

DOI: 10.18372/2310-5461.71.21416

УДК 004.93'12:621.397:528.88

Є. Ю. Саприкін, аспірант

Науковий центр аерокосмічних досліджень Землі

Інституту геологічних наук

Національної академії наук України

<https://orcid.org/0009-0004-2347-3756>e-mail: ye.sapr@gmail.com

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

Вступ

Виявлення і класифікація малорозмірних компактних об'єктів на основі даних аерознімання включає в себе клас актуальних задач, серед яких дедалі більшу роль відіграє виявлення об'єктів засобами БПЛА. Зокрема, в останні роки відбувається розвиток засобів та 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 [1].

Не можна не зазначити, що проблема розмінування останніми роками змінила свій статус - із подолання наслідків давно минулих конфліктів, хоча і жаклих, але локалізованих здебільшого у країнах третього світу, ця проблема перемістилася у центр Європи і набула сучасної загрозливої динаміки. Яскравим прикладом кардинальної зміни ситуації є вихід цілого ряду європейських країн з конвенції про нерозповсюдження протипіхотних мін [2].

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 поверхневого обстеження, наприклад у випадку території, яка ніколи не була під окупацією чи у зоні бойових дій, але могла мінуватися дистанційно. Таким чином, постановка задачі окремого виявлення і класифікації поверхневих мін стала ще більш доцільною.

Аналіз останніх досліджень і публікацій

Для виявлення мін у дослідженнях останніх років застосовується цілий спектр різноманітних сенсорів [3], що виділяє їх з-поміж інших об'єктів, і обумовлене їх значною небезпекою і

непересічним масштабом проблеми, зокрема і для України. Насамперед ці сенсори 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 проблемою є виявлення певного типу об'єктів – то більше різноманіття засобів залучається для її розв'язання і більша кількість досліджень з'являється. 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 і найбільш розповсюдженою технологією дистанційного зондування, що використовується з БПЛА [4]. 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 і економічною доцільністю. Методи виявлення об'єктів із застосуванням глибокого навчання переважно використовують саме зображення з оптичних камер видимого діапазону.

Інфрачервоні камери теплового діапазону є одним з 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 вони є допоміжними до зображень видимого діапазону, хоча можуть використовуватись і незалежно [3, 4, 5, 6].

Поточний стан розвитку засобів магнітометрії, що використовуються з БПЛА для виявлення об'єктів, перебуває у стадії, коли ще не затверджені єдині стандарти для зберігання, відображення і обробки магнітометричних даних. Загальні підходи вже вироблені, але деталі залежать від виробника магнітометра і розробника методу. Виявлення мін за допомогою бортових магнітометрів БПЛА на сьогоднішній день залишається актуальною дослідницькою задачею, виконання якої, не зважаючи на певні успіхи, ще не поставлене 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 потрібні умови аерознімання з БПЛА практично неможливі. Отже, бортовий магнітометр БПЛА – корисний, але не універсальний засіб для виявлення мін [7, 8].

Значна кількість публікацій присвячена окремим методам виявлення [5, 6, 7, 8], 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 [9], однак все ще проблема подолання їх нестачі є актуальною. Нерівномірно представлені дані різних камер і сенсорів. Проблема недостатності публічних наборів даних має два виміри. По-перше, даних бракує власне 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 [10] відбувається певна комерціалізація, створюються стартапи та приватні компанії [11,12], які спеціалізуються на дистанційному виявленні, що лише частково публікують свої досягнення, а деталі реалізації часто стають комерційною таємницею.

Щодо методологічного підходу, одну з новачій можна знайти в статті [4] де запропоновані градації дистанційного виявлення об'єкту як *видима аномалія*, *розпізнавана аномалія* та *унікальна розпізнавана аномалія*. Підкреслюється, що різні типи даних відрізняються своєю здатністю забезпечити відповідні градації виявлення об'єктів. У статті [3] наводиться градація сенсорів у балах за рівнем технологічної готовності, де зображенням кольорової моделі *Red, Green, Blue* (далі RGB) відповідає бал 9, тепловим зображенням – 8–9, а магнітометрії – 7–8.

