

<https://doi.org/10.31891/2307-5732-2026-363-74>

УДК 637.5.02

СТУПНИЦЬКИЙ РОСТИСЛАВ

Національний університет "Львівська політехніка"

<https://orcid.org/0009-0002-3933-6436>

e-mail: rostyslav.stupnytskyi.mknssh.2024@lpnu.ua

КРИВЕНЧУК ЮРІЙ

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0002-2504-5833>

e-mail: yurii.p.kryvenchuk@lpnu.ua

ПРОЄКТУВАННЯ CNN-ДЕТЕКТОРІВ МАЛОРОЗМІРНИХ БПЛА ДЛЯ ПЕРИФЕРІЙНИХ ПРИСТРОЇВ ДЛЯ ДОСЯГЕННЯ КОМПРОМІСУ МІЖ ТОЧНІСТЮ ТА ШВИДКОДІЄЮ

У роботі висвітлюється, як збереження дрібнодетальної інформації під час даунсемплінгу, удосконалення багатомасштабного злиття ознак у neck/head і використання дозованих модулів уваги можуть підвищувати якість детекції малих цілей та зменшувати кількість хибних спрацювань на складному фоні

Ключові слова: CNN, YOLO, детекція БПЛА, малі об'єкти, real-time, edge.

STUPNYTSKYI ROSTYSLAV, KRYVENCHUK YURIJ

Lviv Polytechnic National University

DESIGN OF CNN DETECTORS FOR SMALL-SIZED UAVS FOR PERIPHERAL DEVICES TO ACHIEVE A COMMITMENT BETWEEN ACCURACY AND SPEED

This article investigates the application of convolutional neural networks (CNNs) to improve the accuracy and robustness of small unmanned aerial vehicle (UAV) detection in images and video streams, with a particular focus on one-stage real-time detectors derived from the YOLO family and their lightweight adaptations for edge deployment. The study outlines how preserving fine-grained spatial cues during downsampling, strengthening multi-scale feature fusion in the neck/head, and incorporating selective (cost-aware) attention modules can enhance the detection of tiny targets while reducing false alarms caused by birds, clouds, compression artifacts, and cluttered backgrounds. It examines the core design mechanisms of CNN-based detectors for small objects, emphasizing the role of high-resolution branches, efficient feature pyramid topologies, and stable bounding-box regression when objects occupy only a few pixels. Additionally, the article discusses key evaluation aspects, including the importance of small-object metrics and the speed-accuracy trade-off that governs practical anti-UAV systems operating under strict latency, memory, and power constraints. Furthermore, the article considers operational challenges such as domain shifts across landscapes and weather conditions, low-light and infrared scenarios, and the need for temporal consistency in video, where integrating post-processing and tracking can improve stability beyond frame-level performance. By synthesizing recent research trends and practical constraints, the article underscores the necessity for continued development of CNN-centric design strategies and benchmarking protocols to support reliable real-time UAV detection on resource-limited platforms. To better handle extremely small targets, it highlights low-overhead choices such as a P2 scale branch, anti-aliasing downsampling, IoU-aware losses that stabilize regression on tiny boxes, calibrated confidence scoring, hard-negative mining, and deployment-minded quantization/pruning with NPU-friendly operators, etc. It also notes that training data should cover varied skies and seasons to reduce domain shift. It suggests reporting end-to-end latency and energy, not only GPU FPS. Finally, it calls for benchmarks and reproducible deployment configs., and emphasizes careful threshold tuning and lightweight temporal smoothing to suppress flicker in borderline detections. In practice, this combination helps maintain both precision and stable tracking under real-world noise.

Keywords: CNN, YOLO, UAV detection, small objects, real-time, edge deployment.

Стаття надійшла до редакції / Received 02.02.2026

Прийнята до друку / Accepted 01.02.2026

Опубліковано / Published 26.03.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Яропуд Віталій, Колісник Микола, Штуць Андрій

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

Масове застосування безпілотних літальних апаратів (БПЛА) у цивільних та військових сценаріях суттєво підвищило вимоги до систем спостереження й автоматичного виявлення малорозмірних цілей у відеопотоці. Типові об'єкти (квадрокоптери, FPV-дрони, малі літаки) часто займають незначну частку кадру, мають низький контраст на фоні неба або складних ландшафтів, можуть частково перекриватися перешкодами та швидко змінювати масштаб і ракурс. У таких умовах класичні підходи комп'ютерного зору демонструють високі показники пропусків і хибних спрацювань, особливо при слабкому освітленні, низькій якості відео, атмосферних завадах та на великих дистанціях.

