

ЗАСТОСУВАННЯ МЕТОДІВ ГЛИБОКОГО НАВЧАННЯ ДЛЯ ВИЯВЛЕННЯ БПЛА

А. М. Колесник^{1,а}, А. Ю. Шелестов¹

¹ Навчально-науковий Фізико-технічний інститут

Анотація

У роботі розглянуто актуальну проблему виявлення безпілотних літальних апаратів (БПЛА) за допомогою застосування методів штучного інтелекту, зокрема глибокого навчання та комп'ютерного зору. Проведено огляд основних підходів до детекції дронів – радіолокаційних, акустичних, інфрачервоних, радіочастотних та оптичних – із визначенням їхніх переваг та обмежень. Основну увагу зосереджено на оптичному виявленні з використанням згорткових нейронних мереж, зокрема архітектури YOLOv8, яка забезпечує високу точність і швидкодію в умовах реального часу. Описано структурні компоненти моделі, функції втрат, ключові метрики оцінювання (mAP, Precision, Recall, F1-score), а також практичні аспекти навчання моделей для задачі виявлення дронів. Робота має прикладне значення для розробки ефективних систем моніторингу повітряного простору як у військових, так і в цивільних умовах.

Ключові слова: безпілотні літальні апарати, виявлення дронів, комп'ютерний зір, глибоке навчання, YOLOv8, нейронні мережі, обробка зображень, моніторинг повітряного простору, функції втрат, метрики оцінки.

Вступ

Упродовж останнього десятиліття безпілотні літальні апарати (БПЛА), або дрони, набули стрімкого поширення в усьому світі. Вони поступово втратили статус вузькоспеціалізованих технологій і стали універсальним інструментом, що активно впроваджується у широкий спектр сфер – від безпеки та моніторингу до сільського господарства, логістики та цивільної інфраструктури. Розвиток мікроелектроніки, штучного інтелекту та автономних систем керування дозволив зробити ці пристрої доступними та ефективними. Дрони дедалі частіше виконують функції, що раніше потребували участі людини, знижуючи витрати, прискорюючи процеси та підвищуючи точність.

Таке поширення БПЛА зумовлює не лише технологічну еволюцію, а й суттєву трансформацію соціально-безпекового контексту. Безпілотники стають новим фактором впливу на простір як у мирний, так і в конфліктний час. Їхня автономність, мобільність, малі габарити та низька вартість створюють переваги, але водночас породжують нові виклики. Зокрема, дрони активно застосовуються для виконання задач, пов'язаних із розвідкою, стеженням, точковими атаками або порушенням режимів доступу в контрольованих зонах. Це піднімає питання про збалансоване регулювання та контроль їх використання. Одним із найбільш критичних аспектів є зростання ризиків, пов'язаних із недобросовісним

або ворожим використанням дронів. У різних країнах фіксуються випадки використання БПЛА для шпигунства, терористичних атак, саботажу об'єктів критичної інфраструктури, а також втручання в роботу авіаційного транспорту [1, 2, 3, 4]. Використання компактних дронів, оснащених камерами чи вибуховими пристроями, унеможливило своєчасне реагування при відсутності спеціалізованих систем спостереження та виявлення. Особливо помітно роль БПЛА проявляється у контексті повномасштабної війни в Україні. Саме тут безпілотники набули нового виміру як масовий, гнучкий та відносно недорогий засіб ведення бойових дій. Вони використовуються не лише як платформи для збору даних, але й як ефективна ударна зброя, здатна вражати цілі з високою точністю та мінімальним ризиком для особового складу. Застосування FPV-дронів у бойових операціях дало змогу українським силам підвищити ефективність і точність вогневих засобів, що значно вплинуло на динаміку бойових дій [5, 6, 7].

Масштабне виробництво БПЛА, яке досягло мільйонів одиниць за рік, свідчить про зміну пріоритетів у військових технологіях [6]. Але ця тенденція породжує і нову фазу протистояння – боротьбу між системами виявлення, придушення та знищення дронів, з одного боку, та вдосконаленням алгоритмів автономного обльоту, маскування та атак, з іншого.

У такій ситуації актуальним постає завдання створення високоточної системи для виявлення дронів, здатної працювати в реальному часі, з високим рівнем адаптивності до умов навколишнього середови-

^аkolesnyk.am@gmail.com

ща та варіативності загроз. Попри вже наявні у світі технології антидронові боротьби, вони здебільшого базуються на класичних фізичних принципах (радіолокація, акустика, тепловізійний контроль), що не завжди дозволяє ефективно працювати з малою авіацією в урбанізованому середовищі або в умовах радіоелектронного впливу.

