

ГОРЕЛОВ СЕРГІЙ

Хмельницький національний університет  
e-mail: [shorielov@ukr.net](mailto:shorielov@ukr.net)

БАРМАК ОЛЕКСАНДР

Хмельницький національний університет  
<https://orcid.org/0000-0003-0739-9678>  
e-mail: [alexander.barmak@gmail.com](mailto:alexander.barmak@gmail.com)

МАНЗЮК ЕДУАРД

Хмельницький національний університет  
<https://orcid.org/0000-0002-7310-2126>  
e-mail: [eduard.em.km@gmail.com](mailto:eduard.em.km@gmail.com)

## МЕТОД ВИЯВЛЕННЯ БАГАТОРОТОРНИХ БПЛА ЗАСОБАМИ ШТУЧНОГО ІНТЕЛЕКТУ

Зростаюче використання безпілотних літальних апаратів (БПЛА) у різноманітних комерційних та технічних секторах підкреслило необхідність надійного спостереження за БПЛА, особливо з огляду на питання громадської безпеки. У відповідь на цю вимогу було швидко розвинуто методи ідентифікації БПЛА. Незважаючи на прогрес, маленький розмір дронів, складні умови повітряного простору та зміни у освітленні залишаються значними викликами в цій сфері досліджень. З метою розв'язання цих викликів проведено дослідження, що базується на новому підході до виявлення БПЛА невеликих розмірів, використовуючи вдосконалену версію YOLOv8.

Запропоновано метод, який дозволяє інтегрувати модуль високої деталізації для підвищення точності виявлення дрібних повітряних об'єктів. Також було оптимізовано архітектуру шляхом видалення елементів, що є більш важливими для великих об'єктів, тим самим зменшуючи обчислювальне навантаження та прискорюючи швидкість виявлення БПЛА. Крім того, використання Swin Transformer дозволяє краще виявляти об'єкти різних масштабів та зменшує обчислювальну складність. Також впровадження модуля уваги GAM у архітектуру мережі значно підвищує здатність до асиміляції ознак, що призводить до помітного підвищення ефективності виявлення БПЛА.

У порівнянні з оригінальною базовою моделлю, наш запропонований метод демонструє суттєві покращення, збільшуючи  $P$  (precision),  $R$  (recall) та  $mAP$  (mean average precision) на 9%, 10,2% та 6% відповідно. Крім того, він істотно оптимізує модель за кількістю входних параметрів на 32,5% та 32,4% відповідно. Запропонований метод у порівняльних експериментах та експериментах зі специфічними наборами даних показав велику перспективу для практичної реалізації в системах виявлення об'єктів БПЛА, що дає підстави говорити про перспективу застосування в реальних умовах.

Ключові слова: БПЛА, виявлення об'єктів, YOLOv8, глибоке навчання.

GORELOV SERHII

Khmelnytsky National University  
e-mail: [shorielov@ukr.net](mailto:shorielov@ukr.net)

BARMAC OLEXANDER

Khmelnytsky National University  
<https://orcid.org/0000-0003-0739-9678>  
[alexander.barmak@gmail.com](mailto:alexander.barmak@gmail.com)

MANZIUK EDUARD

Khmelnytsky National University  
<https://orcid.org/0000-0002-7310-2126>  
[eduard.em.km@gmail.com](mailto:eduard.em.km@gmail.com)

## METHOD OF DETECTING MULTI-ROTOR UAVS USING ARTIFICIAL INTELLIGENCE

The escalating deployment of Unmanned Aerial Vehicles (UAVs) in various commercial and technical sectors has highlighted the need for robust UAV surveillance, particularly for public safety considerations. In response to this demand, there has been rapid advancement in methods for identifying UAVs. Despite the progress, the diminutive nature of drones, the intricate environments of aerial space, and fluctuating lighting conditions continue to present considerable challenges in this field of study. Addressing these issues, our study introduces an innovative detection approach for small UAVs, utilizing an enhanced version of YOLOv8.

Our strategy involves integrating a high-definition detection module to augment the accuracy of spotting diminutive aerial objects. Concurrently, we streamline the architecture by removing components less critical for larger objects, thereby diminishing the computational load and boosting UAV detection speed. Additionally, the use of the Swin Transformer enables better detection of objects of varying scales and reduces computational complexity. The implementation of the GAM attention module into the network architecture significantly enhances feature assimilation, leading to a noticeable increase in UAV detection efficiency.

Compared to the original baseline model, our proposed method shows substantial improvements, increasing  $P$  (precision),  $R$  (recall), and  $mAP$  (mean average precision) by 9%, 10.2%, and 6% respectively. Furthermore, it significantly optimizes the model and its size by 32.5% and 32.4%. The proposed method, in comparative experiments and experiments with specific datasets, has shown great potential for practical implementation in UAV detection systems, suggesting its feasibility for real-world application.

