



РОЗРОБЛЕННЯ АДАПТИВНОЇ ФУНКЦІЇ ВТРАТ ДЛЯ ПОКРАЩЕННЯ ДЕТЕКЦІЇ МАЛОРОЗМІРНИХ БЕЗПІЛОТНИХ ЛІТАЛЬНИХ АПАРАТІВ

Виявлення малорозмірних безпілотних літальних апаратів (БПЛА) за реальних умов спостереження залишається актуальною проблемою систем автоматичного моніторингу повітряного простору. Досліджено вплив зміни функції втрат на якість виявлення малорозмірних об'єктів одностадійними детекторами сімейства моделей YOLO (англ. *You Only Look Once* – ти дивишся тільки раз). Встановлено, що стандартна функція втрат не розрізняє об'єкти за масштабом, унаслідок чого великі та малі цілі роблять порівняльний внесок у сумарний loss, а оптимізація моделі природно зміщується в бік більших об'єктів і простіших для локалізації цілей. Запропоновано адаптивну функцію втрат, у якій ваговий коефіцієнт кожного анкера визначається обернено пропорційно до площі bounding box відповідного об'єкта. Розроблено механізм boost-only-модифікації *target_scores* (цільові бали) в алгоритмі TaskAlignedAssigner, який підсилює градієнтний сигнал від малих цілей без пригнічення процесу виявлення великих об'єктів. Запропонований метод адаптивної функції втрат інтегровано в реалізації детекторів YOLOv8s та YOLOv11s у середовищі PyTorch й апробовано на спеціалізованому наборі даних виявлення БПЛА, що містить 17 697 анованих зображень із 12 246 об'єктами, розподілених за чотирма розмірними категоріями. Оцінено приріст метрик *Precision*, *Recall*, *F1*, *mAP@0,5* та *mAP@0,5:0,95* щодо базової конфігурації моделей. Виявлено, що запропонована функція втрат стабільно покращує повноту виявлення (*Recall*) та F1-міру для обох досліджуваних архітектур детекторів об'єктів у всіх розмірних групах, з найвиразнішим ефектом на дуже малих і малих цілях. Загальні інтегральні метрики (*mAP@0,5* та *mAP@0,5:0,95*) також зростають, тоді як якість виявлення великих об'єктів зберігається на рівні базової моделі. Охарактеризовано закономірності впливу адаптивного вагового коефіцієнта анкера на якість виявлення об'єктів різних масштабів. Принципово, що великі об'єкти не постраждали – *Recall* для них збережено на рівні базової моделі. Встановлено, що запропонований підхід до модифікації функції втрат не збільшує кількість параметрів моделі та не впливає на швидкість інференсу. Перспективою подальших етапів дослідження є комбінування адаптивної функції втрат з модифікованою функцією втрат Focal Loss та метрикою оцінювання якості локалізації GIoU (англ. *Generalized Intersection over Union*), а також адаптація підходу до багатокласових сценаріїв і edge-розгортання.

Ключові слова: виявлення літальних об'єктів; комп'ютерний зір; моделі YOLOv8 та YOLOv11; алгоритм TaskAlignedAssigner; глибинне навчання детектора об'єктів.

Вступ / Introduction

Стрімке поширення малорозмірних безпілотних літальних апаратів (БПЛА) створює нові виклики для систем автоматичного моніторингу повітряного простору та комплексів протидії безпілотним загрозам. Малі дрони займають незначну частину кадру, мають слабо виражені візуальні ознаки та часто зливаються з фоном, що ускладнює їх виявлення за умов складного освітлення, шуму, часткових перекриттів і великої дистанції спостереження. Попри істотний прогрес у розвитку архітектур детекторів об'єктів за останнє десятиліття, надійне виявлення дрібномасштабних цілей залишається невирішеною проблемою практичних застосувань.

Більшість сучасних досліджень спрямована на вдосконалення архітектури детекторів: розширення піраміди ознак, інтеграцію модулів уваги, модифікації нескладної частини мережі, додаткові високороздільні виходи. Про-

те якість виявлення малих об'єктів залежить не тільки від структури нейромережевої моделі, а й від того, як організовано процес її навчання детектора об'єктів. Стандартні функції втрат одностадійних детекторів не розрізняють великі та малі цілі – обидва типи об'єктів роблять порівняльний внесок у сумарний loss, а під час оптимізації модель природно орієнтується на більш виражені та простіші для локалізації об'єкти. Малорозмірні БПЛА в такому разі не отримують достатнього градієнтного сигналу і систематично пропускаються навіть за високих інтегральних метрик. Це обґрунтовує доцільність розроблення адаптивної функції втрат, яка підсилює внесок малих об'єктів безпосередньо на етапі оптимізації моделі.

Об'єкт дослідження – розроблення адаптивної функції втрат для покращення детекції малорозмірних БПЛА.

Предмет дослідження – методи і засоби розроблен-

© Copyright 2026 by the author(s)

Скаліш Роман Дмитрович, здобувач третього (освітньо-наукового) рівня вищої освіти, кафедра комп'ютерних наук.

Email: skalish.roman@nltu.lviv.ua; <https://orcid.org/0009-0007-4065-3021>

Процик Юрій Степанович, канд. фіз.-мат. наук, доцент, кафедра комп'ютерних наук.

Email: protsyk@nltu.edu.ua; <https://orcid.org/0000-0002-8226-2113>

Цитування за ДСТУ: Скаліш Р. Д., Процик Ю. С. Розроблення адаптивної функції втрат для покращення детекції малорозмірних безпілотних літальних апаратів. Науковий вісник НЛТУ України. 2026, т. 36, № 4. С. 106–113.

Citation APA: Skalish, R. D., & Protsyk, Yu. S. Adaptive loss function for improving detection of small-scale unmanned aerial vehicles.