У зв'язку з цим дана наукова робота зосереджена на дослідженні сучасних підходів до виявлення БПЛА із застосуванням методів штучного інтелекту, зокрема комп'ютерного зору. Метою цього дослідження є огляд рішень для виявлення безпілотних літальних апаратів (БПЛА), що базуються на різних підходах – від класичних методів до сучасних систем на основі глибокого навчання. Основна увага приділяється оптичному каналу, зокрема методам комп'ютерного зору, які працюють із відео- та фотозображеннями. Розглядаються архітектури типу YOLO, їх структура, ключові компоненти та застосування до задачі виявлення дронів у реальних умовах.

1. Огляд літератури

Одним із ключових аспектів у забезпеченні ефективною протидії безпілотним літальним апаратам (БПЛА) є своєчасне та точне їх виявлення. Детекція дронів у просторі дозволяє заздалегідь оцінити рівень загрози, ухвалити рішення щодо відповідної реакції та ініціювати заходи захисту. Саме етап виявлення формує основу будь-якої комплексної системи протидії дронам, незалежно від того, чи йдеться про військове застосування, охорону стратегічних об'єктів, контроль повітряного простору чи захист цивільної інфраструктури.

Радари. Радари традиційно використовуються для виявлення повітряних об'єктів і залишаються надійним інструментом для моніторингу простору на великих дистанціях за будь-яких погодних умов. Однак класичні радіолокаційні системи були оптимізовані для виявлення великих цілей, і тому часто стикаються з труднощами при роботі з малими дронами, що летять низько або зависають на місці. Основними викликами є розрізнення дронів від птахів через подібність їхніх радіолокаційних відбиттів та висока маневреність БПЛА [8, 9]. Сучасні підходи, такі як аналіз мікро-Допплерівських ефектів, дозволяють виявляти характерні патерни, що виникають через обертання пропелерів, і тим самим класифікувати дрони окремо від природних об'єктів [10]. Проте радарні системи залишаються дорогими та вимагають складної обробки сигналів для зменшення кількості хибних спрацювань, особливо у міських умовах.

RF-аналізатори. Радіочастотні аналізатори (RF-аналізатори) є ефективним методом пасивного виявлення дронів, що ґрунтується на перехопленні сигналів у певному діапазоні. Вони відслідковують патерни радіозв'язку між дроном і оператором, і можуть навіть ідентифікувати тип дрона або його MAC-адресу при використанні Wi-Fi-з'єднання [11]. Однак автономні дрони, що не передають сигнал під час польоту або роблять це альтернативними способами,

наприклад оптоволоконні кабелі, залишаються неловимими для таких систем. Також RF-аналізатори чутливі до інформаційного шуму в переповненому спектрі, що потребує складних алгоритмів фільтрації і класифікації сигналів [12, 13]. Для підвищення ефективності часто застосовується мережа сенсорів із можливістю триангуляції.

Акустичне виявлення. Акустичне виявлення ґрунтується на аналізі характерних звуків, що утворюються двигунами та пропелерами дронів. Використовуючи мікрофонні масиви та алгоритми цифрової обробки сигналів, сучасні системи можуть фіксувати дрони навіть у складних акустичних середовищах [14]. Важливою перевагою є можливість роботи за умов обмеженого освітлення. Однак ефективність систем обмежується високим рівнем фонового шуму та меншою дальністю виявлення порівняно з радарними або RF-аналізаторами. Інтеграція методів глибокого навчання і використання складних технік фільтрації шумів суттєво покращує результати [15]. Акустичні системи все більше застосовуються як доповнення до інших технологій у цивільній та військовій сферах, однак не можуть бути основним методом виявлення через свої обмеження.

Інфрачервоне (IR) виявлення. Тепловізійні камери забезпечують надійне виявлення дронів завдяки здатності фіксувати теплове випромінювання, що робить їх ефективними вночі або в умовах поганої видимості. Це дає змогу інтегрувати IR-камери з іншими сенсорами для побудови багатоканальних систем виявлення. Основними перевагами є всепогодна робота, портативність і можливість спостереження за об'єктами в темряві. Водночас ускладнення виникають через низьку теплову сигнатуру деяких типів дронів та обмежену роздільну здатність, через що невеликі дрони можуть бути погано помітними на значних відстанях.

Оптичне виявлення. Оптичне виявлення є одним із найпоширеніших методів моніторингу дронів завдяки використанню камер високої роздільної здатності. Воно дозволяє здійснювати реальний візуальний контроль над траєкторією руху об'єкта та забезпечує можливість його ідентифікації за зовнішніми ознаками [16, 17, 18]. Великі переваги включають доступність технології, простоту інтеграції в системи відеоспостереження та широкі можливості масштабування. Але ефективність оптичного виявлення істотно залежить від умов видимості. Сучасні системи часто використовують алгоритми комп'ютерного зору та глибокого навчання.

