трансферного) донавчання нейромережі, пренавченої на відкритих датасетах загального призначення.
3. Додатковим типом даних іншої фізичної природи, ніж основний, для виявлення поверхневих мін з БПЛА визначено теплові аерозображення та авіаційні магнітометричні вимірювання. Для виявлення мін на теплових аерозображеннях адаптовано окрему згорткову нейромережу архітектури YOLO, навчену на власне створеному датасеті, а для виявлення за матеріалами авіаційної магнітометрії – статистичне виявлення аномалій магнітного сигналу.
4. Комплексування даних різної фізичної природи в роботі виконується шляхом злиття карт ймовірностей знаходження мін, отриманих кожним із задіяних сенсорів, за байєсівським правилом підсумовування ймовірностей.
5. Для оцінювання достовірності виявлення мін у роботі обрано загальноприйняті показники – точність (precision), чутливість (recall) та узагальнену середню точність (*mean average precision*).

Список використаних джерел

- Попов, М. О., Станкевич, С. А., Мосов, С. П., Титаренко, О. В., Дугін, С. С., Голубов, С. І., & Андреев, А. А. (2021). Технологія автоматизованого виявлення мін за результатами комплексування багатоспектральної та інфрачервоної зйомки з безпілотних літальних апаратів. У *Аерокосмічні технології в Україні: проблеми та перспективи: матеріали IV науково-практичної конференції (9–10 вересня 2021 р.)* (С. 13–15).
- Butler, D. K. (2003). Implications of magnetic backgrounds for unexploded ordnance detection. *Journal of Applied Geophysics*, 54(1–2), 111–125. <https://doi.org/10.1016/j.jappgeo.2003.08.022>
- Deininger, L., Stimpel, B., Yuce, A., Abbasi-Sureshjani, S., Schönenberger, S., Ocampo, P., Korski, K., & Gaire, F. (2022). *A comparative study between vision transformers and CNNs in digital pathology* (arXiv:2206.00389). arXiv. <https://doi.org/10.48550/arXiv.2206.00389>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). *An image is worth 16x16 words: Transformers for image recognition at scale*. Paper presented at the International Conference on Learning Representations (ICLR). <https://openreview.net/forum?id=YicbFdNTTy>
- Elmenreich, W. (2002). *An introduction to sensor fusion* (Technical Report No. 502, pp. 1–28). Vienna University of Technology.
- Gavazzi, B., Le Maire, P., Munsch, M., & Dechamp, A. (2016). Fluxgate vector magnetometers: A multisensor device for ground, UAV, and airborne magnetic surveys. *The Leading Edge*, 35(9), 795–797. <https://doi.org/10.1190/tle35090795.1>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Issaoui, H., ElAdel, A., & Zaied, M. (2024). Object detection using convolutional neural networks: A comprehensive review. In *Proceedings of 27th International*

- Symposium on Real-Time Distributed Computing (ISORC 2024)* (pp. 102–107). IEEE. <https://doi.org/10.1109/ISORC61049.2024.10551342>
- Jegham, N., Koh, C. Y., Abdelatti, M., & Hendawi, A. (2025). *YOLO evolution: A comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions* (arXiv:2411.00201). arXiv. <https://doi.org/10.48550/arXiv.2411.00201>
- Jordan, S., Driggers, R., Furxhi, O., Leslie, P., Cavanaugh, R., Renshaw, K., & Jacobs, E. (2024). Comparison of scene contrast temperature in MWIR and LWIR. *Proceedings of SPIE, 13045*, Article 1304506. <https://doi.org/10.1117/12.3013305>
- Kirkpatrick, J., Pascanu, R., Rabinowitz, N., Veness, J., Desjardins, G., Rusu, A. A., & Hadsell, R. (2017). Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences, 114*(13), 3521–3526. <https://doi.org/10.1073/pnas.1611835114>
- Lee, J., & Lee, H. (2024). Modeling residual magnetic anomalies of landmines using UAV-borne vector magnetometer: Flight simulations and experimental validation. *Remote Sensing, 16*(16), Article 2916. <https://doi.org/10.3390/rs16162916>
- Macharet, D. G., Perez-Imaz, H. I. A., Rezeck, P. A. F., Potje, G. A., Benyosef, L. C. C., Wiermann, A., Freitas, G. M., Garcia, L. G. U., & Campos, M. F. M. (2016). Autonomous aeromagnetic surveys using a fluxgate magnetometer. *Sensors, 16*(12), Article 2169. <https://doi.org/10.3390/s16122169>
- Munsch, M., Boulanger, D., Ulrich, P., & Bouiflane, M. (2007). Magnetic mapping for the detection and characterization of UXO: Use of multi-sensor fluxgate 3-axis magnetometers and methods of interpretation. *Journal of Applied Geophysics, 61*(3–4), 168–183. <https://doi.org/10.1016/j.jappgeo.2006.06.004>
- Narkhede, P., Walambe, R., & Kotecha, K. (2023). Sensor fusion methodologies for landmine detection. In M. Saraswat, C. Chowdhury, C. K. Mandal, & A. H.

- Gandomi (Eds.), *Lecture Notes in Networks and Systems: Vol. 551* (pp. 891–907). Springer. https://doi.org/10.1007/978-981-19-6631-6_62
- Nguyen, T. T., Hao, D. N., Lopez, P., Cremer, F., & Sahli, H. (2005). Thermal infrared identification of buried landmines. *Proceedings of SPIE*, 5794, 198–208. <https://doi.org/10.1117/12.626263>
- Poliachenko, I., Kozak, V., Bakhmutov, V., Cherkes, S., & Varava, I. (2023). Preliminary results of UAV magnetic surveys for unexploded ordnance detection in Ukraine: Effectiveness and challenges. *Geophysical Journal*, 45(5), 126–140. <https://doi.org/10.24028/gj.v45i5.289117>
- Prouty, M. D., & Tchernychev, M. (2016). Real-time threat detection using magnetometer arrays. In *Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security, Defense, and Law Enforcement Applications XV* (Vol. 9825, Article 98250O). SPIE. <https://doi.org/10.1117/12.2224338>
- Ram-Cohen, T., Alimi, R., Weiss, E., & Zalevsky, Z. (2017). Characterization and detection of oscillating magnetic dipole signals. *Measurement Science and Technology*, 28(4), Article 045104. <https://doi.org/10.1088/1361-6501/aa59c0>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *YOLO: You Only Look Once: Unified, real-time object detection* (arXiv:1506.02640). arXiv. <https://doi.org/10.48550/arXiv.1506.02640>
- Terven, J. R., & Cordova-Esparza, D. M. (2023). *A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS* (arXiv:2304.00501). arXiv. <https://doi.org/10.48550/arXiv.2304.00501>
- van de Ven, G. M., Soures, N., & Kudithipudi, D. (2025). Continual learning and catastrophic forgetting. In J. Wixted (Ed.), *Learning and memory: A comprehensive reference* (3rd ed., pp. 153–168). Academic Press. <https://doi.org/10.1016/B978-0-443-15754-7.00073-0>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, & R. Fergus (Eds.), *Advances in neural information processing systems* (Vol. 30, pp. 5998–6008). Curran Associates.

Von der Linden, W., Dose, V., & Von Toussaint, U. (2014). *Bayesian probability theory: Applications in the physical sciences*. Cambridge University Press. <https://doi.org/10.1017/CBO9781139565608>

Xiao, L., Li, W., Yao, S., Liu, H., & Ren, D. (2024). High-precision and lightweight small-target detection algorithm for low-cost edge intelligence. *Scientific Reports*, 14(1), Article 23542. <https://doi.org/10.1038/s41598-024-75243-1>

Zeiler, M. D., & Fergus, R. (2013). *Visualizing and understanding convolutional networks* (arXiv:1311.2901). arXiv. <https://doi.org/10.48550/arxiv.1311.2901>

Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2023). *Dive into deep learning* (Version 1.0.3). <https://d2l.ai/>

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43–76. <https://doi.org/10.48550/arXiv.1911.02685>

РОЗДІЛ 3

РОЗРОБКА МЕТОДИКИ ВИЯВЛЕННЯ МАЛОРОЗМІРНИХ КОМПАКТНИХ ОБ'ЄКТІВ НА ОСНОВІ КОМПЛЕКСУВАННЯ ДАНИХ АЕРОЗНІМАННЯ РІЗНОЇ ФІЗИЧНОЇ ПРИРОДИ

Методика виявлення малорозмірних компактних об'єктів на земній поверхні базується на підборі і використанні найбільш доцільного набору сенсорів і сучасних статистичних методів, машинного та глибокого навчання, що передбачає врахування специфіки конкретного типу об'єктів та/або середовища пошуку, і найбільш доцільного підходу до процесу машинного навчання. У цьому дослідженні як об'єкти пошуку розглядаються міни, розташовані на поверхні Землі. Додатковою уточнювальною умовою розробки методики є спеціалізація на гуманітарному розмінуванні відкритих площ.

Виявлення і класифікація поверхневих мін залишаються актуальними задачами, адже роботизовані платформи, які зараз широко використовуються, здебільшого встановлюють міни саме на поверхні. На поверхні знаходяться і міни, розповсюджені за допомогою артилерійських та авіаційних систем дистанційного мінування (Денисов і Матвійчук, 2024).

Слід відділяти задачу пошуку прихованих під поверхнею мін через те, що вона вимагає окремого, складнішого набору як сенсорів, так і методів (Baur et al., 2026; Hutsul et al., 2024). Втім, у гуманітарному розмінуванні часто має місце комбінований сценарій, коли потрібно виявляти як поверхневі, так і приховані міни. Сценарій із виключно поверхневими мінами можливий, наприклад, тоді, коли досліджувана територія не була окупована, але противник мав змогу мінувати дистанційно, або коли територія мінувалася нашою стороною і є точні відомості про використані засоби.

Система виявлення мін має відповідати таким вимогам, як легкість масштабування та адаптація до нових класів заданого типу об'єктів, що передбачає використання загальнодоступних апаратних засобів і програмного забезпечення.




Рис. 3.1. Загальна схема методики

3.1. Модульна структура методики

Методика поділяється на три функціональні модулі згідно з основними процесами, що виконуються в її межах – модулі навчання, планування та виявлення. Модуль навчання, крім власне організації процесу навчання нейромереж, включає в себе також збір даних (зображень, вимірів), створення і підтримання тренувальних і тестових наборів даних, і тестування

програмної частини системи із отриманням вхідної інформації для блоку планування і виконання обстежувального польоту.

У рамках модуля навчання вирішуються наступні задачі:

- оцінка достатності навчальних даних, а саме - RGB та теплових зображень;
- визначення оптимального підходу до проблеми недостатності навчальних даних (аугментація, передавальне навчання);
- забезпечення здатності цільових навчених моделей до генералізації;
- забезпечення можливості швидкого донавчання при появі додаткових даних;
- забезпечення вхідних даних для планування обстеження (головним чином, необхідної просторової розрізненості і похідної від неї висоти обстежувального польоту);
- забезпечення необхідного формату донавчених цільових моделей нейромереж.

Для основного типу даних для поверхневих об'єктів – RGB-зображення – найкращим розв'язанням проблеми недостатності даних є обмежена аугментація та передавальне навчання, а саме – тонке налаштування на обмежених цільових датасетах нейромереж, пренавчених на великих датасетах загального користування.

Для теплових зображень наразі використовується лише аугментація, а тренування мережі відбувається з нуля через недоступність базових датасетів, співставних із такими для RGB.

Для магнітометричних даних наразі використовується статистичне виявлення аномалій.

Тестування донавчених моделей доцільно організувати так, щоб максимально наблизитися до умов, що передбачаються під час практичного використання. З усіх умов найпростіше забезпечити, щоб у тестовому наборі даних була стала просторова розрізненність чи принаймні така, що перебуває у вузькому діапазоні, як це забезпечується в автоматичному режимі польоту БПЛА. Тоді отримані результати можна буде використати для планування майбутніх обстежувальних польотів. До додаткових умов можуть належати фон, розташування об'єктів, ступінь освітлення. Також може бути доцільним тестування для окремих підгруп об'єктів (протитанкових, протипіхотних мін тощо).

Модуль планування на основі даних, отриманих під час тестування, забезпечує перехід від просторової розрізненності, за якої система забезпечує прийнятний результат, до конкретних параметрів обстежувального польоту БПЛА для кожного типу даних, що використовується. Головний параметр, який визначається на цьому етапі, – висота польоту (Роров et al., 2023).

Формується запит щодо переліку об'єктів, наявних у навчальному наборі даних або споріднених, які потрібно виявити. З них вибирається найменший, і серед результатів тестування на наявних тестових наборах знаходиться той, у якому цей об'єкт або максимально наближений до нього виявляється із показниками якості, не меншими за задані пороги.

Якщо за результатами обстеження та виявлення показники ефективності не відповідатимуть отриманим на тестовому наборі даних, то необхідно додати нові дані до навчального набору даних і провести повторне донавчання на цільовому наборі. Якщо ж показники ефективності не змінилися, то доповнення навчального набору є бажаним, але не обов'язковим.

Також можуть бути враховані додаткові відомості про досліджувану територію. Наприклад, може бути відомо, що територія мінувалася лише дистанційно з БПЛА, що обмежує набір можливих мін.

Модуль виявлення передбачає отримання даних з обстежувальних польотів БПЛА у вигляді окремих зображень чи ортофотоплану та масиву магнітометричних даних, використання навчених нейронних мереж та/або статистичних методів виявлення аномалій, результатом чого є формування ймовірнісної карти для кожного типу даних, які наступним кроком поєднуються із використанням байєсівського злиття ймовірностей (Elmenreich, 2002). Злиття може відбуватися лише на ділянках, де значення, отримані окремими сенсорами, перебувають у наперед визначених діапазонах або досягають певного порогового значення. Наприклад, немає сенсу враховувати низький рівень ймовірності аномалії, визначений магнітометрією, якщо за даними RGB чи тепловими даними визначається тип міни, який не містить феромагнетиків. Так само немає сенсу комплексувати результати виявлення у RGB із високою достовірністю.

Крім власне виявлення, цей модуль також відповідає за збір додаткових навчальних даних, які ітеративно покращуватимуть якість системи виявлення. Якщо додаткові дані стосуватимуться наявних класів об'єктів, то для донавчання можна використати безпосередньо відомі гіперпараметри. Якщо ж виникне потреба додати нові класи, що суттєво відрізняються від початкового цільового набору даних, то може знадобитися нове дослідження з пошуку оптимальних гіперпараметрів.

Процес адаптації до нових даних організовується напівавтоматично: система, виявляючи об'єкт, зберігає фрагмент зображення зі згенерованою обмежувальною рамкою. Потім отримані зображення верифікуються

оператором і додаються до набору навчальних даних, після чого відбувається донавчання нейромережі. Нові класи додаються оператором вручну або на основі хибно класифікованих цілей, або тих, що не були виявлені системою.