Keywords: UAV; object detection; YOLOv8; deep learning.

### Постановка проблеми

Тема розпізнавання багатороторних безпілотних літальних апаратів (БПЛА) засобами штучного інтелекту в останні роки набула великої актуальності у сучасному науково-технічному середовищі.

Зростання популярності БПЛА спостерігається у різноманітних сферах життєдіяльності – від аграрної та геодезійної галузей до використання в мілітарних цілях і системах нагляду. Це зумовлено різноманітністю їх застосувань, здатністю виконувати завдання в недоступних або небезпечних для людей зонах, а також їх ефективністю та доступністю.

У зв'язку з цим, ідентифікація та моніторинг БПЛА стають критично важливими задачами, особливо у контексті забезпечення національної безпеки та приватності. Розпізнавання багатороторних БПЛА методами штучного інтелекту відіграє ключову роль у вирішенні цього питання. Штучний інтелект, а конкретно – машинне навчання та нейронні мережі, демонструють значні результати в детектуванні та класифікації об'єктів у реальному часі, навіть у складних умовах.

Актуальність дослідження посилюється високою здатністю сучасних методів штучного інтелекту адаптуватися до динамічних умов реального середовища, вирішувати завдання з великою точністю та ефективністю, що є умовою для покращення систем розпізнавання БПЛА.

### Аналіз останніх джерел

Зростання продуктивності апаратних засобів підвищило здатність обробки даних комп'ютерами, що призвело до стрімкого прогресу в технологіях обробки візуальних даних, які базуються на глибокому навчанні з використанням великого набору даних. Виявлення об'єктів за допомогою технологій комп'ютерного зору привернуло значну увагу дослідників. Технологія розвивалася від традиційного виявлення ознак [1, 2, 3], що використовували обчислення згорток для розпізнавання об'єктів, до використання глибокого навчання для підвищення точності розпізнавання при візуальному представленні об'єктів. Порівняно з традиційними методами виявлення електромагнітних сигналів, такими як радар, лазер, інфрачервоне випромінювання, аудіо та радіочастоти, виявлення об'єктів за допомогою візуальних сенсорів, зокрема камер, що записують групові відео та зображення, пропонує більш інтуїтивне виявлення. Виявлення об'єктів за допомогою візуальних сенсорів, має переваги, такі як виявлення у реальному часі та динамічний запис послідовних зображень цілей, низька вартість, висока швидкість виявлення та стійкість до низьковисотних перешкод [4].

Виявлення об'єктів є важливою сферою досліджень в області комп'ютерного зору та основою для чисельних, складних, візуальних завдань. Його широко застосовують у промисловості, сільському господарстві та інших галузях [5, 6]. З 2014 року було досягнуто значного прогресу в методах виявлення об'єктів, заснованих на глибокому навчанні. В промисловості було введено різноманітні алгоритми, включаючи Faster R-CNN [7], SSD [8] і серію YOLO [9]. Зі швидким розвитком технології виявлення цілей з'явилося кілька ефективних методів, які можна застосувати для завдань виявлення БПЛА [10–14]. Наприклад, у дослідженні [10] яке присвячене детектуванню обличчя на зображенні, вказано, що згорткові нейронні мережі стикаються з викликом забезпечення балансу між точністю виявлення та розміром моделі. Для вирішення цієї проблеми автори запропонували рекурентний шлях і модуль просторової уваги в оригінальний детектор обличчя (EXTD), покращуючи його здатність вилучати характеристики з маленьких цілей БПЛА. Розмір моделі складає лише 690,7 кБ. Однак, ця модель показує повільний час виведення та не підходить для використання у практичних інженерних сценаріях. У дослідженні [11] було запропоновано мережу виявлення цілей БПЛА на основі інтегрального об'єднання функцій: спочатку вилучаються характеристики чутливого поля цілі за допомогою res2net, далі покращується продуктивність мережі вилученням деяких та злиттям інших характеристик, і нарешті досягається кращий результат на самостійно побудованому наборі даних для виявлення БПЛА. У роботі [12] авторами було наведено новий метод виявлення БПЛА, цей метод покращує процес ідентифікації БПЛА, зосереджуючись на параметрах та обчислювальних можливостях для забезпечення виявлення в режимі реального часу через веб-додаток. Це дозволяє отримувати дані про присутність БПЛА у визначеній зоні з будь-якого місця, навіть через мобільний телефон. Експерименти показують, що використання веб-додатку надає переваги у порівнянні з традиційними методами обробки, і процес виявлення є значно ефективнішим. У роботі [13] пропонується легка згорткова нейронна мережа з розширеними функціями, здатна до високоточного виявлення об'єктів низького польоту у реальному часі. Вона ефективна проти нелегальних дронів у повітряному просторі. У роботі [14] пропонується новий метод глибокого навчання, який називається мережею згорткових перетворень – Convolutional and Transformation Network (CT-Net). Основа цієї мережі спочатку включає блок трансформації що підсилює увагу, він створює підсилений механізм для покращення здатності моделі вилучати характеристики. Потім застосовується легкий модуль bottleneck для контролю обчислювального навантаження та зниження обчислювальних вимог. Також, пропонується структура злиття інформації з різних джерел або каналів для покращення точності виявлення при роботі з об'єктами різного масштабу, особливо малими об'єктами. Підхід досягає mAP 0,966 на самостійно створеному наборі даних для маленьких об'єктів низької висоти, демонструючи високу точність виявлення. Проте, встановлений показник швидкості обробки зображень у системі, складає лише 37 кадрів на секунду. Для виявлення БПЛА, швидкість обробки зображень є критичним фактором. Оскільки БПЛА часто рухаються з високою швидкістю і можуть з'являтися в різноманітних середовищах, системам виявлення необхідно швидко аналізувати візуальну інформацію, щоб ефективно ідентифікувати і відстежувати ціль. Швидкість в 37 кадрів на секунду (frames per second – FPS) може бути недостатньою для деяких сценаріїв використання, де важлива миттєва реакція. Тому, існуючий показник FPS вказує на потенціал для розвитку та оптимізації