Одним із найефективніших підходів до виявлення дронів при використанні оптичного каналу є комп'ютерний зір. Наприклад, у [19] запропоновано метод, що імітує зорову систему комах для покращення контрасту перед обробкою згортковими нейронними мережами (CNN). Огляд у [20] порівнює популярні архітектури, такі як YOLO, Faster R-CNN, SSD та EfficientDet, і показує перевагу YOLOv5 і Faster R-CNN у задачах реального часу. У [21] автори тренували YOLOv3 на великій вибірці аерофотознімків, досягнувши 92% точності. Нарешті, [22] демонструє

комбінування CNN і RNN (зокрема LSTM), що знижує хибні спрацювання на 25%.

Отже, методи глибокого навчання демонструють перевагу над класичними алгоритмами за точністю, адаптивністю до складних середовищ і здатністю до роботи в динамічних сценах.

2. Yolo

Моделі сімейства YOLO (You Only Look Once) відрізняються серед архітектур для виявлення об'єктів у повітряному просторі, поєднуючи швидкість і точність, що важливо для реального часу, порівняно з Faster R-CNN, EfficientDet чи Vision Transformers. Найбільш перспективна реалізація – YOLOv8 – забезпечує високу продуктивність і адаптується до різних сценаріїв завдяки переднавченим вагам. Розвинена екосистема оптимізації інференсу дозволяє запускати модель на вбудованих і мобільних пристроях. Тестування підтвердило стійкість YOLOv8 до змін освітлення, фонового шуму та варіативності форм дронів, що робить її ідеальним вибором для моніторингу повітряного простору в реальному часі.

YOLO розбиває зображення на сітку, де кожна клітинка прогнозує координати, ймовірність і клас об'єкта, що дозволяє одночасно локалізувати й класифікувати об'єкти з урахуванням контексту, навіть при складному фоні чи перекриттях. Архітектура YOLOv8 (рисунок 1, [23]) використовує anchor-free витяг ознак і три модулі (Backbone, Neck, Head), забезпечуючи високу точність для малих, швидких або замаскованих об'єктів, таких як дрони. Модель легко донавчається на спеціалізованих наборах даних, адаптуючись до різних умов освітлення та особливостей об'єктів. Поєднання швидкодії, точності та адаптивності робить YOLOv8 оптимальним вибором для моніторингу повітряного простору в реальному часі.

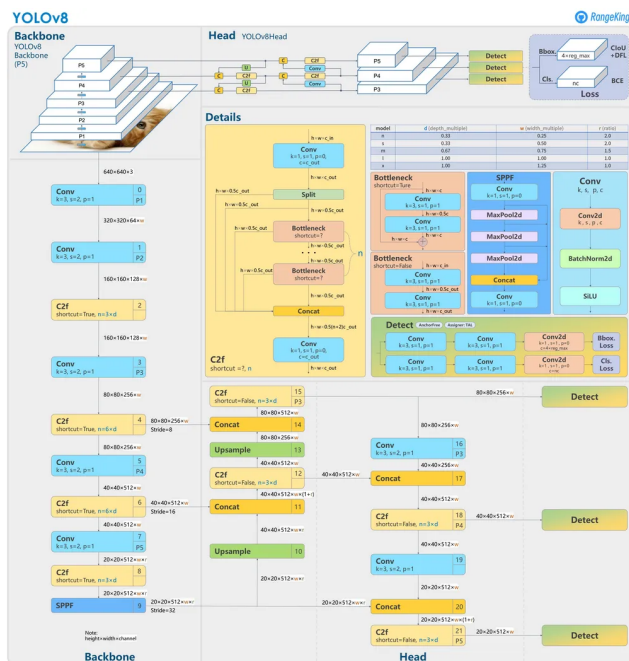


Рис. 1. Архітектура моделі YOLOv8 [23].

2.1. Архітектура Yolo

На першому етапі зображення обробляється Backbone, який виділяє ознаки різної складності – від простих до високорівневих. У YOLOv8 він побудований на вдосконалених C2f-блоках, що поєднують згортки, нормалізацію, активацію та часткові з'єднання, зменшуючи надмірність ознак і покращуючи передавання градієнта. Backbone починається зі Stem-блоку, далі йдуть етапи Stage 1–5, які послідовно витягують все складніші ознаки. При цьому зменшується розмір карт ознак (у 8x, 16x, 32x разів), а кількість каналів зростає.