Через постійну потребу в оновленні навчальних даних і донавчанні, виникають постійні зв'язки між модулями. Від модуля виявлення нові навчальні дані надходять у навчальний модуль, який, своєю чергою, може вплинути на параметри польотів, що обчислюються модулем планування.

3.2. Аналіз доцільності застосування сенсорів

Коли метою є висока достовірність виявлення об'єктів, виникає необхідність пошуку компромісу між максимальним розширенням набору сенсорів для даного типу об'єктів і доцільністю, практичною і економічною, використання певного набору. Цей набір загалом не є сталим і змінюється з розвитком технологій (Baur et al., 2026). У табл.3.1. наведено стислий аналіз доцільності набору сенсорів на прикладі зображень оптичного діапазону, теплових зображень та магнітометрії для виявлення поверхневих компактних об'єктів, а саме мін.

Таблиця 3.1. Аналіз сенсорів для комбінованої методики виявлення об'єктів

Тип даних	Сталі характеристики			Змінні характеристики			
	Характеристики об'єктів пошуку	Характеристики середовища	Джерела перешкод і хибних тривог	Розвиток сенсорів	Розвиток методів машинного навчання	Наявність навчальних даних	Пріоритетність і обов'язковість
Зображення видимого діапазону	Усі поверхневі об'єкти є видимими за певної досяжної розрізненості	Середовище, як правило, природне, контрастує з штучними об'єктами.	Можливі перешкоди у вигляді рослинності. Можливе використання муляжів.	Досягнуто найкращого рівня, подальший розвиток суттєво не вплине	Високий рівень, ітеративне покращення може вплинути на граничні випадки	Дефіцит цільових датасетів, збільшення може суттєво вплинути, наявність великих базових датасетів	Найвищий пріоритет, використання обов'язкове
Теплові зображення	Видимість об'єктів змінюється залежно від часу доби	У природному середовищі високий контраст у відповідний час доби	Недотримання оптимального часу доби, відсутність суттєвих добових коливань	Нижча розрізненість, обумовлена фізикою, технічний розвиток високий	Аналогічно попередньому, зі зміщенням в бік виявлення аномалій	Дефіцит, збільшення датасетів може суттєво вплинути, дефіцит базових датасетів	Пріоритет другий після RGB, використання залежить від обставин
Магнітометрія	Лише об'єкти із значним вмістом феромагнетиків, достатнього розміру для фіксації з мінімальної висоти польоту БПЛА	Магнітне поле Землі, часто викривлене багатьма факторами.	Малий вміст феромагнетиків, малий розмір; лінії електропередач, залишки побутових та промислових об'єктів, залізовмісні відходи, залишки техніки, залишки використаних боєприпасів	Наявні сенсори суттєво відрізняються, можливість обмежена, розвиток триває і може суттєво вплинути	Доцільність застосування глибокого навчання сумнівна, методи виявлення аномалій домінують	Із розвитком можливе отримання впізнаних сигнатур і створення датасетів	Середній пріоритет, використання залежить від обставин

У таблиці наведено три найширше використовувані типи даних для виявлення поверхневих мін з БПЛА. З аналізу характеристик об'єктів, середовища, розвитку сенсорів і методів впливає, що зображення видимого діапазону — тип даних із найвищим пріоритетом, обов'язковий для переважної більшості конфігурацій, а теплові зображення та магнітометрія мають більші обмеження й є додатковими типами даних.

Наприклад, якщо пріоритетом є пошук протитипотних мін на кшталт ПФМ-1, то застосування магнітометрії не зможе забезпечити покращення результату, на відміну від теплових зображень. Якщо ж на території ймовірна

наявність прихованих мін ТМ, то доцільність застосування магнітометра значно зростає.

Якщо на досліджуваній території встановилася погода без значних коливань температури, то використання теплових зображень вже є недоцільним.

Втім, точний кількісний вираз викладених міркувань ще потребує додаткових досліджень. Наразі визначення набору сенсорів скоріше обумовлене логікою і здоровим глуздом.

3.3. Збір навчальних даних і формування датасетів

Згідно із визначеними вище сенсорами та типами даних, для яких планується використати машинне, і зокрема глибоке, навчання, потрібно здійснити збір первинних даних для навчання та створити з них відповідні датасети.

Окрім випадків, коли дослідження стосується загальнодоступних розповсюджених об'єктів, що вже представлені у вигляді готових датасетів, виникає необхідність зібрати дані та підготувати датасети власними силами. При цьому важливо зібрати якнайрізноманітніший набір об'єктів за різних умов зйомки та з використанням різних засобів. Можна констатувати, що зображень, зібраних на одній території однією камерою за однакових параметрів місії, недостатньо для повноцінного дослідження відповідно до сучасних вимог. Здатність до генералізації отриманого детектора має бути перевірена на різноманітних зображеннях, отриманих різними камерами у різних умовах.

Під час експериментів із глибоким навчанням необхідним є поділ наявних даних на навчальні та тестові. Випадок із мінами має особливість –

розмір і форма об'єктів є сталими і заздалегідь відомими. Для навчального набору необхідно виконувати аугментацію даних і намагатися зробити його якомога різноманітнішим. Хоча форма міни є сталою, положення у просторі може бути різним, і та сама міна, розташована під іншим кутом, є іншим зображенням з точки зору нейромережі, отже, цим способом аугментації варто користуватись у першу чергу.

Потреба у окремому тестовому датасеті викликана тим, що інакше не можливо оцінити здатність нейромережі до генералізації. Тому бажано, щоб тестовий датасет включав зображення, отримані іншою камерою в інших умовах, ідеально — з кількох різних камер. Також варто мати у тестовому датасеті модифікації мін, що відрізняються від навчального набору.

Дуже бажано отримати вхідні дані для майбутнього планування місії як результат тестування. Для цього тестові датасети потрібно komponувати так, щоб у них зображення мали сталу або близьку просторову розрізненість. Це дасть змогу після тестування надати рекомендації щодо найгіршої просторової розрізненості, за якої гарантований прийнятний результат виявлення. Слід визначити таку розрізненість для всіх класів або принаймні для мінімального та максимального за розміром. За отриманими даними, завдяки відомій розрізненості та сталому розміру об'єктів, можна дати рекомендації щодо параметрів майбутньої місії БПЛА.

Мала кількість зображень критична для навчального датасету, для тестового ж кількість не є принциповою. Однак якщо було здійснено кілька тестів за окремими датасетами зі сталою розрізненістю, варто також провести підсумкове тестування, об'єднавши всі тестові датасети в один великий датасет.

3.4. Трансферне (передавальне) навчання

Стосовно задачі пошуку поверхневих мін трансферне навчання покликане вирішити такі завдання, як

- подолання обмеженої кількості навчальних даних;
- покращення здатності до генералізації;
- спрощення розширення множини об'єктів пошуку.

Збір зображень і створення датасетів таких специфічних об'єктів, як міни, відзняті з БПЛА, пов'язані з низкою організаційних складностей, тому зазвичай маємо справу з досить обмеженими датасетами. Частково із проблемою можна боротися шляхом аугментації (штучного нарощування) даних. Проте навіть велика кількість даних не вирішує проблему одноманітності форми мін, що сприяє перенавчанню і слабкій здатності до генералізації.

Якщо навчання буде здійснюватися на єдиному великому цільовому датасеті з нуля, то під час розширення датасету зображеннями нових чи існуючих класів доведеться проводити тривалу процедуру повного навчання, оскільки задача послідовного навчання для згорткових нейромереж не розв'язана. Тобто, можливо, реалізувати не послідовне навчання у його класичному визначенні, а певну гібридну модель, де один раз відбувається дуже витратне навчання на великому базовому датасеті, а навчання на легкому цільовому розширюваному датасеті відбуватиметься у міру його доповнення.

Міни є специфічними промисловими виробами, що мають спільні риси із багатьма виробами загального вжитку, до того ж інколи ця схожість їм надається свідомо, що з гуманітарної точки зору є негативним фактором, але водночас сприяє вирішенню задачі виявлення методами глибокого навчання.

На даний час у наявності є великі датасети загального користування, які використовуються як базові для багатьох задач трансферного навчання.

Отже, рішення полягає у тому, щоб на базі мережі YOLO, тренуваної на великому датасеті загального використання, здійснювати донавчання (тонке налаштування) на базі цільового датасету мін, відзнятих з БПЛА. Водночас необхідно уникнути явища *катастрофічного забування* розпізнавальних ознак об'єктів (Kirkpatrick et al., 2017), що містяться у базовій мережі. З цією метою використовується підхід, за якого під час навчання фіксуються значення певних шарів, що містять інформацію про базові риси.

Досить трудомісткою є серія експериментів із визначення оптимального ступеня фіксації шарів основи базової мережі та оптимальної кількості навчальних епох. Також за наявності різних базових датасетів результат може відрізнятись. Коли оптимальні гіперпараметри знайдені, обчислювальні витрати на донавчання дуже обмежені порівняно з навчанням «з нуля», отже, додаючи нові дані до цільового датасету, можна швидко отримати донавчену мережу.

Є сенс починати дослідження з мінімальної кількості епох і максимальної кількості фіксованих шарів, тому що збільшення кількості епох збільшує час навчання, а фіксованих шарів — скорочує. Таким чином, можна оптимізувати загальний час навчання, необхідний для досягнення результату.

При збільшенні числа епох результат поступово покращується і досягає максимуму в певний момент, а потім починає погіршуватися, що і є маркером для фіксації результату.

Пошук оптимальної кількості фіксованих шарів можна почати з усіх шарів основи (backbone) згорткової мережі. У випадку, якщо базовий набір містить предмети, максимально подібні до цільових мін, такий варіант може

бути оптимальним. Згодом, зменшуючи кількість фіксованих шарів, можна досягти оптимального значення.

Слід зазначити, що у найкращому випадку для всіх класів цільового датасету буде знайдено єдині оптимальні значення гіперпараметрів або, принаймні, можливо буде знайти компроміс із прийнятним рівнем виявлення для всіх класів при одному наборі значень. Якщо ж оптимальна конфігурація для одних класів буде неприйнятною для інших, можливо, варто використати варіант із комбінуванням тренуваних мереж, де вони виконуватимуть розпізнавання паралельно, а результат об'єднати шляхом пригнічення гіршого значення (*non-maximum suppression*).




Рис. 3.2. Порядок глибокого навчання з використанням обмеженого обсягу навчальних зображень

3.4. Використання теплових зображень

Теплові зображення можуть бути використані у той же спосіб, що і RGB-зображення, адже вони, за дотримання добового циклу різниці температур, можуть бути контрастними і деталізованими. Водночас треба

враховувати, що теплові зображення, отримані в тій самій місії, поступаються просторовою розрізненністю RGB-зображенням. При використанні теплових зображень як допоміжних можна вдаватися до підходу, за якого для них використовується режим єдиного класу, отже, виконується лише виявлення без визначення типу.

Якщо ж очікуються умови, за яких теплові зображення будуть відігравати основну роль, наприклад, при камуфлюванні мін або перекритті рослинністю, то варто створювати повноцінні датасети, при цьому бажано мати зображення певних мін, зроблених у певному діапазоні, центром якого має бути час доби із максимальним контрастом із навколишнім середовищем. Зміни зображення в часовому діапазоні дозволяють додатково нарощувати навчальні дані, що неможливо для зображень видимого діапазону.

Водночас підхід із трансферним навчанням, описаний для RGB-зображень, важче застосувати для теплових зображень через відсутність таких потужних базових датасетів, тож потрібно навчати з нуля.

3.5. Використання магнітометрії

Як було сказано в попередніх розділах, використання глибокого навчання для аналізу магнітометричних даних наразі, хоч і можливе, не дає переваг над статистичними методами. Натомість, варто використовувати статистичний метод виявлення аномалій і отриману карту ймовірностей використовувати для підсилення результатів, отриманих попередніми сенсорами.

Необхідно виконати очищення сигналу від шуму, видалення тренду, викликаного зовнішніми завадами, і на базі очищеного сигналу будувати карту ймовірності знаходження об'єкта.

3.6. Комплексування результатів виявлення різними сенсорами

Як було відзначено у розділі 2.4., до сенсорів різної фізичної природи найдоцільніше застосовувати злиття результатів виявлення (на противагу злиттю даних чи окремих рис).

Коли йдеться виключно про виявлення поверхневих об'єктів, в окремих випадках один тип зображень може забезпечити задовільний результат. Отже, слід окреслити сценарії, за яких буде виправданим комплексування результатів кількох камер та/або сенсорів різних фізичних принципів.

Одразу треба зазначити, що будь-які сенсори висувають до місії БПЛА суворіші вимоги, ніж камери видимого діапазону. Скажімо, з висоти, на якій ефективно працюватиме магнітометр, можна зробити дуже якісні і навіть надлишкові з точки зору інформативності RGB-знімки. Місія БПЛА для зйомки RGB-зображень буде економічнішою за будь-які інші.

Отже, у контексті злиття результатів слід вести мову про ті сценарії, де результати в видимому діапазоні мають суттєві недоліки. До таких можна віднести погіршення видимості природними факторами, такими, як рослинність, а також умисне камуфлювання. Якщо міна замаскована до візуальної невпізнанності, то теплові зображення чи магнітометрія можуть стати єдиними джерелами інформації.

Інтеграцію двох (або більше) отриманих різними методами карт достовірності виявлення наземних мін — як результатів, наприклад, оптичних p_o та магнітометричних p_m польових досліджень — можна виконати таким чином. Просторова інтеграція полягає в перетині просторових сегментів, які перевищують заздалегідь визначений поріг ймовірності, у випадку нейромереж на кшталт YOLO — визначених

прямокутних меж. У межах сегмента перетину використовується *байєсівське підсумовування ймовірностей* (Narkhede et al., 2022).

Якщо виявлення міни здійснювалося послідовно оптичним і магнітометричним методом, то формула матиме наступний вигляд

$$p_{\Sigma} \cong \frac{p_o \cdot p_m}{p_o \cdot p_m + (1 - p_o) \cdot (1 - p_m)}$$

Тут p_{Σ} – результуюча ймовірність. У межах сегментів, що не перекриваються, ймовірність зберігається (рис. 3.3). Як результат інтеграції оптичних та магнітометричних даних, отримуємо єдину спільну карту достовірності виявлення наземних мін.




Рис. 3.3. Підсумкова ймовірність у межах сегментів, що перекриваються.




Рис. 3.4. Діаграма виявлення об'єктів із злиттям ймовірностей

3.7. Геоінформаційна платформа

На всіх етапах роботи з виявлення мін виконується робота з просторово розподіленими даними. Спочатку відбувається планування місії, результатом якого є траєкторія польоту БПЛА – одна чи декілька для різних сенсорів. Результатом виконання місії є зображення із просторовою прив'язкою або траєкторія польоту із отриманими значеннями магнітного поля. Результатом виявлення об'єктів є карта ймовірності знаходження цілей. Отже, якщо ставиться задача об'єднати всі етапи процесу у єдиний програмний комплекс, то результат фактично є геоінформаційною системою.