системи виявлення БПЛА, з метою досягнення більш високої швидкості обробки кадрів без втрати точності виявлення.

Хоча у технології виявлення БПЛА було досягнуто значного прогресу, існуючі методи виявлення все ще стикаються з проблемами балансування точності виявлення, розміру моделі та швидкості виявлення. Мережа виявлення серії YOLO ефективно вирішила ці проблеми. Моделі серії YOLO пройшли вісім офіційних ітерацій та кілька версій, продемонструвавши чудову точність та швидкодію виявлення. Ці моделі мають широке застосування у різних галузях, включаючи медицину, транспорт, дистанційне зондування та промисловість [15]. Вчені широко досліджували використання моделей серії YOLO для виявлення цілей БПЛА, як це відображено у численних працях [16–19]. Наприклад, у дослідженні [16], шляхом інтеграції модуля механізму уваги в алгоритм виявлення PP-YOLO, були зроблені вдосконалення для покращення його продуктивності. Крім того, введення функції активації Mish, вирішило проблему градієнт-зникнення під час процесу зворотного розповсюдження, що призвело до значного підвищення точності виявлення. У роботі [17] було запропоновано алгоритм виявлення БПЛА для складних міських фонів, на основі YOLOv3. Він використовував популярну архітектуру Feature Pyramid Network (FPN), яка ефективно використовує інформацію на різних рівнях роздільної здатності, щоб покращити здатність системи виявляти об'єкти незалежно від їхнього розміру в зображенні. Також була використана мережа Ghost для прискорення моделі. Експериментальні результати показали, що алгоритм виявив високу стійкість та ефективно виявляє малі цілі БПЛА у складних сценах. У дослідженні [18] згортоква нейронна мережа, MobileNet2, замінила оригінальний backbone CSPDarknet53, високопродуктивної моделі YOLOv4. Ця заміна була спрямована на зменшення масштабу моделі та спрощення обчислювальних операцій. Експериментальні результати показали, що Mob-YOLO може досягти точного моніторингу цілей БПЛА в реальному часі з меншим розміром моделі, що робить її придатною для вбудованих процесорів. У роботі [19] було запропоновано розподілену антидронову систему на основі YOLOv5. Об'єднуючи ідеї поліпшення, запропоновані у вищевказаній літературі щодо серії YOLO, авторами пропонується вдосконалити модель YOLOv8s та зробити її придатною для виявлення маленьких об'єктів БПЛА, без суттєвих втрат точності виявлення та швидкості на складному наборі даних про малі БПЛА.

**Мета роботи** полягає в удосконаленні моделі YOLOv8s для покращення виявлення безпілотних літальних апаратів (БПЛА) шляхом адаптації архітектури мережі до конкретних особливостей практичного застосування, зокрема виявлення об'єктів малих розмірів.

**Виклад основного матеріалу**

Зважаючи на проведений аналіз за основу було обрано YOLOv8. YOLOv8 є еволюцією попередніх версій YOLO, включаючи нові характеристики та удосконалення для подальшого підвищення продуктивності та гнучкості, досягаючи вражаючої швидкості та високої ефективності. YOLOv8 пропонує п'ять моделей різного розміру: нано, мала, середня, велика та дуже велика. Наномодель має лише 3,2 мільйони параметрів, що сприяє легкому впровадженню на мобільні пристрої та пристрої, які працюють лише на CPU. Щоб знайти баланс між точністю виявлення та швидкістю, в цій роботі використовується модель YOLOv8s для виявлення БПЛА, яка є результатом розширення та поглиблення структури наномережі.