Neck інтегрує ознаки з різних рівнів, поєднуючи локальні деталі з глобальною семантикою. У YOLOv8 Neck базується на FPN і PAN: перший поширює інформацію згори вниз, другий – знизу вгору. Це дає змогу ефективно виявляти об'єкти різних розмірів. Neck виконує upsample і concat, створюючи три вихідні карти ознак (P3–P5) для охоплення об'єктів різного масштабу, включно з дрібними, як-от дрони.

На завершальному етапі Head здійснює передбачення координат, класів і рівнів впевненості. YOLOv8 використовує anchor-free підхід, що покращує обробку об'єктів нестандартної форми. Три Detect-блоки працюють відповідно з P3, P4 і P5, охоплюючи малі, середні й великі об'єкти. Для фільтрації застосовується non-maximum suppression, що залишає лише найрелевантніші передбачення.

Завдяки поєднанню ефективного вилучення, агрегації та передбачення ознак YOLOv8 досягає високої точності й швидкодії, що робить її особливо ефективною в системах виявлення дронів у складних умовах.

2.2. Навчання моделі

Процес навчання моделей YOLO для задачі виявлення безпілотних літальних апаратів (БПЛА) потребує врахування особливостей об'єктів спостереження, умов експлуатації та обмежень апаратного забезпечення. Оскільки дрони зазвичай мають малі розміри, високу маневреність і часто фігурують на складному фоні, навчання моделей має бути ретельно спланованим з урахуванням цих специфічних викликів. На етапі підготовки даних рекомендується використовувати набори, що охоплюють широкий спектр сценаріїв: різні висоти польоту, погодні умови, типи ландшафтів (міські, природні) та умови освітлення. Розмітка повинна забезпечувати точні координати обмежувальних рамок (bounding boxes) та, за потреби, класифікацію типів дронів. Для забезпечення якісного навчання слід прагнути до обсягу даних щонайменше у декілька тисяч зображень із добре представленими різними класами дронів; мінімально допустимим обсягом можна вважати 400-500 зображень. Важливо також створювати або доповнювати датасети за допомогою штучної генерації даних: синтетичного вставлення зображень дронів у реальні сцени, а також нарізки з відео, що дозволяє суттєво підвищити варіативність і здатність моделі

до узагальнення.

Критичним етапом є розширення даних (data augmentation), що сприяє покращенню стійкості моделі до змін у зовнішньому вигляді об'єктів. Доцільно застосовувати горизонтальні віддзеркалення, зміну масштабу, модифікацію яскравості та контрастності, а також сучасні техніки об'єднання зображень, що створюють нові варіанти композицій сцени. Вибір архітектури моделі повинен залежати від вимог до швидкодії, точності та складності сцени. Для застосувань у реальному часі доцільно обирати легкі модифікації, такі як YOLOv8n або YOLOv8s; для задач із пріоритетом на максимальну точність – більш важкі версії, зокрема YOLOv8m або YOLOv8l. Рекомендованою практикою є використання попередньо навчених вагових коефіцієнтів (pre-trained weights) з великих датасетів, із подальшим донавчанням (fine-tuning) на спеціалізованих даних. Рекомендовані параметри навчання включають початкову швидкість навчання у межах 0.001–0.01 із застосуванням оптимізаторів SGD або Adam, використання scheduler'ів для зменшення швидкості навчання протягом епох. Вибір розміру batch size слід здійснювати максимально можливим відповідно до доступної пам'яті системи, що особливо важливо при роботі з високороздільними зображеннями або великими серіями даних. Стандартною практикою є використання найбільшого допустимого batch size для стабілізації градієнтів під час навчання. Важливо забезпечити баланс між функціями втрат: об'єктної втрати (objectness loss), втрати локалізації (localization loss) та втрати класифікації (classification loss), з урахуванням акценту на виявленні малих об'єктів.

Зважаючи на те, що дрони часто займають незначну площу кадру, доцільним є збільшення роздільної здатності вхідних даних під час навчання, а також адаптація архітектури моделі для покращення обробки дрібних об'єктів. Окрім того, ефективність може бути підвищена шляхом експериментальної оптимізації: варіювання гіперпараметрів, використання різних варіантів аугментації та модифікацій самої архітектури. Таким чином, ефективне навчання моделей YOLO для задачі виявлення дронів вимагає комплексного підходу, що включає належну підготовку та розширення даних, правильний вибір архітектури, гнучке налаштування параметрів навчання та ретельну валідацію результатів для досягнення стабільної та високої якості виявлення.

