

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

на тему Метод розпізнавання БПЛА за зображенням з тепловізора
засобами глибокого навчання

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент 2 курсу, група КНм-23-1

Курс, група виконавця

Максим
КАЗІОНОВ

Підпис

Ім'я, прізвище

Керівник: д.т.н., проф., завідувач кафедри
КН

Науковий ступінь, посада

Олександр
БАРМАК

Підпис

Ім'я, прізвище

Нормоконтроль к.т.н., доцент кафедри КН

Науковий ступінь, посада

Руслан БАГРІЙ

Підпис

Ім'я, прізвище

До захисту допускаю:

Зав. кафедри КН, д.т.н., професор

Олександр
БАРМАК

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь магістр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук


(підпис)
д.т.н., професор О.В. Бармак
« 01 » вересня 2024 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА

1. Тема кваліфікаційної роботи магістра: «Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання»

2. Завдання видано студенту Максиму КАЗІОНОВУ
(прізвище, ім'я, по батькові)

3. Керівник роботи зав. каф. КН, д.т.н., проф. Олександр БАРМАК
(прізвище, ім'я, по батькові)

4. Затверджені наказом університету від «___» _____ 2024 р. № ___.

5. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета кваліфікаційної роботи магістра – підвищення якості виявлення БПЛА за тепловізійними зображеннями із застосуванням методів глибокого навчання на основі архітектури YOLO. Для досягнення поставленої мети потрібно виконати наступні задачі: провести аналіз предметної області для проблеми виявлення БПЛА, огляд існуючих публікацій щодо виявлення БПЛА за тепловізійними зображеннями та вивчення сучасних архітектур YOLO для задач детекції об'єктів; вдосконалити метод виявлення БПЛА за тепловізійними зображеннями шляхом розробки та налаштування кількох версій моделі YOLO, які враховують низький контраст та теплові шуми; визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з існуючими підходами для детекції БПЛА в умовах реальних спостережень

Реферат

Кваліфікаційна робота магістра присвячена підвищенню якості виявлення БПЛА за зображеннями з тепловізора шляхом вдосконалення методу із застосуванням методів глибокого навчання на основі архітектури YOLO.

Актуальність теми. Виявлення безпілотних літальних апаратів (БПЛА) є надзвичайно важливим завданням через активне використання дронів як у цивільній, так і у військовій сферах. Завдяки широкій доступності та зростанню функціональних можливостей БПЛА їх застосування поширюється для різноманітних цілей, у тому числі для незаконної діяльності, такої як незаконне спостереження, контрабанда та порушення безпеки об'єктів критичної інфраструктури. У контексті сучасних умов держави, що перебуває в стані війни, завдання швидкого та точного виявлення БПЛА стає критично важливим для забезпечення безпеки та захисту стратегічних об'єктів.

Складність виявлення БПЛА обумовлена їхньою різноманітністю за розмірами, формами, матеріалами та стелс-технологіями, які дозволяють їм залишатися малопомітними у багатьох спектрах спостереження. Використання тепловізійних зображень у задачах виявлення БПЛА є перспективним рішенням, оскільки такі зображення дозволяють виявляти об'єкти за тепловим випромінюванням навіть у темну пору доби. Однак, низький контраст, фоновий тепловий шум та змінні погодні умови значно ускладнюють цю задачу. У таких умовах використання методів глибокого навчання, зокрема архітектури YOLO, дозволяє автоматизувати процеси обробки теплових зображень та підвищити точність і швидкість виявлення БПЛА. Завдяки здатності нейронних мереж ефективно обробляти теплові зображення та виділяти ознаки, які важко виявити традиційними методами, вони забезпечують високу якість ідентифікації об'єктів навіть за умов низького контрасту та сильних шумових перешкод.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за зображеннями з тепловізора із застосуванням методів

глибокого навчання на основі архітектури YOLO. Для досягнення поставленої мети потрібно виконати наступні завдання:

- 1) провести аналіз предметної області для проблеми виявлення БПЛА на тепловізійних зображеннях;
- 2) проаналізувати існуючі публікації щодо ідентифікації БПЛА на зображеннях;
- 3) дослідити існуючі моделі глибокого навчання для виявлення об'єктів на зображеннях з тепловізора;
- 4) вдосконалити метод розпізнавання БПЛА за допомогою моделей глибокого навчання;
- 5) підготувати відповідний набір даних для донавчання нейронної мережі;
- 6) донавчити попередньо навчену нейронну мережу для виявлення БПЛА на тепловізійних зображеннях;
- 7) розробити застосунок для валідації запропонованого методу;
- 8) оцінити ефективність запропонованого методу за допомогою статистичних показників та порівняти його з іншими підходами.

Об'єктом дослідження є процес виявлення БПЛА за зображеннями з тепловізора із використанням методів глибокого навчання.

Предметом дослідження є архітектури глибокого навчання, що застосовуються для виявлення об'єктів на тепловізійних зображеннях.

Методи дослідження. Методи глибокого навчання, зокрема архітектури YOLO, а також методи попередньої обробки зображень, регуляризації, ранньої зупинки та оптимізації.

Наукова новизна одержаних результатів. Удосконалено метод виявлення БПЛА за зображеннями з тепловізора із застосуванням методів глибокого навчання, який відрізняється від існуючих підходів розробкою трьох архітектур YOLO, що дозволило моделі краще виділяти ознаки об'єктів, застосування адаптивної функції втрат для кращої оцінки якості визначення рамок об'єктів, використання регуляризації та метод ранньої зупинки для запобігання перенавчанню, що

дозволило підвищити якість і точність виявлення БПЛА за зображеннями з тепловізора.

Апробація результатів кваліфікаційної роботи магістра та публікації. За темою роботи підготовлені тези на наукову конференцію: Казіонов М.А. “МЕТОД РОЗПІЗНАВАННЯ БПЛА ЗА ЗОБРАЖЕННЯМ З ТЕПЛОВІЗОРА ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ”. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп’ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 246-250

Також, результати роботи опубліковані у науковому журналі – ВДОСКОНАЛЕНИЙ МЕТОД ВИЯВЛЕННЯ БПЛА ЗА ТЕПЛОВІЗІЙНИМИ ЗОБРАЖЕННЯМИ НА ОСНОВІ МОДЕЛІ ГЛИБОКОГО НАВЧАННЯ YOLO / Казіонов М.А., Скрипник Т.К., Пасічник О.А., Вознюк Л.О. // Науковий журнал «Вісник Хмельницького національного університету. Серія: Технічні науки» Хмельницький, 2025, №1 (Довідка з редакції)

Структура та обсяг роботи. Кваліфікаційна робота магістра складається із завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань із 52 найменувань та 3 додатків. Загальний обсяг дипломної роботи магістра становить 101 сторінку, з них 83 сторінки основного тексту та 18 сторінок додатків. У роботі наведено 19 рисунків, 6 формул та 1 таблиця.

Ключові слова: БПЛА, тепловізійне зображення, виявлення об’єктів, глибоке навчання, згорткові нейронні мережі, YOLO, SIoU, детекція об’єктів.

Зміст

Перелік скорочень

Вступ

РОЗДІЛ 1 Аналіз сучасного стану у використанні методів глибокого навчання для розпізнавання БПЛА за зображенням з тепловізора

1.2 Аналіз існуючих публікацій щодо розпізнавання БПЛА за зображенням з тепловізора

1.3 Аналіз існуючих моделей глибокого навчання для виявлення об'єктів на зображеннях

1.4 Мета та завдання дослідження

Висновки до розділу 1

РОЗДІЛ 2. Вдосконалення методу виявлення БПЛА за аналізом зображення с тепловізора

2.1 Модель глибокого навчання для виявлення БПЛА

2.1.1. Огляд архітектури YOLO

2.1.2. Архітектура YOLO для виявлення БПЛА за тепловізійними зображеннями

2.2 Вдосконалення моделі для виявлення БПЛА

2.2.1. Огляд цілей та вимог до покращень

2.2.2 Покращення обробки просторових ознак та оптимізація параметрів моделі

2.2.3 Модифікація моделі для роботи з тепловізійними зображеннями

2.3 Формування множини навчальних даних

2.4 Метрики для оцінювання якості виявлення БПЛА

Висновки до розділу 2

РОЗДІЛ 3. Основні кроки методу по вдосконаленню та використанню YOLO для виявлення БПЛА

3.1 Основні кроки методу по вдосконаленню архітектури глибокого навчання

3.2 Застосування вдосконалених моделей для ідентифікації БПЛА

3.3 Висновок до розділу 3

РОЗДІЛ 4 Експериментальна перевірка ефективності вдосконаленого методу виявлення БПЛА

4.1 Опис застосунку для проведення експериментів

4.2 Опис датасету

4.2.1 Опис наборів тепловізійних зображень БПЛА

4.2.2. Попередня обробка вхідних даних

4.3 Експерименти

4.3.1. Результати вдосконалення архітектури YOLO для виявлення БПЛА за тепловізійними зображеннями

Висновки до розділу 4

Загальні висновки

Додатки

Перелік скорочень

Скорочення, термін, позначення	Пояснення
БПЛА	Безпілотний літальний апарат
YOLO	You Only Look Once
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
DL	Глибоке навчання – метод навчання нейронних мереж з великою кількістю шарів
SIoU	Покращена версія IoU, яка враховує відстань, форму та вирівнювання рамок
Early Stopping	Метод для зупинки навчання моделі, коли її продуктивність на валідаційній вибірці перестає покращуватися
BatchNorm	Нормалізація активацій між шарами для прискорення збіжності навчання

Вступ

Актуальність теми. Виявлення безпілотних літальних апаратів (БПЛА) є надзвичайно важливим завданням через активне використання дронів як у цивільній, так і у військовій сферах. Завдяки широкій доступності та зростанню функціональних можливостей БПЛА їх застосування поширюється для різноманітних цілей, у тому числі для незаконної діяльності, такої як незаконне спостереження, контрабанда та порушення безпеки об'єктів критичної інфраструктури. У контексті сучасних умов держави, що перебуває в стані війни, завдання швидкого та точного виявлення БПЛА стає критично важливим для забезпечення безпеки та захисту стратегічних об'єктів.

Складність виявлення БПЛА обумовлена їхньою різноманітністю за розмірами, формами, матеріалами та стелс-технологіями, які дозволяють їм залишатися малопомітними у багатьох спектрах спостереження. Використання тепловізійних зображень у задачах виявлення БПЛА є перспективним рішенням, оскільки такі зображення дозволяють виявляти об'єкти за тепловим випромінюванням навіть у темну пору доби. Однак, низький контраст, фоновий тепловий шум та змінні погодні умови значно ускладнюють цю задачу. У таких умовах використання методів глибокого навчання, зокрема архітектури YOLO, дозволяє автоматизувати процеси обробки теплових зображень та підвищити точність і швидкість виявлення БПЛА. Завдяки здатності нейронних мереж ефективно обробляти теплові зображення та виділяти ознаки, які важко виявити традиційними методами, вони забезпечують високу якість ідентифікації об'єктів навіть за умов низького контрасту та сильних шумових перешкод.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за зображеннями з тепловізора із застосуванням методів глибокого навчання на основі архітектури YOLO. Для досягнення поставленої мети потрібно виконати наступні завдання:

- 1) провести аналіз предметної області для проблеми виявлення БПЛА на тепловізійних зображеннях;

- 2) проаналізувати існуючі публікації щодо ідентифікації БПЛА на зображеннях;
- 3) дослідити існуючі моделі глибокого навчання для виявлення об'єктів на зображеннях з тепловізора;
- 4) вдосконалити метод розпізнавання БПЛА за допомогою моделей глибокого навчання;
- 5) підготувати відповідний набір даних для донавчання нейронної мережі;
- 6) донавчити попередньо навчену нейронну мережу для виявлення БПЛА на тепловізійних зображеннях;
- 7) розробити застосунок для валідації запропонованого методу;
- 8) оцінити ефективність запропонованого методу за допомогою статистичних показників та порівняти його з іншими підходами.

Об'єкт дослідження. Процес виявлення БПЛА за зображеннями з тепловізора із використанням методів глибокого навчання.

Предмет дослідження. Архітектури глибокого навчання, що застосовуються для виявлення об'єктів на тепловізійних зображеннях.

Методи дослідження. Методи глибокого навчання, зокрема архітектури YOLO, а також методи попередньої обробки зображень, регуляризації, ранньої зупинки та оптимізації.

Наукова новизна одержаних результатів. Удосконалено метод виявлення БПЛА за зображеннями з тепловізора із застосуванням методів глибокого навчання, який відрізняється від існуючих підходів розробкою трьох архітектур YOLO, що дозволило моделі краще виділяти ознаки об'єктів, застосування адаптивної функції втрат для кращої оцінки якості визначення рамок об'єктів, використання регуляризації та метод ранньої зупинки для запобігання перенавчанню, що дозволило підвищити якість і точність виявлення БПЛА за зображеннями з тепловізора.

Апробація результатів кваліфікаційної роботи магістра та публікації. За темою роботи підготовлені тези на наукову конференцію: Казіонов М.А. “МЕТОД РОЗПІЗНАВАННЯ БПЛА ЗА ЗОБРАЖЕННЯМ З ТЕПЛОВІЗОРА ЗАСОБАМИ

ГЛИБОКОГО НАВЧАННЯ”. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп’ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 246-250

Також, результати роботи опубліковані у науковому журналі – ВДОСКОНАЛЕНИЙ МЕТОД ВИЯВЛЕННЯ БПЛА ЗА ТЕПЛОВІЗІЙНИМИ ЗОБРАЖЕННЯМИ НА ОСНОВІ МОДЕЛІ ГЛИБОКОГО НАВЧАННЯ YOLO / Казіонов М.А., Скрипник Т.К., Пасічник О.А., Вознюк Л.О. // Науковий журнал «Вісник Хмельницького національного університету. Серія: Технічні науки» Хмельницький, 2025, №1 (Довідка з редакції)

Структура та обсяг роботи. Кваліфікаційна робота магістра складається із завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань із 43 найменувань та 3 додатків. Загальний обсяг дипломної роботи магістра становить 92 сторінки, з них 73 сторінки основного тексту та 19 сторінок додатків. У роботі наведено 35 рисунків, 10 формул та 7 таблиць.

Ключові слова: БПЛА, тепловізійне зображення, виявлення об’єктів, глибоке навчання, згорткові нейронні мережі, YOLO, SIoU, детекція об’єктів.

РОЗДІЛ 1 Аналіз сучасного стану у використанні методів глибокого навчання для розпізнавання БПЛА за зображенням з тепловізора

1.1 Аналіз предметної області

Розпізнавання образів – це процес, що дозволяє ідентифікувати й класифікувати об'єкти на зображеннях або відео за допомогою алгоритмів, які можуть автоматично виділяти характерні риси об'єктів. Такий підхід стає дедалі важливішим у різних сферах, включаючи військові операції, де точне і швидке ідентифікування об'єктів може бути вирішальним для успіху місії. Останніми роками, завдяки розвитку обчислювальних потужностей і алгоритмів машинного навчання, особливо глибокого навчання, досягнуто значного прогресу у розпізнаванні образів. Військова сфера є однією з ключових галузей, що використовує ці технології для підвищення точності та швидкості виявлення і ідентифікації загроз.