Створення окремої геоінформаційної системи – дуже трудомістка задача, тому доцільніше використати наявну систему, яка має можливість розширення за допомогою окремих модулів, що виконують вищезгадані функції. Враховуючи критичний фактор вартості масштабування, геоінформаційні системи із платними ліцензіями на кожне робоче місце виключаються з розгляду.




Рис. 3.5. Загальна архітектура геоінформаційної платформи

Ідеальним вибором є система із відкритим кодом, що розповсюджується безоплатно і має можливість модульного розширення. Цим умовам відповідає відома геоінформаційна система QGIS. Система розробляється

неформальною міжнародною спільнотою програмістів і розширюється модулями, створеними мовою Python, яка одночасно є і мовою більшості бібліотек машинного навчання. Окрім ядра геоінформаційної системи, наявні також модулі, що реалізують згадані функції і потребують мінімальної доробки. Важливо, що розпізнавання об'єктів може виконуватися в ГІС, і результат може бути представлений у вигляді векторного шару. За допомогою стандартних засобів ГІС можна виконати функцію перетину шарів і реалізувати обчислення результуючої достовірності виявлення об'єктів.

Висновки до третього розділу

1. Розроблено методику, що включає в себе обґрунтований вибір сенсорів і методів машинного та глибокого навчання, розв'язання проблеми недостатності навчальних даних через трансферне навчання і аугментацію, спрощення донавчання мережі на додаткових даних шляхом встановлення оптимальних гіперпараметрів, і комплексування результатів ймовірнісної природи, отриманих аналізом даних різної фізичної природи.

2. Розроблено і випробувано раціональну схему організації процесу глибокого навчання в умовах дефіциту навчальних даних; продемонстровано можливість знаходження оптимального ступеня фіксації шарів під час трансферного навчання (тонкого налаштування) і оптимальної тривалості навчання; продемонстровано залежність від спорідненості базового та цільового датасетів.

3. Обрано найдоцільніший спосіб комплексування результатів виявлення різними сенсорами, а саме поєднання карт ймовірностей, отриманих незалежно одна від одної. Такий підхід дозволяє абстрагуватися від особливостей конкретного методу машинного та/або глибокого навчання.

4. Таким чином, методи побудови процесу глибокого навчання і комплексування результатів виявлення сенсорами різної фізичної природи поєднано в методику виявлення малорозмірних компактних об'єктів, що орієнтована на специфіку виявлення поверхневих мін у гуманітарному розмінуванні і ставить пріоритетом легкість масштабування системи.

Список використаних джерел

- Денисов, І., & Матвійчук, Ю. (2024). Аналіз засобів дистанційного мінування, виклики та новітні технології для забезпечення ефективності та безпеки в сучасних військових конфліктах. In *Proceedings of V International Scientific and Practical Conference “Ricerche Scientifiche e Metodi Della Loro Realizzazione: Esperienza Mondiale e Realtà Domestiche”* (pp. 167–172). Associazione Italiana di Storia Urbana. <https://doi.org/10.36074/logos-26.04.2024.034>
- Baur, J., Lekhak, S., Steinberg, G., Nikulin, A., Smet, T. D., Brinkley, A., Ientilucci, E. J., Nitsche, F., Myers, H., Elliott, J., Bauch, T., Raqueno, N., & Frucci, J. (2026). A Comparative Evaluation of UAV-Based Remote Sensing and Geophysical Techniques for Landmine Detection on a Seeded Minefield. Preprints. <https://doi.org/10.20944/preprints202605.0758.v1>
- Elmenreich, W. (2002). *An introduction to sensor fusion* (Technical Report No. 502, pp. 1–28). Vienna University of Technology.
- Hutsul, T., Khobzei, M., Tkach, V., Krulikovskiy, O., Moisiuk, O., Ivashko, V., & Samila, A. (2024). Review of approaches to the use of unmanned aerial vehicles, remote sensing and geographic information systems in humanitarian demining: Ukrainian case. *Heliyon*, 10(7), Article e29142. <https://doi.org/10.1016/j.heliyon.2024.e29142>

Kirkpatrick, J., Pascanu, R., Rabinowitz, N., Veness, J., Desjardins, G., Rusu, A. A., & Hadsell, R. (2017). Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences*, 114(13), 3521–3526.

<https://doi.org/10.48550/arXiv.1612.00796>

Narkhede, P., Walambe, R., & Kotecha, K. (2023). Sensor fusion methodologies for landmine detection. In M. Saraswat, C. Chowdhury, C. K. Mandal, & A. H. Gandomi (Eds.), *Lecture Notes in Networks and Systems: Vol. 551* (pp. 891–907). Springer. https://doi.org/10.1007/978-981-19-6631-6_62

Popov, M. O., Stankevich, S. A., Mosov, S. P., Dugin, S. S., & Saprykin, I. Y. (2023). Drone-based landmine detection mission planning. In *Proceedings of the 7th International Conference on Methods and Systems of Navigation and Motion Control* (pp. 151–154). IEEE.

<https://doi.org/10.1109/MSNMC61017.2023.10329129>

РОЗДІЛ 4

ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ РОЗРОБЛЕНОЇ МЕТОДИКИ ВИЯВЛЕННЯ КОМПАКТНИХ ОБ'ЄКТІВ

Експериментальне дослідження було проведене із застосуванням даних, отриманих на спеціально облаштованому полігоні, переважно вкритому низькою рослинністю, із фрагментами асфальту та гравію, що відповідають умовам розташування мін у реальності. Відмінністю умов полігону від реальності було те, що міни встановлювалися перед початком робіт, а не перебували там тривалий час. Втім, більше наближення до реальних умов має відбуватися на випробувальних стадіях, на початковій стадії ж пріоритетною задачею є швидке накопичення навчальних даних. Був використаний набір протитанкових та протипіхотних мін радянських і російських моделей, більшість із яких може бути встановлена роботизованими комплексами чи розповсюджена з БПЛА, як із металевими, так і з пластиковими корпусами. Було зібрано підбірки RGB- та теплових зображень із застосуванням ряду моделей комерційних БПЛА та камер, а також магнітометричних даних із використанням експериментального магнітометра. Варто зазначити, що облаштування полігону для виявлення поверхневих мін є значно простішою задачею, ніж для мін, прихованих під шаром ґрунту.

4.1. Застосування розробленої методики для виявлення мін на аерозображеннях за допомогою згорткових нейронних мереж

Виявлення поверхневих мін за допомогою згорткових нейронних мереж було започатковане у дослідницьких центрах розвинених країн, які формулювали свою місію як гуманітарну, передусім для допомоги країнам,

постраждалим від минулих конфліктів (Baur et al., 2020). На початку використовувалися модифікації архітектури R-CNN, згодом і до сьогодні перевагу отримали мережі архітектури YOLO.

Перевагою мережі YOLO з перших її версій були швидкодія і порівняно менша вибагливість до ресурсів, що дуже важливо для перспектив масштабування рішень на її основі. Згодом інші характеристики також були доведені до конкурентоспроможного рівня. На даний час фактично архітектура YOLO є першим вибором для виявлення компактних об'єктів на RGB-зображеннях (Terven & Cordova-Esparza, 2023).

Вимоги YOLO до навчальних даних значні, хоча й менші порівняно з деякими іншими перспективними архітектурами, як-от трансформери (Deiningner et al., 2022). Тож для спеціалізованих задач проблема нестачі навчальних даних завжди стоїть гостро. Не є винятком і міни, відзняті з БПЛА. Датасети у публічному доступі досить обмежені, хоча прогрес у цьому напрямку спостерігається. Час роботи на спеціалізованих полігонах також дуже обмежений. Тож необхідно вдаватися до певних методів подолання нестачі навчальних даних, таких як аугментація та передавальне навчання.

4.1.1. Навчальний та тестовий датасети

Навчальний датасет, на якому проведені подальші експерименти, складається з шести типів наземних мін: різних варіацій протитанкових мін ТМ – 64 шт., та кількох типів протипіхотних мін, таких як МОН50 – 378, МОН90 – 108, МОН100 – 42, МОН200 – 30, ПМН2 – 16, ПФМ1 – 52, всього – 690 елементів. Зображення для ПФМ1 були взяті з публічного набору даних Бінгемтонського університету (Binghampton, 2025). Зображення для решти були відзняті спеціально на військових полігонах України.

Навчати мережу “з нуля” на основі такого обмеженого набору даних недоцільно. Штучне нарощування (*аугментація*) даних може допомогти до певної міри, і цією процедурою не варто нехтувати, але потрібно зважати на те, що здатність до генералізації за застосування лише цього підходу буде обмеженою. Власне, окрім обмеженої кількості зображень, самі властивості мін як одноманітних об’єктів не сприяють генералізації.

Більш ефективним способом є трансферне (передавальне) навчання (тонке налаштування) (*transfer learning, fine-tuning*), засноване на великих універсальних датасетах. У нашому випадку датасети Microsoft Common Objects in Context (Lin et al.,2014) (далі за текстом COCO) та Google Open Images V7 (Krasin et al.,2017) (далі – OIV7) були обрані як базові. Тестування проводилося на наборі даних, також зібраному на українських полігонах, який був трохи менш деталізованим і мав дещо іншу кольорову гаму порівняно з навчальним, що сприяло перевірці здатності до генералізації. Приклади зображень наведені на рис. 4.1.



Рис. 4.1. Навчальний (а) та тестовий (б) датасети

4.1.2. Досліджувані архітектури та моделі нейромереж

Базовою моделлю, обраною для експерименту, була модель *small* зі стандартного набору конфігурацій YOLO – *nano, small, medium, large* та *extra*

large (Ultralytics, 2023). Експеримент показав, що моделі *small* та *medium* є найбільш придатними для цієї мети. Модель *nano* виявилася недостатньою, середня ж не дає значної переваги порівняно з малою, а велика є надлишковою.

Для оцінки детектора використовувалися стандартні показники, такі як *влучність* P (*precision*) та *повнота* R (*recall*), які розраховуються як (4.1) та (4.2) відповідно:

$$P = \frac{TP}{FP + TP} \quad (4.1)$$

де TP – *true positives*, FP – *false positives*

$$R = \frac{TP}{FN + TP} \quad (4.2)$$

де FN – *false negatives*

Найважливішим показником для виявлення наземних мін є R (*recall*, *повнота*), тому він використовується для ілюстрації результатів тестування.

Також загальноприйнятим показником якості детектора об'єктів є *узагальнена середня влучність* (*mean average precision*, mAP), зазвичай представлена у двох варіантах – $mAP50$ та $mAP50-95$. Вона запроваджується через ще один важливий показник IoU (*Intersection over Union*, *відношення перетину до об'єднання*), що являє собою відношення площі перетину, визначеного детектором, та істинного розташування об'єкта, до їх об'єднання.

Відповідно, $mAP50$ рахується за значення $\text{IoU} \geq 0,5$, а $mAP50-95$ — як середнє значення за рядом значень IoU від 0,5 до 0,95.

Для спрощення на графіках показано три типи мін: протитанкові ТМ та протипіхотні МОН50 і МОН200. Їх достатньо для того, щоб

продемонструвати дисбаланс класів, спричинений різною їхньою спорідненістю з класами базового датасету.

4.1.3. Підбір базових датасетів

Великою гуманітарною проблемою є схожість мін зі звичайними предметами, і особливо з іграшками, але ця ж обставина є сприятливою для підбору базових датасетів для передавального навчання. У датасетах загального користування, що з'явилися у публічному доступі завдяки бурхливому розвитку технологій комп'ютерного зору, є багато предметів зі спорідненими рисами з мінами, що, власне, є передумовою успішного передавального навчання.

4.1.3.1. Вплив сумісності класів базового та цільового датасетів

Одним із аспектів цього дослідження є демонстрація впливу базового датасету на кінцевий результат. Можна стверджувати, що всі міни з набору мають базові спільні візуальні риси, також притаманні ряду побутових предметів, представлених у базових датасетах, що, власне, і є запорукою успіху передавального навчання (тонкого налаштування). Однак різні міни мають різну репрезентацію своїх розпізнавальних ознак вищого порядку в базовому датасеті. Це можна проілюструвати досить простим експериментом: навчену на базовому датасеті мережу можна застосувати для виявлення об'єктів у цільовому (тренувальному) датасеті.

Таблиця 4.1. Відповідність цільового та базового датасетів

 a)	 б)	 в)
frisbee: 100% 0,9	bottle: 29,1 0,2 skateboard: 3,4 0,27 fire hydrant: 14 0.12 snowboard: 2.6 0.2 frisbee: 21.4 0.35 parking meter: 1.3 0.18 baseball bat: 0.5 0.09 bird: 8.7 0.08 kite: 5 0.24	bowl: 1.3 0.02 cell phone: 0.8 0.14 sports ball: 0.3 0.02 toothbrush: 4.2 0.19 elephant: 1.1 0.05 surfboard: 0.5 0.23 umbrella: 0.5 0.12 train: 0.5 0.09
		bottle: 7 0,28 fire hydrant: 7 0,2 frisbee: 73 0,67 sports ball: 7 0,8 orange 7 0,33

У таблиці наведено результат експерименту, який показує різницю в балансі інформації у базовому датасеті між ТМ та МОН. Нижній рядок демонструє об'єкти базового датасету Microsoft COCO, асоційовані з мінами навчального датасету. Міна ТМ чітко асоціюється з одним класом базового датасету, до того ж із великою оцінкою достовірності, що свідчить про те, що базова мережа вже має набір рис – від базових до вищих для класу ТМ. Міни МОН асоціюються з цілим набором об'єктів базового набору з невисокою достовірністю, що вказує на відсутність чітко вираженого набору високорівневих ознак у базовому наборі або, принаймні, на їх розмиття між множиною класів. Експеримент показав, що результати тестування після тонкого налаштування для цих мін також помітно відрізняються від результатів ТМ.

Датасет Google OIV7 (далі OIV7) (Kuznetsova et al., 2020) є значно потужнішим за датасет COCO. У таблиці наведено кількісне порівняння

датасетів. Експерименти продемонстрували можливість отримання більш збалансованого результату на його основі.

Табл. 4.2. Порівняння датасетів Microsoft COCO та Google OIV7

Датасет	COCO	OIV7
кількість класів	80	601
кількість зображень	118000	9000000
кількість обмежувальних рамок (анотованих об'єктів)	не вказано	16000000

4.1.4. Пошук оптимальних гіперпараметрів і результати тестування на базовому датасеті

В експерименті мережа YOLO навчалася зі змінною кількістю епох тренування — циклів обробки всього набору даних — і зі змінною кількістю фіксованих (frozen) шарів секції нейромережі, відомої як основа (backbone), що відповідає за екстракцію характерних рис об'єктів пошуку.

Фіксація (*freeze*) шару означає, що коефіцієнти ряду низько- і середньорівневих шарів не змінюються під час навчання. Тут і далі кількість фіксованих шарів згадується відповідно до параметра *freeze* в API Ultralytics (Ultralytics, 2025), який було використано в експериментах. Стартова кількість епох навчання була обрана рівною 20, що критично мало для навчання з нуля, але за припущенням експерименту достатньо для тонкого налаштування нейромережі, яка вже містить певну інформацію про базові риси.