2.3. Функції втрат

Моделі типу YOLO (You Only Look Once) мають архітектурну особливість одночасної оптимізації задач локалізації, класифікації та виявлення об'єкта в межах одного проходу через мережу. Це потребує застосування комбінованих функцій втрат, оскільки використання лише класичної крос-ентропії або середньоквадратичної помилки (MSE) є недостатнім. Сучасні рішення, такі як YOLOv8, EfficientDet, Detectron2, стандартно використовують складені функції втрат для досягнення балансу між різними

аспектами навчання. У YOLOv8 реалізовано трьохкомпонентну функцію втрат, яка включає втрату для локалізації об'єкта (box loss), втрату класифікації об'єкта (cls loss) та фокальну втрату розподілу (dfl loss).

Першою важливою складовою є функція box loss, яка відповідає за точність просторової локалізації об'єктів у кадрі. У контексті виявлення дронів це має особливе значення, оскільки безпілотники часто займають дуже малу частину зображення, можуть бути частково закриті іншими об'єктами або мати нестандартну форму. Для підвищення точності локалізації у YOLOv8 використовується вдосконалена метрика Complete Intersection over Union (CIoU), яка враховує не тільки площу перекриття передбаченого та реального боксів, а також їхні центри та пропорції.

Формально функція втрат для локалізації визначається як:

$$\text{box_loss} = 1 - \text{CIoU}(\mathbf{B}_p, \mathbf{B}_{gt}),$$

де \mathbf{B}_p – передбачений bounding box, а \mathbf{B}_{gt} – відповідний ground truth. Метрика CIoU (Complete Intersection over Union) враховує не лише площу перекриття, а й відстань між центрами боксів та відмінності в їхніх розмірах, забезпечуючи точнішу оцінку схожості.

Метрика CIoU (Complete IoU) визначається за наступною формулою:

$$\text{CIoU} = \text{IoU} - \left(\frac{\rho^2(\mathbf{b}, \mathbf{b}_{gt})}{c^2} \right) - \alpha \cdot v,$$

де:

- IoU – класичне перекриття (Intersection over Union),
- $\rho^2(\mathbf{b}, \mathbf{b}_{gt})$ – квадрат евклідової відстані між центрами передбаченого боксу \mathbf{b} та істинного \mathbf{b}_{gt} ,
- c – діагональ мінімального прямокутника, що охоплює обидва бокси,
- v – показник різниці у співвідношенні сторін (aspect ratio),
- α – динамічний коефіцієнт регуляризації, що обчислюється як:

$$\alpha = \frac{v}{(1 - \text{IoU}) + v},$$

а сам показник v визначається так:

$$v = \left(\frac{4}{\pi^2} \right) \cdot \left(\arctan \left(\frac{w_{gt}}{h_{gt}} \right) - \arctan \left(\frac{w}{h} \right) \right)^2,$$

де w, h – ширина і висота передбаченого боксу, а w_{gt}, h_{gt} – відповідно ширина і висота еталонного.

Використання метрики CIoU у функції втрат `box_loss` забезпечує:

- Точну локалізацію об'єктів за рахунок врахування не лише площі перекриття, але й геометричних характеристик боксів.
- Швидшу та стабільну збіжність моделі під час навчання, особливо у випадках, коли передбачений та еталонний бокси не перекриваються, але розташовані близько один до одного.

- Покращену узгодженість форми передбачених боксів з реальними об'єктами, що особливо важливо для об'єктів із різноманітними пропорціями.

Другою ключовою компонентою є *cls loss*, яка відповідає за коректне визначення класу об'єкта. Попри те, що в межах даного дослідження розглядається лише один клас («дрон»), класифікаційна функція зберігає свою актуальність для забезпечення гнучкості моделі та можливості масштабування на багатокласові задачі в майбутньому. У YOLOv8 класифікаційна втрата базується на бінарній крос-ентропії (Binary Cross-Entropy, BCE), що дозволяє виконувати незалежне передбачення для кожного класу:

$$\text{cls_loss} = - [y \cdot \log(p) + (1 - y) \cdot \log(1 - p)],$$

де $y \in \{0, 1\}$ – справжня мітка класу, а $p \in [0, 1]$ – передбачена ймовірність приналежності до класу. У випадку дисбалансу даних, коли кількість негативних прикладів значно перевищує кількість позитивних (наприклад, дрони зустрічаються рідше за порожній фон), може застосовуватися модифікація BCE – Focal Loss, яка знижує вагу «легких» прикладів і підвищує увагу до складних.