Можна констатувати, що серед дослідників вкоренився підхід, коли сенсори різних фізичних принципів порівнюються і 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.

Метою дослідження є підвищення достовірності виявлення і класифікації малорозмірних компактних об'єктів, а саме поверхневих мін, 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.

Методика

Запропонована 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 даному дослідженні у якості об'єктів пошуку розглядаються міни, розташовані на земній поверхні. Додатковою уточнюючою умовою розробки методики є спеціалізація на гуманітарному розмінуванні відкритих площ.

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

Методика ділиться на три функціональні модулі згідно основних процесів, що виконуються в її межах – модулі навчання, планування та виявлення (рис. 1).




Рис.1. Загальна схема запропонованої методики

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 [13], а саме – тонке налаштування на обмежених цільових датасетах нейромереж, пренавчених на великих датасетах загального користування.

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

Для магнітометричних даних наразі використовуються статистичне виявлення аномалій [14].

Тестування донавчених моделей доцільно організувати так, щоб максимально наблизитись до умов, які передбачаються при практичному використанні. З усіх умов найпростіше забезпечити, щоб у тестового набору даних була стала просторова розрізненість, чи принаймні така, що знаходиться у вузькому діапазоні, що забезпечується

при автоматичному режимі польоту БПЛА. Тоді отримані результати можна буде використати для планування майбутніх обстежувальних польотів. З додаткових умов може грати роль фон розташування об'єктів, ступінь освітлення. Також може бути доцільним тестування для окремих підгруп об'єктів (протитанкові, протипіхотні міни, і т. п.).

Модуль планування на основі даних, отриманих під час тестування, забезпечує перехід від просторової розрізненості, за якої система забезпечує прийнятний результат, до конкретних параметрів обстежувального польоту БПЛА для кожного з типів даних, що використовуються. Головний параметр, який визначається на цьому етапі – висота польоту.

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 порогові.

Якщо за результатами обстеження і 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 необхідним.

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 [15] та/або статистичних методів виявлення аномалій [5], результатом чого є формування ймовірнісної карти для кожного типу даних, які наступним кроком поєднуються із використанням Байєсівського злиття ймовірностей [14]. При цьому ймовірність, отримана кожним наступним сенсором, вважається апостеріорною до попередньо отриманої [16]. Наприклад, для злиття ймовірнісних результатів послідовно виконаних оптичного і магнітометричного досліджень формула буде мати вигляд

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

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

Підходи до злиття сенсорів діляться на злиття на рівні даних, на рівні розпізнавальних ознак та на рівні рішення [16]. У нашому випадку перевага віддається злиттю на рівні рішення через те що, по-перше, такі різномірні дані, як RGB-, теплові зображення та дані магнітометрії несумісні у їх первісному вигляді, і по-друге, вимагатиме так само і злиття навчальних датасетів, що виключається через різні підходи до машинного навчання для різних типів даних. Враховуючи, що результат виявлення усіх типів даних має ймовірнісну природу, саме такий варіант є оптимальним.

Злиття може відбуватися лише на ділянках, де значення, отримані окремими сенсорами, знаходяться у наперед визначених діапазонах або досягають визначеного порогового значення. Наприклад, нема сенсу враховувати низький рівень ймовірності аномалії, визначений магнітометрією, якщо за даними RGB чи тепловими визначається тип міни, який не містить феромагнетиків. Так само нема сенсу комплексувати результати виявлення у RGB із високою достовірністю з іншими типами.

Крім власне виявлення, цей модуль відповідає також за збір додаткових навчальних даних, які мають ітеративно покращувати якість системи виявлення. Якщо додаткові дані стосуватимуться існуючих 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 при виявленні об'єкта 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, що в свою чергу може вплинути на параметри польотів, що обчислюються модулем планування.