YOLOv8 поділяється на backbone, neck та head, які використовуються для екстракції особливостей, злиття багатьох особливостей та виведення прогнозу. Дизайн мережі YOLOv8 представлений на рис. 1.

Мережа екстракції особливостей в основному вилучає особливості окремих масштабів з зображень за допомогою модулів C2f та SPPF. Модуль C2f, в порівнянні з C3 модулем, який використовувався у попередніх версіях мережі, зменшує кількість шарів мережі на один згортковий шар, роблячи модель легшою. Також він інтегрує переваги структури ELAN з YOLOv7, ефективно розширюючи гілку градієнтів за допомогою bottleneck модулів для

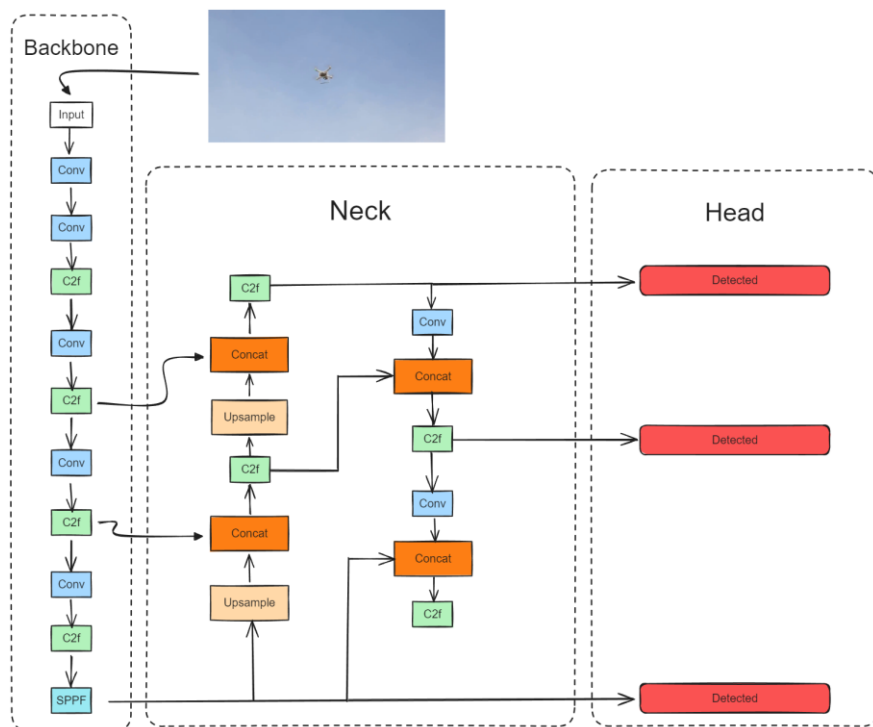


Рис. 1. Структура мережі YOLOv8

отримання більш багатой інформації про потік градієнтів [20]. SPPF зменшує кількість шарів мережі на основі SPP (spatial pyramid pooling – “піраміда” з узагальнюючих шарів) [21], щоб усунути зайві операції та виконувати швидше злиття особливостей. Модуль багаторівневого злиття використовує комбінацію FPN (feature pyramid network – згорткова нейронна мережа, побудована у вигляді піраміди) [22] та PAN (path aggregation network – мережа агрегації шляхів) [23]. Шляхом двостороннього злиття особливостей низького та високого рівня він підсилює особливості низького рівня з меншими полями сприйняття та покращує здатність виявлення цілей різних масштабів. Рівень виявлення передбачає позиції цілей, категорії, оцінки впевненості та іншу інформацію. YOLOv8 працює без використання якорів (рисунк 3). Це означає, що прогнозується центр об’єкта, а не зміщення від відомого якорного блоку. У попередніх версіях YOLO якорні блоки були відомою складною частиною, оскільки вони могли представляти розподіл блоків цільового бенчмарку, але не розподіл призначеного для користувача набору даних.

Безякірне виявлення зменшує кількість прогнозів блоків, що пришвидшує процес немаксимального пригнічення (NMS), складний етап постобробки, який відбирає кандидатські детекції після виведення. В кінцевому підсумку, вона виконує багатомасштабні прогнози, використовуючи характеристики, зменшені у  $8\times$ ,  $16\times$ , та  $32\times$ , для досягнення точних прогнозів для малих, середніх і великих цілей. Детальні модулі в мережі YOLOv8 ілюстровані на рис. 2.