Особливість задачі полягає в тому, що малий об'єкт у БПЛА-кадрах не є стабільною категорією, одна й та сама ціль може переходити між масштабами залежно від висоти зйомки, фокусної відстані, кута огляду та маневру. Додатково, візуальні ознаки БПЛА істотно варіюються між моделями та конфігураціями (форма, розмір, пропелери, матеріали), а також змінюються через розмиття руху, стиснення відеопотоку та шум сенсора. Це ускладнює побудову універсальних ознак і робить детекцію чутливою до доменних відмінностей між наборами даних, таких як різні ландшафти (ліс, місто, відкрите поле), різні погодні умови (туман, дощ, дим), різні режими освітлення (денний, нічний, контроле світло).

По-перше, центральною проблемою є збереження дрібнодетальної інформації під час побудови багатомасштабного подання ознак. У згорткових мережах (CNN) зменшення роздільної здатності

(downsampling) підвищує семантичність ознак, але призводить до втрати локальних деталей, критичних для малих цілей. Для БПЛА це означає, що інформативні структури можуть зникати на глибших рівнях, а детектор стає залежним від правильності злиття ознак між масштабами (FPN/PAFPN/AFPН та похідні), а також від наявності високороздільних гілок (наприклад, P2-рівня), здатних утримувати дрібні контури та точки.

По-друге, детекція БПЛА у реальному часі висуває жорсткі обмеження на обчислювальну складність. У практичних системах виявлення часто необхідне розгортання детекторів безпосередньо на периферійних пристроях (edge), де ресурси обмежені, CPU/GPU/NPU мають скромну продуктивність, доступна пам'ять невелика, а енергоспоживання та затримки є критичними. Це формує конфлікт вимог, з одного боку потрібна висока точність для малих об'єктів (що зазвичай вимагає більших моделей і вищої вхідної роздільності), з іншого – необхідна легковаговість, стабільний FPS та мінімальні затримки. У результаті актуальними стають архітектурні прийоми зменшення параметрів і FLOPs (depthwise-separable згортки, ghost-блоки, компактні neck/head, прюнінг, квантування) без суттєвої деградації якості саме на малих цілях.

По-третє, для БПЛА-сценаріїв критичним є баланс між recall і кількістю хибних спрацювань. Підсилення чутливості до малих об'єктів часто збільшує помилкові детекції на шумових структурах: птахи, гілки, блиск, дрібні хмари, перешкоди або артефакти стиснення. Практичні системи повинні враховувати ці ризики, оскільки надлишок хибних тривог знижує довіру до системи та ускладнює роботу операторів. Водночас, пропуски малих БПЛА можуть мати значно вищу ціну, тому детектор має забезпечувати стабільний високий recall у широкому спектрі умов, підтримуючи контрольований рівень precision за рахунок налаштування порогів, калібрування впевненості та підсилення просторово-канальної селективності ознак.

Додатковим ускладненням є те, що сучасний ландшафт детекції включає не лише чисті CNN-архітектури, а й гібридні підходи (CNN + attention). У контексті реального часу на edge найбільш практичним компромісом залишаються згорткові нейронні мережі та їх гібридні модифікації з помірними attention-модулями, оскільки вони забезпечують ефективний інференс. Крім того, такі архітектури краще зберігають баланс між точністю та затримкою за умов обмежених ресурсів пам'яті й енергоспоживання, що є критичним для автономних edge-пристроїв. Саме тому одноетапні CNN-детектори сімейства YOLO та їх сучасні модифікації для малих об'єктів (розширені neck/head, увага, легковагові блоки, компресія) є доцільною основою для оглядового аналізу тенденцій у задачі виявлення БПЛА.

Аналіз досліджень та публікацій

Сучасні дослідження у тематиці детекції малих об'єктів та систем протидії БПЛА демонструють зміщення від одиночних методів до системних, комбінованих рішень. Огляди з детекції малих об'єктів підкреслюють комплексний характер проблеми дуже малих цілей: одночасно впливають втрати інформації під час даунсемплінгу, доменні зсуви між датасетами, дисбаланс позитивних/негативних прикладів і нестабільність локалізації для малих обмежувальних рамок [2]. Огляди з протидії БПЛА додають практичний контекст – важливі робота в реальному часі, стійкість до складних погодних і світлових умов, а також стабільність у відеопотоці, де одиничний кадр не завжди дає надійне рішення [3]. Нижче узагальнено найбільш характерні напрями розвитку згорткових детекторів для БПЛА.