Дані та вихідні матеріали дослідження

Вхідними даними для реалізації методики є RGB, теплові зображення та дані магнітометрії, відзняті за допомогою БПЛА на спеціальних вій-

ськових полігонах, облаштованих в Україні і наближених до реальних умов. Отримані зображення організуються у набори даних формату, адаптованого для навчання нейромереж архітектури YOLO [17], а саме – діляться на фрагменти 640x640, і супроводжуються текстовими файлами із нормалізованими координатами міток. Також вхідними даними слід вважати великі універсальні набори даних, доступні для загального використання, а саме Microsoft COCO (common objects in context) [18] та Google Open Images [19], що використовуються для передавального навчання при розв’язанні проблеми недостатності навчальних даних і для досягнення здатності нейромережі до генералізації.

Результати

Експериментальне дослідження було проведене із застосуванням даних, отриманих на спеціально облаштованому полігоні, переважно вкритому низькою рослинністю, із фрагментами асфальту і гравію, що відповідає умовам розташування мін у реальності. Відмінністю умов полігону від реальності було те, що міни встановлювались перед початком робіт, а не перебували там протягом довгого часу. 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 та російських моделей, більшість із яких може бути встановлена роботизованими комплексами чи розповсюджена з БПЛА, як з металевими так і з пластиковими корпусами.

Були зібрані підбірки RGB та теплових зображень із застосуванням ряду моделей комерційних БПЛА та камер, та магнітометричних даних із застосуванням експериментального магнітометра.

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 [9]. Зображення для решти були відзняті спеціально на військових полігонах України.

Навчати мережу «з нуля» на основі такого обмеженого набору даних неефективно. Штучне нарощування (аугментація) даних може допомогти до певної міри, але потрібно зважати на те, що здатність до генералізації при застосуванні тільки цього підходу буде обмеженою. Власне, окрім обмеженої кількості зображень, самі властивості мін як одноманітних об’єктів не сприяють генералізації.

Більш ефективним способом є передавальне навчання (тонке налаштування), засноване на великих універсальних датасетах [13]. У нашому випадку датасети Microsoft Common Objects in Context [18] (далі за текстом MS COCO) та Google Open Images V7 [19] (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 у порівнянні з навчальним, що сприяло перевірці здатності до генералізації. Приклади зображень наведені на рис. 2.




Рис. 2. Приклади аерозображень навчального (а) та тестового (б) датасетів

Тренуючи у процесі донавчання всю базову пренавчену нейромережу цілком, отримуємо посередній результат для мін ТМ та незадовільний результат для МОН50 і МОН200. Причина цього полягає у явищі катастрофічного забування [20].

Для подолання цього явища у проведеній серії експериментів мережа YOLO навчалася зі змінною кількістю епох тренування (циклів обробки всього набору даних) і фіксованих шарів секції нейромережі, відомої як основа (*backbone*), що

відповідальна за екстракцію розпізнавальних ознак об’єктів пошуку. Фіксація (*freeze*) шару означає, що коефіцієнти ряду низько- і середньорівневих шарів не змінюються під час донавчання (тонкого налаштування). Тут і далі кількість фіксованих шарів згадується відповідно до параметра *freeze* Ultralytics API [21], використаного для експериментів. Стартова кількість епох навчання була обрана рівною 20, що критично мало для навчання з нуля, але, за припущенням експериме-

нту, достатньо для тонкого налаштування нейромережі, яка вже містить деяку інформацію про базові розпізнавальні ознаки.

Для ілюстрації використаємо один із найбільш наочних способів візуалізації якості навчання нейромережі – криву повнота-достовірність (recall-confidence). Повнота цікавить нас найбільше че-

рез особливість задачі пошуку мін – важливіше не пропустити міну реальну, проблема ж хибних тривог хоч і серйозна, але другорядна у порівнянні з пропущеною реальною міною. На рис. 3 зображено криві повнота-достовірність для нейромережі YOLO11m, пренавченої на датасеті COCO.