Зокрема, у реаліях сучасних військових конфліктів все частіше використовуються безпілотні літальні апарати (БПЛА). Вони стали важливим інструментом у веденні бойових дій, виконуючи широкий спектр завдань: від розвідки до ударних операцій. БПЛА дозволяють проводити розвідку з високою точністю, уникати ризиків для особового складу та оперативно коригувати вогонь. Однак, одночасно з поширенням БПЛА виникає необхідність їх швидкого та надійного виявлення і знешкодження. Ворог може використовувати БПЛА для розвідки позицій, навігації артилерійського вогню, а також для атак із застосуванням вибухівки. Через це засоби ідентифікації та боротьби з БПЛА стають пріоритетними напрямками досліджень у військовій сфері.

Традиційні оптичні системи для виявлення та розпізнавання БПЛА мають ряд обмежень. Вони залежать від умов освітлення, видимості та атмосферних явищ, таких як туман чи дим. Це робить їх менш ефективними в умовах бойових дій, особливо в нічний час або під час маскуванню апаратів. У цьому контексті тепловізори, що базуються на сприйнятті інфрачервоного випромінювання, стали

потужним інструментом для виявлення об'єктів, що випромінюють тепло, таких як двигуни БПЛА. Тепловізійні зображення дозволяють виявляти об'єкти незалежно від умов освітлення, що робить їх особливо корисними для роботи вночі чи в складних погодних умовах.

Однак, тепловізійні зображення мають свої специфічні особливості. Вони характеризуються меншою деталізацією порівняно з оптичними зображеннями, а також можуть бути зашумленими через вплив навколишнього середовища. БПЛА можуть мати різний тепловий відбиток залежно від типу двигуна, матеріалів конструкції та умов роботи. Це створює додаткові труднощі для автоматизованих систем розпізнавання.

Тут на допомогу приходять методи машинного навчання. Останні досягнення в галузі глибокого навчання, зокрема згорткові нейронні мережі (CNN) [1][2], дозволяють навчати моделі, здатні ідентифікувати об'єкти на тепловізійних зображеннях з високою точністю. CNN використовують багат шарову структуру, яка дозволяє виділяти характерні риси об'єктів на різних рівнях деталізації. Спочатку мережа вчиться розпізнавати прості ознаки, такі як контури чи краї об'єктів, а на більш глибоких рівнях – складніші форми та патерни. Завдяки цьому CNN здатні адаптуватися до специфічних характеристик тепловізійних зображень, таких як розмитість або низька контрастність.

Також важливу роль у розпізнаванні БПЛА відіграють методи сегментації зображень, що дозволяють автоматично виділяти області на зображенні, які можуть містити об'єкт інтересу, наприклад, сам БПЛА або його частини. Сегментація полегшує процес класифікації, оскільки алгоритм працює лише з виділеними частинами зображення, а не з усією його площею. Для цього використовуються різні підходи, зокрема "Fully Convolutional Networks" (FCN) [3], які застосовуються для піксельної класифікації зображень.

Ще одним підходом є використання рекурентних нейронних мереж (RNN) [4] у поєднанні з CNN [6] для аналізу послідовностей зображень, що дозволяє відстежувати рух БПЛА на відео в реальному часі. Це особливо корисно в ситуаціях,

коли важливо не лише виявити об'єкт, але й передбачити його траєкторію, що дозволяє ефективніше протидіяти загрозам з боку БПЛА.

Сучасні системи також можуть використовувати методи обробки великих обсягів даних для створення тренувальних вибірок [7], на яких алгоритми навчаються розпізнавати БПЛА в різних умовах. Застосування таких підходів дозволяє враховувати численні фактори, такі як висота польоту, швидкість руху, кут атаки та типи БПЛА, що суттєво підвищує загальну точність системи.

Важливим аспектом є питання узагальнення моделей. Оскільки БПЛА можуть мати різні форми, розміри та характеристики, алгоритми машинного навчання повинні бути здатними узагальнювати набуті знання, щоб виявляти нові типи БПЛА або пристосовуватися до змінних умов бойових дій. Для цього використовуються техніки transfer learning [4], які дозволяють перенавчати моделі на нових вибірках, зберігаючи при цьому набуті знання з попередніх навчальних сесій.

Отже, розпізнавання БПЛА за зображенням з тепловізора є складною, але критично важливою задачею, вирішення якої вимагає застосування передових методів машинного навчання. Розвиток алгоритмів, здатних працювати з низькоякісними тепловізійними зображеннями в реальних умовах бойових дій, підвищує ефективність військових операцій та дозволяє значно покращити засоби протидії повітряним загрозам.

1.2 Аналіз існуючих публікацій щодо розпізнавання БПЛА за зображенням з тепловізора

У сучасному світі, де технології стрімко розвиваються, задача розпізнавання безпілотних літальних апаратів (БПЛА) за допомогою тепловізійних зображень набуває все більшого значення. Ця проблема привертає увагу багатьох дослідників, які прагнуть розробити ефективні методи виявлення та класифікації БПЛА в різноманітних умовах.

Розпізнавання БПЛА за тепловізійними зображеннями є непростим завданням через низку факторів. Серед них можна виділити малі розміри цілей, змінні умови

навколишнього середовища та потенційну схожість теплових сигнатур БПЛА з іншими об'єктами. Однак, завдяки стрімкому розвитку методів машинного навчання, особливо глибоких нейронних мереж, з'явилися нові можливості для вирішення цієї складної задачі.

Одне з перших значущих досліджень у цій галузі було присвячено розробці методу виявлення малих безпілотних літальних апаратів з використанням згорткової нейронної мережі (CNN) на основі інфрачервоних зображень [10][11]. Автори даних робіт змогли досягти високої точності виявлення навіть в складних умовах навколишнього середовища, що стало важливим кроком у розвитку даного напрямку.

Подальші дослідження розширили цей підхід, зосередившись на розробці глибокої нейронної мережі для виявлення та класифікації БПЛА на інфрачервоних зображеннях [12]. У цій роботі було використано архітектуру You Only Look Once (YOLO) з модифікаціями для роботи з тепловізійними даними. Результати виявилися вражаючими – точність виявлення перевищила 90%, що підтвердило ефективність глибокого навчання для вирішення цієї задачі.

Важливим кроком у розвитку методів розпізнавання БПЛА стало застосування техніки передачі навчання [13][14][16]. Дослідники запропонували адаптувати моделі, попередньо навчені на зображеннях видимого спектру, до роботи з тепловізійними даними. Цей підхід дозволив значно скоротити час навчання та підвищити ефективність розпізнавання, що особливо важливо при обмежених наборах даних.

Цікавий підхід було запропоновано в дослідженні, де автори використали генеративні змагальні мережі (GAN) для покращення якості тепловізійних зображень перед їх подачею на вхід моделі розпізнавання [15]. Це дозволило підвищити точність виявлення БПЛА в умовах низької контрастності та наявності шумів, що часто зустрічаються при роботі з тепловізійними даними.

Окрема увага була приділена розробці легковагих архітектур CNN для розпізнавання БПЛА в реальному часі [17][18]. Автори цих досліджень змогли

досягти балансу між швидкістю обробки та точністю розпізнавання, що є критично важливим для практичного застосування таких систем в польових умовах.

Значний прогрес було досягнуто завдяки впровадженню мультимодальних підходів, які комбінують дані з тепловізійних та оптичних камер [19][20]. Використання ансамблю нейронних мереж дозволило досягти вищої точності порівняно з моделями, що працюють лише з одним типом даних. Це відкрило нові можливості для створення більш надійних систем виявлення БПЛА.

Особливої уваги заслуговує дослідження, присвячене розробці спеціалізованої архітектури глибокої нейронної мережі для обробки послідовностей тепловізійних зображень [22]. Автори цієї роботи врахували часову динаміку руху БПЛА, що дозволило суттєво підвищити точність розпізнавання в складних умовах, таких як міське середовище або лісова місцевість.

Розвиваючи ідею врахування часової складової, інша група дослідників запропонувала метод розпізнавання БПЛА на основі комбінації згорткових та рекурентних нейронних мереж [21]. Цей підхід дозволив ефективно обробляти як просторові, так і часові характеристики тепловізійних зображень, що особливо важливо при відстеженні рухомих цілей.

Окреме дослідження було присвячено проблемі розпізнавання БПЛА в умовах міського середовища [24]. Автори розробили спеціалізовану CNN архітектуру, яка враховує специфіку теплових сигнатур у міському ландшафті. Це дослідження має особливе значення для розробки систем безпеки в густонаселених районах.

Важливим напрямком досліджень стала розробка методів розпізнавання БПЛА на великих відстанях з використанням тепловізійних зображень низької роздільної здатності [25]. Запропонована модель на основі глибокого навчання показала високу ефективність навіть при роботі з зображеннями поганої якості, що відкриває нові можливості для систем раннього виявлення.

Значний внесок у розвиток методів машинного навчання для розпізнавання БПЛА зробило дослідження, присвячене автоматичному анотуванню тепловізійних зображень [27]. Автори розробили метод, який дозволяє створювати великі

навчальні датасети з мінімальним втручанням людини. Це суттєво прискорило процес навчання моделей та підвищило їх точність.

Окрема увага була приділена розробці робастних методів розпізнавання БПЛА в умовах активної протидії [28]. Дослідники запропонували архітектуру нейронної мережі, стійку до спроб маскуванню теплового сліду БПЛА. Це дослідження має особливе значення для застосування в військовій сфері та системах безпеки критичної інфраструктури.

Цікавий підхід було запропоновано в роботі, присвяченій розпізнаванню типів БПЛА за їхніми тепловими сигнатурами [23]. Автори використали ансамбль глибоких нейронних мереж, що дозволило не лише виявляти БПЛА, але й класифікувати їх за розміром та призначенням. Це відкриває нові можливості для створення більш інтелектуальних систем моніторингу повітряного простору.

Важливим етапом у розвитку методів розпізнавання БПЛА стало проведення порівняльного аналізу різних архітектур глибоких нейронних мереж [37]. Автори цього дослідження надали цінні рекомендації щодо вибору оптимальної архітектури залежно від конкретних умов застосування, що допомагає практикам у розробці ефективних систем.

Нарешті, варто відзначити дослідження, присвячене проблемі розпізнавання груп БПЛА на тепловізійних зображеннях [24]. Автори розробили спеціалізовану архітектуру нейронної мережі, здатну ефективно виявляти та відстежувати множинні цілі одночасно. Це дослідження має особливе значення для створення систем протидії роям БПЛА.

Аналізуючи ці та інші публікації, можна зробити висновок, що методи глибокого навчання, зокрема різноманітні архітектури згорткових нейронних мереж, є найбільш ефективними для вирішення задачі розпізнавання БПЛА за зображеннями з тепловізора. Вони демонструють високу точність, здатність адаптуватися до різних умов зйомки та можливість роботи в режимі реального часу.

Водночас, дослідження в цій галузі продовжуються, спрямовані на подальше підвищення ефективності та надійності систем розпізнавання БПЛА. Серед перспективних напрямків можна виділити розробку більш ефективних методів

обробки послідовностей зображень, вдосконалення технік передачі навчання для роботи з обмеженими наборами даних, а також створення гібридних систем, що поєднують дані з різних типів сенсорів.

Таким чином, розпізнавання БПЛА за тепловізійними зображеннями залишається актуальною та динамічною областю досліджень, яка має велике практичне значення для систем безпеки, моніторингу повітряного простору та інших галузей застосування.

1.3 Аналіз існуючих моделей глибокого навчання для виявлення об'єктів на зображеннях

Виявлення об'єктів на зображеннях є однією з фундаментальних задач комп'ютерного зору, яка має широкий спектр практичних застосувань: від систем автономного керування транспортними засобами до аналізу медичних зображень та систем відеоспостереження. Ця задача полягає не лише у визначенні наявності об'єкта на зображенні, але й у точному визначенні його розташування та класифікації. З розвитком глибокого навчання ця галузь зазнала значного прогресу, що призвело до появи ряду ефективних архітектур та методів.

Одним з перших успішних підходів до виявлення об'єктів за допомогою глибокого навчання став R-CNN (Region-based Convolutional Neural Networks), представлений Россом Гіршиком та його колегами у 2014 році [29]. R-CNN використовував селективний пошук для генерації приблизно 2000 регіонів-кандидатів на зображенні, які потім обрізалися та масштабувалися перед подачею до згорткової нейронної мережі (CNN) для вилучення ознак. Ці ознаки потім класифікувалися за допомогою SVM для кожного класу об'єктів. Хоча R-CNN показав значне покращення точності порівняно з попередніми методами, він мав суттєві обмеження: процес був повільним (потребував близько 47 секунд на зображення), вимагав великого обсягу пам'яті для зберігання ознак, і навчання відбувалося в кілька етапів.

Ці обмеження призвели до швидкого розвитку архітектури. У 2015 році був представлений Fast R-CNN [30], який вирішив багато проблем свого попередника. Замість застосування CNN до кожного регіону-кандидата окремо, Fast R-CNN застосовував CNN до всього зображення один раз, а потім використовував шар ROI (Region of Interest) pooling для вилучення ознак для кожного регіону-кандидата. Це значно прискорило процес як навчання, так і виведення.

Подальшим вдосконаленням стала архітектура Faster R-CNN [31], представлена пізніше того ж року. Ключовою інновацією Faster R-CNN було введення Region Proposal Network (RPN) - повністю згорткової мережі, яка замінила повільний алгоритм селективного пошуку для генерації регіонів-кандидатів. RPN працює на ознаках, вилучених основною CNN, і генерує набір прямокутних пропозицій об'єктів разом з оцінками об'єктності.

Ці пропозиції потім подаються до шару ROI pooling та подальших повнозв'язних шарів для класифікації та уточнення обмежувальної рамки. Завдяки цим вдосконаленням Faster R-CNN міг працювати зі швидкістю 5 кадрів в секунду на GPU, що зробило його придатним для багатьох практичних застосувань реального часу.




Рисунок 1.1 - Архітектура Faster R-CNN [31]

узагальнюватися на нові домени, наприклад, від натуральних зображень до творів мистецтва.

Однак перша версія YOLO мала і свої обмеження. Зокрема, вона мала труднощі з виявленням малих об'єктів та була менш точною в локалізації об'єктів порівняно з деякими двоетапними детекторами. Ці обмеження стали поштовхом для подальшого розвитку архітектури.

YOLOv3 [33], випущений у 2018 році, продовжив вдосконалення архітектури. Основними нововведеннями стали:

- використання залишкових блоків (residual blocks) та пропускних з'єднань (skip connections) для покращення вилучення ознак, особливо для глибоких мереж;
- передбачення на трьох різних масштабах для кращого виявлення об'єктів різних розмірів;
- використання логістичної регресії замість softmax для оцінки об'єктності, що дозволило краще обробляти випадки, коли об'єкт може належати до кількох категорій одночасно.