Scientific Bulletin of UNFU, 36(4), 106–113. <https://doi.org/10.36930/40360412>

ня адаптивної функції втрат для покращення процесу виявлення малорозмірних БПЛА, які дадуть змогу кількісно описати механізм диференційованої пріоритизації об'єктів за масштабом у процесі навчання моделі.

Мета роботи – розробити адаптивну функцію втрат для покращення процесу виявлення малорозмірних БПЛА, яка дасть змогу вибірково підсилювати навчальний сигнал від малих цілей, не змінюючи внесок великих об'єктів у загальну функцію втрат і, цим самим, усуне конкуренцію між різномасштабними об'єктами в процесі їхньої оптимізації.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- описати адаптивну функцію втрат з ваговим коефіцієнтом, обернено пропорційним до площі bounding box, що дасть змогу кількісно охарактеризувати механізм диференційованої пріоритизації об'єктів за масштабом у процесі навчання детектора об'єктів та обґрунтувати вибір гіперпараметрів підсилення;
- розробити механізм інтеграції адаптивного вагового коефіцієнта анкера в алгоритмі TaskAlignedAssigner сучасних детекторів, який не пригнічує детекцію великих об'єктів, що дає можливість вибірково підсилювати навчальний сигнал від малих цілей, не змінюючи внесок великих об'єктів у загальну функцію втрат, і цим самим усуває конкуренцію між різномасштабними об'єктами в процесі оптимізації моделі;
- виконати оцінку запропонованого методу адаптивної функції втрат на спеціалізованому наборі даних БПЛА для двох архітектур детекторів об'єктів, що підтверджує стабільне покращення Recall на 0,8-1,5 п.п. – для інтегральних метрик і до 2,4 п.п. – для малих і дуже малих об'єктів на обох досліджених архітектурах детекторів об'єктів, доводячи архітектурну узагальненість методу та його практичну ефективність за умов збереження якості виявлення великих цілей;
- дослідити вплив адаптивної функції втрат на детекцію об'єктів різних розмірних категорій БПЛА, що дає змогу виявити кількісні закономірності залежності ефективності роботи методу від масштабу об'єкта та підтвердити коректність boost-only-механізму – підсилення малих цілей без деградації якості виявлення великих.

Аналіз останніх досліджень та публікацій. У роботі [6] автори запропонували Focal Loss – модифікацію стандартної функції втрат, що динамічно знижує внесок легко класифікованих прикладів і пріоритизує складні, ефективно усуваючи дисбаланс між фоновими та об'єктними прикладами. Водночас, встановлено, що цей підхід до пріоритизації навчальних прикладів не враховує геометричного масштабу об'єктів і не вирішує проблему систематичної недопріоритизації малорозмірних цілей.

У роботі [12] автори дослідили завдання виявлення БПЛА різних розмірів засобами глибинного навчання моделі та встановили, що якість їхньої детекції об'єктів істотно знижується зі зменшенням розміру цілі: Recall знижується від 0,89 – для дронів середнього розміру до 0,52 – для об'єктів, що займають менше 20 пікселів у кадрі. Показано, що стандартні детектори оптимізуються переважно під великі та добре помітні об'єкти, тоді як малі цілі систематично пропускаються.

У роботі [1] автори запропонували систему виявлення та супроводу БПЛА на основі глибинного навчання моделі поєднано з фільтром Калмана. Зазначено, що навіть сучасні архітектури детектора об'єктів демонструють нестабільну точність в разі детекції малорозмірних об'єктів за умов складного фону та змінного освітлення.

У дослідженні [13] автори вдосконалили архітектуру моделі YOLO для виявлення малих дронів на великих відстанях. Досліджено, що деградація точності є монотонною функцією відстані та розміру об'єкта, а стандартна функція втрат не забезпечує достатнього градієнтного сигналу для малорозмірних цілей за умов значної дистанції спостереження.

У роботі [11] автори розробили підхід до навчання детектора об'єктів детектора дронів винятково на синтетичних наборах даних і перевірили його на реальних зображеннях. Показано, що синтетичне генерування даних здатне істотно покращити виявлення рідкісних і малорозмірних об'єктів, проте потребує значних ресурсів для формування репрезентативної вибірки.

У дослідженні [7] автори здійснили систематичний аналіз методів глибинного навчання моделей для завдань виявлення дронів. Констатовано, що питання підвищення чутливості детекторів до малорозмірних БПЛА через модифікацію функції втрат залишається значно менш дослідженим порівняно з підходами на основі зміни архітектури детектора об'єктів або стратегій аугментації даних.

У роботі [5] автори запропонували метод покращення процесу виявлення малих дронів через багатомасштабне оброблення та аугментацію даних. Встановлено, що комбінування аугментації з модифікованою пірамідою ознак дає приріст mAP на малих об'єктах, проте ефект істотно залежить від якості розмітки та конкретної архітектури детектора об'єктів.

У дослідженні [4] автори розробили архітектуру детектора об'єктів на базі моделі YOLOv11 із модулем Residual Attention та покращенням високороздільних ознак для виявлення малих БПЛА у реальному часі. Показано, що введення механізму уваги підвищує mAP на малорозмірних об'єктах на 4 п.п., проте ціною зростання кількості параметрів на 18 % та відповідного зниження швидкодії інференсу.

Отже, проведений аналіз останніх досліджень та публікацій засвідчує, що більшість наявних підходів до підвищення якості детекції малорозмірних БПЛА зосереджені на модифікації архітектури детектора об'єктів або стратегій формування навчальних даних, тоді як функція втрат, зазвичай, залишається стандартною. Внаслідок цього великі та малі об'єкти роблять порівнянний внесок у сумарний loss, а оптимізація моделі природно зміщується в бік більших об'єктів і простіших для локалізації цілей. Жодне з розглянутих досліджень не пропонує механізму масштабно-залежного зважування навчального сигналу безпосередньо в компоненті присвоєння міток без зміни архітектури детектора об'єктів, що обґрунтовує доцільність запропонованого підходу до модифікації функції втрат.