Рис. 3. Криві повнота-достовірність для нейромережі YOLO11m, пренавченої на датасеті COCO, фіксовані шари – 7 ліворуч, 10 праворуч; навчальні епохи – 15, 20, 25, 30 згори дониз

Приведені графіки ілюструють закономірність – існують оптимальні значення кількості епох та фіксованих шарів при донавчанні нейромережі. Виявлено, що оптимальні значення цих гіперпараметрів відрізняються для різних типів мін, і причина цього може полягати, крім власних особливостей цих мін і їх репрезентації у навчальному датасеті, у різній спорідненості класів цільового та базового датасетів.



а



б

Рис. 4. Оброблене аерозображення із результатами виявлення. Міни протитанкові ТМ (а) та протипіхотні МОН (б). Доновчена нейромережа YOLOv8, модель *small*, базовий датасет OIV7, 20 епох навчання, 5 фіксованих шарів

У таблиці 1 наведені найкращі з досягнутих показників ефективності, отримані для двох версій нейромереж та двох базових датасетів у режимі єдиного класу, тобто налаштовані на виявлення будь-яких мін з цільового навчального набору. У таблиці 2 наведено порівняння найкращого показника mAP_{50-95} , досягнутого для використаних мереж і цільового датасету із середнім значенням цього показника для базових використаних мереж, пренавчених на датасеті MS COCO за даними компанії Ultralytics.

Таблиця 1

Результати тестування конфігурації мережі із тренуванням в режимі єдиного класу

Нейромережа	Модель	Кількість		Базовий датасет	P	R	mAP_{50}	mAP_{50-95}
		Епох навч.	Фікс. шарів					
YOLO v8	<i>small</i>	20	5	OIV7	0,747	0,989	0,865	0,707
YOLO v8	<i>medium</i>	25	7	OIV7	0,75	0,989	0,878	0,716
YOLO v11	<i>small</i>	20	5	COCO	0,612	0,817	0,613	0,447
YOLO v11	<i>medium</i>	23	10	COCO	0,684	1	0,878	0,702

Таблиця 2

Порівняння показника mAP_{50-95} нейромереж YOLO для датасету COCO та для цільового датасету з виявлення мін

Нейро-мережа	Модель	Кількість		Значення базової мережі	Найкращі значення цільової мережі	
		Епох навч.	Фікс. шарів		mAP_{50-95} , датасет COCO + цільовий	mAP_{50-95} , датасет OIV7 + цільовий
YOLO v8	<i>small</i>	22	5	0,449		0,741
YOLO v8	<i>medium</i>	25	8	0,502		0,743
YOLO v11	<i>small</i>	17	5	0,47	0,706	
YOLO v11	<i>medium</i>	23	10	0,515	0,74	

У дослідженні також були використані теплові зображення, і було продемонстровано здатність їх використання для самостійного виявлення на прикладі протитанкових мін сімейства ТМ. 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.

Таблиця 3

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

Показник	P (влучність)	R (повнота)	mAP 50	mAP 50–95
Значення	0,441	0,829	0,456	0,354

Проте зазвичай доступні для навчання теплові зображення нижчої, ніж RGB, просторової розрізненості. Їх доцільно використовувати для тренування в режимі єдиного класу, фактично для виявлення теплових аномалій.

На рис. 5 на тепловому аерозображенні протитанкова міна ТМ має розмір 20×20 пікселів і впевнено виявляється, міни меншого розміру мають гранично малий розмір для виявлення: зображення міни ПФМ1 вироджується до стохастичної аномалії і не виявляється.