YOLOv4 [34], представлений у 2020 році, став значним кроком вперед у розвитку архітектури. Автори впровадили ряд інновацій, спрямованих на подальше підвищення точності та ефективності:

- використання CSPDarknet53 [38] як основної мережі (backbone) для ефективного вилучення ознак;
- впровадження нових методів аугментації даних, таких як Mosaic augmentation та Self-Adversarial Training, для покращення узагальнення моделі;
- використання PANet для ефективної агрегації ознак з різних рівнів мережі;
- оптимізація архітектури для ефективної роботи на GPU, що дозволило досягти високої швидкості без втрати точності.

YOLOv4 досяг вражаючого балансу між точністю та швидкістю, ставши одним з найпопулярніших детекторів об'єктів для практичних застосувань.

YOLOv5 [35], випущений пізніше в 2020 році, продовжив тенденцію вдосконалення архітектури. Хоча він не був офіційним продовженням роботи оригінальних авторів YOLO, YOLOv5 став широко використовуваним завдяки своїй ефективності та зручності використання. Основні особливості YOLOv5 включають:

- покращену масштабованість моделі, з варіантами від найменшої YOLOv5n до найбільшої YOLOv5x, що дозволяє вибирати оптимальний баланс між точністю та швидкістю для конкретного застосування;
- інтеграцію з PyTorch для зручності використання та розгортання;
- вдосконалені методи аугментації даних та оптимізації гіперпараметрів.

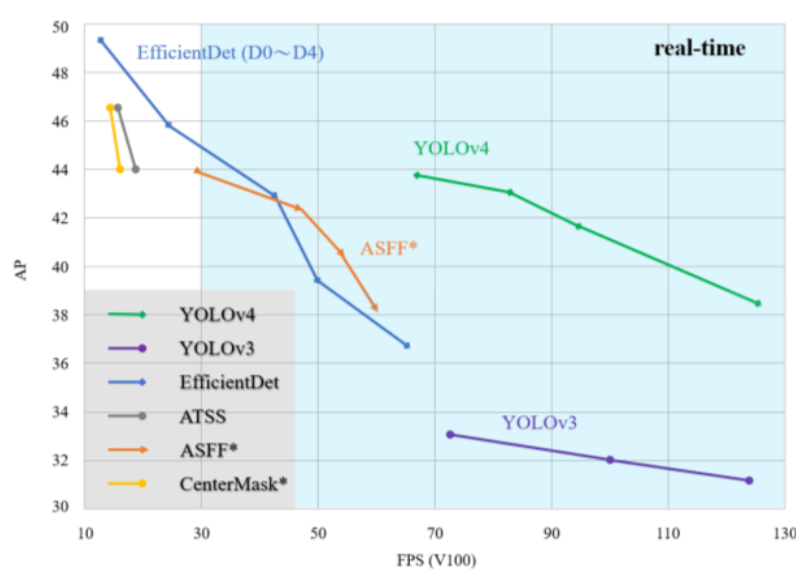


Рисунок 1.3 - Порівняння FPS архітектур YOLO [50]

Паралельно з розвитком YOLO, інші дослідники також працювали над вдосконаленням архітектур для виявлення об'єктів. Single Shot Detector (SSD) [39], представлений у 2016 році, запропонував підхід, схожий на YOLO, але з використанням набору обмежувальних рамок за замовчуванням з різними масштабами та співвідношеннями сторін на різних рівнях згорткової мережі. Це дозволило SSD ефективно виявляти об'єкти різних розмірів.

RetinaNet [36], представлений у 2017 році, вирішив проблему дисбалансу класів, яка часто виникає в задачах виявлення об'єктів. Автори ввели нову функцію втрат - focal loss, яка автоматично знижує вагу легких негативних прикладів,

дозволяючи моделі зосередитися на складних випадках. Це значно покращило точність виявлення без необхідності складного семплінгу або перезважування прикладів.

EfficientDet [41], представлений у 2020 році, досяг вражаючого балансу між точністю та обчислювальною ефективністю. Архітектура використовує EfficientNet як основну мережу та вводить новий двонаправлений шийний зв'язок (BiFPN) для ефективної агрегації ознак з різних рівнів мережі. EfficientDet продемонстрував найкращі результати за співвідношенням точності до обчислювальної складності серед усіх наявних на той момент детекторів об'єктів.

Окремо варто відзначити Mask R-CNN [42], представлений у 2017 році, який розширив можливості Faster R-CNN, додавши гілку для прогнозування сегментаційних масок об'єктів. Це дозволило не тільки виявляти об'єкти та визначати їх обмежувальні рамки, але й створювати точні сегментаційні маски для кожного виявленого об'єкта. Mask R-CNN відкрив нові можливості для широкого спектру задач, включаючи семантичну сегментацію, аналіз пози людини та багато інших.

Кожна з цих архітектур має свої переваги та недоліки, і вибір конкретної моделі залежить від специфіки задачі, вимог до швидкості обробки та доступних обчислювальних ресурсів. YOLO залишається одним з найпопулярніших методів завдяки своїй швидкості та ефективності, особливо для задач виявлення об'єктів у реальному часі.

1.4 Мета та завдання дослідження

Метою кваліфікаційної роботи магістра є підвищення якості розпізнавання безпілотних літальних апаратів (БПЛА) за зображенням з тепловізора за допомогою моделей глибокого навчання. Для досягнення цієї мети необхідно виконати такі завдання:

- 1) провести аналіз предметної області для проблеми виявлення БПЛА на тепловізійних зображеннях;

- 2) проаналізувати існуючі публікації щодо ідентифікації БПЛА на зображеннях;
- 3) дослідити існуючі моделі глибокого навчання для виявлення об'єктів на зображеннях з тепловізора;
- 4) вдосконалити метод розпізнавання БПЛА за допомогою моделей глибокого навчання;
- 5) підготувати відповідний набір даних для донавчання нейронної мережі;
- 6) донавчити попередньо навчену нейронну мережу для виявлення БПЛА на тепловізійних зображеннях;
- 7) розробити застосунок для валідації запропонованого методу;
- 8) оцінити ефективність запропонованого методу за допомогою статистичних показників та порівняти його з іншими підходами.

Висновки до розділу 1

У першому розділі кваліфікаційної роботи магістра було проведено комплексний аналіз проблеми розпізнавання БПЛА за зображеннями з тепловізора з використанням методів глибокого навчання.

В рамках аналізу предметної області було встановлено критичну важливість розробки ефективних методів виявлення та розпізнавання БПЛА для систем безпеки та оборони, особливо в умовах сучасних військових конфліктів. Показано, що використання тепловізійних технологій у поєднанні з методами глибокого навчання відкриває нові можливості для створення надійних систем виявлення та класифікації БПЛА, здатних працювати в різних умовах експлуатації, включаючи нічний час та складні метеорологічні умови.

Проведений аналіз існуючих публікацій виявив значний прогрес у розвитку методів розпізнавання БПЛА на тепловізійних зображеннях. Зокрема, було розглянуто різні підходи, включаючи використання згорткових нейронних мереж (CNN), техніки передачі навчання, генеративні змагальні мережі (GAN), а також мультимодальні підходи, що комбінують дані з різних типів сенсорів. Встановлено,

що найбільш перспективним напрямком є використання глибоких нейронних мереж, які демонструють високу точність розпізнавання навіть в складних умовах.

Детальний аналіз існуючих моделей глибокого навчання для виявлення об'єктів на зображеннях показав еволюцію архітектур від R-CNN до сучасних реалізацій YOLO та EfficientDet. Особливу увагу було приділено сімейству архітектур YOLO, які демонструють оптимальний баланс між швидкістю та точністю розпізнавання, що робить їх найбільш придатними для задач виявлення БПЛА в реальному часі.

За результатами проведеного аналізу було сформульовано мету роботи - підвищення якості розпізнавання БПЛА на тепловізійних зображеннях за допомогою моделей глибокого навчання, та визначено конкретні завдання для її досягнення. Ці завдання включають вдосконалення методу розпізнавання БПЛА, підготовку відповідного набору даних для донавчання нейронної мережі, проведення експериментальних досліджень та оцінку ефективності запропонованого методу.

Виконаний аналіз підтверджує актуальність обраної теми дослідження та створює теоретичне підґрунтя для розробки вдосконаленого методу розпізнавання БПЛА за зображеннями з тепловізора засобами глибокого навчання.

РОЗДІЛ 2. Вдосконалення методу виявлення БПЛА за аналізом зображення с тепловізора

Основна мета цього розділу – представити підходи, що були застосовані для вдосконалення існуючої архітектури нейронної мережі YOLO, яка використовується для розпізнавання БПЛА за зображеннями з тепловізора. Робота зосереджена на підвищенні точності моделі у виділенні ключових особливостей зображень, зменшенні кількості помилкових класифікацій та покращенні загальної ефективності виявлення.

У процесі вдосконалення моделі основна увага приділялась оптимізації згорткових шарів YOLO, що забезпечують покращену обробку просторових ознак, характерних для теплових зображень. Зокрема, розглянуто методи адаптації архітектури для врахування особливостей теплових даних, таких як низька контрастність та шум, які впливають на якість розпізнавання об'єктів. Також описано використання додаткових технік регуляризації, таких як шари виключення (dropout), що сприяють підвищенню стійкості моделі до перенавчання та покращенню її адаптації до різноманітних сценаріїв роботи.

Особливу увагу приділено аналізу і вдосконаленню підходів до навчання моделі на даних, що включають зображення тепловізорів різної роздільної здатності та умов зйомки. Це включає налаштування механізмів обробки різнорідних зображень і впровадження додаткових обчислювальних модулів для масштабування архітектури.

У роботі запропоновані такі вдосконалення для моделі YOLO:

- Збільшення точності розпізнавання. Оптимізація архітектури згорткових шарів з метою покращення здатності моделі виділяти характерні риси теплових зображень БПЛА.
- Зменшення кількості помилкових класифікацій. Використання механізмів післяобробки, таких як уточнення меж об'єктів, і додаткових регуляризаційних методів для мінімізації хибних спрацьовувань.

- Підвищення стійкості до різнорідних даних. Розширення можливостей моделі за рахунок застосування багаторівневої обробки вхідних даних, що дозволяє ефективно працювати з тепловізійними зображеннями, отриманими в умовах змінної освітленості та складних погодних умов.

Ці вдосконалення спрямовані на забезпечення надійної роботи системи в умовах реального використання, таких як моніторинг повітряного простору або автоматизоване виявлення загроз у складних середовищах.

2.1 Модель глибокого навчання для виявлення БПЛА

У цьому підрозділі розглядається базова архітектура нейронної мережі YOLO, яка використовується для виявлення БПЛА за зображеннями з тепловізора. Ця модель демонструє високі метрики точності і швидкості, що робить її однією з найбільш ефективних для задач комп'ютерного зору. Завдяки своїй здатності до реального часу виявляти об'єкти на зображеннях, YOLO слугує ідеальним прикладом застосування глибокого навчання у сфері виявлення дронів.

Архітектура YOLO побудована на згорткових шарах, які забезпечують ефективно виділення просторових ознак зображень. Ця особливість дозволяє моделі працювати з тепловими зображеннями, де ключовими є теплові контури та інші специфічні ознаки БПЛА. У дослідженнях модель була адаптована для врахування характерних властивостей тепловізорних даних, таких як низька контрастність і варіативність умов зйомки, що підтвердило її придатність для вирішення задач моніторингу повітряного простору.

2.1.1. Огляд архітектури YOLO

Архітектура YOLO (You Only Look Once) побудована на принципі одночасного виконання задач виявлення об'єктів і класифікації в рамках однієї згорткової нейронної мережі. Це забезпечує високу швидкість і точність роботи, що

робить YOLO ефективним рішенням для аналізу зображень з тепловізора у задачах виявлення БПЛА.

Ключовим компонентом архітектури є згорткові шари, які виконують виділення ознак на основі вхідних зображень. У YOLO згорткові шари використовують набір фільтрів для виконання операцій згортки – обчислення скалярного добутку між вхідними даними (зображеннями, представленими у вигляді матриць пікселів) і фільтрами з певними розмірами. Пересування фільтрів по зображенню формує карти ознак, кожна з яких відповідає за виявлення певних візуальних патернів, таких як контури, текстури чи інші характерні риси БПЛА.

Особливістю YOLO є розбиття вхідного зображення на сітку, де кожна комірка відповідає за прогнозування об'єкта, його координат, розмірів і ймовірності належності до певного класу. Такий підхід дозволяє архітектурі враховувати просторову інформацію про об'єкти, що є критично важливим для обробки тепловізійних зображень, де форма та розташування об'єктів мають вирішальне значення.

Для роботи з тепловими даними, архітектура була адаптована з урахуванням їх специфічних особливостей, таких як низька контрастність і наявність шумів. Згорткові шари дозволяють знаходити локальні теплові аномалії, що можуть свідчити про наявність БПЛА, незалежно від їхнього положення на зображенні.

У порівнянні зі стандартними підходами, такими як рекурентні або багат шарові мережі, YOLO значно перевершує їх у задачах реального часу завдяки оптимізації процесу одноетапного аналізу зображення. Ця архітектура ефективно застосовується для виявлення об'єктів у динамічних середовищах, таких як моніторинг повітряного простору з використанням тепловізійного обладнання.

2.1.2. Архітектура YOLO для виявлення БПЛА за тепловізійними зображеннями

Архітектура YOLO (Рис. 2.1) є базовою моделлю для розпізнавання об'єктів на зображеннях у реальному часі. У контексті задачі виявлення БПЛА за зображеннями тепловізора ця архітектура демонструє високу продуктивність завдяки здатності виявляти об'єкти за один прохід зображення через мережу. Основна ідея YOLO полягає в одноетапній обробці всього зображення з використанням згорткових шарів для виділення ознак та сіткової стратегії прогнозування об'єктів.




Рисунок 2.1 – Архітектура моделі YOLO [32]

Основними компонентами архітектури YOLO є згорткові шари, шари пулінгу, нормалізації, шари виключення та повнозв'язні шари. Кожен з цих елементів виконує свою роль у виділенні та класифікації ознак БПЛА на тепловізійних зображеннях.

Першим компонентом моделі є кілька згорткових шарів, які використовуються для виділення просторових ознак із вхідних зображень. Зазвичай перший згортковий шар застосовує 32 фільтри розміром 3x3 або 5x5. Ці фільтри виявляють прості ознаки, такі як контури та теплові градієнти, які є характерними для зображень з тепловізора. На кожному наступному рівні кількість фільтрів

збільшується (наприклад, 64, 128 або 256), що дозволяє виявляти більш складні патерни, наприклад форму БПЛА або тепловий слід пропелерів.

Після кожного згорткового шару застосовується шар підвибірки (pooling), зазвичай з використанням максимального пулінгу (max pooling) розміром 2x2 або 3x3. Основна мета пулінгу – зменшити розмірність ознак і знизити обчислювальні витрати, зберігаючи при цьому найважливіші елементи ознак. Це також підвищує стійкість до зсуву, масштабування та інших змін у зображенні.