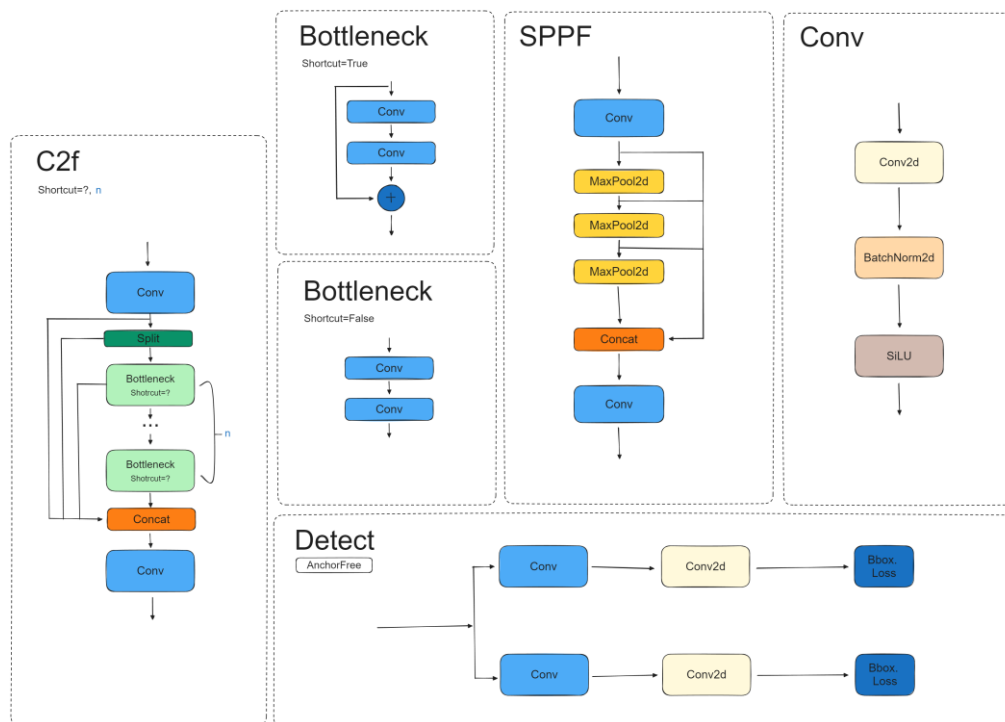


Рис. 2. Структурна схема мережі YOLOv8




Рис. 3. Візуалізація якорного блоку в YOLO

YOLOv8 вилучає характеристики об’єктів, використовуючи глибоку залишкову мережу. Вона завершує багатомасштабний прогноз використовуючи структуру PAN, але YOLOv8 все ще виконує три

ітерації зменшення при екстракції характеристик, щоб отримати максимальну карту характеристик. Однак, значна частина інформації про характеристики цілі втрачається, що могло б бути корисним для виявлення малих цілей. Таким чином, ця стаття вдосконалює YOLOv8 і пропонує модель мережі для виявлення маломасштабних цілей, а удосконалена структура мережі зображена на рисунку 4. Удосконалення полягає у наступних кроках:

1. Підвищення здатності моделі до виявлення крихітних цілей, за допомогою інтеграції шару високої роздільної здатності в частину head та вилучення шару виявлення та пов'язаних з ним шарів екстракції та комбінування характеристик для прогнозування великих цілей.
2. Модуль backbone було вдосконалено шляхом інтеграції Swin Transformer(C3STR) [24].
3. Механізм уваги GAM [25] було введено у модуль комбінування багаторівневих характеристик (Concat), це необхідно, щоб посилити злиття цільових характеристик моделі.

