

Ельвіра КАЙДАН,

студентка 4 курсу, Національного аерокосмічного університету

«Харківський авіаційний інститут»

ORCID: <https://orcid.org/0009-0007-1437-6884>

e-mail: e.s.kaidan@student.khai.edu

Науковий керівник: Дмитро КРИЦЬКИЙ,

кандидат технічних наук, доцент кафедри

інформаційних технологій проектування (105)

Національного аерокосмічного університету

«Харківський авіаційний інститут», м. Харків, Україна

e-mail: d.kruckyi@khai.edu

DOI: <https://doi.org/10.32620/pls.2025.8.55>

ПОЛІПШЕНІ МЕТОДИ РОЗПІЗНАВАННЯ ОБ'ЄКТІВ У UAV НА ОСНОВІ YOLO

Анотація. У роботі представлено результати вдосконалення системи розпізнавання об'єктів для безпілотних літальних апаратів на основі оптимізації передобробки зображень та переходу до нової нейронної мережі YOLO11s. Запропонований метод паддингу білими полями замість масштабування забезпечив збереження геометричних пропорцій та підвищення впевненості класифікації. Скорочення кількості класів дозволило зменшити час обробки кадру та підвищити точність. Перехід від YOLO8n до YOLO11s забезпечив суттєвий приріст якості, зменшення латентності та скорочення часу навчання з двох годин до менше ніж 30 хвилин. Представлені графіки та реальні приклади демонструють покращені характеристики моделі.

Ключові слова: UAV, детекція об'єктів, YOLO11s, паддинг, класифікація, нейронні мережі.

Вступ. Технології автоматичного розпізнавання об'єктів відіграють ключову роль у роботі безпілотних літальних апаратів, забезпечуючи виконання задач моніторингу, ідентифікації та супроводу цілей. Ефективність таких систем визначається точністю, швидкістю та стабільністю моделей, що використовуються для аналізу відеопотоків [3, Art. 684].

Попередня модель YOLO8n забезпечувала робочий рівень точності, однак мала обмеження, пов'язані з нестабільністю класифікації, затримками під час роботи в реальному часі та значним часом навчання [1, Art. 234] [5, p. 325]. У цьому дослідженні проведено цикл експериментів з оновленими методами передобробки та новою архітектурою YOLO11s, що дозволило суттєво підвищити продуктивність системи в задачах розпізнавання військової техніки [2, Art. 732] [4, Art. 1519].

1.Методика дослідження

1.1 Оптимізація передобробки: паддинг замість масштабування

Попередні експерименти використовували класичне масштабування зображення до квадратної форми, що призводило до деформації пропорцій об'єктів[8]. Такий підхід негативно впливав на точність, оскільки модель отримувала викривлені ознаки — розтягнуті технічні засоби, спотворені гусениці, змінені силуети. Для

військової техніки, в якій навіть невеликі деталі впливають на класифікацію, це є критичним недоліком [9, Art. 638].

У вдосконаленій системі застосовано паддинг білими полями, що дозволяє зберегти оригінальні співвідношення сторін, уникаючи будь-якої геометричної деформації (рис. 1).




Рис. 1. Приклад застосування паддингу

Такий підхід забезпечує коректну передачу текстур, контурів і характерних структур об'єктів. У результаті стабільність детекцій значно зростає: модель демонструє вищу впевненість, менше

помилкових перебоїв та краще тримає рамку на об'єкті навіть при складних ракурсах.

Крім того, паддинг не потребує додаткових обчислювальних витрат, а отже, підходить для систем, що працюють безпосередньо на борту БпЛА зі слабкими GPU.

1.2 Зменшення кількості класів як фактор підвищення точності

У попередній версії системи класифікація охоплювала велику кількість категорій із мінімальними міжкласовими відмінностями, через що модель витрачала обчислювальні ресурси на розмежування надто подібних об'єктів, що знижувало точність. У новій конфігурації набір класів був оптимізований та скорочений до ключових типів бойової техніки — tank, armored_vehicle, support_vehicle, vehicle. Це зменшило кількість хибних класифікацій, підвищило точність за рахунок фокусування на найбільш значущих категоріях та пришвидшило роботу моделі завдяки меншій кількості порівнянь у вихідному шарі.