Матеріали та методи дослідження. У дослідженні використано спеціалізований набір даних для детекції БПЛА, сформований з реальних кадрів спостереження повітряного простору на платформі Roboflow і розподілений на навчальну, валідаційну та тестову підвибірки у співвідношенні 70/20/10 (17 697 анованих зображень, 12 246 об'єктів). Для перевірки запропонованого методу обрано одностадійні детектори на підставі моделей YOLOv8s та YOLOv11s у реалізації Ultralytics; навчання детектора об'єктів здійснювали у середовищі PyTorch з попередньо навченими вагами COCO на GPU NVIDIA A100. Оцінювання моделей здійснено на тес-

товий підвибірці за метриками *Precision*, *Recall*, *F1*, *mAP@0,5* та *mAP@0,5:0,95* за чотирма розмірними групами об'єктів.

Результати дослідження та їх обговорення / Research results and their discussion

Розроблення та використання адаптивної функції втрат (англ. *Adaptive Loss Function*) є одним із найефективніших методів підвищення точності детекції малорозмірних БПЛА. Малорозмірні дрони займають лише кілька пікселів на зображенні, що створює проблему дисбалансу класів та високої чутливості до помилок локалізації.

Багато дослідників стверджують [6, 7, 12], що стандартні функції втрат малоефективні, бо спостерігається:

- дисбаланс "фон/об'єкт", тобто стандартна перехресна ентропія (англ. *Cross-Entropy*) переважується легкими негативними прикладами (небом, деревами), ігноруючи крихітний дрон;
- чутливість до зміщення IoU, тобто традиційні метрики, як-от Intersection over Union (IoU), стають нестабільними, коли об'єкт має розмір 4×4 чи 8×8 пікселів, бо зсув на 1 піксель критично знижує IoU до нуля;
- втрата градієнта, коли маленькі об'єкти генерують слабкі градієнти, які "затухають" на тлі великих об'єктів під час зворотного поширення помилки.

Запропонована функція втрат. Нехай A_i – площа bounding box i -го об'єкта у пікселях, A_0 – опорна площа, що відповідає пороговому розміру малого об'єкта, w_{max} – верхнє обмеження вагового коефіцієнта. Адаптивний ваговий коефіцієнт для i -го анкера визначають за такою формулою:

$$w_i = \min(A_0 / A_i, w_{max}), \forall i \in m, \quad (1)$$

де: w_i – ваговий коефіцієнт i -го анкера; A_i – площа bounding box i -го об'єкта у пікселях; A_0 – опорна площа, що відповідає пороговому розміру малого об'єкта; w_{max} – верхнє обмеження вагового коефіцієнта.

Уведений адаптивний ваговий коефіцієнт w_i – це масштабно-залежний множник навчального сигналу i -го анкера, обернено пропорційний до площі відповідного bounding box, що задає внесок цього анкера у функцію втрат. Процес домноження навчального сигналу кожного анкера на його адаптивну вагомість w_i під час формування target_scores надалі позначаємо як адаптивне зважування навчального сигналу.

Для об'єктів, площа яких менша за A_0 , адаптивний ваговий коефіцієнт анкера зростає обернено пропорційно до площі; для більших об'єктів $w_i = 1$, оскільки $A_0/A_i \leq 1$. Обмеження w_{max} запобігає нестабільності навчання детектора об'єктів на екстремально малих bounding box.

Вибір гіперпараметрів A_0 та w_{max} обґрунтовано в такий спосіб. Опорна площа $A_0 = 32 \times 32 = 1024$ пікселі відповідає верхній межі категорії small у класифікації COCO (об'єкти площею $A_0 \leq 32^2$ відносять до small), що є усталеним стандартом у дослідженнях детекції малих об'єктів і дає можливість зіставляти результати з опублікованими в літературі. Верхнє обмеження вагового коефіцієнта $w_{max} = 4$ обрано за принципом "нехай об'єкти на межі категорії very small ($16 \times 16 = 256$ px²) отримують повний boost": для такого об'єкта $A_0/A_i = 1024/256 = 4$, що збігається з w_{max} . Об'єкти меншого розміру теоретично заслуговують на більший ваговий коефіцієнт, проте $w_{max} = 4$ запобігає переважанню одинич-

них піксельних помилок у градієнті та нестабільності навчання детектора об'єктів. Систематичний grid-search за параметрами (A_0 , w_{max}) винесено у перспективи подальших етапів дослідження.

Загальну функцію втрат одностадійного детектора з anchor-free підходом (YOLOv8/YOLOv11) розглядають як зважену суму трьох компонентів – втрати регресії координат bounding box (CIoU), класифікаційної втрати (BCE) та Distribution Focal Loss [3]:

$$L_{total} = \lambda_{box} \cdot L_{box} + \lambda_{cls} \cdot L_{cls} + \lambda_{dfl} \cdot L_{dfl}, \quad (2)$$

де: L_{total} – загальна функція втрат; L_{box} – втрата регресії координат bounding box (CIoU); L_{cls} – класифікаційна втрата (BCE); L_{dfl} – Distribution Focal Loss; λ_{box} , λ_{cls} , λ_{dfl} – відповідні вагові коефіцієнти балансування компонентів.