Рис. 5. Результат виявлення мін на тепловому аерозображенні за допомогою моделі *medium* нейромережі YOLOv11, тренуваної в режимі єдиного класу

Комплексування результатів різної фізичної природи


Комплексування результатів оптичного виявлення і магнітометрії є доцільним, наприклад, у випадку низької якості оптичного зображення, коли результатом нейромережі є виявлення з низькою достовірністю.




a




b



c



d



e

Рис. 5. Результати оптичного виявлення і магнітометрії:

a – розпізнавання мін ТМ-72 та МОН-100 на аерозображенні за допомогою нейромережі;
b – ТМ-72 – рівень магнітного поля після видалення шуму та тренду; *c* – ймовірність виявлення за даними магнітометрії; *d* – МОН-100 – рівень магнітного поля; *e* – ймовірність

Обидві міни впевнено фіксуються магнітометром. Результуючу достовірність можна обчислити за формулою (1). 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 покращення достовірності результату оптичного виявлення у комплексі з магнітометричним у порівнянні з одним тільки 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 предмету з ферромагнітного металу.

Висновки

Розроблено методику, що включає в себе ґрунтований 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.

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

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.

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 розминуванні і ставить пріоритетом легкість масштабування системи.

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.

Були застосовані 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 були отримані оптимальні значення кількості епох донавчання та кількості фіксованих шарів.

Були випробувані 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 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 22х 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 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 $TM P = 0,441$, $R = 0,829$, $mAP50 = 0,456$, $mAP50-95 = 0,354$.

Для теплових зображень низької розрізненості (біля 8 мм/піксель) було доведено перевагу підходу із тренуванням в режимі єдиного класу, для якого було досягнуто показників $P = 0,996$, $R = 0,995$, $mAP50 = 0,994$, $mAP50-95 = 0,884$.

Для обробки магнітометричних даних робочим підходом є послідовне усунення шуму, усунення тренду і статистичне виявлення аномалії. Ефективне виявлення можливе для мін, що містять феромагнетики у складі корпусу, таких як протитанкова ТМ, протипіхотні МОН100 та 200. Для подібних мін, з дотриманням висоти біля 2 метрів, можливе виявлення аномалій із достовірністю 0,8–0,95, що дає значне покращення загального результату виявлення при умовах, що погіршують виявлення RGB та/або тепловими зображеннями.

Проведено експериментальне комплексування результатів виявлення мін різними сенсорами БПЛА з використанням байєсівського злиття імовірностей. Досліджувалося комплексування 100 пар RGB та теплових аерозображень окремих мін та 30 пар аерозображень та магнітометричних вимірювань окремих мін. Досягнуто середнє підвищення достовірності виявлення мін на 20 % при комплексуванні RGB та теплових аерозображень і на 35 % при комплексуванні аерозображень та магнітометричних даних (для окремих типів мін).