повторюваний мотив у роботах про БПЛА – посилення пірамід ознак і повернення деталей з високороздільних рівнів. Для дуже малих цілей недостатньо підняти ознаки вгору по піраміді ознак (FPN), важливо не втратити кілька пікселів, які несуть інформацію про дрон. Тому практичні модифікації часто вводять додаткові високороздільні гілки (наприклад, рівень P2) або уточнюють топологію злиття, щоб ранні деталі не розчинялися в семантичних ознаках [4]. У роботах, орієнтованих на малих об'єктів метрики, багатомасштабність часто поєднують із підсиленням контексту навколо цілі. Для БПЛА таким контекстом може бути структура неба, горизонту або ділянки ландшафту; ця інформація допомагає відрізнити справжню ціль від шуму й дрібних перешкод, які локально виглядають схоже.

Частина публікацій показує, що приріст на малих БПЛА часто досягається без зміни базової частини (бекбону) – а рахунок перебудови проміжного блоку (neck) (шляхи передачі ознак) та детекційної голови. Такі зміни можуть виглядати локальними, але на практиці вони визначають, чи дійдуть дрібні деталі до регресора обмежувальних рамок і чи буде достатньо інформації для класифікації. Прикладом є роботи на базі YOLOv8n, де увага приділяється саме передачі високороздільних ознак для малих цілей [7]. Типові рішення включають посилення зворотних зв'язків (bottom-up), введення додаткових вузлів злиття та спрощення детекційної голови (head) для стабільнішої регресії на дуже малих рамках. У багатьох роботах це робиться так, щоб приріст точності не зруйнував вимоги реального часу.

Anti-UAV практично завжди зводиться до питання – чи витримає модель цільову платформу. Тому популярні модифікації включають глибинно-роздільні згортки, ghost-подібні (примарні) блоки, перепараметризацію та інші прийоми зменшення обчислень. EDGS-YOLOv8 демонструє характерну стратегію – точність підсилюється в критичних місцях (на малих цілях), а зазначена вага моделі стримується [6]. Подібна логіка простежується і в DRBD-YOLOv8, де акцентовано баланс між параметрами, швидкістю та якістю на протидії БПЛА даних [9]. Практична цінність таких робіт полягає в демонстрації реалістичного дизайну для розгортання, а не лише лабораторної mAP на потужному GPU.

Оскільки даунсемплінг є місцем, де дуже малі цілі губляться найшвидше, у 2025 році активно з'являються модулі розумного зменшення роздільної здатності. LRDS-YOLO пропонує легку адаптивну схему, яка прагне зберегти корисні локальні структури під час редукції та водночас не перевантажити обчислення [10].

В оглядах детекції малих об'єктів цей напрям подається як один з найперспективніших, якщо зменшити втрати на ранніх шарах, то решта мережі отримує сильніший сигнал і потребує менше компенсаторних прийомів у проміжного блоку та детекційної голови [2]. Для БПЛА це особливо важливо у низькоконтрастних сценах, де контури слабкі й легко зникають.

Нічні та слабоосвітлені сцени стали типовою умовою експлуатації протидії БПЛА. ELS-YOLO демонструє, що навіть легковагова модель може бути адаптована до сцен із низьким освітленням, якщо поєднати перепараметризований базової частини (бекбону) з помірними модулями уваги та коректною тренувальною стратегією [11]. Практичний висновок – модель, натренована на денних даних, часто деградує вночі. Тому сучасні роботи включають цільові аугментації (затемнення, підтягування шуму, туман, стискання) і тестування в умовах, близьких до експлуатації, що прямо впливає на кількість пропусків у відеопотоці.

Загальний тренд на увагу торкнувся і YOLO – у 2025 році з'являються attention-centric постановки, зокрема YOLOv12 [12]. Для дуже малих об'єктів увага корисна тим, що може вибірково підсилувати слабкі локальні сигнали та приглушувати фон, який інакше перетягує на себе активації. Водночас для крайових пристроїв детекції attention має бути дозованою, у UAV-працях частіше використовують легкі варіанти (channel/spatial attention, неквадратичні блоки), інтегровані в окремі вузли, а не повну заміну CNN на важкі трансформерні схеми. Це зберігає швидкодію та підвищує стабільність на складному фоні.