Результати показали, що таке скорочення класів у поєднанні з оновленою архітектурою забезпечило приріст точності на 5–12% залежно від категорії.

1.3 Перехід від YOLOv8n до YOLO11s

Одним із найбільш визначальних змін стало повне оновлення архітектури моделі. Модель YOLO11s, що використана у цьому дослідженні, є суттєво глибшою та потужнішою порівняно з YOLOv8n. Ключові характеристики надані в табл. 1.

Таблиця 1

Ключові характеристики

Параметр	YOLOv8n	YOLO11s	Різниця
Час навчання	>2 год	<30 хв	у 4+ рази швидше
Розмір ваг	~6–7 МБ	~20 МБ	у 3 рази більше
Глибина	низька	значно глибша	більше рівнів обробки
Точність mAP	нижча	значно вища	стабільне зростання
Затримка	вища	нижча	швидша реакція

Порівняльна таблиця продемонструвала, що нова модель перевершує попередню за всіма ключовими метриками — mAP@0.5, mAP@0.5–0.95, precision, recall, FPS.

2. Результати та оцінювання

2.1 Аналіз кривих ефективності моделі YOLO11s

На рисунку 2 представлено узагальнений колаж із чотирьох ключових кривих ефективності моделі: F1–Confidence, Precision–Confidence, Recall–Confidence та Precision–Recall. Сукупний аналіз цих

графіків дозволяє комплексно оцінити стабільність роботи моделі, вплив порогу впевненості на якість детекції та узгодженість роботи класифікатора на різних рівнях Recall.




Рис. 2. Ключові криві впевненості

Крива F1–Confidence демонструє, що модель досягає оптимального співвідношення точності та повноти при порогах близько 0.35–0.45, що свідчить про стабільність роботи та відсутність різких деградацій продуктивності. Такий характер залежності підкреслює здатність YOLO11s підтримувати збалансовані рішення в умовах різної якості зображення [7, Art. 13435]. У свою чергу, крива Precision–Confidence монотонно зростає і наближається до 1.0 на високих порогах впевненості. Це вказує на те, що модель практично не формує хибнопозитивних детекцій, зберігаючи високу селективність щодо основних класів об'єктів. Водночас, графік Recall–Confidence демонструє очікуване зниження повноти зі збільшенням порогу, однак при низьких значеннях впевненості Recall перевищує 0.9. Така особливість є критичною для сценаріїв, де необхідно мінімізувати ризик пропуску цілі, зокрема у розвідувальних задачах [6, pp. 82–83].

Нарешті, Precision–Recall Curve підтверджує загальний високий рівень роботи моделі: криві всіх класів проходять поблизу верхньої межі, а середнє значення mAP@0.5 становить 0.939, що суттєво перевищує результати попередньої моделі YOLOv8n. Отримана форма PR-кривої демонструє здатність YOLO11s впевнено розрізняти об'єкти навіть за умов низького контрасту та неповної видимості [6, pp. 82–83].

2.2 Динаміка втрат під час навчання

Графіки BoxLoss, ClsLoss, DFLoss (Рис. 3) свідчать про рівномірне зменшення втрат, без різких стрибків, що підтверджує стабільність

навчального процесу. Метрики mAP50 та mAP50-95 показують плавне, прогресивне зростання протягом усього циклу тренування, досягаючи високих значень вже на 30–40 епісі.




Рис. 3. Динаміка навчання моделі YOLO11s

2.3 Візуальні результати детекції

Порівняльні зображення (рис. 4) демонструють здатність моделі точно розпізнавати техніку в умовах:

низької контрастності,
диму та пилу,
складних ракурсів,
часткових перекриттів.




Рис. 4. Розпізнавання техніки у різних умовах

Модель впевнено виділяє контури танків навіть у зашумлених сценах, що було однією з найслабших сторін попередньої архітектури.