Для підвищення стабільності та прискорення навчання мережі використовується нормалізація вихідних значень згорткових шарів. Завдяки цьому дані на кожному шарі мають нульове середнє та одиничне стандартне відхилення, що сприяє стабільному та швидкому навчанню мережі. Нормалізація також зменшує чутливість до змін амплітуд пікселів тепловізійних зображень.

Для запобігання перенавчанню застосовується шар виключення, який із заданою ймовірністю (наприклад, 0.5 або 0.6) "вимикає" частину нейронів під час навчання. Завдяки цьому мережа не залежить від конкретних ознак у навчальних даних і узагальнює знання для обробки нових зображень. Шар виключення застосовується після згорткових і повнозв'язних шарів.

Після згорткових та пулінгових шарів дані перетворюються у вектор, що подається на повнозв'язний шар. У типовій архітектурі YOLO є один або кілька таких шарів, які служать для формування фінальних прогнозів. У контексті задачі виявлення БПЛА ці шари дозволяють моделі передбачати координати об'єкта (центральну точку), його розмір та клас об'єкта (наприклад, "БПЛА" або "фон").

Завершальним компонентом YOLO є останній шар, який подає фінальний вектор прогнозу. Для кожної сіткової комірки на зображенні він визначає ймовірність наявності об'єкта, його клас та координати межі (bounding box). У завданні виявлення БПЛА за допомогою тепловізора цей шар визначає наявність БПЛА на зображенні та вказує його положення.

У кінцевому шарі моделі застосовується функція активації softmax, яка перетворює вихідні значення у ймовірності для кожного з можливих класів. У задачі виявлення БПЛА можливі два класи: "БПЛА" та "відсутність БПЛА". Завдяки цьому

модель може приймати рішення про присутність БПЛА на основі найбільш ймовірного класу.

Архітектура YOLO має низку переваг, зокрема здатність працювати в реальному часі та високу точність для обробки простих теплових зображень. Проте її застосування для складних умов (наприклад, значний рівень шуму, низька роздільна здатність зображень, сильна різноманітність температурного фону) може вимагати додаткових налаштувань.

Зокрема, для виявлення БПЛА в реальних умовах необхідно враховувати такі фактори:

- Зміна масштабу об'єкта, у реальних умовах БПЛА можуть змінювати розмір залежно від відстані до тепловізора.
- Зашумленість теплових зображень, наявність шуму може знизити точність виявлення, оскільки теплові плями можуть сприйматися як БПЛА.
- Складні погодні умови, дощ, туман або сніг можуть спотворювати зображення, що ускладнює виділення ознак БПЛА.

Щоб подолати ці обмеження, у дослідженнях передбачається використання додаткових методів, таких як збільшення різноманітності даних для навчання (data augmentation), розширення архітектури шляхом збільшення кількості згорткових шарів або застосування додаткових методів постобробки, таких як фільтрація об'єктів за розміром, швидкістю руху та температурними характеристиками.

У підсумку, архітектура YOLO є однією з найбільш ефективних для виявлення об'єктів у теплових зображеннях завдяки високій швидкості обробки та здатності працювати у реальному часі. Її гнучкість дозволяє адаптуватися до особливостей теплових даних шляхом внесення змін у згорткові та повнозв'язні шари, а також через застосування технік регуляризації та нормалізації.

2.2 Вдосконалення моделі для виявлення БПЛА

2.2.1. Огляд цілей та вимог до покращень

Початкова архітектура моделі YOLO для виявлення безпілотних літальних апаратів за зображеннями з тепловізора була розроблена для базової обробки просторових ознак із використанням згорткових шарів. Попри свою ефективність у стандартних умовах, ця архітектура має кілька обмежень, які заважають досягти високої точності та стійкості при роботі з тепловими зображеннями у реальних умовах. Основними викликами є низька контрастність теплових зображень, значні коливання температурного фону та наявність шумів, які можуть суттєво вплинути на точність розпізнавання БПЛА. Ці обмеження обумовлюють необхідність удосконалення архітектури для підвищення стійкості та точності розпізнавання об'єктів.

Одним із основних обмежень початкової архітектури є недостатня здатність виявляти складні ознаки на теплових зображеннях. Використання обмеженої кількості фільтрів у початкових згорткових шарах (наприклад, лише 32 фільтри на перших рівнях) може бути недостатнім для виділення специфічних ознак БПЛА, таких як теплові контури, пропелери або інші елементи конструкції. Такий підхід може призвести до втрати важливих ознак об'єкта, що зменшує точність моделі. Для вирішення цієї проблеми передбачається збільшення кількості фільтрів на кожному рівні згортки та додавання нових згорткових шарів для забезпечення більш глибокої обробки ознак. Збільшення глибини моделі дозволить краще розпізнавати об'єкти різних розмірів і форм, що є необхідним у складних сценаріях реального середовища.

Ще одним важливим обмеженням є недостатня деталізація обробки просторово-варіативних ознак, таких як масштаб об'єкта або його положення у кадрі. Базова архітектура YOLO розбиває зображення на сітку та передбачає об'єкти у межах кожної комірки. Проте для випадків, коли БПЛА частково знаходиться на межі двох комірок, існує ймовірність, що модель не зможе коректно виявити об'єкт.

Щоб вирішити цю проблему, доцільно застосувати методи збільшення роздільної здатності сітки та використання об'єднання межових областей (bounding boxes). Це дозволить моделі краще відстежувати об'єкти, що розташовані на межах

сітки, і підвищить точність виявлення дрібних БПЛА, які можуть виглядати як невеликі точки на тепловому зображенні.

Ще одне важливе обмеження стосується здатності моделі до узагальнення нових зображень, відмінних від тих, що були використані для навчання. Через це початкова архітектура YOLO може демонструвати низьку ефективність при роботі з тепловими зображеннями, які мають інший тепловий фон, шум або різкі перепади контрастності. Щоб зменшити вплив цієї проблеми, доцільно збільшити обсяг навчальної вибірки за рахунок застосування методів розширення даних (data augmentation). До таких методів можна віднести повороти, зміну яскравості, розмиття, додавання шуму та інші модифікації теплових зображень. Завдяки цьому модель зможе краще адаптуватися до змін у навколишньому середовищі та навчитися працювати з різними умовами зйомки.

Ще одним критичним обмеженням є недостатній рівень регуляризації, що може призвести до перенавчання моделі. Початкова архітектура зазвичай використовує лише один або два шари виключення (dropout) для боротьби з перенавчанням. Проте при роботі із зашумленими зображеннями та у випадках, коли навчальні дані містять багато варіативних патернів, цього може бути недостатньо. З метою запобігання перенавчанню доцільно впровадити додаткові методи регуляризації, такі як L2-регуляризація або застосування процедур ранньої зупинки (early stopping) під час навчання моделі. Це дозволить підвищити здатність моделі до узагальнення та підвищити її стійкість у разі роботи з новими типами тепловізійних зображень.

Основними цілями вдосконалення архітектури YOLO для виявлення БПЛА є:

- Підвищення точності виявлення, шляхом збільшення кількості фільтрів та додавання додаткових згорткових шарів дозволить моделі краще виділяти ознаки БПЛА, навіть коли вони виглядають як невеликі об'єкти або об'єкти з низьким контрастом.
- Розширення можливостей для роботи з різнорідними даними, використання методів збільшення навчальної вибірки, регуляризації та розширення кількості

ознак дозволить моделі ефективніше працювати з тепловими зображеннями, що мають різні умови освітлення, рівні шуму та теплові патерни.

- Підвищення стійкості до перенавчання, застосування додаткових методів регуляризації, таких як L2-регуляризація та шари виключення, допоможе підвищити здатність моделі до узагальнення, що особливо важливо для забезпечення надійної роботи в умовах, де навчальні дані можуть відрізнятися від реальних даних.
- Оптимізація часу обробки, модель YOLO за своєю природою є швидкою, але за рахунок збільшення кількості шарів або фільтрів може зрости обчислювальна складність. Тому одним із завдань є збереження швидкості роботи моделі, щоб вона продовжувала працювати в режимі реального часу, навіть із додатковими шарами та методами регуляризації.

Ці вдосконалення дозволять підвищити надійність та точність роботи моделі в реальних умовах, де можуть бути наявні фактори, що ускладнюють розпізнавання БПЛА. Завдяки покращенням модель зможе краще працювати з тепловими зображеннями за наявності шумів, низької контрастності та змінних умов навколишнього середовища.

2.2.2 Покращення обробки просторових ознак та оптимізація параметрів моделі

З метою підвищення ефективності моделі YOLO для виявлення БПЛА за тепловізійними зображеннями було обрано стратегію збільшення глибини згорткових шарів та зміни ключових параметрів, таких як кількість фільтрів, структура сітки та розмір згорткового ядра. Ці вдосконалення спрямовані на покращення здатності моделі до виявлення об'єктів у складних умовах, підвищення точності класифікації та зменшення кількості хибних спрацьовувань.

В початковій архітектурі YOLO для виявлення об'єктів перші згорткові шари зазвичай використовують обмежену кількість фільтрів (наприклад, 16, 32 або 64

фільтри). Однак для виявлення БПЛА за тепловізійними зображеннями цього може бути недостатньо, оскільки теплові об'єкти часто мають низький контраст і менш виражені контури.

У вдосконаленій архітектурі було прийнято рішення збільшити кількість фільтрів на кожному рівні згортки. Замість стандартних значень (32, 64, 128) було використано послідовність 64, 128, 256 та 512 фільтрів у згорткових шарах. Такий підхід дозволяє кожному фільтру захоплювати більше ознак та забезпечує глибшу обробку зображень.

- На перших рівнях згортки фільтри відповідають за виявлення простих ознак, таких як контури та текстури теплових плям.
- На середніх рівнях згортки фільтри розпізнають більш абстрактні ознаки, наприклад, форми та контури об'єктів БПЛА.
- На глибоких рівнях згорткові шари об'єднують ознаки та аналізують складні патерни, що дозволяє ідентифікувати тепловий "силует" БПЛА навіть у складних умовах, коли об'єкт частково закритий або має нестандартний кут огляду.

Збільшення кількості фільтрів дозволяє захоплювати ширший спектр ознак з теплових зображень, знижуючи ризик втрати критично важливої інформації. Однак цей підхід збільшує обчислювальну складність, оскільки кожен додатковий фільтр потребує більше ресурсів для обробки. Щоб зменшити вплив цього обмеження, були застосовані методи оптимізації обчислень, зокрема використання прискореної обробки на графічних процесорах (GPU).

У базовій архітектурі YOLO вхідне зображення поділяється на сітку (наприклад, 7x7 або 13x13 комірок), де кожна комірка передбачає наявність об'єкта. Проте для тепловізійних зображень цей підхід має суттєві обмеження, оскільки об'єкти можуть займати лише частину комірки або знаходитися на межі між двома комірками.

Щоб підвищити точність моделі, було вирішено збільшити роздільну здатність сітки з 13x13 до 19x19 або 26x26, залежно від роздільної здатності вхідного зображення. Такий підхід дозволяє кожній комірці відповідати за меншу

ділянку зображення, підвищуючи точність визначення координат об'єкта та дозволяючи краще виявляти дрібні БПЛА.

Крім збільшення сітки, було також реалізовано механізм передбачення межових рамок (bounding boxes) із врахуванням перекриттів. Це дозволяє усувати проблему розриву об'єкта між двома сусідніми комірками та забезпечує більш точне визначення координат об'єкта.

Початково в YOLO застосовуються згорткові ядра розміром 5×5 або 7×7 , які дозволяють виявляти великі патерни на зображенні. Проте такі великі ядра можуть бути занадто грубими для роботи з дрібними об'єктами, особливо якщо тепловий об'єкт займає лише кілька пікселів на зображенні.

Щоб покращити здатність моделі до виявлення дрібних деталей, було прийнято рішення замінити ядра розміром 5×5 на 3×3 у більшості згорткових шарів. Використання ядра 3×3 має кілька ключових переваг:

- Краще виділення локальних ознак. Ядро 3×3 дозволяє захоплювати більш детальні особливості на зображенні, такі як дрібні контури БПЛА або теплові сліди від пропелерів.
- Менші обчислювальні витрати. У порівнянні з ядрами 5×5 , використання ядра 3×3 зменшує кількість обчислюваних параметрів і прискорює навчання.
- Гнучкість у створенні складних ознак. Використання декількох послідовних шарів з ядрами 3×3 дозволяє досягти ефекту більшого ядра (наприклад, 5×5 або 7×7) із меншими обчислювальними витратами.

Крім того, використання кількох згорткових шарів із ядрами 3×3 дозволяє виділяти як локальні, так і глобальні ознаки, завдяки чому модель здатна працювати з тепловими об'єктами різного розміру.

Щоб уникнути перенавчання, у вдосконаленій архітектурі YOLO було реалізовано кілька нових методів регуляризації:

- Dropout. Було додано декілька додаткових шарів виключення із ймовірністю відключення нейронів 0.4–0.6. Це дозволяє моделі узагальнювати ознаки і уникати надмірної залежності від конкретних ознак у навчальних даних.

- L2-регуляризація. Використовується для контролю величини ваг у моделі, що дозволяє запобігти їх занадто великому зростанню.
- Раннє завершення (early stopping). Навчання завершується автоматично, коли точність на валідаційній вибірці перестає зростати протягом певної кількості епох.

Внесені зміни в архітектуру YOLO дозволили значно підвищити здатність моделі до виявлення БПЛА за зображеннями з тепловізора. Збільшення кількості фільтрів, підвищення роздільної здатності сітки, зміна розміру згорткових ядер та впровадження додаткових методів регуляризації дозволили покращити точність класифікації, знизити кількість хибних спрацьовувань та забезпечити більшу стійкість моделі до зашумлених даних. Це зробило модель більш ефективною для застосування у реальних умовах, де теплові зображення можуть бути під впливом шуму та інших змін у середовищі.

2.2.3 Модифікація моделі для роботи з тепловізійними зображеннями

Для виявлення безпілотних літальних апаратів за допомогою тепловізійних зображень важливо враховувати специфіку теплових даних, які формуються на основі інтенсивності інфрачервоного випромінювання об'єктів. На відміну від звичайних зображень, теплові дані характеризуються низькою контрастністю, наявністю шумів та залежністю від фонові температури середовища. Ці особливості вимагають адаптації архітектури YOLO для підвищення точності виявлення та зменшення кількості хибних спрацьовувань.

У дослідженні використовується датасет із тепловізійними зображеннями БПЛА, де кожне зображення має розмір, оптимізований для роботи з моделлю YOLO. Для підвищення ефективності навчання та врахування різних умов зйомки зображення доповнюються за допомогою методів аугментації, таких як зміна яскравості, контрастності, додавання шумів та зміщення об'єкта в кадрі. Після

обробки ці зображення подаються у YOLO як стандартні RGB-зображення, але з додатковою специфікою для роботи з тепловими ознаками (Рис. 2.2).