Огляди детекції малих об'єктів підкреслюють, що для малих цілей інколи вирішальними є підготовка даних і розподіл масштабів та негативів, а не архітектура [2]. Для БПЛА негативи часто важчі за позитиви: птахи, артефакти стискання, дрібні хмари. Anti-UAV огляд акцентує важливість таких сценаріїв для реальної системи [3]. Практично це реалізують через цільові аугментації, відбір фонів, синтетичні вставки малих об'єктів у різні сцени та роботу з складних негативних прикладів. Такі прийоми не замінюють реальних даних, але суттєво розширюють варіативність умов і допомагають підвищити recall без неконтрольованого зростання хибних тривог.

Edge-вимоги підштовхують до компресії, але для дуже малих цілей це ризиковано через те, що слабкі ознаки легко втрачаються. Тому роботи на кшталт DRBD-YOLOv8 демонструють обережні, структурні оптимізації й підкреслюють збереження якості при зменшенні обчислень [9]. У більш загальних підходах дедалі частіше комбінують м'яке прюнінція з дистилляцією знань, де компактна модель навчається від більшої на складних прикладах, щоб не втратити чутливість до малих БПЛА. Це є логічним для цілі стабільного реального часу на обмеженому залізі.

Коли рамка займає десятки пікселів, зсув на 2-3 пікселі вже суттєво змінює перетину-над-об'єднанням (IoU), а отже і метрики. Тому з'являються модифікації функцій втрат, які адекватніше поводяться з малими об'єктами. У DRBD-YOLOv8 запропоновано DN-Shape перетину-над-об'єднанням (IoU), націлений на стабільнішу регресію рамок [9]. Огляди детекції малих об'єктів також згадують адаптивне призначення позитивів (призначення позитивних прикладів) і узгодження класифікації/локалізації як важливі чинники для дуже малих цілей [2]. На практиці це означає, що правильний функції втрат і правила призначення можуть дати приріст без зміни архітектури, особливо коли проблема полягає у нестабільній локалізації та плаваючих оцінок впевненості (score).

Anti-UAV огляди підкреслюють, що реальна система рідко покладається на один кадр, адже потрібне підтвердження в часі та зменшення мерехтливих помилок [3]. Тому поширюються прості пост-обробки (N-кадрове підтвердження, згладження оцінок впевненості, фільтрація нестабільних обмежувальних рамок) і інтеграція з трекером. Для малих БПЛА це дає помітний практичний ефект – одиничні хибні спрацювання часто зникають після часової валідації, а пропуски частково компенсуються трекінгом, який підтримує траєкторію. Важливість напряму полягає в тому, що покращення на відео не завжди видно у стандартних офлайн-метриках, але воно критично впливає на експлуатацію.

Формулювання цілей статті

Метою роботи є: узагальнити сучасні підходи до побудови легковагових згорткових детекторів малорозмірних цілей у знімках/відео з БПЛА та сформулювати практичні принципи проєктування CNN-архітектур для реального часу з урахуванням багатомасштабності, стійкості та ресурсних обмежень.

Виклад основного матеріалу

На рисунку 1 наведено типову динаміку метрик точності та швидкодії в абляційному аналізі покровових модифікацій детектора: приріст mAP50 досягається ціною зменшення FPS, а найбільш цінними є зміни, що поліпшують дрібнодетальне багатомасштабне представлення ознак без різкого зростання обчислень [6].

Практичний висновок з таких абляцій полягає в тому, що оптимізація для БПЛА не зводиться до нарощування розміру моделі. Натомість ефект часто дають точкові зміни у проміжному блоці багатомасштабного злиття та детекційній голові, які покращують передачу високороздільних ознак і стабілізують локалізацію на дуже малих рамках [2,6]. У роботах зі спрямуванням на малі об'єкти це узгоджується з висновками оглядів – якщо слабкий локальний сигнал губиться на ранніх етапах, то подальше ускладнення архітектури дає обмежений ефект, тоді як відновлення дрібних ознак у піраміді ознак може суттєво підвищити APS [2].

На рисунку 2 показано компроміс між швидкістю і точністю для низки детекторів на anti-UAV даних.