Тренуючи всю базову мережу цілком, без фіксації шарів, отримуємо досить посередній результат для мін ТМ та незадовільний — для МОН50 і МОН200. Як кількості зображень, так і кількості епох навчання (20 в експерименті) недостатньо для вивчення нейромережею складних ознак

МОН. Однак результат набагато кращий для ТМ, оскільки початкова мережа містить значно більше релевантної інформації, представленої під маркером “*frisbee*”.

4.1.4.1. Зміна кількості фіксованих шарів нейромережі

Коли кількість фіксованих шарів нейромережі змінюється до 5, виявлення МОН різко покращується, для ТМ — дещо покращується. Це пояснюється тим, що перші п’ять шарів початкової мережі містять багато корисної інформації для виявлення МОН50, яка знищується так званим *катастрофічним забуванням* (Kirkpatrick et al., 2017) у випадку нульового числа фіксованих шарів.

Фіксація більшої кількості шарів (7 та 10) не покращує ситуацію, а навіть погіршує її для МОН50, оскільки ці наступні шари відповідальні за більш специфічні високорівневі риси, які не представлені в базовій мережі для МОН50, на відміну від ТМ, для якої відбувається поступове покращення від нуля до десяти фіксованих шарів.

Моделі *nano* та *medium* мережі YOLO, що розглядалися як альтернативи моделі *small*, також були протестовані таким самим чином, показавши подібні результати, але з деякими нюансами. Результати тестування (криві достовірність-повнота) представлені на рис. 4.2-4.4.




Рис. 4.2. Криві повнота-достовірність (*recall-confidence*) виявлення мін ТМ, МОН50 та МОН200 за допомогою моделі *nano* мережі YOLOv11 на базовому датасеті COCO:

а) 3 фіксовані шари, б) 5 шарів, в) 7 шарів, та г) 10 шарів

Для моделі *nano* не вдалося досягти задовільного результату для МОН, проте для МОН50 він дещо покращився на 7 фіксованих шарах. Загалом, експеримент показав, що можливостей моделі *nano* недостатньо для досягнення мети. Ймовірно, обсягу інформації, успадкованої з набору даних COCO в цій моделі, недостатньо для повноцінної трансформації до рис МОН.




Рис. 4.3. Крива повнота-достовірність (*recall-confidence*) виявлення мін ТМ, МОН50 та МОН200 за допомогою моделі *small* мережі YOLOv11 на базовому датасеті COCO, 20 епох навчання:

а) тренування без фіксації шарів, б) 3 фіксовані шари, в) 5 шарів, г) 7 шарів, д) 10 шарів




Рис. 4.4. Крива повнота-достовірність (*recall-confidence*) виявлення мін ТМ, МОН50 та МОН200 за допомогою моделі *medium* мережі YOLOv11 на базовому датасеті COCO:

а) 3 фіксовані шари, б) 5 шарів, в) 7 шарів, г) 10 шарів, д) 13 шарів

У випадку застосування моделі *medium* оптимальна кількість фіксованих шарів збільшилася до 7–10 з 5, що спостерігалися для моделі *small*, ймовірно, через дещо інший розподіл ознак у більшій мережі. Але при збільшенні кількості фіксованих шарів до 13 спостерігається погіршення точності виявлення МОН.

4.1.4.2. Зміна кількості епох навчання

Важливим питанням є визначення оптимальної тривалості навчання або кількості епох у контексті глибокого навчання. Виходячи з 20 епох, використаних як початкова оцінка їх кількості, було випробувано від 12 до 25 епох для моделі *small* та від 15 до 30 для моделі *medium*.

На наступних графіках спостерігається помітна різниця в точності між 12-ю та 15-ю епохами, а також між 5-м та 7-м фіксованими шарами. Відбувається погіршення повноти на 25-и епохах для МОН200 та нестабільність для інших типів мін. Найкраща точність забезпечується, коли кількість епох становитиме близько 15 для малої моделі. Крім того, зміни показників суттєво відрізняються для різних класів — ймовірно, залежно від двох основних факторів: перший — подібність до оригінального набору даних (COCO), інший — представленість та мінливість зображень цього типу міни в цільовому датасеті. Наступний рисунок показує результати аналогічного тестування для моделі *medium* нейромережі YOLOv11.




Рис. 4.5. Крива повнота-достовірність (*recall-confidence*) виявлення мін ТМ, МОН50 та МОН200 за допомогою моделей *small* (а, б) та *medium* (в, г) мережі YOLOv11 на базовому датасеті COCO. Для моделі *small* фіксовано 5 (а) та 7 (б) шарів, кількість епох складає 12, 15, 20, 25 згори донизу. Для моделі *medium* фіксовано 7 (в) та 10 (г) шарів, кількість епох навчання – 15, 20, 23, 25, 30 згори донизу

На рис. 4.5 показано, що максимум повноти (*recall*) для моделі *medium* досягається на 25 епохах, а вже на 30 спостерігається деградація. Знову ж таки, деградація є більш драматичною для МОН200, яка погано представлена в навчальному наборі даних, і не є надто критичною для інших. Оптимальна кількість епох вища для більшої мережі (близько 25 для моделі *medium*, близько 15 – для *small*), що є очікуваним результатом. Здатність до узагальнення, яка деградує внаслідок перенавчання, очевидно, є більш критичною для МОН через їхні складніші ознаки форми.

Ще один важливий висновок полягає в тому, що немає суттєвої різниці між малими та середніми моделями для задачі виявлення поверхневих мін, тому доцільно використовувати саме малу модель у критичному за обчислювальним ресурсом середовищі, наприклад, такому, як бортовий комп'ютер БПЛА.

Результатів проведених експериментів, очевидно, недостатньо для повного узагальнення або універсальних рекомендацій щодо оптимальної кількості фіксованих шарів нейромережі чи навчальних епох. Але виявлено, що оптимальні значення цих гіперпараметрів відрізняються для різних типів мін, і причина цього може полягати не лише в власних особливостях цих мін і їх репрезентації в навчальному датасеті, а й у різній спорідненості класів цільового та базового датасетів.

4.1.5. Зміна базового датасету

Датасет Google OIV7 (далі – OIV7) є значно потужнішим за датасет COCO. Нижче наведено результати виявлення мін для моделі *small* мережі YOLOv8 із базовим датасетом OIV7.




Рис. 4.6. Крива повнота-достовірність виявлення мін за допомогою моделі *small* мережі YOLOv8, навченої 20 епох, для 0, 5, 7, 10 фіксованих шарів




Рис. 4.7. Крива повнота-достовірність виявлення мін за допомогою моделі *small* мережі YOLOv8, навченої 18, 20, 23, 25 епох, для 5 фіксованих шарів

Приведені графіки ілюструють ту саму закономірність — існують оптимальні значення кількості епох і фіксованих шарів. При цьому залучення потужнішого базового датасету OIV7 забезпечує більш збалансовані за типами мін результати, ніж з простим базовим датасетом COCO. Зокрема, при 20 епохах і 5 шарах спостерігається оптимальний показник повноти для всіх мін. Це можна пояснити тим, що у OIV7 рівномірніше представлені базові риси всіх об'єктів розпізнавання.

Варто врахувати, що з датасетом OIV7 тестувалася рання версія YOLOv8, забезпечуючи при цьому результат, кращий, ніж YOLOv11 з базовим COCO, ілюструючи тим самим відомий факт, що дані грають не меншу, а часто більшу роль, ніж архітектура нейромережі. З іншого боку, результати для моделі *medium* при цьому не кращі за *small*.




Рис. 4.8. Криві повнота-достовірність виявлення мін за допомогою моделі *medium* мережі YOLOv8, 25 епох навчання, для 6, 7, 8, 9 фіксованих шарів




Рис. 4.9. Криві повнота-достовірність виявлення мін за допомогою моделі *medium* мережі YOLOv8, 20, 23, 25 епох навчання, 7 фіксованих шарів




Рис. 4.10. Порівняння виявлення мін за допомогою моделі *small* мережі YOLOv8 на базовому датасеті COCO (а), моделі *small* мережі YOLOv11 на базовому датасеті COCO (б) та моделі *small* мережі YOLOv8 на базовому датасеті OIV (в); для всіх – 20 епох навчання, 5 фіксованих шарів

Рисунок 4.10 демонструє два можливі шляхи покращення слабого результату виявлення мін: *a-b* – перехід на новішу, досконалішу архітектуру або *a-в* – використання потужнішого датасету як базового. У цьому випадку другий варіант кращий.

4.1.6. Порівняння результатів виявлення мін

Стандартною практикою оцінки ефективності застосування нейромереж для виявлення і класифікації є порівняння показників *mAP50* або *mAP50-95*, які є певними інтегральними показниками і мають бути обчислені на репрезентативному датасеті, хоча й традиційно меншому, ніж навчальний. Стосовно поверхневих мін, відзнятих з БПЛА, доцільно запровадити правило сталості просторової розрізненості тестових датасетів, щоб показники відображали ефективність для конкретних відтворюваних параметрів місії БПЛА.

4.1.6.1. Використання базового датасету Microsoft COCO, мережа YOLOv11

Нижче у таблицях наведені показники для різних класів окремо і узагальнені у розрізі кількості навчальних епох і фіксованих шарів, червоним виділені незадовільні показники, синім – найкращі з досягнутих у експерименті для окремої мережі і типу міни, у нижньому рядку показаний результат при комплексуванні кількох мереж, оптимальних для окремих класів, шляхом вибору найкращих значень.

Таблиця 4.3. Показники навчання моделі *small* мережі YOLOv11

Кількість		Тип міні							
		TM		MON50		MON200		Total	
епох навч.	фікс. шарів	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$
20	0	0,952	0,786	0,556	0,336	0,156	0,0579	0,555	0,393
15	5	0,995	0,844	0,992	0,656	0,95	0,503	0,979	0,668
15	7	0,995	0,876	0,97	0,653	0,65	0,479	0,872	0,669
17	5	0,995	0,873	0,992	0,675	0,787	0,569	0,925	0,706
17	7	0,989	0,827	0,788	0,494	0,593	0,443	0,79	0,588
20	5	0,952	0,837	0,963	0,596	0,649	0,453	0,855	0,629
20	7	0,995	0,884	0,624	0,392	0,967	0,755	0,862	0,677
комплекс		0,995	0,884	0,992	0,675	0,967	0,755	0,987	0,771

Таким чином, спостерігаємо зміну показника $mAP50$ від 0,555 на початку процесу удосконалення до 0,978, а $mAP50-95$ — від 0,393 до 0,771.

Таблиця 4.4. Показники навчання моделі *medium* мережі YOLOv11

Кількість		Тип міні							
		TM		MON50		MON200		Total	
епох навч.	фікс. шарів	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$
20	0	0,821	0,721	0	0	0	0	0,274	0,24
25	0	0,947	0,847	0	0	0	0	0,316	0,282
20	7	0,995	0,851	0,934	0,663	0,939	0,655	0,956	0,723
20	10	0,995	0,88	0,889	0,576	0,969	0,696	0,951	0,717
23	7	0,995	0,848	0,995	0,648	0,959	0,674	0,983	0,723
23	10	0,995	0,884	0,935	0,546	0,993	0,789	0,974	0,74
25	7	0,995	0,861	0,995	0,532	0,924	0,716	0,971	0,703
25	10	0,995	0,882	0,944	0,587	0,944	0,692	0,961	0,72
комплекс		0,995	0,882	0,995	0,663	0,993	0,789	0,994	0,778

Для моделі *medium* мережі YOLOv11 на початку процесу удосконалення прийнятна якість забезпечується лише для мін ТМ. Значення *mAP*50 змінюється від 0,274 до 0,316 та від 0,944 до 0,944; *mAP*50-95 – від 0,24 до 0,28 та від 0,778 до 0,778.

4.1.6.2. Використання базового датасету Google Open Images V7, мережа YOLOv8

Для цього дослідження були доступні лише моделі YOLOv8, навчені на OIV7, проте було отримано прийнятні робочі показники.

Таблиця 4.5. Показники навчання моделі *small* мережі YOLOv8

Кількість		Тип міні							
		ТМ		MON50		MON200		Total	
епох навч.	фікс. шарів	<i>mAP</i> 50	<i>mAP</i> 50-95	<i>mAP</i> 50	<i>mAP</i> 50-95	<i>mAP</i> 50	<i>mAP</i> 50-95	<i>mAP</i> 50	<i>mAP</i> 50-95
20	4	0,995	0,88	0,884	0,557	0,933	0,737	0,937	0,724
20	5	0,995	0,872	0,992	0,602	0,951	0,749	0,98	0,741
20	6	0,987	0,827	0,983	0,492	0,087	0,046	0,685	0,455
22	5	0,995	0,872	0,992	0,602	0,951	0,749	0,98	0,741
22	6	0,988	0,859	0,948	0,559	0,721	0,41	0,886	0,609

Варто зауважити, що використання значно потужнішого базового датасету призвело до більш збалансованих показників між класами.

Таблиця 4.6. Показники навчання моделі *medium* мережі YOLOv8

Кількість		Тип міни							
		TM		MON50		MON200		Total	
епох навч.	фікс. шарів	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$	$mAP50$	$mAP50-95$
25	25	0,995	0,884	0,95	0,566	0,746	0,368	0,897	0.606
25	25	0,958	0,843	0,995	0,576	0,95	0,667	0,968	0.695
25	25	0,937	0,814	0,905	0,563	0,99	0,851	0,944	0.743
комплекс		0.995	0,884	0,995	0,576	0,99	0,851	0,99	0,77

При тренуванні нейромережі в режимі єдиного класу на базі датасету, класи якого мають споріднені ознаки, що вірно у випадку мін, перехід до режиму єдиного класу призводить до покращення характеристик. Найкращий результат було досягнуто для конфігурації *medium* мережі YOLOv11, 23 епохи навчання, 10 фіксованих шарів, з базовим датасетом COCO. Можливо, для моделі *medium* мережі YOLOv11 з базовим датасетом OIV7 можна досягнути ще кращого результату – це один з напрямків майбутніх досліджень.

Таблиця 4.7. Результати тестування конфігурації мережі із тренуванням в режимі єдиного класу

Нейро-мережа	Модель	кількість		базовий датасет	P (влучність)	R (повнота)	$mAP50$	$mAP50-95$
		епох навч.	фікс. шарів					
YOLOv8	<i>small</i>	20	5	OIV7	0,747	0,989	0,865	0,707
YOLOv8	<i>medium</i>	25	7	OIV7	0,75	0,989	0,878	0,716
YOLOv11	<i>small</i>	20	5	COCO	0,612	0,817	0,613	0,447
YOLOv11	<i>medium</i>	23	10	COCO	0,684	1	0,878	0,702

Варто зазначити, що отримані показники досягаються за дуже малої кількості даних і тривалості навчання, що дозволяє віднести застосований підхід до технік *пришвидшеного навчання (few-shot learning)* (Zhang & Liu, 2023).