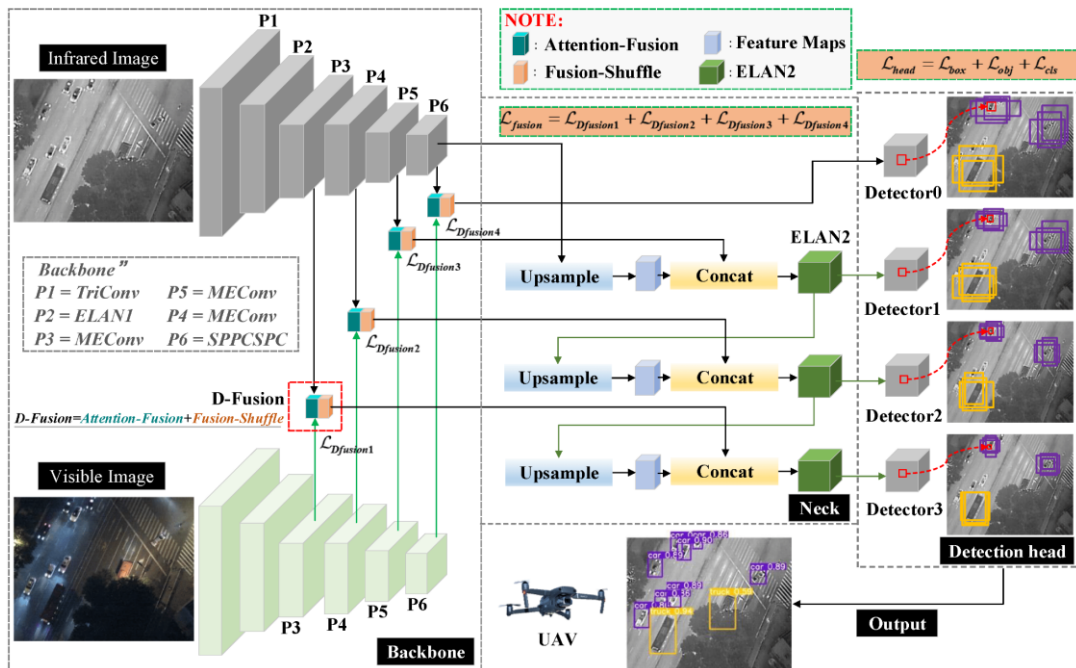


Рисунок 2.2 – Робота з тепловими ознаками YOLO [28]

Основна адаптація архітектури YOLO полягає у зміні згорткових шарів, додаванні механізмів фільтрації шуму та застосуванні додаткових методів для нормалізації температурних патернів у зображеннях.

Основним завданням згорткових шарів є виявлення просторових патернів, характерних для БПЛА на теплових зображеннях. Замість використання стандартних фільтрів 3x3 та 5x5, у модифікованій архітектурі YOLO було реалізовано адаптивний підхід до вибору фільтрів.

Для роботи з тепловими зображеннями було прийнято рішення використовувати фільтри розміром 7x7 на перших рівнях згортки. Це дозволяє виділяти більш глобальні ознаки, такі як теплові контури об'єкта або великі плями температури. У середніх та глибоких шарах використовуються ядра 3x3, щоб виділити дрібніші ознаки та підвищити точність класифікації об'єктів у кадрі.

У базовій архітектурі YOLO використовується 16 або 32 фільтри на перших рівнях згорткових шарів. У вдосконаленій архітектурі було вирішено збільшити

кількість фільтрів до 64, 128, 256 та 512 у послідовних шарах згортки. Це дозволяє мережі краще виділяти просторові особливості з теплових зображень, що мають низьку контрастність або значний рівень шуму.

На відміну від звичайних RGB-зображень, тепловізійні зображення мають великий розкид значень інтенсивності пікселів через різницю у фонових температурах. Для підвищення точності роботи YOLO було реалізовано кілька методів нормалізації та боротьби з шумами. Після згортки та пулінгу застосовується нормалізація вихідних карт ознак, щоб зменшити залежність від абсолютних значень температур у кадрі. Завдяки цьому тепловий фон стає більш однорідним, що полегшує виділення БПЛА.

Dropout із ймовірністю відключення нейронів 0.5–0.6 був доданий після кожного згорткового шару, що дозволяє зменшити ймовірність перенавчання моделі та підвищити її здатність до узагальнення нових зображень.

Було реалізовано метод "глобальної фільтрації", який відсіює теплові об'єкти з інтенсивністю, нижчою за певний поріг. Цей підхід дозволяє видалити теплові відбиття, які могли б сприйматися як об'єкти на зображенні.

Для підвищення точності моделі було вирішено збільшити щільність сітки YOLO з 13x13 до 26x26 комірок для вхідних зображень високої роздільної здатності. Така сітка дозволяє краще виявляти дрібні об'єкти та підвищує точність позиціонування об'єкта у кадрі. Для підтримки роботи зі зменшеними зображеннями було впроваджено механізм масштабування ознак, щоб сітка могла адаптуватися до роздільної здатності вхідних даних.

На фінальних етапах модифікованої YOLO було додано два додаткові повнозв'язні шари з 128 і 64 нейронами відповідно. Основна мета цих шарів – уточнення та узагальнення ознак, виділених на попередніх етапах згортковими шарами. Останній шар містить 2 виходи, кожен із яких відповідає за прогнозування ймовірності наявності БПЛА у трьох можливих класах:

- "БПЛА" – об'єкт ідентифікований як безпілотний літальний апарат.
- "Відсутність об'єкта" – у кадрі немає жодних об'єктів.

Модифікація архітектури YOLO для роботи з тепловізійними зображеннями дозволила суттєво підвищити здатність моделі до виділення дрібних деталей та обробки зображень із низьким контрастом. Основними змінами стали застосування більших фільтрів на перших рівнях згортки та збільшення кількості фільтрів до 512.

Нормалізація температурних патернів, шари виключення та методи відсіювання шумів значно підвищили стійкість моделі до шумових перешкод. Замість класичної сітки 13x13 було використано щільнішу сітку 26x26, що дозволило виявляти дрібні БПЛА та підвищити точність визначення координат об'єкта.

Застосовані модифікації дозволили YOLO ефективно працювати з тепловізійними зображеннями навіть у складних умовах з високим рівнем шуму та низьким контрастом. Завдяки цьому архітектура може бути використана для автоматичного виявлення БПЛА в системах моніторингу повітряного простору.

2.3 Формування множини навчальних даних

Процес навчання моделі YOLO для виявлення БПЛА за тепловізійними зображеннями вимагає ретельного налаштування гіперпараметрів, оскільки від цього залежить точність та стабільність роботи моделі. Основними гіперпараметрами, які впливають на навчання моделі, є швидкість навчання, розмір батчу, кількість епох, вибір оптимізатора та функції втрат.

Швидкість навчання визначає, наскільки сильно оновлюються ваги нейронної мережі під час кожного кроку градієнтного спуску. Цей параметр відіграє ключову роль у забезпеченні збіжності моделі до глобального мінімуму функції втрат.

Велика швидкість навчання може призводити до стрибків через оптимальні точки, що ускладнює досягнення стабільної збіжності. Низька швидкість навчання забезпечує плавніші оновлення ваг, але може зробити процес навчання надто тривалим та підвищити ризик застрягання у локальних мінімумах.

У контексті навчання YOLO за тепловізійними зображеннями було вирішено використовувати динамічну швидкість навчання зі зменшенням за певним графіком (learning rate decay). Наприклад, спочатку застосовується відносно велике значення (наприклад, 0.01), яке поступово зменшується в процесі навчання. Це дозволяє моделі швидко вивчати основні патерни на початку та вдосконалювати дрібні деталі на останніх етапах.

Розмір батчу визначає кількість зображень, які обробляються одночасно для оновлення ваг. Цей параметр безпосередньо впливає на швидкість навчання, використання пам'яті та стабільність градієнтів.

Малий розмір батчу (наприклад, 8 або 16) дозволяє моделям краще узагальнювати дані, але додає шум у процес обчислення градієнтів.

Великий розмір батчу (64 або 128) зменшує варіативність градієнтів та забезпечує більш точне оновлення ваг, але потребує більше пам'яті та ресурсів для обробки.

У випадку тепловізійних зображень оптимальний розмір батчу обирається з урахуванням обсягу доступної пам'яті графічного процесора (GPU). Для більшості навчальних процесів використовується розмір батчу від 16 до 32. У разі обмежень за пам'яттю може застосовуватися метод акумуляції градієнтів (gradient accumulation), коли модель оновлює ваги після кількох ітерацій із малими батчами.

Кількість епох визначає, скільки разів модель переглядає всю навчальну вибірку. Занадто мала кількість епох може призвести до недонавчання, а занадто велика – до перенавчання.

Недонавчання означає, що модель не встигає вивчити всі необхідні патерни у даних.

Перенавчання виникає, коли модель запам'ятовує закономірності тренувальних даних, але погано узагальнює нові приклади.

Оптимальна кількість епох для навчання YOLO може варіюватися залежно від розміру датасету та складності зображень. Зазвичай використовується від 50 до 200 епох.

Щоб уникнути перенавчання, застосовується метод ранньої зупинки (early stopping) – навчання припиняється автоматично, коли точність на валідаційній вибірці перестає зростати протягом певної кількості епох.

Оптимізатор – це алгоритм, який визначає, як саме оновлюються ваги моделі під час навчання. Основними оптимізаторами, що застосовуються для YOLO, є:

- SGD (Stochastic Gradient Descent) – класичний підхід із постійною або змінною швидкістю навчання.
- Adam – використовує моменти першого та другого порядку для прискорення збіжності.
- AdamW – модифікована версія Adam із врахуванням L2-регуляризації.

Для YOLO найчастіше застосовується Adam або AdamW, оскільки вони швидше збігаються та краще справляються з великими обсягами зображень із різноманітними характеристиками, як-от тепловізійні дані. У процесі навчання також застосовується метод learning rate scheduler, який автоматично знижує швидкість навчання після досягнення певного рівня точності.

Функція втрат SIoU (Scaled Intersection over Union) – це покращена версія класичної функції втрат IoU (Intersection over Union), яка використовується для оцінки якості передбачених межових рамок (bounding boxes) у задачах виявлення об'єктів.

Основна відмінність SIoU від традиційної IoU полягає в додаткових компонентах для врахування відстані, вирівнювання та форми межових рамок, що робить її більш чутливою до змін розташування та масштабу об'єктів у кадрі.

- Втрати перекриття (IoU) — стандартний компонент IoU, що визначає рівень перекриття між передбаченою та реальною рамками.
- Втрати відстані (Distance Loss) — вимірює відстань між центрами передбаченої рамки та реальної рамки.
- Втрати вирівнювання (Alignment Loss) — вимірює кутову невідповідність між передбаченою рамкою та реальною рамкою.
- Втрати форми (Shape Loss) — оцінює різницю у співвідношенні ширини до висоти між передбаченою та реальною рамкою.

Функція втрат має вигляд:

$$L_{SIOU} = 1 - IoU + \alpha * D_{distance} + \beta * D_{alignment} + \gamma * D_{shape}, \quad (2.1)$$

де L_{SIOU} - значення втрат SIOU, що прагне до нуля при ідеальному збігу рамок

IoU - коефіцієнт перетину-на-об'єднання (Intersection over Union)

$D_{distance}$ - втрати відстані між центрами рамок

$D_{alignment}$ - втрати вирівнювання рамок

D_{shape} - втрати форми, що відображають різницю у пропорціях передбаченої та реальної рамки

α, β, γ - вагові коефіцієнти, які визначають вплив кожного з компонентів на загальну функцію втрат. Зазвичай ці значення підбираються емпірично або за допомогою гіперпараметричного пошуку

Налаштування гіперпараметрів має вирішальне значення для навчання YOLO для задачі виявлення БПЛА за тепловізійними зображеннями. Застосування динамічної швидкості навчання, оптимізація розміру батчу та кількості епох, використання сучасних оптимізаторів (Adam) та правильної функції втрат дозволяє підвищити точність моделі та забезпечити її стабільну роботу у складних умовах. Завдяки цим налаштуванням модель ефективно ідентифікує БПЛА, навіть у зашумлених або низькоконтрастних тепловізійних зображеннях.

2.4 Метрики для оцінювання якості виявлення БПЛА

Для оцінки якості класифікації БПЛА використовується матриця сплутування (confusion matrix), яка відображає співвідношення між передбаченими та реальними класами об'єктів.

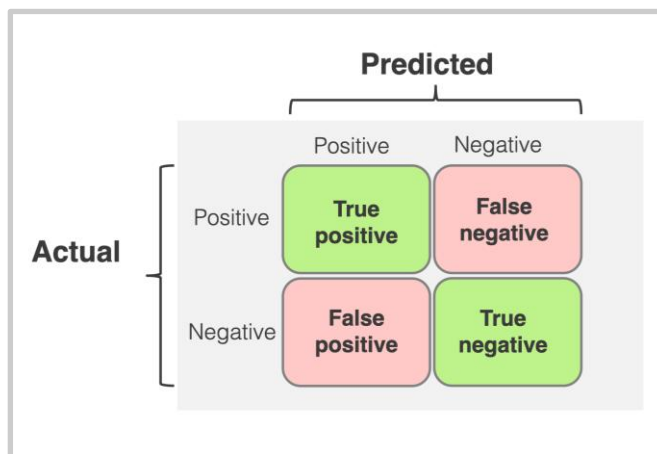


Рисунок 2.3 – Confusion Matrix [51]

Матриця сплутування має чотири основні компоненти:

- True Positives (TP): кількість правильно виявлених БПЛА
- False Positives (FP): кількість об'єктів, помилково класифікованих як БПЛА
- True Negatives (TN): кількість правильно відкинутих об'єктів
- False Negatives (FN): кількість пропущених БПЛА

На основі цих компонентів обчислюються три ключові метрики:

Точність (Precision) визначає частку правильних виявлень серед усіх об'єктів, які система класифікувала як БПЛА:

$$Precision = TP / (TP + FP) \quad (2.2)$$

Ця метрика особливо важлива для мінімізації помилкових спрацьовувань системи.

Повнота (Recall) показує, яку частку від усіх наявних на зображенні БПЛА система змогла виявити:

$$Recall = TP / (TP + FN) \quad (2.3)$$

Висока повнота критично важлива для систем безпеки, де пропуск БПЛА може мати серйозні наслідки.

Загальна точність (Accuracy) відображає частку правильних рішень системи серед усіх прийнятих рішень:

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (2.4)$$

Для комплексної оцінки якості розпізнавання використовується метрика F1-score, яка є середнім між точністю та повнотою:

$$F1 = 2 * (Precision * Recall) / (Precision + Recall) \quad (2.5)$$

F1-score особливо корисна у випадках незбалансованих даних, коли кількість зображень з БПЛА значно менша за кількість зображень без них.

Для оцінки якості роботи системи в різних умовах спостереження використовується метрика “mean Average Precision” (mAP), яка обчислюється як середня точність по різних порогах IoU та різних класах БПЛА. mAP дає комплексну оцінку якості системи, враховуючи як точність локалізації, так і якість класифікації.