Третім важливим елементом є *df loss* (Distribution Focal Loss), яка відповідає за дискретизовану регресію координат обмежувальних рамок. Замість традиційної регресії координат за допомогою L1 або L2 втрат, YOLOv8 прогнозує розподіл ймовірностей для кожної координати в межах фіксованого діапазону, що дозволяє отримувати більш точні оцінки через обчислення зваженого середнього значення.

$$\text{df_loss} = \text{CE}(p, y_{\text{left}}) \cdot (1 - r) + \text{CE}(p, y_{\text{right}}) \cdot r,$$

де p – передбачений розподіл, y_{left} і y_{right} – сусідні дискретні бінки навколо істинного значення координати, $r \in [0, 1]$ – інтерполяційна вага. Ця функція забезпечує дискретизовану регресію координат і дозволяє підвищити точність локалізації.

Такий підхід є особливо корисним у контексті виявлення дронів, де точна локалізація є критично важливою, оскільки безпілотники мають малий розмір і можуть частково накладатися на інші об'єкти або фонові структури.

$$\text{Total Loss} = \lambda_{\text{box}} \cdot \text{box_loss} + \lambda_{\text{cls}} \cdot \text{cls_loss} + \lambda_{\text{df}} \cdot \text{df_loss},$$

де λ_{box} , λ_{cls} , λ_{df} – вагові коефіцієнти для кожного компонента функції втрат, які визначають їхній вплив на загальну оптимізацію. У реалізації від Ultralytics ці значення задані емпірично та, як правило, не потребують ручного налаштування. Таким чином, трьохкомпонентна функція втрат YOLOv8 забезпечує баланс між локалізацією, класифікацією та стабільною регресією координат, що є особливо важливим для ефективного виявлення дронів у реальному часі в умовах складних і варіативних сцен.

3. Метрики

Для об'єктивного порівняння різних моделей або налаштувань однієї і тієї ж моделі використовуються спеціалізовані метрики, які дозволяють кількісно оцінити якість передбачень. Ці метрики повинні враховувати як наявність/відсутність об'єкта, так і якість просторової локалізації. У межах даної роботи, яка розглядає задачу виявлення дронів, було обрано п'ять базових метрик: mAP@0.5, mAP@0.5:0.95, Precision, Recall та F1-score. Кожна з них виконує важливу функцію в аналізі результатів і має власну математичну природу.

IoU-поріг (Intersection over Union) – це ключовий параметр при оцінюванні mAP. Він визначає мінімальний рівень перекриття передбаченого прямокутника (bounding box) з еталонним (ground truth), який дозволяє вважати передбачення коректним. IoU розраховується за формулою:

$$\text{IoU} = \frac{|B_p \cap B_{gr}|}{|B_p \cup B_{gr}|},$$

де B_p – передбачений bounding box, B_{gr} – еталонний (ground truth) bounding box.

Метрика mean Average Precision (mAP) є ключовим показником ефективності моделей об'єктної детекції. Вона узагальнює якість детекції як з погляду знаходження об'єкта (класифікація), так і з погляду точності його локалізації (регресія координат). Концептуально mAP базується на обчисленні площі під кривою Precision-Recall, яка відображає залежність точності передбачень від повноти на різних порогох впевненості. У випадку одно-класової задачі, AP (Average Precision) відповідає якості моделі для одного класу (дрон), а mAP збігається з AP, оскільки усереднення відбувається лише по одному класу.

mAP@0.5 mAP@0.5 – це середнє значення точності (AP) при фіксованому порозі IoU ≥ 0.5 . Це означає, що для того, щоб передбачення вважалося вдалим (true positive), прямокутники передбачення і ground truth повинні перекриватися щонайменше на 50% площі. Цей варіант mAP є найбільш поширеним у прикладних задачах через свою інтерпретованість і достатню суворість. Він дозволяє отримати зважену оцінку ефективності моделі без надмірного покарання за неідеальну локалізацію.

mAP@0.5:0.95 Більш суворі версія метрики, mAP@0.5:0.95, передбачає усереднення результатів AP на десяти порогах IoU: від 0.5 до 0.95 з кроком 0.05. Тобто:

$$\text{mAP@0.5:0.95} = \frac{1}{10} \sum_{i=0}^9 \text{AP}_{\text{IoU}=0.5+0.05i}.$$

Ця метрика дозволяє глибше оцінити стабільність і точність локалізації, а не лише здатність знаходити об'єкти. Її часто використовують для порівняння моделей у міжнародних змаганнях і benchmark-наборах, де важливий не лише факт виявлення об'єкта, а й геометрична відповідність. Precision – це частка правильно передбачених об'єктів серед усіх передбаче-

них. Вона показує, наскільки достовірні передбачення моделі: скільки з виявлених дронів справді є дронами, а не помилковими виявленнями. Формально:

$$\text{Precision} = \frac{TP}{TP + FP}$$

де TP – кількість вірно передбачених об'єктів, FP – кількість хибних позитивних передбачень. Високе значення precision означає низьку ймовірність хибної тривоги, що особливо важливо в задачах моніторингу, безпеки або автономного управління, де кожне помилкове виявлення може спричинити хибну реакцію системи.