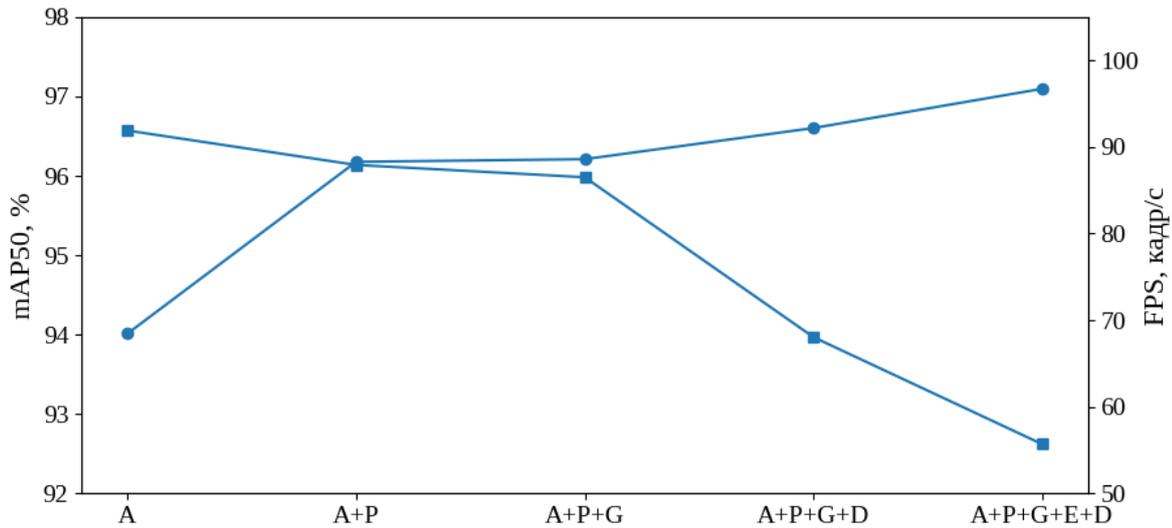


Рис. 1. Зміна mAP50 та FPS в абляційному експерименті EDGS-YOLOv8

Видно, що моделі, орієнтовані на реальний час, утворюють фронт Парето – при близьких значеннях FPS точність визначається якістю багатомасштабного злиття, підсиленням ознак та прийомами полегшення архітектури [3,6]. З погляду проектування системи це означає, що вибір моделі не може базуватися лише на mAP, потрібно враховувати вимоги до затримки, типові дистанції виявлення, бюджет хибних тривог та доступні апаратні ресурси [3].

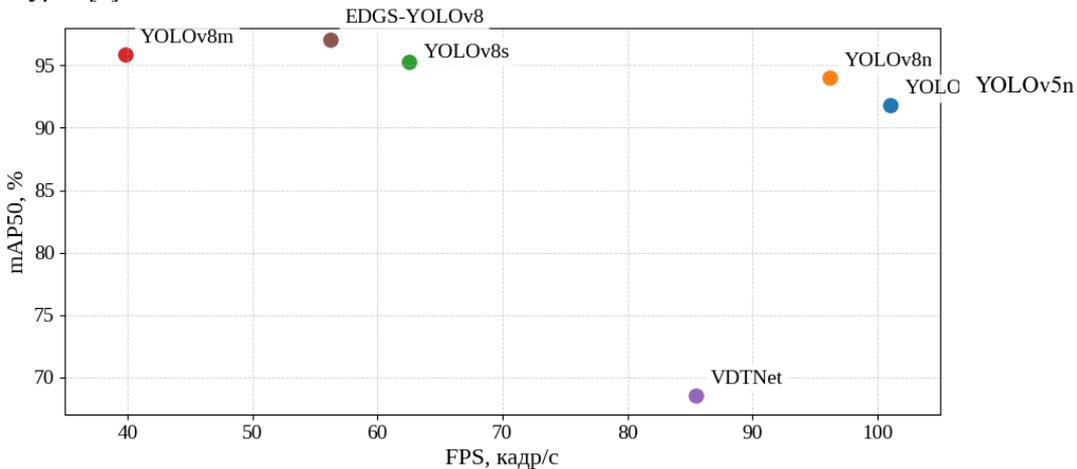


Рис. 2. Компроміс швидкість-точність на DUT Anti-UAV

Для задачі малих повітряних цілей показовою є метрика AP-small. У багатьох роботах її інтерпретують як показник здатності детектора утримувати дрібні локальні структури та адекватно призначати позитивні приклади для малих рамок [2]. На рисунку 3 порівняно AP-small для базового YOLOv8 і модифікації SOD-YOLO на різних масштабах моделі, що ілюструє типову перевагу спеціалізованого дизайну для дрібних об'єктів [4].