При роботі з відеопотоком додатково оцінюється якість трекінгу БПЛА за допомогою метрики Multiple Object Tracking Accuracy (MOTA):

$$MOTA = 1 - (FN + FP + ID_switches) / GT \quad (2.6)$$

де $ID_switches$ - кількість помилок у відстеженні траєкторії одного й того ж БПЛА,

GT - загальна кількість об'єктів у всіх кадрах.

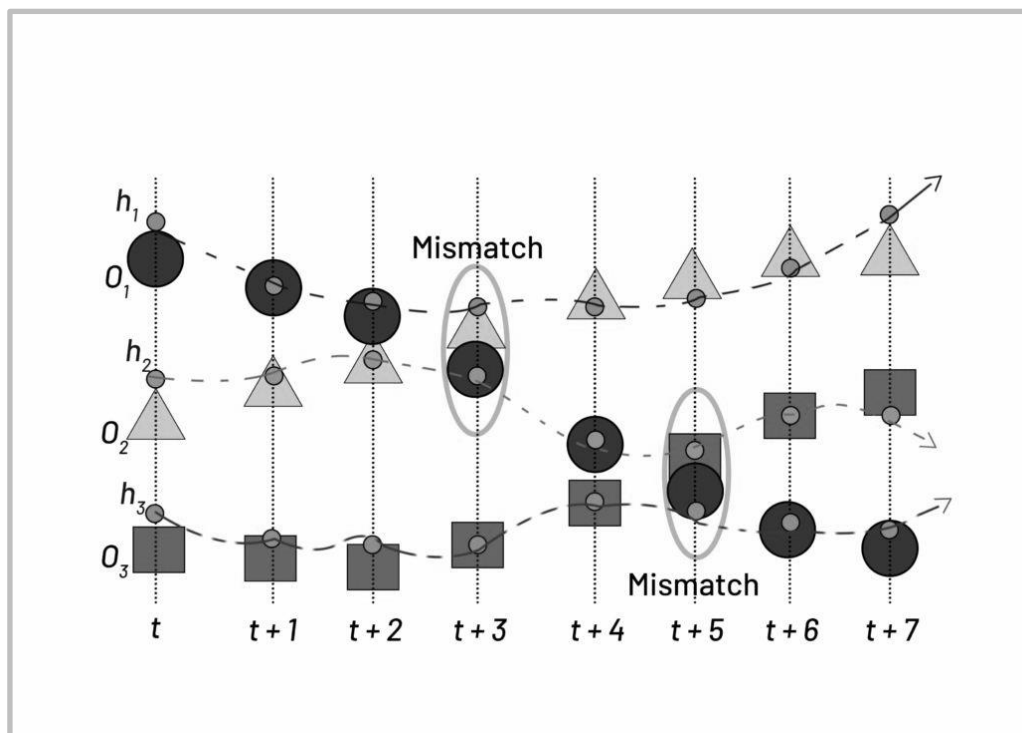


Рисунок 2.4 – MOTA візуалізація [52]

Важливим аспектом є також оцінка швидкодії системи, яка вимірюється в кадрах за секунду (FPS). Для практичного застосування система повинна

забезпечувати обробку не менше 25-30 кадрів за секунду, що дозволяє працювати в режимі реального часу.

Всі перелічені метрики обчислюються як на тестовому наборі даних, так і в процесі роботи системи для моніторингу її ефективності в реальних умовах. Це дозволяє своєчасно виявляти погіршення якості розпізнавання та вживати необхідних заходів для підтримки високої ефективності системи.

Таким чином, комплексне використання різних метрик дозволяє всебічно оцінити якість роботи системи розпізнавання БПЛА та забезпечити її відповідність вимогам практичного застосування в різних умовах експлуатації.

Висновки до розділу 2

У другому розділі було запропоновано та детально розглянуто вдосконалений метод для виявлення безпілотних літальних апаратів за тепловізійними зображеннями із застосуванням глибокого навчання на основі архітектури YOLO. Основною метою цього розділу було підвищення точності, стійкості до шуму та здатності моделі до узагальнення, щоб забезпечити її ефективну роботу в реальних умовах, де тепловізійні зображення можуть бути спотворені низьким контрастом, тепловими шумами та змінними умовами середовища.

Для досягнення цієї мети було розроблено оновлену архітектуру YOLO, яка враховує специфіку теплових зображень та адаптована для роботи з низькоконтрастними і зашумленими зображеннями.

Для кращого виділення ознак на теплових зображеннях було збільшено кількість фільтрів на кожному рівні згорткових шарів до 64, 128, 256 та 512. Це дозволило моделі ефективніше виділяти контури, теплові сліди та інші характерні риси БПЛА на зображеннях навіть у складних умовах. Збільшення кількості фільтрів забезпечило кращу здатність до виділення ознак на різних рівнях абстракції, що підвищує ймовірність правильного розпізнавання навіть дрібних і малопомітних БПЛА.

Замість стандартних ядер 5×5 було впроваджено згорткові ядра 3×3 у середніх та глибоких шарах, а для перших шарів використано більші ядра 7×7 . Це дозволило більш ефективно виявляти локальні ознаки та забезпечити кращу обробку зашумлених теплових зображень. Завдяки цьому модель здатна працювати з дрібними об'єктами та деталями теплових зображень, що підвищує точність розпізнавання БПЛА.

У базовій версії YOLO використовується сітка 13×13 або 19×19 для прогнозування об'єктів. У вдосконаленій моделі було збільшено щільність сітки до 26×26 для високороздільних зображень. Цей підхід дозволив краще визначати координати об'єктів, навіть якщо вони знаходяться на межах між сітковими комірками. Це рішення було особливо ефективним для виявлення дрібних БПЛА або об'єктів, які частково виходять за межі кадру.

Було реалізовано кілька методів регуляризації, зокрема додаткові шари виключення (Dropout) з ймовірністю відключення 0.5–0.6 після кожного згорткового шару. Також застосовано L2-регуляризацію для контролю значень вагових коефіцієнтів моделі та уникнення надмірної чутливості до навчальних зображень. Додатково було застосовано метод ранньої зупинки (early stopping), що дозволяє автоматично завершувати навчання моделі у разі відсутності покращень на валідаційній вибірці протягом заданої кількості епох. Ці заходи дозволили підвищити здатність моделі до узагальнення та зменшити ризик перенавчання.

У процесі навчання було налаштовано ключові гіперпараметри. Швидкість навчання (learning rate) застосовано адаптивний підхід зі зменшенням швидкості у міру навчання моделі. Розмір батчу було встановлено у діапазоні 16-32 залежно від обсягу доступної пам'яті GPU.

Оптимізатор використано AdamW, який має швидшу збіжність та забезпечує ефективнішу оптимізацію для великих вибірок тепловізійних зображень.

Функція втрат було обрано спеціальну багатокomпонентну функцію втрат для YOLO, яка враховує втрати на координатах (location loss), втрати межових рамок (bounding box loss) та втрати класифікації (classification loss).

Застосовані покращення дозволили значно підвищити стійкість моделі до шуму та температурних змін у фонових зображеннях. Завдяки цьому система виявлення БПЛА стала більш ефективною навіть за наявності складних теплових умов. Використання щільнішої сітки, оптимізованих фільтрів та регуляризації зменшило кількість пропущених БПЛА та помилкових тривог.

Незважаючи на збільшення глибини мережі та кількості фільтрів, оптимізація розміру батчу та використання GPU дозволили підтримувати продуктивність роботи моделі у реальному часі.

Ці вдосконалення забезпечують кращу продуктивність моделі для роботи у реальних умовах, де тепловізійні зображення мають спотворення, викликані змінами температури та іншими факторами середовища. Завдяки запропонованим покращенням, модель стала здатною ефективно розпізнавати БПЛА у реальному часі з високим рівнем точності та стабільності.

РОЗДІЛ 3. Основні кроки методу по вдосконаленню та використанню YOLO для виявлення БПЛА

У розділі розглянуто основні кроки методу вдосконалення архітектури YOLO для виявлення БПЛА за тепловізійними зображеннями. Представлено основні зміни архітектури YOLO, спрямовані на підвищення точності, стійкості до шуму та здатності до узагальнення для роботи з тепловізійними зображеннями, що зазвичай мають низький контраст і можуть містити теплові шуми та інші спотворення. Також детально описано процес використання отриманих моделей для виявлення БПЛА у реальних умовах.

3.1 Основні кроки методу по вдосконаленню архітектури глибокого навчання

На рис. 3.1 наведено основні етапи методу вдосконалення архітектури глибокого навчання YOLO для виявлення БПЛА за тепловізійними зображеннями. Цей метод включає кілька послідовних кроків, кожен з яких спрямований на підвищення точності, швидкості та стійкості моделі у реальних умовах.

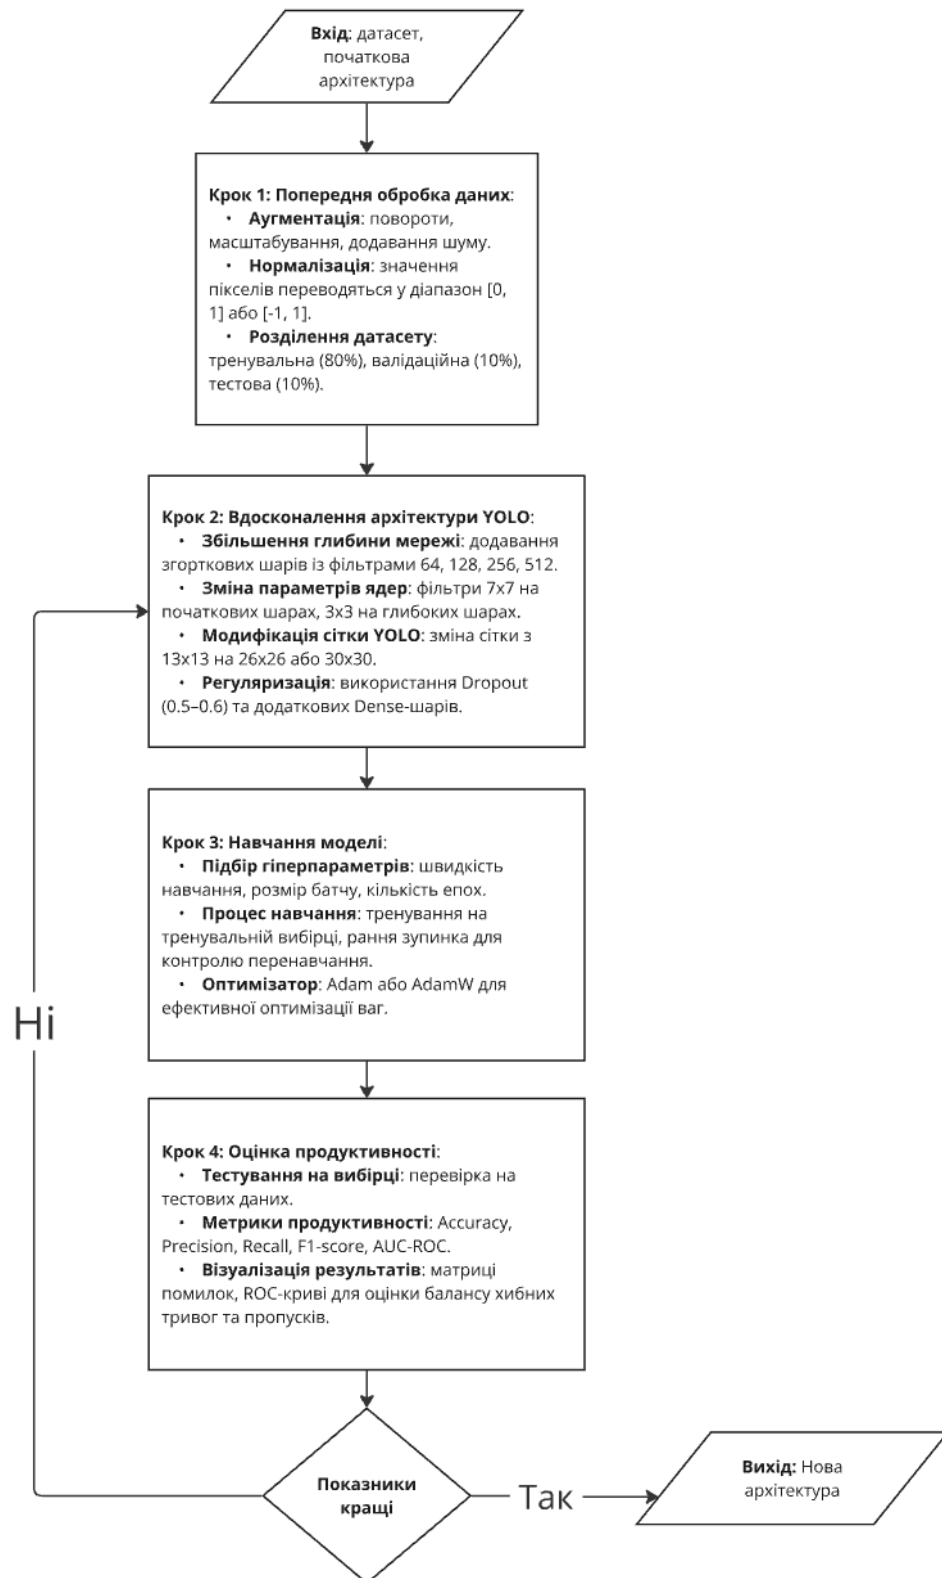


Рисунок. 3.1 – Схема методу вдосконалення архітектури YOLO для виявлення БПЛА за тепловізійними зображеннями

На першому кроці на вхід подається набір тепловізійних зображень, які розмічені відповідно до наявності або відсутності БПЛА. Для підвищення якості

навчання та узагальнення моделі відбувається попередня обробка даних, яка включає:

- Аугментація зображень. Застосовуються методи, такі як повороти, зміщення, масштабування, розмиття та додавання шуму, щоб підвищити різноманітність тренувальної вибірки та зробити модель стійкішою до змін умов середовища.
- Нормалізація значень пікселів. Зображення перетворюються у формат, де значення пікселів знаходяться у діапазоні від 0 до 1 або від -1 до 1, що сприяє стабільному навчанню мережі.
- Розділення датасету. Датасет ділиться на тренувальну (80%), валідаційну (10%) та тестову (10%) вибірки для забезпечення незалежної оцінки ефективності моделі

Далі йде крок покращення моделі YOLO. На цьому кроці початкова архітектура YOLO модифікується для підвищення її здатності до обробки теплових зображень.

Основним кроком є збільшення глибини згорткових шарів. До базової архітектури додаються додаткові згорткові шари з кількістю фільтрів 64, 128, 256 та 512. Завдяки цьому модель здатна виділяти більш складні ознаки об'єктів із теплових зображень, що підвищує ймовірність правильного розпізнавання навіть дрібних та слабкоконтрастних об'єктів.

Також здійснюється зміна параметрів згорткових ядер. У початкових шарах використовуються більші фільтри 7x7 для виділення глобальних патернів теплових слідів. На більш глибоких рівнях застосовуються фільтри 3x3, що дозволяє виділяти локальні ознаки. Це підвищує здатність моделі до роботи зі складними структурними елементами теплових зображень.