У стандартній схемі навчання детектора об'єктів сумарна функція втрат не залежить від розміру об'єкта. У запропонованому підході модифікація відбувається на рівні алгоритму TaskAlignedAssigner [3] – компонента, який зіставляє передбачення моделі з ground truth і формує target_scores для кожного анкера. Замість прямого множення target_scores на w_i , що в попередніх експериментах призвело до пригнічення детекції великих об'єктів (Recall для великих цілей знизився з 0,98 до 0,07), застосовано boost-only-механізм, який тільки підсилює target для малих об'єктів і не змінює target для великих:

$$b_i = \frac{w_i - 1}{w_{max} - 1}, b_i \in [0, 1], \quad (3)$$

$$s_i \leftarrow s_i + (1 - s_i) \cdot b_i, \quad (4)$$

де: b_i – коефіцієнт підсилення i -го анкера; s_i – цільовий бал (target score) i -го анкера; w_i – ваговий коефіцієнт i -го анкера; w_{max} – верхнє обмеження вагового коефіцієнта.

Для великих об'єктів ($w_i = 1$) маємо $boost_i = 0$, отже, target_scores залишається незмінним. Для дуже малих цілей ($w_i = w_{max}$) маємо $boost_i = 1$, і target_scores тягнеться до 1, формуючи сильніший градієнтний сигнал. Вплив поширюється і на регресійні компоненти втрат, оскільки в реалізації v8DetectionLoss бокс-вагомість кожного анкера визначається сумою target_scores за класами для foreground-маски.

Як зазначено вище, малорозмірні безпілотники займають від кількох пікселів до сотих частки площі всього кадру. Стандартні функції втрат (на кшталт класичної cross-entropy або базової MSE для регресії меж) часто ігнорують такі об'єкти, фокусуючись на великих елементах зображення. Адаптивна функція втрат вирішує цю проблему шляхом динамічного перерозподілу вагових коефіцієнтів помилок під час навчання детектора безпілотних об'єктів.

Механізм працює покроково. На кожній ітерації навчання для кожного анкера за формулою (1) обчислюється адаптивна вагомість w_i як обернено пропорційна до площі bounding box відповідного об'єкта (з обмеженням w_{max}). Далі ця вагомість нормується у коефіцієнт підсилення $boost_i \in [0, 1]$ за формулою (3): для великих об'єктів ($w_i = 1$) $boost_i = 0$, для найменших ($w_i = w_{max}$) $boost_i = 1$. Отриманий коефіцієнт застосовується до цільових балів target_scores в алгоритмі TaskAlignedAssigner за формулою (4) у режимі boost-only: він тільки підтягує target малих об'єктів до 1 і не змінює target великих. Унаслідок цього градієнт від малорозмірних цілей зростає, і модель отримує сильніший навчальний сигнал саме на складних малих об'єктах, тоді як внесок великих залишається незмінним.

Варто зауважити, що запропонований метод не виконує безпосереднього згладжування (фільтрування) шуму складного фону – неба, дерев чи міської забудови. Працюючи винятково на рівні навчального сигналу, він підвищує відносний внесок малих об'єктів переднього плану у функцію втрат, унаслідок чого оптимізатор змушений впевненіше відокремлювати малі цілі від фонових структур. Отже, підвищення компоненті стійкості до складного фону є непрямым наслідком підсилення сигналу переднього плану, а не окремою операцією придушення фонового шуму.

Набір даних. Для перевірки запропонованої функції втрат використано спеціалізований набір даних для детекції БПЛА, сформованого з реальних кадрів спостереження повітряного простору на платформі Roboflow. Набір охоплює різні типи БПЛА, умови освітлення, рівні шуму, складні фони (хмарність, забудова, відкритий простір) та різні дистанції спостереження. Сукупна вибірка налічує 17 697 анованих зображень із 12 246 об'єктами класу drone. Об'єкти розподілено на чотири

категорії за площею bounding box: дуже малі – до 16×16 пікселів (256 px^2); малі – $256\text{--}1024 \text{ px}^2$; середні – $1024\text{--}4096 \text{ px}^2$; великі – понад 4096 px^2 . Структуру вибірки зображень наведено в табл. 1.

Оскільки БПЛА на зображеннях часто мають дуже різний візуальний розмір залежно від дистанції зйомки (від кількох пікселів на горизонті до заповнення всього кадру), то розподіл вибірки зображень або відеокадрів у наборі даних для детекції БПЛА за розмірними групами об'єктів зазвичай здійснюється на основі стандартів COCO (англ. *Common Objects in Context*), які класифікують об'єкти за їхньою площею в пікселях ($S = w \cdot h$). У реальних датасетах для виявлення дронів (наприклад, Drone-vs-Bird, Det-Fly або Anti-UAV) класичний підхід COCO іноді модифікують, оскільки понад 70–80 % реальних цілей є саме малими або надмалими ($S < 16^2 \text{ px}$). Тому вибірку часто балансують або додатково розділяють: надмалі (англ. *Extremely Small / Tiny*); оптимальний баланс вибірки.

Табл. 1. Розподіл вибірки набору даних для детекції БПЛА за розмірними групами об'єктів ($n = 17\,697$ зображень) / Distribution of the UAV detection dataset by object size categories ($n = 17,697$ images)

Вибірка	К-сть зображень	К-сть об'єктів	Дуже малі ($\leq 16 \times 16$)	Малі (16–32)	Середні (32–64)	Великі (> 64)
Навчальна	12 389	8 559	970	3 073	2 040	2 476
Валідаційна	3 539	2 444	267	872	577	728
Тестова	1 769	1 243	144	449	294	356
Разом	17 697	12 246	1 381	4 394	2 911	3 560