Для порівняння з найкращими досягнутими показниками точності досліджених нейромереж після тонкого налаштування — в табл. 4.8 наводяться значення показника *mAP50-95* для нейромереж архітектури YOLO на базовому датасеті COCO згідно з документацією компанії-розробника Ultralytics (Ultralytics, 2025).

Таблиця 4.8. Порівняння показника *mAP50-95* нейромереж YOLO для датасету COCO та для цільового датасету з виявлення мін

Нейро-мережа	модель	Кількість		Значення mAP50-95, датасет COCO	Найкраще значення	
		епох навч.	фікс. шарів		mAP50-95, датасет COCO	mAP50-95, датасет OIV7
YOLOv8	<i>small</i>	22	5	0,449		0,741
YOLOv8	<i>medium</i>	25	8	0,502		0,743
YOLOv11	<i>small</i>	17	5	0,47	0,706	
YOLOv11	<i>medium</i>	23	10	0,515	0,74	

У нейромережевому інструментарії компанії Ultralytics набагато краще представлений датасет Microsoft COCO, який є компромісом повноти й економічності. Датасет Google OIV7 представлений менше, зокрема, поки що не доступні широкому загалу тренувані на ньому мережі YOLOv11. Одна з причини може полягати в тому, що відповідно до розміру датасету, таке тренування потребує значних обчислювальних потужностей. Одним із можливих напрямків майбутніх досліджень має стати використання датасету OIV7 разом з нейромережею YOLOv11.

4.2. Тестування розробленої методики на реальних аерозображеннях

Щодо роботи із реальними зображеннями, отриманими з БПЛА, сучасні нейромережеві бібліотеки використовують два підходи. У деяких випадках зображення обробляється як цілісне, покладаючись на здатність мережі до сприйняття варіювання розмірів, що притаманне всім версіям YOLO, окрім початкових (Terven & Cordova-Esparza, 2023). Цей спосіб прийнятний у випадку незначної різниці в розмірах зображень порівняно з тими, що були використані під час навчання.

Більш строгий підхід полягає у розбитті зображення з перекриттям на фрагменти, що точно відповідають розміру навчальних зображень. Хоча час обробки при цьому збільшується, це дає можливість при цьому покладатися на дані показників ефективності, обчислених бібліотекою на базі тестового датасету із відомою просторовою розрізненністю, і відповідно, параметрами місії БПЛА. Тому для виявлення мін варто віддавати перевагу другому способу.

4.2.1. Тестування розробленої методики на RGB аерозображеннях з визначенням класів мін

Результати отримано шляхом розбиття вхідного зображення на блоки розміром 640×640 пікселів. Для цього використано метод SAHI (Akyon et al., 2022), реалізований однойменною програмною бібліотекою.



Рис. 4.11. Цілісне аерозображення, фрагменти якого були використані для тестового датасету. Розпізнавання виконувалося за допомогою донавченої неймережі YOLOv8, модель *small*, базовий датасет OIV7, 20 епох навчання, 5 фіксованих шарів



Рис. 4.12. Результат виявлення мін за допомогою донавченої без фіксації неймережі YOLOv8, модель *small*

Як впливає з порівняння рис. 4.11 і рис. 4.12, правильно донавчена модель виявляє всі 16 мін, у той час як донавчена без урахування необхідності фіксації шарів модель – 12, отже, отримується 25 % приросту за однакової порогової достовірності, що сприяє усуненню “хибних тривог”.

На рис. 4.13, рис. 4.14 наведені результати виявлення мережею, навченою у режимі єдиного класу, тобто без можливості класифікації. Цей спосіб дозволяє отримати певний приріст показників виявлення за рахунок спільних ознак у різних типах мін, що засвоюються мережею більш концентровано.



Рис. 4.13. Результат виявлення мін нейромережею YOLOv11, тренуваною у режимі єдиного класу, модель *small*, 20 епох навчання, 5 фіксованих шарів



Рис. 4.14. Результат виявлення мін нейромережею YOLOv11, тренованою у режимі єдиного класу, модель *medium*, 23 епохи навчання, 10 фіксованих шарів

Значення ключових показників для наведених моделей.

У таблиці 4.9 представлено зміну показників від найгірших до найкращих із досягнутих. Варто зауважити, що різні розмірності (*small* та *medium*) моделі показують різні кращі показники, отже, необхідно обирати показник, який є пріоритетним для конкретної задачі. У випадку мін важливішим є показник повноти R (recall).

Табл. 4.9. Порівняння показників, впорядковані за показником повноти R (recall)

Нейро-мережа	Модель	Базовий датасет	кількість		Показник		
			епох навч.	фікс. шарів	<i>recall</i>	<i>mAP50</i>	<i>mAP50-95</i>
YOLOv11	<i>small</i>	Google OIV7	20	0	0,535	0,59	0,456
YOLOv11	<i>small</i>	Google OIV7	20	5	0,903	0,98	0,741
YOLOv11	<i>small</i>	Google OIV7, єдиний клас	20	5	0,989	0,865	0,707
YOLOv11	<i>medium</i>	Google OIV7, єдиний клас	25	8	1	0,824	0,667

В результаті аналізу табл. 4.9 можна зробити висновок, що підбір гіперпараметрів в результаті донавчання призводить до суттєвого покращення точності донавченої нейромережі, а максимального рівня повноти (*recall*) сягає у результаті тренування в режимі єдиного класу.

4.2.2. Тестування розробленої методики на RGB аерозображеннях в режимі єдиного класу

Фото рис. 4.15 демонструє покращену здатність тренованої у режимі єдиного класу нейромережі до генералізації. До навчального датасету з круглих протипіхотних мін входили тільки ПМН-2, однак на аерозображенні також виявлено міни ПМН, ПМН-4 та міну ОЗМ. Рівень хибної тривоги низький, хоча й не нульовий.



Рис.4.15. Виявлення мін за допомогою моделі *medium* нейромережі YOLOv11, тренованої в режимі єдиного класу, 23 епохи навчання, 10 фіксованих шарів

На наступному фото – рис. 4.16 – наведено приклад значного рівня хибної тривоги через схожість каміння з мінами ПФМ1 “Пелюстка”. Хибні виявлення такого типу є об’єктивними; їх подолання вимагає зміни підходу до складання датасету і, можливо, до порядку донавчання. Наявність таких хибних виявлень можна вважати платою за здатність мережі до генералізації.



Рис. 4.16. Виявлення мін за допомогою моделі *medium* нейромережі YOLOv11, тренуваної в режимі єдиного класу, 23 епохи навчання, 10 фіксованих шарів

4.3. Тестування розробленої методики на реальних теплових аерозображеннях

Теплові зображення є чи не найуніверсальнішим джерелом інформації для виявлення мін як поверхневих, так і прихованих і виготовлених із будь-яких матеріалів. На жаль, вони також не позбавлені обмежень, але ці обмеження іншого, часового характеру. До того ж, вони мають фізично обумовлено нижчу просторову розрізненність ніж RGB для певної висоти

знімання, отже, у застосуванні до поверхневих мін доречно поставити теплові зображення на друге місце після RGB.

4.3.1. Особливості теплових аерозображень при виявленні мін

Так само, як і RGB-зображення, теплові зображення у даному дослідженні використовуються для виявлення поверхневих компактних об'єктів, а саме — протитанкових та протипіхотних мін. Деякі дослідження показують, що для однакової висоти знімання теплові зображення, так само як і багатоспектральні, показують дещо меншу точність виявлення поверхневих мін, ніж RGB (Baur & Nitsche, 2025), що спричинено насамперед об'єктивно фізично обумовленою різницею у просторовій розрізненості не на користь теплових зображень. Тому в цьому дослідженні вони розглядаються як допоміжні. Також слід зазначити, що результати роботи з тепловими зображеннями суттєво залежать від умов аерознімання (Лялько та ін., 2015; Мосов та ін., 2017). У гуманітарному розмінуванні, яке в першу чергу стосується цього дослідження, доводиться мати справу з мінами, які тривалий час перебувають у середовищі. За короткого відвідування полігону можливо відтворити лише умови, за яких міни встановлені нещодавно. Втім, важливо визначити сам принцип комплексування результатів обробки.


Ще одна особливість теплових зображень полягає в тому, що поки що відсутні датасети із широким набором об'єктів, подібні до Microsoft COCO та Google OIV, які можуть бути використані для базового навчання — переважна більшість теплових датасетів вузькоспеціалізовані. Отже, той підхід, який був застосований для RGB-зображень (передавальне донавчання, тонке налаштування), важче реалізувати для теплових зображень, і, скоріше, доцільно навчати нейромережі за власними датасетами. До сприятливих

обставин слід віднести те, що в багатьох випадках міни, розташовані у природному середовищі, мають високий тепловий контраст.


Спираючись на вищенаведене, можна стверджувати, що роль теплових зображень (у порівнянні з RGB) змістилася від класифікації конкретних об'єктів до більш загального виявлення температурних аномалій, що робить можливим використання таких зображень як допоміжних до RGB. Але за наявності достатньої кількості якісних зображень — як навчальних, так і тестових — вони можуть виконувати функцію основного джерела інформації для виявлення компактних об'єктів із застосуванням неймереж.

4.3.2. Результати навчання неймережі та виявлення мін на теплових зображеннях

Досліджувалася можливість використання теплових аерозображень високої просторової розрізненості для навчання неймережі. Було отримано два набори аерозображень високої просторової розрізненості від бортових камер DJI ZH20T та DJI FC2403, встановлених на БПЛА. Нажаль, єдиною достатньо репрезентованою міною у наборі теплових аерозображень високої розрізненості виявилася протитанкова ТМ у кількох варіаціях, тому результати навчання та тестування наведені для цієї міни.



а) Отримані камерою ZH H20T



б) Отримані камерою M2ED:

високої (зверху) та меншої (знизу) просторової розрізненості

Рис. 4.17. Фрагмент датасета теплових аерозображень протитанкових мін серії ТМ, отриманих камерами БПЛА ZN H20T та M2ED

Результати тестування нейромережі, навченої на створеному датасеті теплових зображень ZN H20T і перевіреної на датасеті M2ED, характеризуються показниками точності, наведеними в табл. 4.10.

Крива достовірність-повнота приведена на рис 4.18.

Табл. 4.10. Результати виявлення мін ТМ на теплових аерозображеннях за допомогою нейромережі, навченої на створених датасетах

Показник	P (влучність)	R (повнота)	$mAP50$	$mAP50-95$
Значення	0,441	0,829	0,456	0,354





Рис. 4.18. Крива достовірність-повнота виявлення мін ТМ нейромережею на теплових аерозображеннях


Різниця RGB та теплових аерознімків, зроблених в рамках одного вильоту БПЛА з однакових висот, разом з різницею в отриманих результатах на прикладі виявлення протитанкової міни TM72, частково заглибленої в ґрунт, ілюструється рис. 4.19.




діаметр міни TM72 250 мм,
на зображенні – 95 пікселів



діаметр міни на зображенні – 30 пікселів



результат виявлення міни неймережею YOLOv11, модель *small*, 25 епох навчання, 7 фіксованих шарів, базовий датасет COCO



результат виявлення міни неймережею YOLOv11, модель *small*, 100 епох навчання, власний датасет

Рис. 4.19. RGB і теплове зображення протитанкової міни TM72, отриманих камерою ZN H20T

Результати тестування виявлення мін за розробленою методикою свідчать про значну перевагу RGB-зображень перед тепловими, отриманими в однакових умовах. Зокрема, на рис. 4.19 оцінка достовірності нейромережою виявлення міни на RGB-зображенні 0,95 суттєво перевищує таку на тепловому зображенні – 0,23. Отже, застосування теплових аерозображень в рамках розробленої методики може розглядатися як допоміжне до RGB аерозображень.

4.3.3. Комплексування RGB та теплових аерозображень при виявленні мін

Комплексування RGB та теплових аерозображень спрямовано на підвищення достовірності виявлення міни через злиття результатів виявлення на RGB- та тепловому зображеннях. Для злиття ймовірностей виявлення міни в видимому та інфрачервоному діапазонах правило Байєса (2.2) набуває вигляд


$$p_{\Sigma} = \frac{p_o \cdot p_{ir}}{p_o \cdot p_{ir} + (1 - p_o) \cdot (1 - p_{ir})} \quad (4.4)$$

де p_{ir} та p_o – значення достовірності, отримані в тепловому та видимому діапазоні відповідно.

На RGB-аерозображенні рис. 4.20 міни МОН50 зливаються з рослинністю, що погіршує достовірність їх виявлення. Натомість, теплове зображення є досить контрастним.



результат виявлення міни нейромережею YOLOv8, модель *small*, 20 епох навчання в режимі єдиного класу, 5 фіксованих шарів, базовий датасет OIV7



результат виявлення міни нейромережею YOLOv11, модель *small*, 75 епох навчання в режимі єдиного класу, власний датасет

Результат злиття імовірностей виявлення мін МОН50 дорівнює 0,46 та 0,39

	Результат злиття імовірностей виявлення мін МОН50 дорівнює 0,92 та 0,82
результат виявлення міни нейромережею YOLOv8, модель <i>medium</i>, 25 епох навчання в режимі єдиного класу, 8 фіксованих шарів, базовий датасет OIV7	

Рис. 4.20. Комплексування RGB та теплового аерозображення для виявлення мін

На наведеному прикладі виявлення поверхневих мін операція злиття ймовірностей не є обов'язковою, оскільки обидва аерозображення — теплове та RGB — окремо дають змогу ухвалити рішення щодо наявності міни. Теплове зображення може бути незамінним під час виявлення поверхневих камуфльованих або заглиблених мін, тому за наявності теплової камери не варто нехтувати отриманням теплового зображення принаймні в межах одного вильоту з використанням RGB-камери. За високої ймовірності камуфлювання мін варто розглядати планування аерозйомки з урахуванням бажаної розрізненості саме теплових зображень.

4.3.4. Визначення мінімально прийнятної просторової розрізненності аерознімання для виявлення мін заданих класів

Лінійні розміри типових наземних мін, що розглядаються, не відрізняються більше ніж у три рази, отже, можна говорити про доцільність і потенційну можливість отримання єдиної тренованої нейромережі, що виявляє міни всіх розмірів. Однак очевидно, що для різних мін межі просторової розрізненності, що забезпечують задовільну надійність, будуть різними. Перш за все, необхідно визначити значення розрізненності, за якого можливе виявлення всіх мін у навчальному наборі. Зробити це можна експериментальним шляхом. Отриманий результат можна вважати орієнтиром, а не обов'язковою вимогою. Достовірність цього показника варто покращувати ітераційно в процесі практичного застосування системи. На рис. 4.21 наведено приклад аерознімка мінімально прийнятної просторової розрізненності.