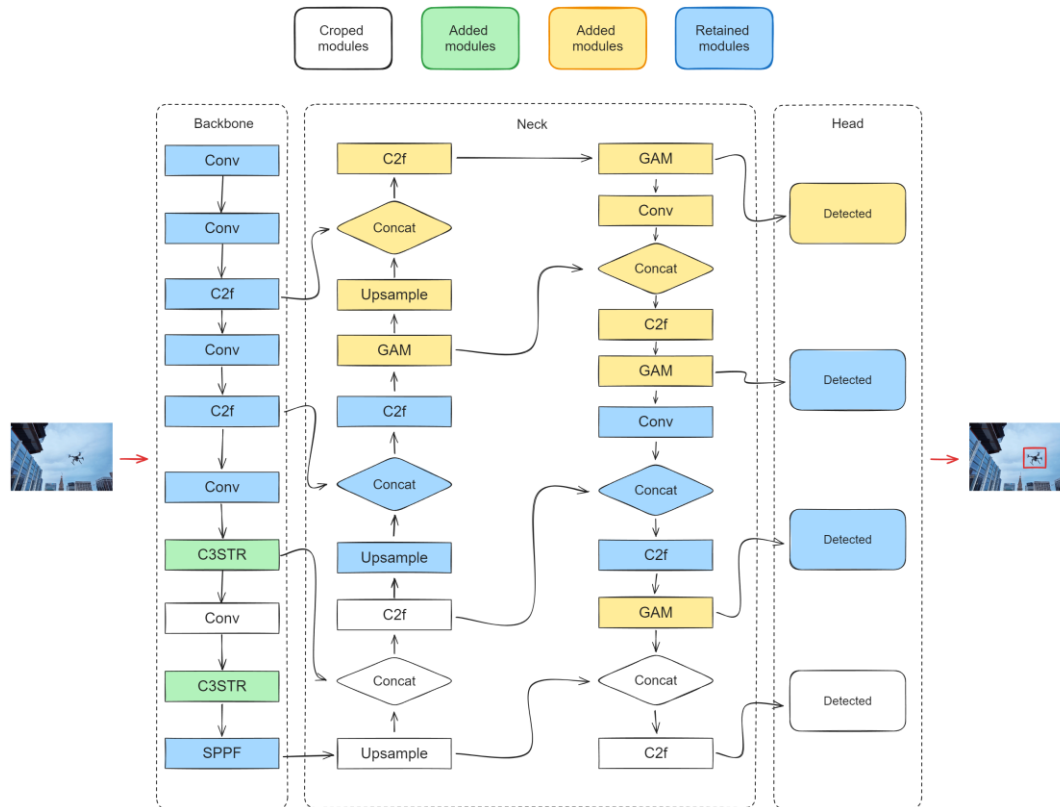


Рис. 4. Діаграма удосконаленої структури мережі YOLOv8

### Аналіз ефективності запропонованого методу

Для оцінки продуктивності моделі було використано загальнодоступний набір даних UAV TIB-Net [10]. Набір даних UAV TIB-Net складається з 2850 зображень, які демонструють різні типи БПЛА, включаючи багатороторні БПЛА та БПЛА з фіксованим крилом. Зображення були зняті фіксованою камерою на землі на відстані близько 500 м від аеродронів, а роздільна здатність зібраних зображень становила 1920 × 1080 пікселів. Ці сцени охоплюють кілька низьковисотних сцен (небо, дерева, будівлі тощо) з зображень польотів БПЛА, повністю враховуючи зразки у різний час дня та в різних погодних умовах.

Апаратна конфігурація, використана для експериментів – це графічна карта NVIDIA GeForce RTX 3060 з 12 ГБ, фреймворк глибинного навчання PyTorch версії 1.13.1, Python версії 3.7.15, CUDA версії 11.7 та операційна система Ubuntu 22.04.

Функції втрат удосконаленої версії YOLOv8 відповідають YOLOv8 і включають втрату прямокутної коробки (*Lossbox*), фокусовану втрату розподілу (*Lossdfl*) та втрату класифікації (*Losscls*).

$$Loss = a \cdot Lossbox + b \cdot Lossdfl + c \cdot Losscls \quad (1)$$

Параметри які є ваговими коефіцієнтами (*a*, *b* і *c*) представляють відповідну пропорцію ваги функції втрат у загальній функції втрат. У цьому експерименті вони становлять *a* = 7.5, *b* = 1.5 та *c* = 0.5 відповідно.

Перед тренуванням зображення та мітки набору даних розподіляються на навчальний набір, набір для перевірки та набір для тестування у співвідношенні 7:1:2. Максимальна кількість епох для тренування набору даних встановлена в 150, з першими трьома епохами, використаними для тренування розігріву. Для регулювання швидкості навчання використовується стратегія оптимізації SGD з початковою швидкістю навчання 0.01. Враховуючи наявність численних дрібних об'єктів на зразкових зображеннях та необхідність балансу між реальним часом та точністю у процесі детектування, розмір зразка нормалізується до 640 × 640. Цей розмір дозволяє розгортати модель без надто великих втрат корисної інформації з зображень. Для того,

щоб мати можливість порівняти продуктивності моделей у експериментах ми не будемо використовувати навчені ваги. Крім того, всі процеси тренування мають однакові налаштування. Основні параметри для процесу тренування показані у таблиці 1.

Таблиця 1

Параметри	Значення
Epochs	150
Warmup-epochs	3
Warmup-momentum	0.8
Batch Size	8
Imgsize	640
Initial Learning Rate	0.01
Final Learning Rate	0.01
Patience	50
Optimizer	SGD
NMSIoU	0.7
Momentum	0.937
Mask-ratio	4
Weight-Decay	0.0005

Щоб перевірити продуктивність моделі, в якості експериментальних показників оцінювання вибрано  $P$ ,  $R$ ,  $AP$ ,  $mAP$ , кількість параметрів, розмір моделі та кадри в секунду (FPS).

Точність ( $P$  - accuracy) та повнота ( $R$  - recall) розраховуються таким чином:

$$P = \frac{TP}{(TP + FP)} \cdot 100\% \quad (2)$$

$$R = \frac{TP}{(TP + FN)} \cdot 100\% \quad (3)$$

де  $TP$  (true positives) позначає кількість правильно виявлених цілей,  $FP$  (false positives) позначає кількість фонів, виявлених як цілі, і  $FN$  (false negatives) позначає кількість цілей, виявлених як фон.