Налаштування моделей і процедура навчання детектора об'єктів. Для експерименту обрано одностадійні детектори на підставі моделей YOLOv8s (Ultralytics) та YOLOv11s – найновішу архітектуру сімейства моделей YOLO. Обидві моделі мають схожу обчислювальну складність (≈ 11 млн параметрів, 28,4–28,6 GFLOPs) і використовуються як базові у промислових застосуваннях. Навчання детектора об'єктів проводили у середовищі PyTorch з попередньо навченими вагами COCO. Параметри навчання детектора об'єктів: розмір вхідного зображення 640×640 пікселів, batch size 16, 80 епох, оптимізатор AdamW з cosine learning rate decay ($lr_0 = 0,01$, $lr_{final} = 0,001$), momentum 0,937, weight decay 0,0005, warmup 3 епохи. Аугментації: mosaic, горизонтальне віддзеркалення з імовірністю 0,5, випадковий поворот до 5° , масштабування 0,5, HSV-перетворення. Для кожної архітектури детектора об'єктів сформовано дві конфігурації моделей: зі стандартною функцією втрат і зі запропонованою адаптивною функцією втрат. Усього досліджено чотири конфігурації моделей: YOLOv8s baseline, YOLOv8s + adaptive loss, YOLOv11s baseline, YOLOv11s + adaptive loss. Опорну площу встановлено $A_0 = 1024$ пікселі, максимальний ваговий ко-

ефіцієнт $w_{max} = 4$. Критерій ранньої зупинки обчислень – стабілізація валідаційної loss протягом 20 епох.

Для забезпечення відтворюваності всі експерименти провели за однакових умов: фіксований seed ініціалізації ($seed = 42$), однакова послідовність аугментацій, ідентичний поділ вибірки для всіх чотирьох конфігурацій моделей. Порівняння конфігурацій моделей здійснили винятково на тестовій підвибірці, яка не використовувалась у процесі навчання детектора об'єктів та підбору гіперпараметрів. Усі моделі натренували на одному наборі даних GPU NVIDIA A100 (40 ГБ) у середовищі Google Colab Pro+.

Результати оцінювання чотирьох конфігурацій моделей на тестовій підвибірці наведено в табл. 2 і 3. Загальні інтегральні метрики (*Precision*, *Recall*, *F1*, *mAP@0,5* та *mAP@0,5:0,95*) розраховано за стандартною методикою фреймворку Ultralytics за порогу confidence 0,25 та порогу IoU 0,5. *Recall* за розмірними групами оцінено на анованих об'єктах тестової підвибірки з розподілом за площею bounding box. Графічне порівняння отриманих результатів детекції об'єктів наведено на рис. 1–5.

Табл. 2. Загальні метрики детекції об'єктів на тестовій підвибірці для чотирьох конфігурацій моделей ($\text{conf} = 0,25$; $\text{IoU} = 0,5$) / Overall object detection metrics on the test subset for four model configurations ($\text{conf} = 0,25$; $\text{IoU} = 0,5$)

Модель	Precision	Recall	F1	mAP@0,5	mAP@0,5:0,95
YOLOv8s baseline	0,9754	0,8957	0,9338	0,9311	0,6546
YOLOv8s + adaptive loss	0,9780	0,9106	0,9431	0,9390	0,6640
YOLOv11s baseline	0,9729	0,8965	0,9331	0,9355	0,6602
YOLOv11s + adaptive loss	0,9736	0,9047	0,9379	0,9373	0,6621

Табл. 3. Recall за розмірними групами об'єктів на тестовій підвибірці для чотирьох конфігурацій моделей / Recall by object size category on the test subset for four model configurations

Модель	Дуже малі ($\leq 16 \times 16$)	Малі (16–32)	Середні (32–64)	Великі (> 64)
YOLOv8s baseline	0,7847	0,8886	0,9116	0,9803
YOLOv8s + adaptive loss	0,8056	0,9109	0,9354	0,9860
YOLOv11s baseline	0,7778	0,8998	0,9184	0,9831
YOLOv11s + adaptive loss	0,7986	0,9176	0,9354	0,9803




Рис. 1. Загальні метрики Precision, Recall, F1, mAP@0,5 та mAP@0,5:0,95 для чотирьох конфігурацій моделей / Overall metrics Precision, Recall, F1, mAP@0.5 and mAP@0.5:0.95 for four model configurations

Згідно з даними табл. 2, запропонована адаптивна функція втрат забезпечила покращення всіх п'яти інтегральних метрик для обох досліджених архітектур детекторів об'єктів. Для моделі YOLOv8s приріст *Recall* становить 1,5 п.п. (0,896 → 0,911), *F1* – 0,9 п.п. (0,934 → 0,943), *mAP@0,5* – 0,8 п.п. (0,931 → 0,939), *mAP@0,5:0,95* – 0,9 п.п. (0,655 → 0,664). Для моделі YOLOv11s – *Recall* +0,8 п.п., *F1* +0,5 п.п. *Precision* не змінився, а навіть незначно зріс для моделі YOLOv8s (0,975 → 0,978), що свідчить про відсутність зростання хибних спрацювань.




Рис. 2. Recall за розмірними групами об'єктів для чотирьох конфігурацій моделей / Recall by object size category for four model configurations




Рис. 3. Динаміка навчання детектора об'єктів: box_loss на тренувальній вибірці / Training dynamics: box_loss on the training subset




Рис. 4. mAP@0,5 на валідаційній для чотирьох конфігурацій моделей за 80 епох / mAP@0.5 on the validation subset for four model configurations over 80 epochs

Найбільший ефект зафіксовано на малих і середніх об'єктах (див. табл. 3, рис. 2). Для дуже малих цілей (≤16×16 пікселів) приріст *Recall* становить 2,1 п.п. для

обох архітектур детекторів графічних об'єктів; для малих (16–32) – 2,2 п.п. для моделі YOLOv8s та 1,8 п.п. для моделі YOLOv11s; для середніх (32–64) – 2,4 та 1,7 п.п. відповідно.