Рис. 4.21. Результат виявлення мін за допомогою моделі *medium* нейромережі YOLOv11, тренованої в режимі єдиного класу, 23 епохи навчання, 10 фіксованих шарів

Просторова розрізненність аерозображення рис. 4.21 складає біля 6 мм/піксель, з висоти знімання біля 10 м. За такої розрізненності зображення міни ПФМ1 “Пелюстка” має розмір 18×10 пікселів, а найкращий результат для даної розрізненності демонструє донавчена в режимі єдиного класу неймережа YOLOv11, модель *medium*, 23 епохи навчання, 10 фіксованих шарів. Всі міни на аерозображенні виявлено, присутні хибні тривоги, зумовлені дрібним сміттям, візуально близьким до ПФМ1. Неймережі сімейства YOLO демонструють можливість виявляти об’єкти на межі розрізнення людським оком. При цьому граничні лінійні розміри різних типів мін складають: ТМ – 55 пікселів, ПФМ1 – 18×10 пікселів, просторова розрізненність – приблизно 6 мм/піксель. Водночас, розрізнявальні характеристики теплового аерозображення, отриманого у тому ж польоті – рис. 4.22 – значно гірші.




Рис. 4.22. Результат виявлення мін на тепловому аерозображенні за допомогою моделі *medium* неймережі YOLOv11, тренуваної в режимі єдиного класу

Протитанкова міна ТМ на тепловому аерозображенні має розмір 20×20 пікселів і впевнено виявляється, а міни меншого розміру мають гранично малий розмір для виявлення: зображення міни ПФМ1 вироджується до *стохастичної аномалії* і не виявляється.

Отже, для виявлення видимих поверхневих мін без завад і маскування, звичайне аерознімання RGB забезпечує прийнятний результат без додаткового залучення теплових аерозображень. Застосування інфрачервоного аерознімання і, відповідно, планування аерозйомки з нижчих висот, має бути обґрунтоване складними умовами розташування мін – їх заглибленням, камуфлюванням, маскуванням, великою кількістю завад тощо.

4.4. Тестування розробленої методики на реальних магнітометричних даних

Якщо йдеться про поверхневі міни, то їх оптичне виявлення є пріоритетнішим, оскільки на RGB-зображенні можна розпізнати будь-яку міну; можливості магнітометрії ж обмежені лише типами мін, корпуси яких виконані з феромагнетиків. Для мін, що містять окремі металеві деталі, згідно з експериментальними дослідженнями (Chornyy et al., 2024), дуже складно побудувати модель їх виявлення на базі загальнодоступних недорогих магнітометрів.

Однак існують сценарії, у яких застосування магнітометрії для виявлення поверхневих мін може бути доречним.

Очевидний сценарій — коли видимість міни погіршена, наприклад, рослинністю чи ґрунтом, і оптичне виявлення має низьку достовірність. При цьому є висока ймовірність хибної тривоги (Sineglazov et al., 2025). Також варто розглядати варіант камуфлювання поверхневих мін аж до повної

нерозпізнаваності детектором у видимому діапазоні — у такому разі варто розглядати поєднання теплових зображень і магнітометрії.

Менш очевидний сценарій — можливе використання противником муляжів мін, виготовлених не з металу. У такому випадку, магнітометрія допоможе виключити принаймні частину таких випадків хибної тривоги.

4.4.1. Особливості виявлення мін за допомогою авіаційної магнітометрії

Магнітометричне аерознімання дозволяє виявляти міни, у тому числі й заглиблені в ґрунт, за девіаціями магнітного поля, спричиненими металевими елементами конструкції міни. Авіаційні магнітометри виявляють феромагнітну міну як аномалію магнітного сигналу, яку реєструє магнітометр. Але цей сигнал зазвичай є дуже зашумленим, особливо за умови розміщення магнітометра на борту БПЛА (Kuru et al., 2024).

Зазвичай для вимірювання та пригнічення магнітного фону під час виявлення мін використовується цифрова статистична фільтрація сигналу магнітометра. Але в реальних умовах пошуку мін окрім шумового фону завжди присутній квазіпостійний сигнал зовнішньої завади — від металевих споруд, наведення від ліній електропостачання тощо, як правило, суттєво потужніший порівняно з фоновим. У процесі руху РП квазіпостійний завадовий сигнал під час магнітометричних вимірювань із БПЛА утворює лінійний або нелінійний тренд, спричинений зміщенням носія магнітометра відносно джерела завади. Наявність тренду у зареєстрованому сигналі унеможливорює виявлення мін як безпосередньо, так і за допомогою смугової фільтрації. Для розв'язання зазначеної проблеми здійснюється вилучення тренду із сигналу, зареєстрованого магнітометром (Попов та ін., 2024). На рис. 4.23 і рис. 4.24 показані результати фільтрації та вилучення тренду з

магнітометричних вимірювань під час проходження носія магнітометра над міною.




Рис. 4.24. Попередня обробка результатів магнітометричних вимірювань з БПЛА:

ліворуч – міни МОН-100, праворуч – міни ТМ-62М

a – вхідний магнітний сигнал, *б* – відфільтрований сигнал, *в* – сигнал після вилучення тренду

Після завершення попередньої обробки магнітного сигналу стає можливим коректне виявлення за ним аномалії, що відповідає міні.

4.4.2. Комплексування магнітометричної та оптичної аерозйомки при виявленні мін

У гуманітарному розмінуванні магнітометричне обстеження ділянки часто проводиться незалежно від результатів оптичного аерознімання, оскільки майже завжди постає і задача пошуку прихованих чи заглиблених мін. Тоді під час обробки наявність додаткової магнітометричної інформації дозволить підвищити достовірність виявлення поверхневих мін. Результиуюча достовірність p_{Σ} буде обчислюватися за правилом Байєса (Narkhede et al., 2023).

$$p_{\Sigma} \cong \frac{p_o \cdot p_m}{p_o \cdot p_m + (1 - p_o) \cdot (1 - p_m)} \quad (4.5)$$

де p_o – достовірність виявлення в оптичному діапазоні, p_m – достовірність за даними магнітометрії

Коригувати достовірність буде доцільно лише в ділянках, де міні виявлено як оптичними, так і магнітометричними засобами. Оптичне виявлення без магнітометричного може відповідати міні з пластиковим корпусом, а тільки магнітометричне — прихованій міні. Але залишається питання щодо величини порогу достовірності виявлення. Нижче наводяться приклади, коли комплексування результатів оптичного та магнітометричного виявлення мін доцільні.

Приклад виявлення міні на зображенні низької якості (рис. 4.25). Видимість міні ТМ на RGB зображенні погіршена, і відповідно, достовірність значно менше ніж зазвичай для мін такого типу. Міна МОН100

також погано розрізняється і оптично розпізнається хибно з дуже низькою достовірністю. Діаметр зображень обох мін — близько 30 пікселів.



Рис. 4.25. Розпізнавання мін ТМ-72 та МОН-100 на аерозображенні за допомогою нейромережі

Магнітні сигнатури обох цих мін показано на рис. 4.26.




Рис. 4.26. Магнітні сигнатури мін рис. 4.25 – ТМ-72 (а) та МОН-100 (б)

ліворуч – відфільтрований магнітний сигнал, праворуч – ймовірність знаходження міни

Втім, обидві міни впевнено фіксуються магнітометром. Результуючу достовірність можна обчислити за (4.5). Для ТМ-72

$$p_{\Sigma} \cong \frac{0,25 \cdot 0,98}{0,25 \cdot 0,98 + (1 - 0,25) \cdot (1 - 0,98)} = 0,94$$

Для МОН-100

$$p_{\Sigma} \cong \frac{0,02 \cdot 0,98}{0,02 \cdot 0,98 + (1 - 0,02) \cdot (1 - 0,98)} = 0,5$$

Отже, отримано кількісне підвищення достовірності результату оптичного виявлення в комплексі з магнітометричним у порівнянні з одним лише оптичним виявленням. Підвищилася і практична цінність результату – отримані значення достовірності є саме достовірністю знаходження мін, тоді як значення, отримані тільки магнітометрією, є достовірністю наявності довільного предмета з феромагнітного металу.

Наступний приклад (рис. 4.27) ілюструє особливість цього підходу. Візуально схожі міни ТМ-62М і ТМ-62ПЗ мають різні корпуси: ТМ-62М – сталевий корпус, ТМ-62ПЗ – пластиковий, обидві розпізнані з низькою достовірністю через невисоку розрізненність і рослинність.



Рис. 4.27. Розпізнавання мін ТМ-62М (а) та ТМ-62ПЗ (б) на аерозображенні за допомогою неймережі




Рис.4.28. Магнітна сигнатура міни ТМ-62М рис. 4.27: *а* – після усунення шуму, *б* – після вилучення тренду, *в* – імовірність виявлення

Для міни ТМ-62М доступне комплексування з результатом магнітометрії, показаним на рис. 4.28. Результуюча достовірність виявлення дорівнює


$$p_{\Sigma} \cong \frac{0,27 \cdot 0,95}{0,27 \cdot 0,95 + (1 - 0,27) \cdot (1 - 0,95)} = 0,88$$

Для міни ТМ-62РЗ з пластиковим корпусом комплексування неможливе. Надійне візуальне розрізнення підтипів мін ТМ – сталевих і пластикових, можливе лише за досить високої просторової розрізненості, за другорядними ознаками, тому в даному дослідженні вони об'єднані в один клас об'єктів. Злиття з результатами магнітометрії виконується лише в тих областях, де висока достовірність магнітометричного виявлення. Отже, для міни з пластиковим корпусом значення достовірності залишається тим самим – 0,36.



Також виражені магнітні сигнатури реєструються у мін МОН-90 та МОН-200 (рис. 4.29).



Рис. 4.29. Розпізнавання мін МОН90 (а) та МОН200 (б) на аерозображенні за допомогою неймережі



а)



б)




Рис. 4.30. Магнітні сигнатури мін рис. 4.29 – МОН90 (а) та МОН200 (б)
ліворуч – відфільтрований магнітний сигнал, праворуч – ймовірність знаходження міни

Для обох мін рис. 4.30 також можна провести корекцію достовірності з урахуванням результату магнітометрії:

$$\text{для МОН90} \quad p_{\Sigma} \cong \frac{0,12 \cdot 0,95}{0,12 \cdot 0,95 + (1 - 0,12) \cdot (1 - 0,95)} = 0,72$$

$$\text{для МОН200} \quad p_{\Sigma} \cong \frac{0,14 \cdot 0,98}{0,14 \cdot 0,98 + (1 - 0,14) \cdot (1 - 0,98)} = 0,89$$

Як підсумок, для частини мін із досліджуваного набору – МОН90, МОН100, МОН200 та ТМ з металевим корпусом можливе значне підвищення достовірності виявлення завдяки комплексуванню з магнітометричним аерозніманням – у середньому на 60%. Втім, слід зазначити, що у цьому прирості відсотків достовірності є елемент випадковості, зумовлений необхідністю металевої конструкції міни.

Варто зазначити, що збільшення достовірності дається ціною виконання додаткового магнітометричного аерознімання на значно меншій висоті, ніж дозволяє оптичне виявлення – рекомендована висота застосування бортового магнітометра БПЛА дорівнює 1-2 м (Chornyy et al., 2024), водночас не забезпечує результату для значної кількості протипіхотних і протитанкових мін в неметалевому виконанні.

4.5. Рекомендації щодо впровадження розробленої методики

Під час тестування розробленої методики важливо отримати показники, що слугуватимуть вхідними даними для планування майбутніх дослідницьких зйомок з БПЛА. Потрібно провести повторну оцінку ефективності з урахуванням нових даних, отриманих під час практичних польотів із виявлення мін. Одночасно потрібно розширювати наявні тренувальні датасети. Це має забезпечити ітеративне покращення показників виявлення мін. Можливо, у певний момент обсяг даних буде достатнім для

створення великих цільових датасетів мін, достатніх для навчання мережі з нуля.

На відомчому або державному рівні варто укласти прозорі правила обміну інформацією між групами дослідників, щоб підвищити ефективність виявлення на національному рівні.

Слід пам'ятати, що наведений набір сенсорів і методів відображає певний момент розвитку індустрії, і може змінюватися з часом. Можлива поява як більш досконалих сенсорів, так і нових перспективних архітектур нейромереж, що не матимуть недоліків, притаманних тим, які використовуються зараз.

Стосовно магнітометрії, бажаним є включення у апаратний комплекс магнітометра, що має реалізовані виробником можливості збору даних із геоприв'язкою.

Висновки до четвертого розділу

1. В рамках дослідження ефективності розробленої методики проведено експерименти із трьома типами даних різної фізичної природи – RGB-зображеннями, одержаними з БПЛА типу DJI Phantom 3, DJI Phantom 4, DJI Matrix 300, тепловими зображеннями, одержаними з БПЛА типу Parrot BeBop Pro, DJI Mavic 2, DJI Zenmuse XT2, DJI Zenmuse H20T та магнітометричними даними, одержаними бортовими авіаційними магнітометрами HWT3100TTL та MagDrone R3. Загалом у дослідженні було використано 1000 RGB-аерозображень окремих мін (700 для навчання), 300 теплових аерозображень окремих мін, 30 наборів магнітометричних даних. Кожний із типів даних оброблявся окремо, в певних випадках результати виявлення мін комплексувалися.

2. Було застосовано нейронні мережі архітектури YOLO версій 8 (пренавчені на датасетах MS COCO та Google OIV7) та 11 (на MS COCO), розмірних модифікацій *nano*, *small* та *medium*. Шляхом експериментів із трансферним навчанням було отримано оптимальні значення кількості епох донавчання та кількості фіксованих шарів.

Було випробувано як режим виявлення і класифікації, так і режим виявлення єдиного класу. Продемонстровано спільність базових розпізнавальних ознак мін і загальнорозповсюджених предметів із базових датасетів, і можливість використати цю спільність у донавчанні згорткової нейромережі.

Для нейромереж архітектури YOLOv11 на базі датасету MS COCO, досягнуті наступні показники:

Для мережі YOLO11small mAP50 та mAP50-95 відповідно становлять 0,979 та 0,668 (покращені від початкових 0,555 та 0,393) для 15 епох і 5 фіксованих шарів. Для мережі YOLO11medium mAP50 та mAP50-95 — відповідно 0,983 та 0,723 (від початкових 0,316 та 0,282) для 23 епох та 7 шарів.

Для YOLO11medium досягнуто значення показника R (повнота) = 1 у режимі єдиного класу, при цьому показники mAP50 та mAP50-95 відповідно становили 0.878 та 0.702 для 25 епох та 8 фіксованих шарів.

Для YOLO8small, пренавченої на базі Google Open Images V7, вдалося досягти показників mAP50 та mAP50-95 відповідно 0,98 та 0,741 донавчанням протягом 22 епох та 5 фіксованих шарів, для YOLO8medium — відповідно 0,968 та 0,695.

Для базової YOLO11small середній показник mAP50-95 дорівнює 0,47, після донавчання на цільовому датасеті для мін досягнуто показник

0,706, для YOLO11medium відповідно з 0,515 показник покращено до 0,74.