Recall (Повнота виявлення) Recall визначає, яку частку реальних об'єктів модель змогла знайти. Це показник чутливості: здатності моделі знаходити всі дійсні об'єкти незалежно від хибних спрацювань. Формально:

$$\text{Recall} = \frac{TP}{TP + FN}$$

де FN – кількість об'єктів, які модель не змогла виявити. Високий recall критично важливий у задачах, де пропуск об'єкта є неприпустимим – наприклад, у сфері військової оборони, відеоспостереження або виявлення загроз. Для задачі виявлення дронів пропущений дрон може означати реальну втрату контролю над повітряним простором.

У реальних умовах підвищення одного з показників (наприклад, Recall) часто відбувається за рахунок зниження іншого (Precision). Наприклад, якщо модель «все бачить» і завжди сигналізує про об'єкт, вона має високий Recall, але з часом може породжувати багато FP, знижуючи Precision. F1-score дозволяє збалансовано оцінити продуктивність моделі, об'єднуючи обидві метрики:

$$\text{F1-score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Це гармонічне середнє, що накладає штраф на дисбаланс: модель отримає високий F1-score лише тоді, коли обидві складові (точність і повнота) є високими. Ця метрика часто використовується для вибору оптимального порогу впевненості моделі у постобробці (наприклад, при пороговому фільтруванні результатів).

Висновки

У межах даної роботи було здійснено комплексний аналіз сучасних методів виявлення безпілотних літальних апаратів (БПЛА) із акцентом на застосування алгоритмів глибокого навчання та комп'ютерного зору. Проведено огляд традиційних підходів детекції, таких як радіолокаційні системи, RF-аналізатори, акустичні та інфрачервоні канали, а також оптичні системи, із визначенням їхніх переваг та обмежень у контексті задач моніторингу повітряного простору.

Особливу увагу приділено аналізу архітектури моделей YOLO, зокрема YOLOv8, яка продемонструвала високий потенціал для використання у реальному

часі завдяки своїй швидкодії, точності та здатності до адаптації до складних умов спостереження. Детально розглянуто структурні компоненти YOLOv8 – Backbone, Neck і Head, їхню роль у процесі вилучення ознак і формування передбачень, а також особливості використання anchor-free підходу для підвищення точності локалізації малих об'єктів.

Проаналізовано функції втрат, які використовуються у сучасних версіях YOLO, зокрема Complete IoU Loss, Binary Cross-Entropy Loss та Distribution Focal Loss. Показано, що правильне балансування втрат є критичним для досягнення високої якості детекції дрібних і швидко рухомих цілей, таких як дрони. Окремо розглянуті основні метрики оцінки якості моделей: mAP@0.5, mAP@0.5:0.95, Precision, Recall та F1-score, які є ключовими для кількісного аналізу ефективності системи виявлення.

У розділі, присвяченому рекомендаціям щодо навчання, наведено практичні аспекти підготовки даних, вибору архітектури, налаштування гіперпараметрів та процедур валідації. Підкреслено важливість використання великого обсягу різномірних даних, активного застосування аугментаційних технік та адаптації моделей для роботи з дрібними об'єктами через підвищення роздільної здатності зображень.

Таким чином, проведене дослідження узагальнює ключові архітектурні особливості, метрики та практичні аспекти навчання моделей YOLO в контексті виявлення безпілотних літальних апаратів. Отримані знання можуть слугувати базою для подальших прикладних досліджень, а також для розробки ефективних систем моніторингу повітряного простору в умовах обмежених обчислювальних ресурсів.