Рис. 5. Приклади детекції моделі YOLOv11s з базовою та адаптивною функціями втрат на тестових зображеннях різних розмірних груп / Detection examples of YOLOv11s model with baseline and adaptive loss functions on test images across different object size categories

Принципово важливим є те, що для великих об'єктів ($>64 \times 64$) якість детекції об'єктів зберігається на рівні базової моделі: Recall для моделі YOLOv8s зріс від 0,9803 до 0,9860, для моделі YOLOv11s – становить 0,9803 проти 0,9831 у базовій конфігурації моделей, тобто залишається у межах статистичної похибки. Це підтверджує коректність запропонованого boost-only-механізму, який не пригнічує великі цілі, а тільки підсилює навчальний сигнал для малих.

Порівняння запропонованого підходу з попередньою мультиплікативною модифікацією (target_scores помноженими на w_i/w_{max}) показало, що пряме множення target_scores критично знижує Recall для великих об'єктів (від 0,98 до 0,07 за $w_{max} = 4$) через перекалібрування confidence – модель навчається передбачати знижену впевненість для великих цілей. Boost-only-формулювання вирішує цю проблему: target для великих об'єктів залишається у діапазоні $[0, 1]$ без штучного зменшення.

Ефект спостерігається на обох архітектурах детекторів об'єктів без зміни їхньої структури, що свідчить про незалежність запропонованого підходу до модифікації функції втрат від конкретної моделі. Підхід до адаптивного зважування навчального сигналу можна використовувати як універсальний механізм підсилення уваги до малорозмірних об'єктів у детекторах сімейства моделей YOLO. Стабільність покращень на новій архітектурі моделі YOLOv11s, яка вже містить алгоритм TaskAlignedAssigner та anchor-free підхід до призначення анкерів, підтверджує комплементарність запропонованого методу до сучасних архітектурних рішень – модифікація функції втрат не конфліктує з оптимізаціями нової архітектури детектора об'єктів, а додає до них.

Підвищення повноти детекції об'єктів на малих цілях супроводжується незначним приростом, а не зниженням Precision. Це принципова відмінність від більшості методів, орієнтованих на small object detection, де покращення Recall зазвичай оплачується зростанням false positives. У контексті систем протидії безпілотним загрозам отриманий результат є практично цінним: пропуск малої цілі (false negative) є критичнішою помилкою, ніж поодинокі хибні спрацювання, але вибудована архітектура детектора об'єктів знижує саме false negatives без помітного зростання false positives.

Аналіз кривих навчання детектора об'єктів (див. рис. 3) показує, що адаптивна функція втрат не погіршує збіжності і досягає кращих значень $mAP@0,5$ у межах тих самих 80 epoch. Box_loss для adaptive-конфігурацій моделей стабільно нижчий протягом усього процесу навчання детектора об'єктів, що відображає сильніший градієнтний сигнал від малих об'єктів і пов'язаний з покращенням локалізації.

Обмеження результатів дослідження. Кожна конфігурація моделей натренована з єдиним фіксованим $seed = 42$, тому наведені метрики є оцінками з одного запуску. Для незалежних повторюваностей на двох архітектурах детектора об'єктів та послідовності покращень у всіх розмірних групах якісна стабільність результатів видається імовірною, однак повноцінна статистична оцінка через 3–5 запусків з різними seed і розрахунком середнього зі стандартним відхиленням залишається завданням майбутніх досліджень. Дослідження не містить безпосереднього експериментального порівняння запропонованого методу з Focal Loss [6] як окре-

мою конфігурацією; запропонована функція позиціонується як комплементарна до Focal Loss (різні критерії пріоритетизації), і дослідження їхньої комбінації виходить за межі цієї роботи. По-третє, гіперпараметри $A_0 = 1024$ та $w_{max} = 4$ обрано на підставі теоретичних міркувань, а не grid-search; систематичний ablation за (A_0 , w_{max}) винесено у перспективи. По-четверте, виявлене незначне зниження Recall для великих об'єктів у конфігурації моделей YOLOv11s + adaptive (0,9803 проти 0,9831) знаходиться у межах статистичної похибки одного запуску, проте остаточне оцінювання стабільності цього спостереження також потрібно проводити в межах майбутнього мульти-seed-експерименту.

Обговорення результатів дослідження. Головна мета розроблення адаптивної функції втрат – підвищити точність виявлення мікро- та міні-БПЛА на складних візуальних фонах за допомогою модифікації математичного апарату навчання нейромереж. Малорозмірні безпілотники займають від кількох пікселів до сотих частки площі всього кадру. Адаптивна функція втрат вирішує цю проблему шляхом динамічного перерозподілу вагових коефіцієнтів помилок під час навчання детектора об'єктів.

У роботі [3] автори запропонували алгоритм TaskAlignedAssigner як механізм узгодження класифікаційного та локалізаційного компонентів під час присвоєння міток анкером. Порівняно з базовою реалізацією алгоритму TaskAlignedAssigner, отримані результати свідчать, що цей компонент допускає безпосередню модифікацію вагових коефіцієнтів target_scores без порушення загальної схеми навчання детектора об'єктів – запропонований boost-only-механізм забезпечив приріст Recall на малих об'єктах на 1,8–2,4 п.п. зі збереженням якості детекції великих цілей на рівні базової моделі.

У дослідженні [10] автори запропонували Generalized IoU як покращену метрику регресії bounding box, що враховує просторове розташування прямокутників навіть за відсутності перетину. На відміну від підходу, наведеного в роботі, запропонована адаптивна функція втрат діє на рівні зважування навчального сигналу, а не регресійного критерію, і є комплементарною до GIoU – поєднання обох підходів може дати синергетичний ефект, що виходить за межі цього дослідження.