3. Для теплових зображень було доведено можливість їх використання як самостійного джерела інформації шляхом тренування нейромереж з нуля (через відсутність відповідних базових датасетів), на датасетах, зібраних за допомогою камер ZN H20T (навчальний) та M2ED (тестовий), для нейромережі YOLO11small зі 100 епохами тренування, було отримано показники для мін класу ТМ:

$P = 0,441$ $R = 0,829$ $mAP50 = 0,456$ $mAP50-95 = 0,354$

Для теплових зображень низької розрізненості (біля 8 мм/піксель) було доведено перевагу підходу із тренуванням в режимі єдиного класу, для якого було досягнуто показників $P = 0.996$, $R = 0.995$, $mAP50 = 0.994$, $mAP50-95 = 0.884$.

4. Для обробки магнітометричних даних робочим підходом є послідовне усунення шуму, усунення тренду та статистичне виявлення аномалії. Ефективне виявлення можливе для мін, що містять феромагнетики у складі корпусу, таких як протитанкова ТМ, протипіхотні МОН100 та МОН200. Для подібних мін, з дотриманням висоти близько 2 метрів, можливе виявлення аномалій із достовірністю 0,8–0,95, що дає значне покращення загального результату виявлення за умов, які погіршують виявлення за RGB- та/або тепловими зображеннями.
5. Проведено експериментальне комплексування результатів виявлення мін різними сенсорами БПЛА з використанням байєсівського злиття ймовірностей. Досліджувалося комплексування 100 пар RGB- та теплових аерозображень окремих мін і 50 пар аерозображень і магнітометричних вимірювань окремих мін. Досягнуто середнього

підвищення достовірності виявлення мін на 20 % при комплексуванні RGB та теплових аерозображень і на 35 % при комплексуванні аерозображень та магнітометричних даних.

Використані джерела

Лялько, В. І., Попов, М. О., Станкевич, С. А., Шкляр, С. В., Подорван, В. М., Лихоліт, М. І., Тягур, В. М., & Добровольська, К. В. (2015). Фізична модель інфрачервоного спектрорадіометра з підвищенням просторової розрізненості за допомогою субпіксельної обробки зображень. *Наука та інновації*, 11(6), 16–28. <https://doi.org/10.15407/scin11.06.016>

Мосов, С. П., Станкевич, С. А., & Чумаченко, С. М. (2017). Обґрунтування вимог до технічних характеристик засобів ведення розвідки пожеж із застосуванням безпілотних літальних апаратів. *Науковий вісник: Цивільний захист та пожежна безпека*, (1), 57–65.

Попов, М. О., Станкевич, С. А., Мосов, С. П., Чорний, С. В., Дугін, С. С., Голубов, С. І., Андрєєв, А. А., & Саприкін, Є. Ю. (2024). *Спосіб дистанційного виявлення металевих об'єктів за допомогою магнітометра* (Заявка на винахід України № а202404889). Укрпатент.

Akyon, F. C., Altinuc, S. O., & Temizel, A. (2022). Slicing aided hyper inference and fine-tuning for small object detection. In *2022 IEEE International Conference on Image Processing (ICIP)* (pp. 966–970). IEEE. <https://doi.org/10.1109/ICIP46576.2022.9897990>

Baur, J., & Nitsche, F. (2025). A false-positive-centric framework for object detection disambiguation. *Remote Sensing*, 17, Article 2429. <https://doi.org/10.3390/rs17142429>

Baur, J., Steinberg, G., Nikulin, A., Chiu, K., & Smet, T. (2020). Applying deep learning to automate UAV-based detection of scatterable landmines. *Remote Sensing*, 12(5), Article 859. <https://doi.org/10.3390/rs12050859>

Binghamton University. (2025). *Earth Sciences Faculty Scholarship*. Earth Sciences. https://orb.binghamton.edu/geology_fac/

Chorny, S., Dugin, S., Stankevich, S., Popov, M., & Golubov, S. (2024). Prototype of a UAV-borne magnetometer for landmine detection. *Ukrainian Journal of Remote Sensing*, 11(3), 26–30. <https://doi.org/10.36023/ujrs.2024.11.3.269>

Deininger, L., Stimpel, B., Yuce, A., Abbasi-Sureshjani, S., Schönenberger, S., Ocampo, P., Korski, K., & Gaire, F. (2022). *A comparative study between vision transformers and CNNs in digital pathology* (arXiv:2206.00389). arXiv. <https://doi.org/10.48550/arXiv.2206.00389>

Kirkpatrick, J., Pascanu, R., Rabinowitz, N., Veness, J., Desjardins, G., Rusu, A. A., & Hadsell, R. (2017). Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences*, 114(13), 3521–3526. <https://doi.org/10.1073/pnas.1611835114>

Kuru, K., Sujit, A., Ansell, D., Pinder, J. M., Jones, D., Watkinson, B. J., Hamila, R., & Tinker-Mill, C. (2024). Intelligent, automated, rapid, and safe landmine, improvised explosive device and unexploded ordnance detection using Maggy. *IEEE Access*, 12, 165736–165755. <https://doi.org/10.1109/ACCESS.2024.3493013>

Kuznetsova, H., Rom, N., Alldrin, N., Uijlings, J., Krasin, I., Pont-Tuset, J., Kamali, S., Popov, S., Mallocci, M., Kolesnikov, A., Duerig, T., & Ferrari, V. (2020). The open images dataset V4: Unified image classification, object detection, and visual relationship detection at scale. *International Journal of Computer Vision*, 128(7), 1956–1981. <https://doi.org/10.1007/s11263-020-01316-z>

Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. In D.

Fleet, T. Pajdla, B. Schiele, & T. Tuytelaars (Eds.), *Computer Vision – ECCV 2014* (Vol. 8693, pp. 740–755). Springer. https://doi.org/10.1007/978-3-319-10602-1_48

Poliachenko, I., Kozak, V., Bakhmutov, V., Cherkes, S., & Varava, I. (2023). Preliminary results of UAV magnetic surveys for unexploded ordnance detection in Ukraine: Effectiveness and challenges. *Geophysical Journal*, 45(5), 126–140. <https://doi.org/10.24028/gj.v45i5.289117>

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *YOLO: You Only Look Once: Unified, real-time object detection* (arXiv:1506.02640). arXiv. <https://doi.org/10.48550/arXiv.1506.02640>

Shklyar, S., Andreiev, A., & Golubov, S. (2025). Accuracy assessment of landmine detection by infrared aerial imaging. *Ukrainian Journal of Remote Sensing*, 12(4), 16–20. <https://doi.org/10.36023/ujrs.2025.12.4.294>

Sineglazov, V., & Lesohorskyi, K. (2025). Intelligent landmine detection with unmanned aerial vehicle mounted thermal camera. In *Proceedings of the Eighth International Workshop on Computer Modeling and Intelligent Systems (CMIS 2025)* (pp. 215–226). CEUR-WS.org. <https://ceur-ws.org/Vol-3988/paper17.pdf>

Terven, J. R., & Cordova-Esparza, D. M. (2023). *A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS* (arXiv:2304.00501). arXiv. <https://doi.org/10.48550/arXiv.2304.00501>

Ultralytics. (2025). *Ultralytics YOLOv8 - State-of-the-art Vision AI*. <https://www.ultralytics.com/yolo>

Zhang, R., & Liu, Q. (2023). Learning with few samples in deep learning for image classification, a mini-review. *Frontiers in Computational Neuroscience*, 16, Article 1075294. <https://doi.org/10.3389/fncom.2022.1075294>

ВИСНОВКИ

1. Розглянуто наявні методи виявлення і класифікації об'єктів і з'ясовано, що жоден із методів, заснованих на одному фізичному принципі, не забезпечує задовільної достовірності виявлення поверхневих мін у реальних умовах.

2. Проаналізовано методи виявлення і класифікації об'єктів, засновані на використанні даних сенсорів різних фізичних принципів, обґрунтовано, що в залежності як від поточного стану розвитку, так і об'єктивних фізичних обмежень, їм притаманний різний ступінь готовності до використання, а також різна доцільність застосування методів машинного і глибокого навчання. Обґрунтовано, що оптимальний набір сенсорів необхідно обирати під конкретні умови, комплексно враховуючи їх особливості.

3. Сформульовано наукове завдання — розробка методики виявлення компактних об'єктів, заснованої на використанні даних різної фізичної природи, одержуваних з БПЛА, і методах машинного навчання. Наведено критерії для оцінки підвищення достовірності виявлення і класифікування, а саме: точність (*precision*) P , чутливість (*recall*) R , узагальнена середня точність (*mean average precision*) mAP . Як окремі важливі завдання виділено подолання недостатності навчальних даних у методах глибокого навчання і забезпечення швидкого донавчання. Для виконання поставленого наукового завдання визначено та представлено низку часткових наукових завдань.

4. Запропоновано для виявлення і класифікації поверхневих мін використовувати набір даних, що включає зображення видимого діапазону, теплові зображення та дані магнітометрії.

5. Запропоновано для покращення ефективності використання нейромереж, подолання дефіциту навчальних даних і забезпечення здатності до генералізації у глибокому навчанні застосувати методи *нарощування даних* (data augmentation), *передавального навчання* (transfer learning), *тонкого налаштування* (fine tuning), *мінімального навчання* (few-shot learning) на базі великих наборів даних загального користування.

6. Запропоновано для підвищення достовірності виявлення використати метод комплексування ймовірнісних результатів виявлення об'єктів на оптичних зображеннях видимого та теплового діапазонів із результатами, отриманими з використанням сенсорів інших фізичних принципів дії, що також мають ймовірнісну природу, з представленням кінцевого результату як координат мітки із результуючою ймовірністю.

7. Розроблено методику, що включає в себе обґрунтований вибір сенсорів і методів машинного та глибокого навчання, розв'язання проблеми недостатності навчальних даних через передавальне навчання і аугментацію, оптимізацію донавчання мережі на додаткових даних шляхом встановлення оптимальних гіперпараметрів, і комплексування результатів ймовірнісної природи, отриманих аналізом даних різної фізичної природи як методами глибокого навчання, так і статистичного виявлення аномалій.

8. Розроблено і випробувано раціональну схему організації процесу глибокого навчання в умовах дефіциту навчальних даних; продемонстровано можливість знаходження оптимального ступеня фіксації шарів нейромережі

під час трансферного навчання (тонкого налаштування) і оптимальної тривалості навчання.

9. Адаптовано спосіб комплексування результатів виявлення різними сенсорами шляхом байєсівського злиття ймовірностей та отримання результуючої карти ймовірностей.

10. Проведено експериментальне дослідження ефективності застосування методики, що включило експерименти із трьома типами даних різної фізичної природи – RGB-зображеннями, одержаними з БПЛА типу DJI Phantom 3, DJI Phantom 4, DJI Matrix 300, тепловими зображеннями, одержаними з БПЛА типу Parrot Bebop Pro, DJI Mavic 2, DJI Zenmuse XT2, DJI Zenmuse H20T та магнітометричними даними, одержаними бортовими авіаційними магнітометрами HWT3100TTL та MagDrone R3. Загалом у дослідженні було використано 1000 RGB-аерозображень окремих мін (700 для навчання), 300 теплових аерозображень окремих мін, 30 наборів магнітометричних даних. Кожний із типів даних оброблявся окремо, в певних випадках результати виявлення мін комплексувалися.

Було застосовано нейронні мережі архітектури YOLO версій 8 та 11, розмірних модифікацій *nano*, *small* та *medium*. Шляхом експериментів із трансферним навчанням було отримано оптимальні значення кількості епох донавчання та кількості фіксованих шарів. Було випробувано як режим виявлення і класифікації, так і режим виявлення єдиного класу. Продемонстровано спільність базових розпізнавальних ознак мін і об'єктів із базових датасетів та можливість використати цю спільність у донавчанні згорткової нейромережі.

Для нейромереж архітектури YOLOv11 на базі датасету MS COCO, досягнуті наступні показники: для мережі YOLO11small mAP50 та mAP50-95

відповідно становлять 0,979 та 0.668 (покращені від початкових 0,555 та 0.393) для 15 епох та 5 фіксованих шарів; для мережі YOLO11medium mAP50 та mAP50-95 - відповідно 0,983 та 0,723 (від початкових 0,316 та 0,282) для 23 епох та 7 шарів; для YOLO11medium досягнуто значення показника R (повнота) = 1 у режимі єдиного класу, при цьому показники mAP50 та mAP50-95 відповідно становили 0.878 та 0.702 для 25 епох та 8 фіксованих шарів. Для YOLO8small, пренавченої на базі Google Open Images V7, вдалося досягти показників mAP50 та mAP50-95 відповідно 0,98 та 0,741 донавчанням протягом 22 епох та 5 фіксованих шарів, для YOLO8medium - відповідно 0,968 та 0,695. Для базової YOLO11small середній показник mAP50-95 дорівнює 0,47, після донавчання на цільовому датасеті для мін досягнуто показник 0,706, для YOLO11medium відповідно з 0,515 показник покращено до 0,74.

Для теплових зображень було доведено можливість їх використання як самостійного джерела інформації шляхом навчання нейромереж. Для нейромережі YOLO11small за 100 епох тренування було отримано показники для мін-класу ТМ: $P = 0,441$, $R = 0,829$, $mAP50 = 0,456$, $mAP50-95 = 0,354$. Також показана ефективність використання теплових зображень низької розрізненності у режимі єдиного класу для комплексування з RGB зображеннями.

Проведено експериментальне комплексування результатів виявлення мін різними сенсорами БПЛА з використанням байєсівського злиття ймовірностей. Досліджувалося комплексування 100 пар RGB- та теплових аерозображень окремих мін і 50 пар аерозображень і магнітометричних вимірювань окремих мін. Досягнуто середнього підвищення достовірності виявлення мін на 20 % при комплексуванні RGB та теплових аерозображень і на 35 % при комплексуванні аерозображень та магнітометричних даних.

11. Надано рекомендації щодо застосування розробленої методики. Обґрунтовано необхідність проведення тестування із сталою просторовою розрізненністю задля можливості визначення оптимальних параметрів польоту БПЛА. Підкреслено необхідність ітеративного накопичення навчальних даних підчас експлуатації, періодичної оцінки ефективності після донавчання мережі. Підкреслено необхідність відстежувати прогрес розвитку сенсорів і появу нових наборів базових та цільових навчальних даних, що можуть змінити оптимальний підхід до глибокого навчання для конкретного сенсора.