ЛІТЕРАТУРА

- [1] Корольов О. Особливості встановлення мінно-вибухових загороджень перед переднім краєм оборони або в умовах безпосереднього зіткнення з противником. Національна безпека України в умовах воєнного стану: проблеми та шляхи їх вирішення : зб. матеріалів конф. (Одеса, 2026 р.). Одеса : Військова академія, 2026. С. 177–178.
- [2] Іванова К. Країни Балтії та Польща виходять з конвенції про заборону протипіхотних мін. Главком. 2025. 18 берез. URL: <https://glavcom.ua/world/world-politics/krajini-baltiji-ta-polshcha-vikhodjat-z-konventsiji-pro-zaboronu-pro-tipikhotnikh-min-1050023.html> (дата звернення: 01.05.2026)
- [3] A Comparative Evaluation of UAV-Based Remote Sensing and Geophysical Techniques for Landmine Detection on a Seeded Minefield / J. Baur, S. Lekhak, G. Steinberg [et al.] // Preprints.org : [electronic journal]. 2026. <https://doi.org/10.20944/preprints202605.0758.v1>
- [4] Baur J., Nitsche F. A False-Positive-Centric Framework for Object Detection Disambiguation. *Remote Sensing*. 2025. Vol. 17, art. 2429. <https://doi.org/10.3390/rs17142429>.
- [5] Method for minefields mapping by imagery from unmanned aerial vehicle / M. O. Popov, S. A. Stankevich, S. P. Mosov [et al.] *Advances in Military Technology*. 2022. Vol. 17, no. 2. P. 211–229. URL: <https://doi.org/10.3849/aimt.01722>.
- [6] Shklyar S., Andreiev A., Golubov S. Accuracy assessment of landmine detection by infrared aerial imaging. *Ukrainian Journal of Remote Sensing*. 2025. Vol. 12, no. 4. P. 16–20. URL: <https://doi.org/10.36023/ujrs.2025.12.4.294>.
- [7] Preliminary results of UAV magnetic surveys for unexploded ordnance detection in Ukraine: effectiveness and challenges / I. Poliachenko, V. Kozak, V. Bakhmutov [et al.] *Geophysical Journal*. 2023. Vol. 45, no. 5. P. 126–140. URL: <https://doi.org/10.24028/gj.v45i5.289117>.
- [8] Prototype of a UAV-borne magnetometer for landmine detection / S. Chorny, S. Dugin, S. Stankevich [et al.] *Ukrainian Journal of Remote Sensing*. 2024. Vol. 11, no. 3. P. 26–30. <https://doi.org/10.36023/ujrs.2024.11.3.269>
- [9] Earth Sciences Faculty Scholarship // Earth Sciences : [website] / Binghamton University. URL: https://orb.binghamton.edu/geology_fac/ (accessed: 12.08.2025).
- [10] Demining Research Community : [website]. URL: <https://de-mine.com/> (accessed: 15.05.2026).
- [11] Real-World Detections in Ukraine // Safe Pro AI : [website]. URL: <https://safeproai.com/landmine-detections/> (accessed: 15.05.2026)
- [12] UADAMAGE Monitoring Platform : [website]. URL: <https://web.uadamage.com/> (accessed: 16.05.2026).
- [13] Gandhi V., Gandhi S. Fine-Tuning Without Forgetting: Adaptation of YOLOv8 Preserves COCO Performance // arXiv : [preprint] / Cornell University. 2025. URL: <https://doi.org/10.48550/arXiv.2505.01016>.
- [14] Stankevich S. A., Saprykin I. Y. Optical and magnetometric data integration for landmine detection with UAV. *WSEAS Transactions on Environment and Development*. 2024. Vol. 20. P. 1059–1066. URL: <https://doi.org/10.37394/232015.2024.20.96>.
- [15] Saprykin I. Optical deep learning landmine detection based on limited dataset of aerial imagery. *Science-Based Technologies*. 2024. Vol. 62, no. 2. P. 107–115. URL: <https://doi.org/10.18372/2310-5461.62.18708>.
- [16] Narkhede P., Walambe R., Kotecha K. Sensor Fusion Methodologies for Landmine Detection. *Lecture Notes in Networks and Systems*. Vol. 551 / ed.: M. Saraswat, C. Chowdhury, C. K. Mandal, A. H. Gandomi. Singapore : Springer, 2023. P. 891–907. https://doi.org/10.1007/978-981-19-6631-6_62.
- [17] YOLO: You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick [et al.] // arXiv : [preprint] / Cornell University. 2016. URL: <https://doi.org/10.48550/arXiv.1506.02640>.

- [18] Microsoft COCO: Common Objects in Context / T. Y. Lin, M. Maire, S. Belongie [et al.] // *Computer Vision – ECCV 2014*. Cham : Springer, 2014. P. 740–755. (Lecture Notes in Computer Science ; vol. 8693). https://doi.org/10.1007/978-3-319-10602-1_48.
- [19] The Open Images Dataset V4: Unified Image Classification, Object Detection, and Visual Relationship Detection at Scale / H. Kuznetsova, N. Rom, N. Alldrin [et al.] *International Journal of Computer Vision*. 2020. Vol. 128, no. 7. P. 1956–1981. URL: <https://doi.org/10.1007/s11263-020-01316-z>.
- [20] Overcoming catastrophic forgetting in neural networks / J. Kirkpatrick, R. Pascanu, N. Rabinowitz [et al.] *Proceedings of the National Academy of Sciences*. 2017. Vol. 114, no. 13. P. 3521–3526. <https://doi.org/10.1073/pnas.1611835114>.
- [21] Ultralytics YOLO Models // Ultralytics : [website]. <https://www.ultralytics.com/yolo> (accessed: 12.08.2025).