Середня точність ( $AP$ ) та середня точність середніх значень ( $mAP$ ) розраховуються таким чином:

$$AP = \int_0^1 p(r) d(r) \quad (4)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

де  $N$  — кількість категорій, а  $AP$  — середня точність кожної категорії. У нашому випадку ми маємо лише одну категорію – БПЛА, тому  $N = 1$ .

На основі набору даних UAV TIB-Net, були проведені експерименти з виявлення БПЛА, для дослідження впливу кожного доданого або модифікованого модуля на загальну продуктивність моделі. Починаючи з оригінального YOLOv8s як базової лінії, покращення head, backbone та neck було розподілено по порядку. Для аналізу покращення продуктивності кожного модуля були визначені базова Модель 1, покращена Модель 2 (з доданою tiny-head), покращена Модель 3 (додана tiny-head і обрізана large-head), покращена Модель 4 (з доданою tiny-head, обрізаною large-head і доданим C3SPR), покращена Модель 5 (з доданою tiny-head, обрізаною large-head та доданим GAM), та покращена Модель 6 (з доданою tiny-head, обрізаною large-head, C3SPR та GAM). Зміни показників оцінювання для цих шести моделей були кількісно досліджені, і оптимальні результати для кожного показника оцінювання були виділені. Експериментальні результати моделей на наборі даних TIB-Net показані в таблиці 2.

Таблиця 2

Компоненти	1	2	3	4	5	6
+Tiny-Head		+	+	+	+	+
-Large-Head			+	+	+	+
+C3SPR				+		+
+GAM					+	+
P	81.4%	87.9%	89.1%	89.5%	88.2%	90.4%
R	78.1%	86.5%	86.5%	88.1%	86.2%	88.3%
mAP	86.1%	91.2%	91.5%	91.7%	90.6%	92.1%
Parameters/million	11.126	10.852	3.527	6.83	8.09	7.511
Model Size/MB	21.9	22.1	13.1	13.9	13.4	14.8
FPS/f.s-1	285	196	226	199	213	191

### Висновки

Для вирішення проблеми, виявлення БПЛА малих розмірів, запропоновано вдосконалену модель виявлення YOLOv8. Модель успішно адаптується до складнощів, пов'язаних з розміром дронів, характеристиками фону повітряного простору, рівнем світлової інтенсивності та іншими зовнішніми чинниками, що впливають на процес виявлення. Для покращення здатності виявляти дрібні об'єкти, спочатку, у частині head, було додано шар високої роздільної здатності для покращення здатності виявляти невеликі об'єкти. У той же час, large-head та надлишкові шари мережі було обрізано для ефективного зменшення кількості параметрів мережі та підвищення швидкості виявлення дронів. Нарешті, механізм уваги GAM було введено у neck для покращення злиття ознак цілей моделі, таким чином покращуючи загальну продуктивність моделі для виявлення дронів. Було проведено порівняльні експерименти на складному наборі даних TIB-Net. У порівнянні з початковою базовою моделлю YOLOv8, запропонований нами метод покращує продуктивність на 9%, 10,2% та 6% за показниками P (precision), R (recall) та mAP (mean average precision) відповідно, а також зменшує кількість параметрів моделі на 32,5% та зменшення розміру моделі на 32,4%. Крім того, модель виявлення показала кращі результати у порівняльних експериментах і експериментах з самоствореним набором даних. Отже, запропонований метод більше підходить для інженерного впровадження та практичного застосування систем виявлення цілей БПЛА.

Однак, додавання додаткових рівнів обробки у модуль head та використання як Swin Transformer, так і GAM модулів, призвело до збільшення часу висновку моделі та FPS знизився порівняно з базовою моделлю. Крім того, з експериментів на самоствореному наборі даних видно, що R знижується, коли фон повітряного простору є більш складним, тобто ймовірність пропуску виявлення зростає. Наступні роботи будуть присвячені покращенню точності виявлення в більш складних фонових умовах повітряного простору, одночасно зменшуючи час прийняття рішення моделлю.