У роботі [2] автори дослідили завдання розрізнення дронів і птахів за умов реального відеоспостереження та встановили, що мала площа об'єкта є ключовим чинником деградації точності детекції об'єктів. Порівняно з цими результатами, запропонований підхід до модифікації функції втрат дає можливість підвищити Recall для об'єктів найменшої розмірної категорії ($\leq 16 \times 16$ пікселів) на 2,1 п.п. відносно базової конфігурації моделей без додаткових архітектурних змін.

У дослідженні [8] автори представили оригінальну архітектуру моделі YOLO, яка вперше забезпечила детекцію об'єктів у режимі реального часу з єдиним проходом мережі. Порівняно з базовою концепцією, сучасні моделі YOLOv8s та YOLOv11s вже інтегрують anchor-free підхід до призначення анкерів і алгоритм TaskAlignedAssigner, проте стандартна функція втрат у них, як і в оригінальній YOLO, не розрізняє об'єкти за масштабом – саме цей недолік усуває запропонований механізм.

У роботі [9] автори запропонували Faster R-CNN – двостадійний детектор з Region Proposal Network, що

забезпечує високу точність локалізації. Натомість, результати нашого дослідження свідчать, що запропонована модифікація функції втрат дає можливість одностадійним детекторам досягати $mAP@0,5 = 0,939$ зі збереженням притаманної їм швидкодії інференсу, без архітектурних ускладнень, характерних для двостадійних підходів.

Унаслідок обговорення результатів дослідження у контексті аналізу наявної літератури було з'ясовано, що жоден з розглянутих підходів [2, 3, 8, 9, 10] не реалізує масштабно-залежного зважування навчального сигналу безпосередньо в компоненті присвоєння міток без зміни архітектури детектора об'єктів. Запропонований boost-only-механізм є оригінальним рішенням, що заповнює цю прогалину та демонструє стабільний позитивний ефект на двох незалежних архітектурах детектора об'єктів.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – отримала подальший розвиток методика навчання одностадійних детекторів об'єктів шляхом введення адаптивного вагового коефіцієнта функції втрат, визначеного обернено пропорційно до площі bounding box, та розроблення boost-only-механізму його інтеграції в компонент алгоритму TaskAlignedAssigner, яка, на відміну від прямого мультиплікативного підходу до зважування target scores, підсилює градієнтний сигнал для малорозмірних цілей без зниження якості детекції великих об'єктів, що дало можливість підвищити показник Recall для малих БПЛА на 1,8–2,4 п.п. за одночасного зростання двох інтегральних метрик $mAP@0,5$ та $mAP@0,5:0,95$.

Практична значущість результатів дослідження – можна застосувати для вдосконалення наявних промислових реалізацій одностадійних детекторів малих літальних об'єктів без зміни їхньої архітектури, збільшення кількості параметрів моделі або зниження швидкодії інференсу, що робить запропонований підхід до модифікації функції втрат придатним для безпосереднього впровадження в системи автоматичного моніторингу повітряного простору та комплекси протидії безпілотним загрозам.

Висновки / Conclusions

Розроблено адаптивну функцію втрат для покращення процесу виявлення малорозмірних БПЛА, яка дає змогу вибірково підсилювати навчальний сигнал від малих цілей, не змінюючи внесок великих об'єктів у загальну функцію втрат і, цим самим, усуває конкуренцію між різномасштабними об'єктами в процесі їхньої оптимізації. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Формалізовано адаптивну функцію втрат з ваговим коефіцієнтом, обернено пропорційним до площі bounding box об'єкта, та обґрунтовано вибір гіперпараметрів $A_0 = 1024$ пікселі та $w_{max} = 4$ на основі усталеної класифікації СОСО, що дало змогу кількісно описати механізм диференційованої пріоритизації об'єктів за масштабом у процесі навчання детектора.
2. Розроблено boost-only-механізм інтеграції адаптивного вагового коефіцієнта анкера в компонент алгоритму TaskAlignedAssigner на основі нормованого коефіцієнта підсилення, який за побудовою значно підсилює градієнтний сигнал для малих цілей і не знижує target_score

для великих графічних об'єктів, що усувало конкуренцію між різномасштабними об'єктами в процесі оптимізації моделі.

3. Сформовано спеціалізований набір даних для детекції БПЛА із 17 697 анотованих зображень та 12 246 об'єктами, розподіленими за чотирма розмірними категоріями, що забезпечило коректну оцінку методу в розрізі масштабу об'єктів та підтвердило репрезентативність експериментальної вибірки.
4. Проведено порівняльний експеримент для чотирьох конфігурацій моделей (YOLOv8s та YOLOv11s із базовою та адаптивною функціями втрат) за однакових умов навчання детектора об'єктів з фіксованим seed ініціалізації, що забезпечило відтворюваність та коректність порівняння результатів.
5. Встановлено, що запропонований підхід до модифікації функції втрат забезпечує покращення всіх інтегральних метрик: Recall +0,8–1,5 п.п., F1 +0,5–0,9 п.п., $mAP@0,5:0,95$ +0,2–0,9 п.п., з найвиразнішим ефектом на дуже малих і малих об'єктах (приріст Recall 1,7–2,4 п.п.) зі збереженням якості детекції великих цілей на рівні базової моделі.
6. Підтверджено архітектурну незалежність методу шляхом його апробації на двох різних архітектурах детекторів об'єктів: стабільний позитивний ефект зафіксовано без зміни їхньої структури, збільшення кількості параметрів або зниження швидкодії інференсу, що свідчить про практичну придатність методу для широкого класу одностадійних детекторів.

Перспективи подальших етапів дослідження охоплюють: мульти-seed-оцінку для побудови довірчих інтервалів; безпосереднє експериментальне порівняння запропонованого методу з Focal Loss та дослідження поєднання обох підходів; систематичний grid-search за гіперпараметрами (A_0 , w_{max}); адаптацію до багатокласових сценаріїв та розгортання на edge-пристроях у завданнях трекінгу в режимі реального часу.