Перелік використаних джерел

1. *ZN.ua*. Дрони шпигували за навчанням українських військових на Patriot у Німеччині – ЗМІ. — 2024. — URL: <https://zn.ua/ukr/europe/droni-shpihuvali-za-navchannjam-ukrajinskikh-vijskovikh-na-patriot-u-nimechchini-zmi.html>.
2. *Київ С*. Російський дрон із фугасною бойовою частиною влучив в укриття на Чорнобильській АЕС. — 2024. — URL: <https://suspilne.media/kyiv/948291-rosijskij-dron-iz-fugasnou-bojovou-castinou-vluciv-v-ukritta-na-cornobilski-aes/>.
3. *Wikipedia*. Gatwick Airport drone incident. — URL: https://en.wikipedia.org/wiki/Gatwick_Airport_drone_incident.
4. *Sentrycs*. Most at-risk locations for drone threats. — URL: <https://sentrycs.com/uk/the-counter-drone-blog/most-at-risk-locations/>.
5. *Tayfun*. FPV дрони: що це таке і як вони працюють. — URL: <https://www.tayfun.in.ua/fpv-drony/>.
6. *Новини С*. Зеленський: 2024 року Україна виробила 22 мільйона FPV-дронів, у 2025-му зробить більше. — 2024. — URL: <https://suspilne.med>

- ia/955367-zelenskij-2024-roku-ukraina-virabila-22-miljona-fpv-droniv-u-2025-mu-zrobit-bilse/.
7. *Укрінформ*. Статистика атак українськими дронами вглиб Росії у 2024 році. — 2024. — URL: <https://www.ukrinform.ua/rubric-ato/3922251-statistika-atak-ukrainskimi-dronami-vglib-rosii-u-2024-roci.html>.
 8. *Systems R. R.* Drone Detection Radar. — 2018. — URL: <https://www.robinradar.com/files/robinradar-brchr-dronedetectie-jan-2018.pdf>.
 9. *Eriksson N.* Conceptual study of a future drone detection system: Countering a threat posed by a disruptive technology : дис. ... маг. / Eriksson N. — Gothenburg, Sweden : Chalmers University of Technology, 2018.
 10. *Karlsson B.* Modeling multicopter radar return: A study in discrimination of multicopter UAVs from birds using the micro-Doppler effect : дис. ... маг. / Karlsson B. — Gothenburg, Sweden : Chalmers University of Technology, 2017.
 11. *Peacock M., Johnstone M. N.* Towards Detection and Control of Civilian Unmanned Aerial Vehicles // 14th Australian Information Warfare and Security Conference. — Perth, Western Australia, 2013. — DOI: [10.4225/75/57a847dfbefb5](https://doi.org/10.4225/75/57a847dfbefb5).
 12. Matthan: Drone Presence Detection by Identifying Physical Signatures in the Drone's RF Communication / P. Nguyen, H. Truong, M. Ravindranathan, A. Nguyen, R. Han, T. Vu // *MobiSys '17*. — Niagara Falls, NY, USA, 2017. — С. 1—14.
 13. *Scheller W. D.* Detecting drones using machine learning : дис. ... маг. / Scheller W. D. — Ames, Iowa, USA : Iowa State University, 2017.
 14. *Casabianca P., Zhang Y.* Acoustic-based UAV detection using late fusion of deep neural networks // *Drones*. — 2021. — Т. 5. — С. 54.
 15. *Maxfield M.* Acoustic Detection of Drones. — n.d. — URL: <https://www.eejournal.com/article/acoustic-detection-of-drones/>.
 16. *Journal T. W. S.* These AI Cameras Detect Wildfires Before They Spread. — 2024. — URL: <https://www.wsj.com/tech/ai/these-ai-cameras-detect-wildfires-before-they-spread-6b6e3229>.
 17. *Technologies Z.* What Is a Machine Vision Camera? — URL: <https://www.zebra.com/us/en/resource-library/faq/what-is-machine-vision-camera.html>.
 18. *Wikipedia.* Automatic Number-Plate Recognition. — URL: https://en.wikipedia.org/wiki/Automatic_number_plate_recognition.
 19. *Library S. D.* Bio-Inspired Enhancement for Optical Detection of Drones Using Convolutional Neural Networks // *Proc. SPIE 12742*. — 2024. — URL: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/12742/127420F/10.1117/12.2673788.full>.
 20. *scribd.* Deep Learning for Unmanned Aerial Vehicles Detection: A Review. — <https://www.scribd.com/document/796295154/Deep-Learning-for-Unmanned-Aerial-Vehicles-Detection-a-Review>.
 21. *Sensors.* Drone Detection Using Deep Learning // *Sensors*. — 2020. — Т. 20, № 14. — С. 3856. — URL: <https://www.mdpi.com/1424-8220/20/14/3856>.
 22. *arXiv.* Deep Learning-Based Drone Detection. — 2024. — URL: <https://arxiv.org/html/2405.10398v1#S3>.
 23. *Nguyen V. K.* A Review of YOLOv8 Ecosystem. — 2023. — Accessed: 2025-05-04. <https://vankhoa21991.medium.com/a-review-of-yolov8-ecosystem-58675b386080>.