Саприкін Є. Ю.

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

Стаття присвячена розробці методики виявлення малорозмірних компактних об'єктів, а саме протитанкових та протипіхотних поверхневих мін, на основі комплексування даних аерознімання різної фізичної природи. Актуальність дослідження зумовлена гостротою проблеми мінного забруднення території України, що катастрофічно зростає унаслідок розвитку безпілотних і роботизованих засобів мінування. Хоча методи виявлення мін на основі даних аерознімання інтенсивно розвиваються, поки що рідко публікуються цілісні описи методики, і здебільшого вони стосуються окремих технологій. Запропонована методика базується на комплексуванні результатів виявлення на основі даних різної фізичної природи із комплексним диференційованим підходом до використання методів машинного та глибокого навчання до типів даних різної фізичної природи, а саме – зображень видимого діапазону, теплових зображень та даних магнітометрії. Визначено пріоритетність обраних типів даних, і щодо зображень видимого діапазону розроблено підхід до мінімізації необхідного обсягу навчальних даних і часу навчання для забезпечення можливості подолання дефіциту навчальних даних та швидкого ітеративного покращення можливостей виявлення, в тому числі при розширенні набору класів об'єктів пошуку. 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 набору даних і конкретної моделі нейронної мережі, а саме кількості навчальних епох і глибини фіксації шарів коефіцієнтів нейронної мережі. Щодо теплових зображень доведена можливість їх використання у глибокому навчанні як самостійно, так і у комплексуванні з результатами видимого діапазону. Щодо даних магнітометрії продемонстровано доцільність статистичних методів виявлення аномалій і використання результатів для покращення достовірності виявлення через комплексування із результатами виявлення на зображеннях. Для тестування розробленої методики використані дані, отримані на полігонах із використанням реальних і навчальних зразків мін.

Ключові слова: БПЛА, виявлення мін, глибоке навчання, передавальне навчання, комплексування результатів виявлення.

Saprykin I.

METHODOLOGY FOR DETECTION OF SMALL-SIZED COMPACT OBJECTS BASED ON COMPLEXING AERIAL SURVEYING DATA OF VARIOUS PHYSICAL NATURE

The article is devoted to the development of a method for detecting small-sized compact objects, namely anti-tank and anti-personnel surface mines, based on the integration of aerial survey data of various physical nature. The relevance of the study is due to the acuteness of the problem of mine contamination of the territory of Ukraine, which is catastrophically increasing due to the development of unmanned and robotic mining vehicles. Although methods for detecting mines based on aerial survey data are intensively developing, complete descriptions of the method are rarely published so far, and mostly they concern individual technologies. The proposed method is based on the integration of detection results based on data of various physical nature with a complex differentiated approach to the use of machine and deep learning methods for data types of various physical nature, namely - visible range images, thermal images and magnetometry data. The priority of the selected data types was determined, and for visible range images, an approach was developed to minimize the required amount of training data and training time to ensure the ability to overcome the shortage of training data and quickly iteratively improve detection capabilities, including when expanding the set of search object classes. To achieve this goal, transfer learning (fine tuning) was used on the basis of large sets of public data with an emphasis on achieving optimal transfer learning hyperparameters for the base and target data sets and a specific neural network model, namely the number of training epochs and the depth of freezing of the layers of neural network coefficients. For thermal images, the possibility of their use in deep learning was proven both independently and in combination with visible range results. For magnetometry data, the feasibility of statistical methods for detecting anomalies and using the results to improve the reliability of detection through combination with detection results in images was demonstrated. Data obtained on test sites using real and training mine samples was used to test the developed methodology.

Keywords: UAV, mine detection, deep learning, transfer learning, integration of detection results.

Дата першого надходження: 17.06.2026 р.

Дата прийняття до друку: 14.08.2026 р.

Дата публікації: 10.09.2026 р.