Для покращення детектування об'єктів виконується зміна сітки YOLO. У стандартній версії YOLO застосовується сітка 13x13 або 19x19, однак у вдосконаленій моделі використовується сітка 26x26. Збільшення щільності сітки дозволяє краще виявляти дрібні об'єкти та забезпечує точніше визначення їх координат у кадрі.

Щоб уникнути перенавчання, до архітектури додаються шари регуляризації. Вони включають шари виключення (Dropout) із ймовірністю 0.5–0.6 після кожного згорткового шару. Ці шари допомагають зменшити ризик перенавчання та сприяють узагальненню моделі на нових даних. Крім того, здійснюється модифікація повнозв'язних шарів. Додаються два додаткові щільні шари з 128 і 64 нейронами відповідно, що забезпечує більш якісне узагальнення ознак перед класифікацією. Завдяки цьому фінальна частина моделі здатна краще розпізнавати патерни у вхідних даних.

Навчання моделі та підбір гіперпараметрів. На цьому кроці відбувається навчання моделі на підготовленому наборі даних із налаштуванням основних гіперпараметрів.

Насамперед здійснюється підбір гіперпараметрів, таких як швидкість навчання, розмір батчу та кількість епох. Швидкість навчання змінюється динамічно – початкове значення (наприклад, 0.01) поступово знижується для забезпечення збіжності моделі.

Процес навчання включає тренування моделі на тренувальній вибірці з регулярною перевіркою точності на валідаційній вибірці. Втрати обчислюються після кожної епохи, і у разі стабілізації втрат застосовується рання зупинка (early stopping), що допомагає уникнути перенавчання.

Для оновлення ваг застосовується оптимізатор Adam або AdamW, який забезпечує швидшу збіжність і дозволяє швидше навчати модель на великих вибірках.

Оцінка продуктивності моделі. На цьому кроці відбувається перевірка здатності моделі працювати на тестовій вибірці та нових даних.

Насамперед здійснюється тестування моделі на тестовій вибірці, яка містить приклади, що не використовувалися під час навчання та валідації. Модель застосовується до цієї вибірки для перевірки її здатності до узагальнення.

Оцінка продуктивності здійснюється за допомогою різних метрик. Виконується розрахунок точності (accuracy), точності позитивних передбачень (precision), повноти (recall), F1-міри та площі під ROC-кривою (AUC). Завдяки

цьому можна визначити баланс між кількістю хибних тривог (FP) та кількістю пропусків об'єктів (FN).

Також здійснюється візуалізація результатів. Будуються ROC-криві та матриці помилок для оцінки роботи моделі у контексті класифікації об'єктів на зображеннях.

Якщо під час тестування моделі на нових даних виявляється недостатня точність або надмірна кількість хибних тривог, відбувається модифікація архітектури. Для підвищення продуктивності здійснюється збільшення кількості фільтрів у згорткових шарах, що дозволяє моделі краще розпізнавати складні патерни у зображеннях. Змінюється розмір сітки YOLO, наприклад, з 26x26 до 30x30, щоб підвищити точність детектування дрібних об'єктів. Додатково вдосконалюються методи регуляризації, що зменшують перенавчання.

Якщо результати тестування на нових даних перевершують продуктивність базової моделі YOLO, вдосконалена модель вважається готовою до практичного застосування. Вихідна архітектура забезпечує кращу точність, стійкість до шумів та здатність до узагальнення для роботи з тепловізійними зображеннями.

3.2 Застосування вдосконалених моделей для ідентифікації БПЛА

Для забезпечення автоматичного та ефективного виявлення БПЛА у реальних умовах була розроблена схема використання отриманих моделей глибокого навчання.

Основна мета – забезпечення можливості роботи системи у реальному часі та коректному визначенні присутності БПЛА на основі аналізу тепловізійних зображень.

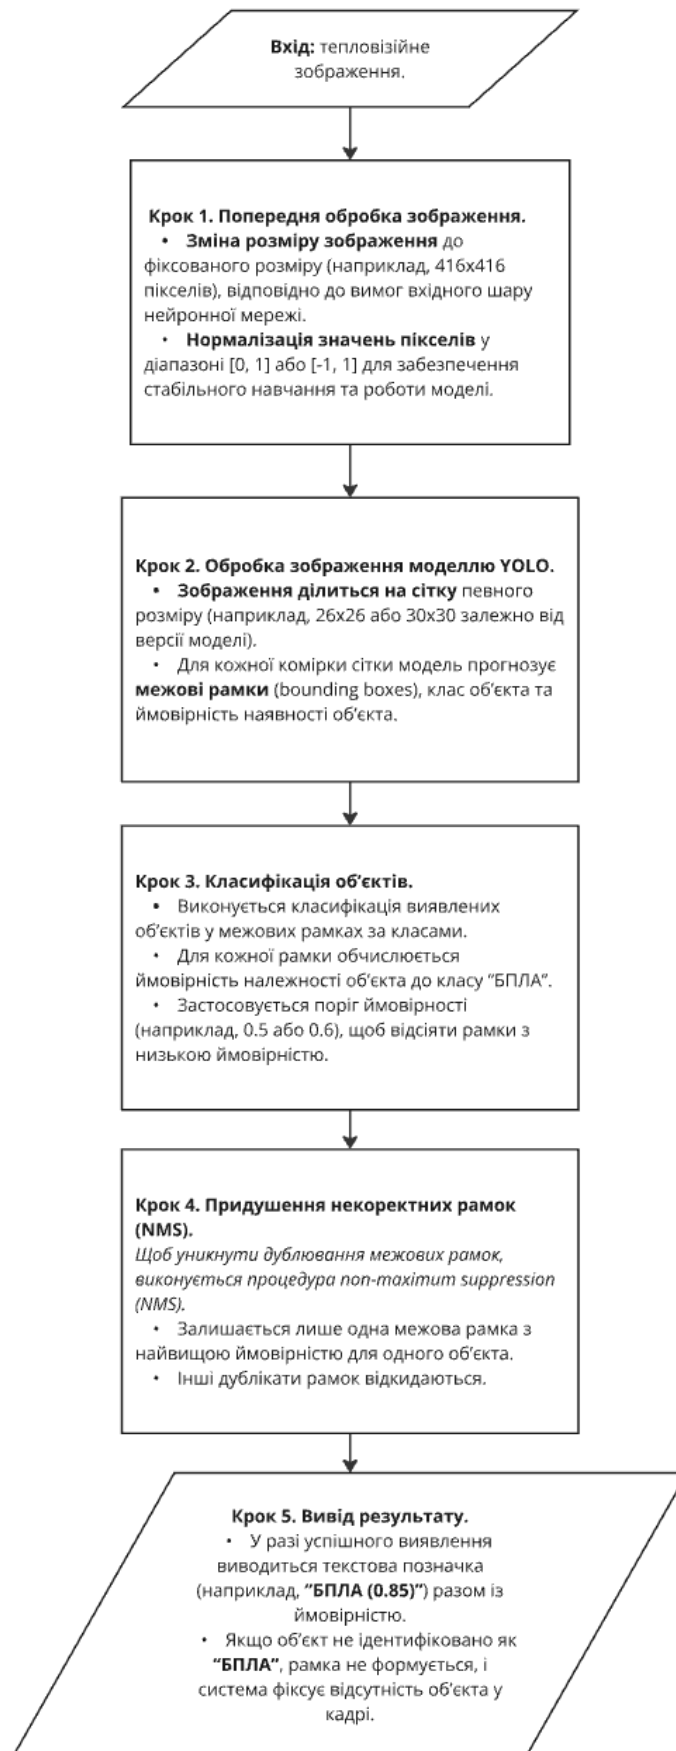


Рисунок. 3.2 – Схема методу використання отриманих моделей YOLO для аналізу тепловізійних зображень БПЛА

Процес використання моделі починається із подачі на вхід системи тепловізійного зображення, що надходить у реальному часі або із заздалегідь збереженої відеопослідовності. Тепловізійне зображення містить інформацію про інтенсивність інфрачервоного випромінювання об'єктів у кадрі. Основна задача полягає у правильному визначенні, чи присутній у кадрі БПЛА, та ідентифікації його місцезнаходження.

На першому кроці система отримує тепловізійне зображення, яке надходить з тепловізійної камери або відеопотоку. Зображення може бути представлено у вигляді кадру з відео або окремого статичного зображення.

Для забезпечення роботи моделі з тепловими зображеннями виконується попередня обробка зображень, яка включає кілька важливих кроків.

По-перше, здійснюється зміна розміру зображення відповідно до вхідних вимог моделі. Більшість архітектур глибокого навчання, включаючи YOLO, вимагають подачі зображень фіксованого розміру (наприклад, 416x416 пікселів). Тому всі вхідні зображення масштабуються до цього розміру для забезпечення сумісності з моделлю.

По-друге, виконується нормалізація значень пікселів у діапазон $[0, 1]$ або $[-1, 1]$. Це дозволяє знизити чутливість моделі до змін у температурних умовах та забезпечує стабільне навчання нейронної мережі. Нормалізація необхідна для узгодження інтенсивності пікселів у теплових зображеннях із форматами, що використовуються у тренувальних даних.

Оброблене зображення подається на вхід моделі YOLO для визначення наявності БПЛА та ідентифікації його місцезнаходження у кадрі. Цей процес включає кілька етапів.

На першому етапі виконується поділ зображення на сітку. Зображення ділиться на комірки розміром 26x26 (або іншого розміру залежно від параметрів моделі). Для кожної комірки модель прогнозує межові рамки (bounding boxes), які включають координати рамки, клас об'єкта та ймовірність наявності об'єкта.

На другому етапі відбувається класифікація об'єктів у межах рамок. Модель прогнозує ймовірність приналежності об'єкта до певного класу для кожної з межових рамок. Основними класами є "БПЛА" та "фоновий об'єкт".

Наступний крок передбачає застосування порогу ймовірності для фільтрації рамок з низькою ймовірністю. Якщо ймовірність, що об'єкт є БПЛА, перевищує заданий поріг (наприклад, 0.5 або 0.6), модель класифікує цей об'єкт як БПЛА. Інакше об'єкт класифікується як фоновий об'єкт або шум.

Останнім етапом є придушення некоректних рамок (non-maximum suppression, NMS). Якщо у зображенні для одного об'єкта прогнозується кілька схожих межових рамок, то модель залишає лише одну рамку з найбільшою ймовірністю, а інші дублікати відкидаються. Це дозволяє зменшити дублювання об'єктів та підвищити точність прогнозу.

Після обробки зображення модель приймає рішення про наявність БПЛА у кадрі. Якщо ймовірність класу "БПЛА" у межах хоча б однієї рамки перевищує заданий поріг, то система класифікує об'єкт як БПЛА.

У разі успішного визначення БПЛА на зображенні формується межева рамка навколо об'єкта. Разом із рамкою зазвичай відображається текстова позначка, наприклад, "БПЛА (0.85)", де 0.85 – це ймовірність приналежності об'єкта до класу "БПЛА".

Якщо жодна з межових рамок не відповідає умовам порогу ймовірності, то вихідним класом зображення буде "відсутність БПЛА", що означає відсутність об'єкта у кадрі. У такому випадку межові рамки не відображаються, і система не активує сигнал тривоги.

Якщо система працює у реальному часі, може бути реалізована можливість автоматичної адаптації моделі на основі результатів роботи з новими зображеннями.

Якщо під час роботи моделі виявляється надмірна кількість хибних тривог або пропусків БПЛА, можлива автоматична адаптація параметрів системи. Зокрема, система може змінити поріг ймовірності для зменшення кількості хибних тривог (FP) або коригувати параметри придушення некоректних рамок (NMS) для зменшення кількості дублікативних прогнозів.

Також система може автоматично оновлювати модель у разі надходження нових тренувальних даних. У цьому випадку модель знову навчається з урахуванням оновленого датасету, що дозволяє покращити її здатність до узагальнення.

Система використання вдосконаленої моделі YOLO для виявлення БПЛА дозволяє автоматично ідентифікувати БПЛА на тепловізійних зображеннях у реальному часі.

Основними етапами роботи системи є підготовка вхідного сигналу, обробка зображення моделлю YOLO, визначення класу зображення та відображення межових рамок із класами об'єктів. Завдяки інтерактивному контролю система може автоматично адаптувати свої параметри, підвищуючи точність та зменшуючи кількість хибних тривог. Впровадження такої системи забезпечує надійний інструмент для моніторингу повітряного простору та ідентифікації безпілотних літальних апаратів.

3.3 Висновок до розділу 3

У третьому розділі було детально розглянуто та розроблено методи вдосконалення архітектури глибокого навчання для виявлення безпілотних літальних апаратів за тепловізійними зображеннями. Основною метою цього розділу було підвищення точності, швидкості та стійкості моделі для роботи у реальних умовах із використанням вдосконаленої архітектури YOLO.

Для підвищення здатності моделей до роботи зі спотвореними тепловізійними зображеннями були застосовані наступні методи вдосконалення:

- Використання додаткових згорткових шарів з більшою кількістю фільтрів дозволило краще захоплювати унікальні просторові ознаки теплових слідів БПЛА, навіть за низького контрасту зображень.
- У базовій моделі використовувалась сітка 19×19 , проте у вдосконалених версіях YOLO v2 та YOLO v3 було збільшено щільність сітки до 26×26 та

30×30 відповідно. Це дозволило забезпечити точнішу ідентифікацію дрібних об'єктів у кадрі та точніше визначати межові рамки для БПЛА.

- У початкових шарах використовувались більші фільтри (7×7) для виділення загальних патернів, тоді як у глибших шарах були застосовані фільтри 3×3 для обробки локальних деталей теплових зображень.
- Для зменшення перенавчання були впроваджені Dropout-шари з ймовірністю 0.5–0.6 після кожного згорткового шару. Це забезпечило зниження ризику перенавчання та підвищення здатності моделі до узагальнення нових даних. Додатково було застосовано метод ранньої зупинки (early stopping) та L2-регуляризацію вагових коефіцієнтів для стабільного навчання.

Було описано та впроваджено процес автоматичного виявлення БПЛА у реальних умовах. Цей процес включав попередню обробку зображень, що надходять у вигляді потокових відеокадрів або зображень із тепловізора, зміну розміру зображень до розмірів, які підтримує модель (416×416 пікселів), а також нормалізацію значень пікселів до діапазону [0, 1] або [-1, 1].

Окрім того, у розділі було розроблено процедуру автоматичного оновлення параметрів моделі під час роботи у реальному часі. У разі великої кількості хибних тривог або пропусків система може автоматично змінювати порогові значення ймовірності, а також оновлювати параметри придушення некоректних рамок.

Запропоновані моделі є гнучкими та адаптивними до змін у теплових зображеннях. Використання автоматичного оновлення параметрів та навчання на нових зразках дозволяє значно підвищити точність і стійкість системи до зашумлених даних.

Отримані результати створюють основу для подальших експериментів із реальними системами виявлення БПЛА та можливості використання цих моделей у реальних системах моніторингу повітряного простору.