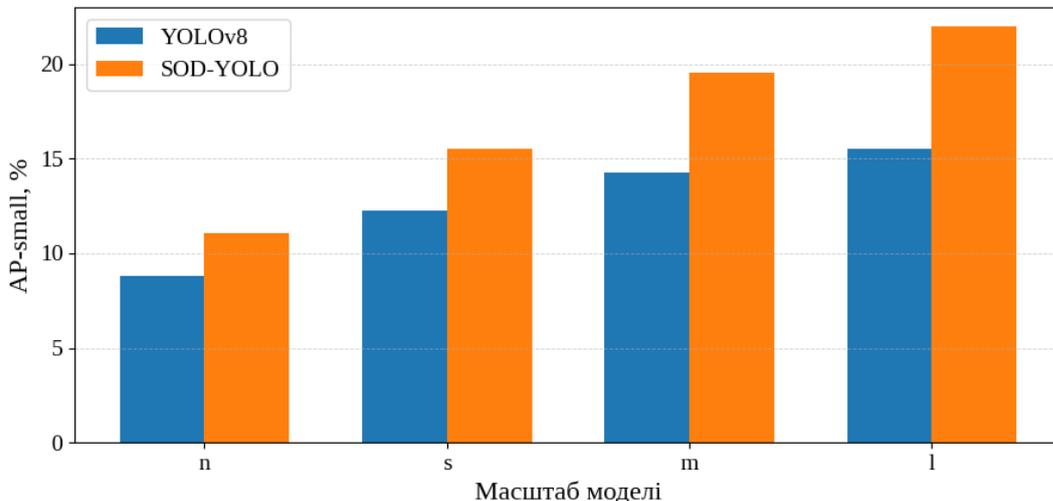


Рис. 3. Порівняння AP-small для YOLOv8 та SOD-YOLO на різних масштабах

Під малорозмірними об'єктами у цій роботі розуміємо випадок, коли ціль займає дуже малу частку кадру та має обмежений візуальний сигнал для одночасної класифікації і локалізації. У термінах популярних бенчмарків (на кшталт COCO) малий об'єкт часто визначають за площею рамки, але для БПЛА більш практичним є визначення через співвідношення розміру цілі до кроку дискретизації карти ознак та через дистанцію до сенсора, яка визначає кількість пікселів на об'єкті [2,3].

Збільшення вхідної роздільності (наприклад 640 до 960 до 1280) підвищує повноту для малих об'єктів, але збільшує обчислювальні операції (FLOPs) і затримку. У сучасних роботах це компенсують локальними архітектурними змінами у проміжному блоці та голові, отримуючи приріст без непропорційного росту ресурсів [4][5][6][9][10]. Показовою є і модифікація під UAV-знімки на базі найменшої конфігурації YOLOv8n, навіть малі моделі можуть давати корисну якість за умови правильної багатомасштабної передачі ознак і грамотного налаштування навчання [7].

Огляди вказують, що переносимість моделей між UAV-датасетами обмежена відмінностями сенсорів, висоти зйомки, фону та деградації відео [2,3]. Тому дані для навчання мають відтворювати реальні умови: шум, розмиття руху, стискання, туман/дим та варіативність освітлення. Важкі негативи (птахи, відблиски, дрібні хмари) слід балансувати з позитивами, інакше модель підвищує чутливість ціною неконтрольованого зростання хибних спрацювань [3].

Окремо для UAV-детекції важливими є прийоми збільшення варіативності масштабу – мозаїчні аугментації, випадкові кропи, а також процедури, що підвищують представленість малих цілей у навчанні. Огляди з детекції малих об'єктів зазначають, що оптимізація даних і розподілу позитивів/негативів інколи дає приріст, порівнянний з архітектурними модифікаціями [2].

YOLO-подібні CNN-детектори складаються з трьох компонентів, і для малих БПЛА недостатньо оптимізувати лише один з них: підсилення злиття ознак працює краще, якщо базова частина зберігає дрібні ознаки, а голова стабільно їх використовує [2][4][5][9][10].

Для розгортання на периферійних пристроях часто застосовують легкі згортки (глибинно-роздільні), компактні блоки та перепараметризацію, що спрощує обчислювальний граф під час інференсу. У EDGS-YOLOv8 і DRBD-YOLOv8 показано, що помірне полегшення базової частини може зберегти точність, якщо критичні покращення реалізовані у злитті ознак та голові [6,9]. Для дрібних БПЛА критичним є високороздільний шлях, коректне вирівнювання/злиття ознак і контроль затримки. Роботи 2024-2025 років демонструють, що адаптивні механізми підсилення та передавання ознак (зокрема у LPAE-YOLOv8) підвищують якість на малих об'єктах, не руйнуючи вимоги реального часу [4][5][6][8][10].