ДОДАТОК А

Зразки досліджуваних поверхневих мін
У дослідженні були використані міни радянських і російських зразків.



a) МОН50 протипіхотна



c) МОН100 протипіхотна



e) PMN протипіхотна



g) ТМ72 протитанкова



f) ТМ62М протитанкова



h) ТМ-62П2 протитанкова



Рис. А.1. Мінімальні та максимальні зображення мін навчального набору даних

ДОДАТОК Б

Наукові праці, опубліковані за темою дисертаційного дослідження

Публікації у монографіях

Б1. Ковтун, С. І., Мосов, С. П., Назаренко, О. О., Нероба, В. Р., Сєлюков, О. В., Станкевич, С. А., & Чубіна, Т. Д. (2025). Розвідка наземних мін з безпілотних літальних апаратів (видимий діапазон довжин хвиль): колективна монографія (В. П. Бабак, Ред.). Видавничий дім «Вініченко». (особистий внесок – розділ, присвячений виявленню мін за допомогою нейронних мереж)

Матеріали, опубліковані в періодичних виданнях:

Б2. Saprykin, I. Y. (2024). Optical deep learning landmine detection based on limited dataset of aerial imagery. *Science-Based Technologies*, 62(2), 107–115. <https://doi.org/10.18372/2310-5461.62.18708> (Індексація: фахове видання України категорії «Б»)

Б3. Popov, M. O., Stankevich, S. A., Mosov, S. P., Dugin, S. S., Golubov, S. I., Andreiev, A. A., Lysenko, A. R., & Saprykin, I. Y. (2024). The concept of a geoinformational platform for landmines and other explosive objects detection and mapping with UAV. *Радіоелектронні і комп'ютерні системи*, (4). <https://doi.org/10.32620/reks.2024.4.17> (Індексація: Scopus; особистий внесок: удосконалення модуля планування місій БПЛА для урахування додаткових умов середовища, інтеграція навчених нейронних мереж у платформу)

Б4. Stankevich, S. A., & Saprykin, I. Y. (2024). Optical and magnetometric data integration for landmine detection with UAV. *WSEAS Transactions on Environment and Development*, 20, 1059–1066. <https://doi.org/10.37394/232015.2024.20.96> (Індексація: Scopus; особистий внесок: розробка методики обробки оптичних даних, здійснення розрахунків, аналіз, візуалізація, валідація)

- Б5. Станкевич, С. А., Уруський, О. С., Мосов, С. П., & Саприкін, Є. Ю. (2024). Використання непрямих ознак для виявлення наземних мін з використанням безпілотних літальних апаратів. *Збірник наукових праць Центру воєнно-стратегічних досліджень Національного університету оборони України*, (2), 98–105. <https://doi.org/10.33099/2304-2745/2024-2-81/98-105> (Індексація: фахове видання України категорії «Б»; *особистий внесок* – адаптація методів глибокого навчання із застосуванням нейронних мереж до врахування непрямих ознак наземних мін, обробка даних)
- Б6. Ментус, І. Е., Ясько, В. А., & Саприкін, Є. Ю. (2024). Методи виявлення мін для гуманітарного розмінування. *Український журнал дистанційного зондування Землі*, 11(3). <https://doi.org/10.36023/ujrs.2024.11.3.271> (Індексація: фахове видання України категорії «Б»; *особистий внесок* – адаптація методів глибокого навчання із застосуванням нейронних мереж для виявлення ряду типів наземних мін)
- Б7. Stankevich, S., Kondratov, O., Herda, M., & Saprykin, I. (2024). Infrared image iterative enhancement in frequency domain. *Radioelectronics and Communications Systems*, 67, 277–286. <https://doi.org/10.3103/S0735272724070045> (Індексація: Scopus; *особистий внесок* – калібрування та обробка теплових аерозображень, підготовка даних)
- Б8. Мосов, С. П., Станкевич, С. А., Нероба, В. Р., & Саприкін, Є. Ю. (2026). Класифікація наземних мін як об'єктів повітряної розвідки в системі цивільного захисту. *Збірник наукових праць Національної академії Державної прикордонної служби України. Серія: військові та технічні науки*, 102(1), 70–80. <https://doi.org/10.32453/3.v102i1.2133> (Індексація: фахове видання України категорії «Б»; *особистий внесок* – аналіз класифікації мін в контексті глибокого навчання, підготовка даних та ілюстрацій)
- Б9. Саприкін Є.Ю. (2026) Методика виявлення малорозмірних компактних об'єктів на основі комплексування даних аерознімання різної фізичної природи, Наукоємні технології, т. 70, № 3 (Прийнято до публікації, індексація: фахове видання України категорії «Б»)

Апробація матеріалів дисертації

Б10. Popov M., Stankevich S., Mosov S., Saprykin I. Drone-based landmine detection by image and signal fusion. Proceedings of the TIEMS Hybrid Annual Conference. Port Alfred: TIEMS, 2023, p. 24. URL: https://www.tiems.info/images/pdf/TIEMS_2023_Hybrid_Annual_Conference_Preliminary_Program_ver_5.pdf (особистий внесок: підготовка та обробка зображень наземних мін, підготовка презентації, доповідь)

Б11. Popov, M. O., Stankevich, S. A., Mosov, S. P., Dugin, S. S., & Saprykin, I. Y. (2023). Drone-based landmine detection mission planning. In *Proceedings of the 7th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)* (pp. 151–154). IEEE. <https://doi.org/10.1109/MSNMC61017.2023.10329129> (Індексація: Scopus; особистий внесок: удосконалення програмного модуля ГІС до планування місій із урахуванням додаткових умов аерознімання, підготовка презентації і тез, доповідь)

Б12. Stankevich, S. A., Mosov, S. P., & Saprykin, I. Y. (2023). Landmine detection in farmlands using optical/radar small drones. In *Proceedings of the International Research and Practice Conference “Sustainable Restoration of Agricultural Landscapes affected by Military Activities”* (p. 71). Talkom. <https://doi.org/10.36994/978-966-388-681-7-2023-71> (особистий внесок: підготовка та обробка даних з виявлення наземних мін за допомогою глибокого навчання)

Б13. Stankevich, S. A., Dugin, S. S., Golubov, S. I., & Saprykin, I. Y. (2024). Workflow for landmine detection in aerial imagery with YOLO-based deep learning. In *Proceedings of the 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Developments (APUAVD)*. IEEE. <https://doi.org/10.1109/APUAVD64488.2024.10765896> (Індексація: Scopus; особистий внесок: участь у аерозйомці реальних мін, підготовка наборів навчальних даних, тренування і тестування нейронних мереж, інтеграція з ГІС, обробка аерозображень для виявлення мін, підготовка презентації і тез, доповідь)

Б14. Stankevich, S. A., Saprykin, I. Y., Dugin, S. S., & Golubov, S. I. (2025). Transfer learning in YOLO-based landmine detection in aerial imagery. In

Proceedings of the 2025 IEEE 8th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC) (pp. 1–6). IEEE. <https://doi.org/10.1109/MSNMC61130.2025.11399716> (Індексація: Scopus; особистий внесок: розробка механізму передавального навчання і тонкого налаштуванням нейромереж, підготовка даних, навчання, тестування виявлення реальних наземних мін на аерозображеннях, узагальнення результатів, підготовка презентації і тез, доповідь)

Свідоцтво про реєстрацію авторського права

Б15. Станкевич, С. А., Титаренко, О. В., Дугін, С. С., Голубов, С. І., Андреев, А. А., Лисенко, А. Р., Саприкін, Є. Ю., Дьомін, Д. В., Юзефович, В. В., Цибульська, Є. О., та Додонов, Є. О. (2025). *Комп'ютерна програма Геоінформаційна платформа для виявлення і картографування наземних мін та інших вибухонебезпечних предметів за допомогою безпілотних літальних апаратів* [Свідоцтво про реєстрацію авторського права на твір № 133879]. Міністерство економіки України.

Заявка на патент України на винахід

Б16. Попов, М. О., Станкевич, С. А., Мосов, С. П., Чорний, С. В., Дугін, С. С., Голубов, С. І., Андреев, А. А., та Саприкін, Є. Ю. (2025). *Спосіб дистанційного виявлення металевих об'єктів за допомогою магнітометра* (Ukrainian Patent Application No. a202404889). Український інститут інтелектуальної власності.

ДОДАТОК В

Скрипти для машинного навчання та виявлення об'єктів

В1. Програмний код Python для роботи з бібліотеками Ultralytics та SAHI

```
#training YOLO
from ultralytics import YOLO
model1 = YOLO('yolov8s.pt')
results = model1.train(
    data="C:\\Science\\datasets_yaml\\mines_multi_small_6.yml",
    #mines_multi_small_6.yml",
    imgsz=640,
    epochs=25,
    batch=4,
    freeze=5,
    #single_cls=True,
    #pretrained=False,
    name='8s_multi_small_25ep_5frzn',
    device='cpu',
    #lr0=0.001,
    #lrf=0.01
)

#detection
model =
YOLO('C:\\Science\\results\\train_results_11s_multi_small_25ep_7frzn_oiv7\\weights\\best.pt')
res =
model.predict('C:\\Science\\datasets\\mines_grass\\datasets\\mines_grass\\images\\',save=True,show=False,
e,conf=0.01,agnostic_nms=True,iou=0.3,augment=True,imgsz=640)

#validation
valid_result =
model1.val(data='C:\\Science\\datasets_yaml\\mines_multi_small_6_val.yml',imgsz=640,conf=0.1,split='
val',plots=True,batch=1,iou=0.3,augment=True,save_json=True, classes=[1,2,5],
    name='val_8s_multi_small_25ep_5frzn_sngl')

from sahi.utils.ultralytics import download_yolo11n_model #download_yolov8s_model .yolov8
# ---- init libraries ----
from sahi import AutoDetectionModel
from sahi.utils.cv import read_image
from sahi.utils.cv import visualize_object_predictions
from sahi.utils.file import download_from_url
from sahi.predict import get_prediction, get_sliced_prediction, predict
from pathlib import Path
from IPython.display import Image
import cv2
import numpy as np
import os
from sahi.utils.cv import visualize_object_predictions
```

```

yolov8_model_path =
"C:\\Science\\results\\training_results\\l1m_multi_small_23ep_7frzn\\weights\\best.pt"
download_yolo11n_model(yolov8_model_path) #download_yolov8s_model(yolov8_model_path)
detection_model = AutoDetectionModel.from_pretrained( # creating detection model
    model_type='yolov11',
    model_path=yolov8_model_path,
    confidence_threshold=0.01,
    agnostic_nms=True
)
directory = 'D:\\IMAGERY\\Selected_36\\5\\'
for filename in os.listdir(directory):
    f = os.path.join(directory, filename)
    if os.path.isfile(f):
        print(filename)
        if 'JPG' in filename:
            result1 = get_sliced_prediction(
                directory+'\\'+filename, detection_model, slice_height=640, slice_width=640,
                overlap_height_ratio=0.40, overlap_width_ratio=0.40,
                #agnostic_nms=True
                postprocess_match_threshold=0.1
            )
            object_prediction_list = result1.object_prediction_list
            img = cv2.imread(directory+'\\'+filename, cv2.IMREAD_UNCHANGED)
            img_converted = cv2.cvtColor(img, cv2.COLOR_BGR2RGB)
            numpydata = np.asarray(img_converted)
            visualize_object_predictions(
                numpydata,
                object_prediction_list = result1.object_prediction_list,
                hide_labels = 0,
                output_dir='C:\\Science\\runs\\detect_sahi_l1s_multi_small_20ep_5frzn',
                file_name = f'{filename}',
                export_format = 'jpg',
                text_th=2,
                rect_th=2
            )

```

B2. Програмний код SciLab для обробки магнітометричних даних

```

// Magnetometer log to signature converter

clear();

function t=maglog(R,X) // log string to mag value conversion

    Y=strsplit(X,[':']);

    if isnum(Y($))

    then P=X;

    else

    K=strindex(X,":");

```

```

if isempty(K)
    then P=X;
else
    P=part(X,1:(K($)-1));
end;
end;
S=tokens(P,[" ",""]);
if size(S,1)>=3 then
    for i=1:3,
        if grep(S(i),R(i))==1 then
            Z(i)=evstr(part(S(i),6:$));
        else
            Z(i)=0;
        end;
        t=sqrt(sum(Z.^2));
    end;
else
    t=-1;
end;
endfunction

mprintf('\n  Magnetometer log conversion\n');
X=mgetl('WEBS\20240806\фон\LOG05461.TXT'); // input log
n=size(X,1); // log records number
R=["Magx:","Magy:","Magz:"];
m=0; // init counter
for i=1:n,
    t=maglog(R,X(i));
    if t>0 then
        m=m+1;
        Y(m)=t;
    end;
end;

```

```

    end;
end;
mprintf('  %u log records converted\n',m);
mprintf('  3D mag range = %.3f .. %.3f\n',min(Y),max(Y));
dat=mopen('WEBS\20240806\ΦOH.dat','wt');
for i=1:m,
    mfprintf(dat,%.6f\n',Y(i));
end;
mclose(dat);
clf();
plot(Y,':m');
a=get("current_axes");
a.font_size=3;
// xs2bmp(0,'WEBS\20240806\ΦOH.bmp');
mprintf('  log conversion complete\n');
// exec('WEBS\MAGLOG.SCI');
// ----- //
clear();
X=read('WEBS\20240806\TM-60M-3.dat',-1,1); // input data
n=size(X,1); // number of samples
S=(1:n)'; // data samples
// clf(); plot(S,X,':m');
// xs2bmp(0,'WEBS\TN-60M-3.bmp');
Y=detrend(X); // remove linear trend
// clf(); plot(S,Y,':m');
// xs2bmp(0,'WEBS\TN-60M-3-detr.bmp');
T=(Y-min(Y))/(max(Y)-min(Y)); // normalized data
Z=abs(Y-mean(Y))/stdev(Y); // whitened data
P=erf(Z/sqrt(2)); // deviation probability
F=P.*T;
G=(1-P).*(1-T);

```

```
Q=F./(F+G); // Bayesian rule
alpha=0.9; // probability threshold
H=find(Q>alpha); // high probability samples
clf();
plot(S,Q,':g',S(H),Q(H),'sr');
a=get("current_axes"); a.font_size=3;
// xs2bmp(0,'WEBS\TN-60M-3-prob.bmp');
// exec('WEBS\MAGPROB.SCI');
```

ДОДАТОК Г

Акт впровадження результатів дисертаційного дослідження

ЗАТВЕРДЖУЮ

Начальник Інституту наукових досліджень з
цивільного захисту НУЦЗ України,
доктор технічних наук, професор

Роман ПОНОМАРЕНКО

« » квітня 2026 р.

АКТ

впровадження результатів наукових досліджень аспіранта Наукового центру
аерокосмічних досліджень Землі ІГН НАН України **Саприкіна Євгена
Юрійовича**

Комісія в складі: голова – заступник начальника інституту, д.т.н., професор
Мелешенко Р. Г., члени комісії – д.військ.н., професор Мосов С. П., Литовченко А. О. склала
цей акт про те, що науковий результат, одержаний Саприкіним Є. Ю., а саме – методика
виявлення малорозмірних компактних об'єктів на основі комплексування даних
аерознімання різної фізичної природи, був використаний при виконанні наукових досліджень
щодо виявлення вибухонебезпечних предметів при нетехнічному обстеженні територій із
застосуванням безпілотного авіаційного комплексу.

Голова комісії

Члени комісії

 Руслан МЕЛЕШЕНКО

 Сергій МОСОВ

 Анастасія ЛИТОВЧЕНКО