### References

1. Dalal, N.; Triggs, B. Histograms of oriented gradients for human detection. In Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA, 20–25 June 2005; Volume 1, pp. 886–893
2. Lowe, D.G. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vis.* 2004, 60, 91–110.
3. Bay, H.; Tuytelaars, T.; van Gool, L. Surf: Speeded up robust features. In Proceedings of the Computer Vision—ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, 7–13 May 2006; Proceedings, Part I 9. Springer: Berlin/Heidelberg, Germany, 2006; pp. 404–417.
4. Dai, J.; Wu, L.; Wang, P. Overview of UAV Target Detection Algorithms Based on Deep Learning. In Proceedings of the 2021 IEEE 2nd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA), Chongqing, China, 17–19 December 2021; Volume 2, pp. 736–745.
5. Zuo, Y. Target Detection System of Agricultural Economic Output Efficiency Based on Kruskal Algorithm. In Proceedings of the 2022 IEEE 2nd International Conference on Mobile Networks and Wireless Communications (ICMNWC), Tumkur, India, 2–3 December 2022; pp. 1–5.
6. Li, S.; Yu, J.; Wang, H. Damages detection of aero-engine blades via deep learning algorithms. *IEEE Trans. Instrum. Meas.* 2023, 72, 5009111.
7. Ren, S.; He, K.; Girshick, R.; Sun, J. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2017, 39, 1137–1149.
8. Liu, W.; Anguelov, D.; Erhan, D.; Szegedy, C.; Reed, S.; Fu, C.Y.; Berg, A.C. Ssd: Single shot multibox detector. In Proceedings of the Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, 11–14 October 2016; Proceedings, Part I 14. Springer International Publishing: Berlin/Heidelberg, Germany, 2016; pp. 21–37.
9. Jiao, L.C.; Zhang, F.; Liu, F.; Yang, S.Y.; Li, L.L.; Feng, Z.X.; Qu, R. A Survey of Deep Learning-Based Object Detection. *IEEE Access* 2019, 7, 128837–128868.
10. Sun, H.; Yang, J.; Shen, J.; Liang, D.; Ning-Zhong, L.; Zhou, H. TIB-Net: Drone Detection Network with Tiny Iterative Backbone. *IEEE Access* 2020, 8, 130697–130707.
11. He, J.; Liu, M.; Yu, C. UAV reaction detection based on multi-scale feature fusion. In Proceedings of the 2022 International Conference on Image Processing, Computer Vision and Machine Learning (ICICML), Xi'an, China, 28–30 October 2022; pp. 640–643.
12. Wastupranata, L.M.; Munir, R. UAV Detection using Web Application Approach based on SSD Pre-Trained Model. In Proceedings of the 2021 IEEE International Conference on Aerospace Electronics and Remote Sensing Technology (ICARES), Virtual, 3–4 November 2021; pp. 1–6.
13. Tao, Y.; Zongyang, Z.; Jun, Z.; Xinghua, C.; Fuqiang, Z. Low-altitude small-sized object detection using lightweight feature-enhanced convolutional neural network. *J. Syst. Eng. Electron.* 2021, 32, 841–853.
14. Ye, T.; Zhang, J.; Li, Y.; Zhang, X.; Zhao, Z.; Li, Z. CT-Net: An Efficient Network for Low-Altitude Object Detection Based on Convolution and Transformer. *IEEE Trans. Instrum. Meas.* 2022, 71, 2507412.
15. Zou, Z.; Chen, K.; Shi, Z.; Guo, Y.; Ye, J. Object Detection in 20 Years: A Survey. *Proc. IEEE* 2023, 111, 257–276.

16. Ma, J.; Yao, Z.; Xu, C.; Chen, S. Multi-UAV real-time tracking algorithm based on improved PP-YOLO and Deep-SORT. *J. Comput. Appl.* 2022, 42, 2885.
17. Li, H.; Yang, J.; Mao, Y.; Hu, Q.; Du, Y.; Peng, J.; Liu, C. A UAV detection algorithm combined with lightweight network. In Proceedings of the 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China, 12–14 March 2021; Volume 5, pp. 1865–1872.
18. Liu, Y.; Liu, D.; Wang, B.; Chen, B. Mob-YOLO: A Lightweight UAV Object Detection Method. In Proceedings of the 2022 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD), Harbin, China, 30 November–2 December 2022; pp. 1–6.
19. Liu, R.; Xiao, Y.; Li, Z.; Cao, H. Research on the anti-UAV distributed system for airports: YOLOv5-based auto-targeting device. In Proceedings of the 2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA), Changchun, China, 20–22 May 2022; pp. 864–867.
20. Li, Y.; Fan, Q.; Huang, H.; Han, Z.; Gu, Q. A Modified YOLOv8 Detection Network for UAV Aerial Image Recognition. *Drones* 2023, 7, 304.
21. He, K.; Zhang, X.; Ren, S.; Sun, J. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* 2015, 37, 1904–1916.
22. Lin, T.Y.; Dollár, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature pyramid networks for object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21–26 July 2017; pp. 2117–2125.
23. Liu, S.; Qi, L.; Qin, H.; Shi, J.; Jia, J. Path aggregation network for instance segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 18–23 June 2018; pp. 8759–8768.
24. Meng, Y., et al.: A swintransformer based bird nest detection approach withunmanned aerial vehicle images for power distributionand pole towers. *IET Cyber - Phys. Syst., Theory Appl.* 1–10 2023.
25. Liu, Y.; Shao, Z.; Hoffmann, N. Global attention mechanism: Retain information to enhance channel-spatial interactions. *arXiv* 2021, arXiv:2112.05561.