Детекційна голова. У роботах для малих цілей часто стабілізують регресію рамок і узгоджують класифікацію з локалізацією. DRBD-YOLOv8, зокрема, спрямований на підвищення ефективності та точності за рахунок налаштувань голови і функцій втрат, чутливих до масштабу та форми рамок [9].

Таким чином, оптимальна система детекції БПЛА формується як компроміс архітектури, даних та інференсу. Найбільший практичний приріст зазвичай дає комбінація збереження дрібних ознак на ранніх шарах, адекватного багатомасштабного злиття у піраміді ознак, контрольованої легковаговості для периферійної платформи та (iv) відео-стабілізації результатів на рівні постобробки/трекінгу [2][3][4][5][6][9][11].

Висновки з даного дослідження

і перспективи подальших розвідок у даному напрямі

У даній статті узагальнено ключові напрями розвитку CNN-детекторів для виявлення малорозмірних БПЛА, де вирішальними є збереження дрібнодетальної інформації та стійкість у складних умовах зйомки. Показано, що практично значущі покращення для малих цілей найчастіше забезпечують архітектурні зміни у багатомасштабному злитті ознак і детекційній голові (включно з високороздільними шляхами та коректним узгодженням ознак між масштабами), а не просте збільшення параметрів моделі. Для реального часу на периферійних пристроях критичною є оптимізація обчислень за рахунок полегшених згорток, компактних блоків і дозованих модулів уваги, при цьому вибір моделі має базуватися на компромісі «точність–швидкодія» та на метриках, чутливих до малих об'єктів. Встановлено, що доменна варіативність (фон, погода, освітлення, стискання відео) та «важкі» негативи напряму впливають на рівень хибних спрацювань, тому підготовка даних і стратегія навчання є не менш важливими за архітектуру. Для експлуатаційної надійності у відеопотоці доцільно застосовувати часову валідацію результатів і інтеграцію з трекінгом, що зменшує мерехтливі помилки та підвищує стабільність детекції. Отримані узагальнення формують практичні принципи проектування легковагових CNN-архітектур для детекції малих БПЛА з урахуванням багатомасштабності, ресурсних обмежень та вимог реального часу.

Література

1. Page M. J., McKenzie J. E., Bossuyt P. M. та ін. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews / Page M. J., McKenzie J. E., Bossuyt P. M. та ін. // *BMJ*. – 2021. – Т. 372. – № n71. – DOI: 10.1136/bmj.n71.
2. Nikouei M. та ін. Small object detection: A comprehensive survey on challenges, techniques and real-world applications / Nikouei M. та ін. – 2025.

3. Dong Y. та ін. Securing the Skies: A Comprehensive Survey on Anti-UAV Methods, Benchmarking, and Challenges / Dong Y. та ін. // CVPR Workshops (Anti-UAV). – 2025.
4. Li Y., Li Q., Pan J. та ін. SOD-YOLO: Small-Object-Detection Algorithm Based on Improved YOLOv8 for UAV Images / Li Y., Li Q., Pan J. та ін. // Remote Sensing. – 2024. – Т. 16. – № 16. – № статті 3057. – DOI: 10.3390/rs16163057.
5. Khalili B. та ін. SOD-YOLOv8—Enhancing YOLOv8 for Small Object Detection / Khalili B. та ін. // Sensors. – 2024. – Т. 24. – № 19. – № статті 6209. – DOI: 10.3390/s24196209.
6. Huang M., Mi H., Wang Y. та ін. EDGS-YOLOv8: An Improved YOLOv8 Lightweight UAV Detection Model / Huang M., Mi H., Wang Y. та ін. // Drones. – 2024. – Т. 8. – № 7. – № статті 337. – DOI: 10.3390/drones8070337.
7. Xu L., Zhao Y., Zhai Y. та ін. Small Object Detection in UAV Images Based on YOLOv8n / Xu L., Zhao Y., Zhai Y. та ін. // International Journal of Computational Intelligence Systems. – 2024. – Т. 17. – № статті 223. – DOI: 10.1007/s44196-024-00632-3.
8. Zhao Y. та ін. LPAE-YOLOv8: Lightweight aerial small object detection via feature enhancement / Zhao Y. та ін. // Scientific Reports. – 2025. – DOI: 10.1038/s41598-025-28741-9.
9. Jiang P., Yang X., Wan Y. та ін. DRBD-YOLOv8: A Lightweight and Efficient Anti-UAV Detection Model [Електронний ресурс] / Jiang P., Yang X., Wan Y. та ін. – 2024. – PMID: PMC11598377.
10. Han Y., Wang C., Luo H. та ін. LRDS-YOLO enhances small object detection in UAV aerial images with a lightweight and efficient design / Han Y., Wang C., Luo H. та ін. // Scientific Reports. – 2025. – Т. 15. – № 1. – DOI: 10.1038/s41598-025-07021-6.
11. Weng T., Niu X. Enhancing UAV Object Detection in Low-Light Conditions with ELS-YOLO: A Lightweight Model Based on Improved YOLOv11 / Weng T., Niu X. // Sensors. – 2025. – Т. 25. – № 14. – № статті 4463. – DOI: 10.3390/s25144463.
12. Tian Y., Ye Q., Doermann D. YOLOv12: Attention-Centric Real-Time Object Detectors [Електронний ресурс] / Tian Y., Ye Q., Doermann D. – 2025. – arXiv:2502.12524.
13. Wang C., Wang R., Wu Z. та ін. YOLO-UIR: A Lightweight and Accurate Infrared Object Detection Network Using UAV Platforms / Wang C., Wang R., Wu Z. та ін. // Drones. – 2025. – Т. 9. – № 7. – № статті 479. – DOI: 10.3390/drones9070479.