Декларація про використання засобів штучного інтелекту. Під час підготовки цієї роботи автори використовували сервіси ChatGPT та Grammarly для: перевірки граматики та орфографії, перефразування та переформулювання складних речень з текстовими зворотами. Після використання цих сервісів автори проаналізували та відредагували контент майбутньої статті, тобто несуть повну відповідальність за зміст публікації.

References

1. Alshaer, N., Abdelfatah, R., Ismail, T., & Mahmoud, H. (2025). Vision-Based UAV Detection and Tracking Using Deep Learning and Kalman Filter. *Computational Intelligence*, 41(1), article ID e70026. <https://doi.org/10.1111/coin.70026>
2. Coluccia, A., Fascista, A., Schumann, A., Sommer, L., Dimou, A., Zarpalas, D., & Sharma, V. (2021). Drone vs. Bird Detection: Deep Learning Algorithms and Results from a Grand Challenge. *Sensors*, 21(8), article ID 2824. <https://doi.org/10.3390/s21082824>
3. Feng, C., Zhong, Y., Gao, Y., Scott, M. R., & Huang, W. (2021). TOOD: Task-aligned One-stage Object Detection. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 3490–3499. <https://doi.org/10.1109/ICCV48922.2021.00349>
4. Han, C., Ullah, M. R., Kayes, A., Hasan, K., Rouf, M. A., Hasan, M. R., Tao, S., Gengli, G., & Billah, M. M. (2026). Real-Time Small UAV Detection in Complex Airspace Using YOLOv11 with Residual Attention and High-Resolution Feature Enhancement. *Journal of Imaging*, 12(3), article ID 140. <https://doi.org/10.3390/jimaging12030140>
5. Laroca, R., dos Santos, M., & Menotti, D. (2025). Improving Small Drone Detection Through Multi-Scale Processing and Data

- Augmentation. *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, pp. 1–6. <https://doi.org/10.1109/IJCNN64981.2025.11227421>
6. Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2020). Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 318–327. <https://doi.org/10.1109/TPAMI.2018.2858826>
 7. Muhamad Zamri, F. N., Gunawan, T. S., Kartiwi, M., Yusoff, S. H., & Yaacob, M. (2024). Deep Learning Techniques for Advanced Drone Detection Systems: A Comprehensive Review. *Indonesian Journal of Electrical Engineering and Informatics*, 12(4), 1040–1050. <https://doi.org/10.52549/ijeei.v12i4.6028>
 8. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
 9. Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
 10. Rezaatofghi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 658–666. <https://doi.org/10.1109/CVPR.2019.00075>
 11. Wisniewski, M., Rana, Z. A., & Petrunin, I. (2024). Drone Detection Using Deep Neural Networks Trained on Pure Synthetic Data. *arXiv preprint arXiv:2411.09077*. <https://doi.org/10.48550/arXiv.2411.09077>
 12. Zhao, J., Zhang, J., Li, D., & Wang, D. (2022). Vision-Based Anti-UAV Detection and Tracking. *IEEE Transactions on Intelligent Transportation Systems*, 23(12), 25323–25334. <https://doi.org/10.1109/TITS.2022.3177627>
 13. Zhou, S., Yang, L., Liu, H., Zhou, C., Liu, J., Pu, S., Tang, Y., & Chen, Z. (2025). Improved YOLO for Long-Range Detection of Small Drones. *Scientific Reports*, 15, article ID 12280. <https://doi.org/10.1038/s41598-025-95580-z>

R. D. Skalish, Yu. S. Protsyk

Ukrainian National Forestry University, Lviv, Ukraine

ADAPTIVE LOSS FUNCTION FOR IMPROVING DETECTION OF SMALL-SCALE UNMANNED AERIAL VEHICLES

Detection of small-scale unmanned aerial vehicles (UAVs) under real-world surveillance conditions remains a pressing challenge for automatic airspace monitoring systems and counter-drone solutions, particularly given the growing diversity of UAV platforms and operational scenarios. The standard loss function of single-stage detectors does not distinguish objects by scale: large and small targets contribute comparably to the total loss, and optimization naturally shifts toward larger, more visually salient objects, so small UAVs receive an insufficient gradient signal during training. This study proposes an adaptive loss function in which the weight of each anchor is defined inversely proportional to the bounding-box area of the corresponding object. The method is implemented as a boost-only modification of target_scores within the TaskAlignedAssigner algorithm, which amplifies the training signal for small objects without suppressing the detection of large ones. As a result, the proposed loss provides a low-cost and architecture-agnostic mechanism for boosting small-object detection sensitivity in modern one-stage detectors without any structural modifications. The approach is integrated into the YOLOv8s and YOLOv11s implementations in PyTorch and evaluated on a specialized UAV detection dataset containing 17,697 annotated images with 12,246 objects distributed across four size categories: very small (up to 16×16 px), small (16–32 px), medium (32–64 px), and large (over 64 px). It is found that the proposed loss function consistently improves detection Recall and F1-score for both studied architectures across all size groups, with the most pronounced effect on very small and small targets, where Recall gains reach 2.1–2.4 percentage points. The overall integral metrics ($mAP@0.5$ and $mAP@0.5:0.95$) also increase, while the detection quality of large objects is preserved at the baseline level. The proposed approach introduces no additional model parameters and has no impact on inference-time performance. Promising directions for further research are the combination of the proposed loss with Focal Loss and Giou, adaptation of the method to multi-class scenarios, and evaluation on edge-deployment platforms.

Keywords: detection of aerial objects; computer vision; YOLOv8 and YOLOv11 models; TaskAlignedAssigner algorithm; deep learning for object detection.