Висновки

Запропоновані вдосконалення дозволили суттєво підвищити ефективність системи детекції на базі БпЛА. Поєднання оптимізованої передобробки, скорочення класів та переходу до архітектури YOLO11s забезпечило:

зростання точності та F1;
стабільнішу роботу моделі в реальних умовах;
зниження латентності та пришвидшення реакції;
скорочення часу навчання більш ніж у 4 рази;
підвищення стійкості до візуальних спотворень.

Отримані результати підтверджують, що

впроваджені методи можуть бути ефективно використані в автономних системах БпЛА, що працюють у складних динамічних сценаріях.

Бібліографічні посилання

1. Yilmaz B., Kutbay U. YOLOv8-Based Drone Detection: Performance Analysis and Optimization // Computers. — 2024. — Vol. 13, № 9. — Art. 234. DOI:10.3390/computers13090234.

2. Kurmashev I., Semenyuk V., Lupidi A., Alyoshin D., Kurmasheva L., Cantelli-Forti A. Optimal YOLO Visual Detector for Enhancing UAV Detection and Classification in Sensor Fusion Systems // Drones. — 2025. — Vol. 9, № 11. — Art. 732. DOI:10.3390/drones9110732.

3. Meimetis D., Daramouskas I., Patrinoopoulou N., Lappas V., Kostopoulos V. Comparative Analysis of Object Detection Models for Edge Devices in UAV Swarms // Machines. — 2025. — Vol. 13, № 8. — Art. 684. DOI:10.3390/machines13080684.

4. Wang Z., Peng Y., Shen C. A YOLO-Based Multi-Scale and Small Object Detection Framework for Low-Altitude UAVs in Cluttered Scenes // Symmetry. — 2025. — Vol. 17, № 9. — Art. 1519. DOI:10.3390/sym17091519.

5. Cheng J., Wang D., Liu J., Deng W. Performance Optimization and Application Research of YOLOv8 Model in Object Detection // Academic Journal of Science and Technology. — 2024. — Vol. 10, No. 1. — P. 325–332. DOI:10.54097/p9w3ax47

6. Ren G., Wu J., Wang W. Research on UAV Target Detection Based on Improved YOLOv11 // Journal of Computer and Communications. — 2025. — Vol. 13, № 3. — P. 74–85. DOI:10.4236/jcc.2025.133006.

7. Zhang C., et al. Studying the performance of YOLO11 incorporating DHSAC // Scientific Reports. — 2025. — Art. 13435. DOI:10.1038/s41598-025-13435-z.

8. Hu C., Shi W. Impact of Scaled Image on Robustness of Deep Neural Networks // arXiv preprint. — 2022. — arXiv:2209.02132.

9. Munir A., Siddiqui A.J., Anwar S., El-Maleh A., Khan A.H., Rehman A. Impact of Adverse Weather and Image Distortions on Vision-Based UAV Detection: A Performance Evaluation of Deep Learning Models // Drones. — 2024. — Vol. 8, No. 11. — Art. 638. DOI:10.3390/drones8110638

E. Kaidan

Improved object recognition methods in UAVS based on YOLO.

Abstract. The paper presents the results of improving the object recognition system for unmanned aerial vehicles based on optimizing image preprocessing and transitioning to the new YOLO11s neural network. The proposed method of padding with white fields instead of scaling ensured the preservation of geometric proportions and increased classification confidence. Reducing the number of classes made it possible to decrease frame processing time and increase accuracy. The transition from YOLO8n to

YOLO11s provided a significant increase in quality, reduced latency, and shortened training time from two hours to less than 30 minutes. The graphs and real-life examples presented demonstrate the improved characteristics of the model.

Keywords: UAV, object detection, YOLO11s, padding, classification, neural networks.

Зразок для цитування:

Кайдан Е. Поліпшені методи розпізнавання об'єктів у UAV на основі YOLO. Пропілії права та безпеки, 2025. №8. С. 218-221. DOI: <https://doi.org/10.32620/pls.2025.8.55>.