References

1. Page M. J., McKenzie J. E., Bossuyt P. M. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews // BMJ. – 2021. – Vol. 372. – n71. – DOI: 10.1136/bmj.n71.
2. Nikouei M. et al. Small object detection: A comprehensive survey on challenges, techniques and real-world applications. – 2025.
3. Dong Y. et al. Securing the Skies: A Comprehensive Survey on Anti-UAV Methods, Benchmarking, and Challenges // CVPR Workshops (Anti-UAV). – 2025.
4. Li Y., Li Q., Pan J. et al. SOD-YOLO: Small-Object-Detection Algorithm Based on Improved YOLOv8 for UAV Images // Remote Sensing. – 2024. – Vol. 16. – No. 16. – Article 3057. – DOI: 10.3390/rs16163057.
5. Khalili B. et al. SOD-YOLOv8—Enhancing YOLOv8 for Small Object Detection // Sensors. – 2024. – Vol. 24. – No. 19. – Article 6209. – DOI: 10.3390/s24196209.
6. Huang M., Mi H., Wang Y. et al. EDGS-YOLOv8: An Improved YOLOv8 Lightweight UAV Detection Model // Drones. – 2024. – Vol. 8. – No. 7. – Article 337. – DOI: 10.3390/drones8070337.
7. Xu L., Zhao Y., Zhai Y. et al. Small Object Detection in UAV Images Based on YOLOv8n // International Journal of Computational Intelligence Systems. – 2024. – Vol. 17. – Article 223. – DOI: 10.1007/s44196-024-00632-3.
8. Zhao Y. et al. LPAE-YOLOv8: Lightweight aerial small object detection via feature enhancement // Scientific Reports. – 2025. – DOI: 10.1038/s41598-025-28741-9.
9. Jiang P., Yang X., Wan Y. et al. DRBD-YOLOv8: A Lightweight and Efficient Anti-UAV Detection Model [Electronic resource]. – 2024. – PMID: PMC11598377.
10. Han Y., Wang C., Luo H. et al. LRDS-YOLO enhances small object detection in UAV aerial images with a lightweight and efficient design // Scientific Reports. – 2025. – Vol. 15. – No. 1. – DOI: 10.1038/s41598-025-07021-6.
11. Weng T., Niu X. Enhancing UAV Object Detection in Low-Light Conditions with ELS-YOLO: A Lightweight Model Based on Improved YOLOv11 // Sensors. – 2025. – Vol. 25. – No. 14. – Article 4463. – DOI: 10.3390/s25144463.
12. Tian Y., Ye Q., Doermann D. YOLOv12: Attention-Centric Real-Time Object Detectors [Electronic resource]. – 2025. – arXiv:2502.12524.
13. Wang C., Wang R., Wu Z. et al. YOLO-UIR: A Lightweight and Accurate Infrared Object Detection Network Using UAV Platforms // Drones. – 2025. – Vol. 9. – No. 7. – Article 479. – DOI: 10.3390/drones9070479.