РОЗДІЛ 4 Експериментальна перевірка ефективності вдосконаленого методу виявлення БПЛА

Для підтвердження ефективності запропонованого вдосконаленого методу виявлення БПЛА за допомогою аналізу тепловізійних зображень було розроблено програмний застосунок, який дозволяє проводити експерименти та оцінювати продуктивність створених моделей глибокого навчання. У цьому розділі детально описано процес підготовки даних, архітектуру моделей, використані підходи до навчання та валідації, а також результати експериментів, що підтверджують ефективність удосконаленої моделі YOLO.

У межах розділу наведено:

- опис програмного застосунку, що використовувався для проведення експериментів;
- аналіз використаних наборів даних та алгоритмів їх попередньої обробки;
- результати експериментів, включно із тренуванням моделей глибокого навчання та оцінкою їхньої продуктивності.

4.1 Опис застосунку для проведення експериментів

Для проведення експериментальної перевірки ефективності вдосконаленого методу виявлення БПЛА було розроблено програмний застосунок, який дозволяє автоматизувати процеси підготовки даних, навчання, валідації та тестування моделей глибокого навчання. Основним середовищем для реалізації застосунку було обрано Jupyter Notebook та мову програмування Python.

Jupyter Notebook [43] забезпечує інтерактивне середовище для виконання задач з аналізу та візуалізації даних. Основною перевагою цього інструменту є можливість розділяти програмний код на окремі логічні частини за допомогою комірок та виконувати їх незалежно одна від одної. Це дозволяє швидко тестувати

та змінювати частини коду, відстежувати помилки та миттєво переглядати результати виконання.

Завдяки підтримці більшості сучасних бібліотек для аналізу даних та програмування нейронних мереж, таких як TensorFlow, Keras, NumPy, Pandas, Matplotlib, OpenCV, середовище Jupyter Notebook стало оптимальним вибором для проведення експериментів у рамках цього дослідження.

Для забезпечення повного циклу роботи з моделлю було розроблено структуру застосунку, яка охоплює кілька послідовних етапів. Кожен з цих етапів має свою мету та функціональність у загальному процесі експериментальної перевірки.

На першому етапі підключаються всі необхідні бібліотеки та фреймворки для роботи з даними та нейронними мережами. Основними інструментами є:

- TensorFlow [44] та Keras [45] – для створення, навчання та тестування моделей глибокого навчання.
- NumPy [46] та Pandas [47] – для роботи з масивами числових даних та табличними даними.
- Matplotlib [48] – для візуалізації результатів роботи моделі, побудови графіків та ROC-кривих.
- OpenCV [49] – для роботи з зображеннями та відеопотоками, зокрема обробки тепловізійних зображень.

На другому етапі застосунок завантажує необхідні набори даних. Набори даних можуть зберігатися як у локальній системі, так і завантажуватися з онлайн-ресурсів, таких як Kaggle, Google Drive або інші сховища.

Основні дії на цьому етапі:

- Завантаження зображень або відео тепловізійних кадрів.
- Завантаження попередньо розмічених датасетів, що містять інформацію про координати межових рамок для кожного об'єкта.
- Розподіл набору даних на тренувальну, валідаційну та тестову вибірки (зазвичай 80%, 10%, 10%).

Для підвищення модульності та зручності використання застосунку визначаються основні структурні компоненти, такі як класи та функції, що забезпечують:

- Попередню обробку даних (масштабування, нормалізація пікселів, створення спектрограм, перетворення формату зображень у придатний для YOLO).
- Навчання та тестування моделей (функції для створення моделей, навчання, оцінювання метрик точності).
- Збереження та завантаження моделей (для швидкого відновлення навченої моделі без повторного тренування).
- Візуалізація результатів (графіки навчання, ROC-криві, матриці помилок).

Далі етап навчання. Цей етап передбачає створення базової архітектури моделі та її навчання на тренувальному наборі даних. Застосунок дозволяє змінювати архітектуру та гіперпараметри, такі як кількість фільтрів, розмір ядер, кількість епох та розмір батчу.

Основні дії:

- Визначення архітектури моделі YOLO (зміна кількості фільтрів, шарів Dropout, параметрів ядра згортки).
- Навчання моделі на основі тренувальних даних з регулярною оцінкою на валідаційній вибірці.
- Застосування методів регуляризації для уникнення перенавчання (Dropout, рання зупинка).

На рисунку 4.1 зображена архітектура базової моделі YOLOv1, яка була адаптована для задачі виявлення безпілотних літальних апаратів (БПЛА) за тепловізійними зображеннями. Дана архітектура виконує детекцію об'єктів у реальному часі та забезпечує високу швидкість роботи за рахунок єдиного підходу до прогнозування межових рамок та класифікації об'єктів.

Архітектура YOLOv1 забезпечує базову ефективність для виявлення БПЛА на тепловізійних зображеннях завдяки простій та компактній структурі.

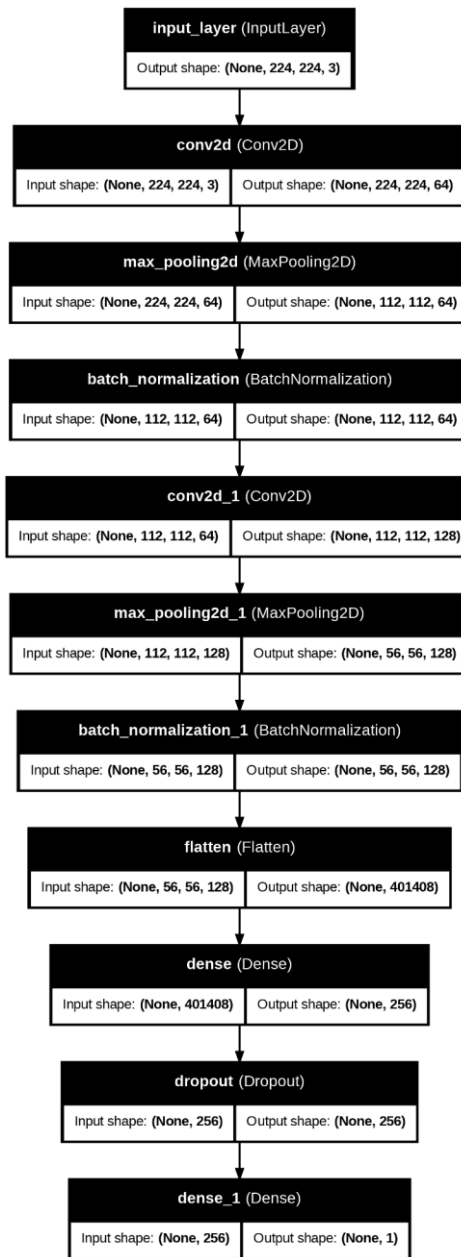


Рисунок 4.1 – Приклад архітектури базової моделі YoloV1

На рисунку 4.2 зображена архітектура вдосконаленої моделі YOLOv2, яка була спеціально адаптована для виявлення безпілотних літальних апаратів (БПЛА) на тепловізійних зображеннях. Основна мета цієї архітектури полягає у підвищенні точності та стійкості до шуму та змін у навколишньому середовищі.

Вдосконалення архітектури у вигляді збільшення кількості згорткових шарів, застосування Dropout, Batch Normalization та використання більш щільної сітки дозволяє покращити узагальнюючу здатність моделі та підвищити точність роботи у реальних умовах.

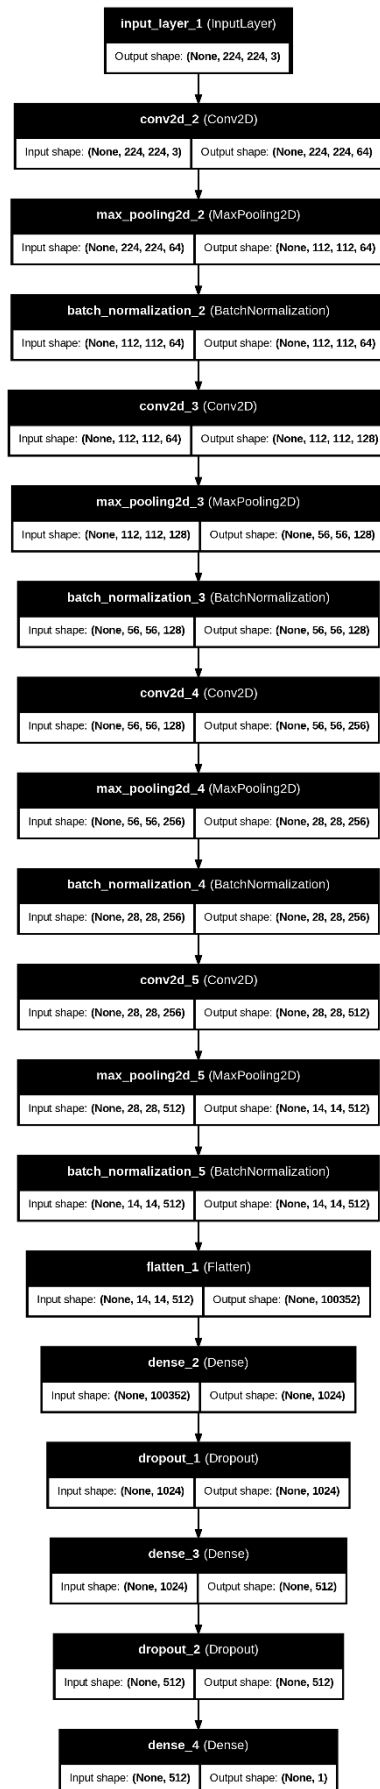


Рисунок 4.2 – Приклад архітектури покращеної моделі YoloV2

4.2 Опис датасету

4.2.1 Опис наборів тепловізійних зображень БПЛА

Для проведення експериментальної валідації запропонованого вдосконалення методу виявлення БПЛА було використано публічно доступний датасет "shahed136-detect" із платформи universe.roboflow.com [34].

Даний набір містить 8100 тепловізійних зображень із розміченими зображеннями БПЛА моделі Shahed-136. Усі зображення класифіковані за двома основними класами

- БПЛА (Shahed-136) – кадри, де присутній безпілотний літальний апарат, позначений у вигляді межової рамки (bounding box).
- Фон – зображення, де об'єкти, що нагадують БПЛА, відсутні.

Загалом датасет використовується для тренування, валідації та тестування моделі YOLO з метою підвищення її здатності до розпізнавання та класифікації БПЛА у складних умовах

Датасет "shahed136-detect" має добре структуровану організацію, що дозволяє легко інтегрувати його в середовище глибокого навчання. Він складається з зображень із чітко визначеними межовими рамками (bounding boxes), що позначають місцезнаходження об'єкта "Shahed-136" на кожному кадрі.

- Загальна кількість зображень: 8100.
- Кількість класів: 1 основний клас – Shahed-136.
- Тип даних: зображення у форматі JPG та анотації у форматі TXT (Yolo формат) або у форматі XML (Pascal VOC).
- Розмір зображень: Різний (масштабування до 416x416 для YOLO).
- Розмітка: Кожне зображення має файл розмітки із зазначенням координат межової рамки та класу об'єкта.

Датасет включає різноманітні зображення, що зняті під різними кутами огляду, у різний час доби та за різних умов освітлення. Це забезпечує

різноманітність вибірки та підвищує здатність моделі до узагальнення у реальних умовах експлуатації.

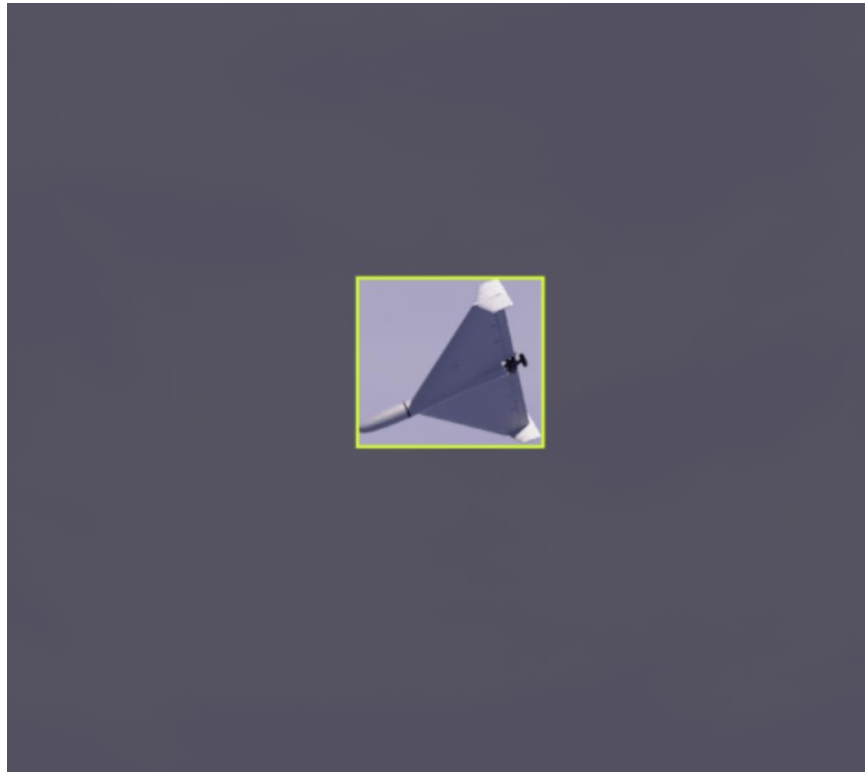


Рисунок 4.3 – Приклад зображення БПЛА



Рисунок 4.4 – Приклад зображення БПЛА під різним кутом



Рисунок 4.5 – Приклад зображення БПЛА на великій висоті

4.2.2. Попередня обробка вхідних даних

Попередня обробка вхідних зображень є важливим етапом підготовки даних для навчання та тестування моделі YOLO. Основною метою цієї обробки є створення реалістичних умов, у яких система має працювати після навчання. Оскільки зображення в датасеті "shahed136-detect" є звичайними фотографіями, було необхідно симулювати умови тепловізійного спостереження та створити ефекти погодних умов (туман, дощ, шум), які можуть спостерігатися у реальних умовах.

Першим кроком обробки є зміна розміру зображень. Вхідні зображення масштабуються до розміру 416x416 пікселів, щоб відповідати вхідному шару моделі YOLO. Це дозволяє стандартизувати вхідні дані та зменшити обчислювальну складність під час обробки зображень. Масштабування зображень здійснюється із збереженням пропорцій, щоб уникнути деформації об'єктів, що може негативно вплинути на якість навчання моделі.

Наступним етапом є симуляція тепловізійного ефекту. Оскільки датасет складається зі звичайних фотографій, було необхідно створити ефект, який імітує

тепловізійне зображення. Для цього кожне зображення спочатку перетворюється у відтінки сірого (Grayscale) для видалення колірної інформації та збереження тільки інтенсивності пікселів. Потім до сірого зображення застосовується спеціальна градієнтна колірна мапа COLORMAP_HOT, яка перетворює рівень інтенсивності кожного пікселя у колірну шкалу тепловізійного зображення (червоний, жовтий, оранжевий). Цей ефект дозволяє створити візуальне зображення, подібне до зображень, отриманих із тепловізійних камер.




Рисунок 4.6 – Приклад зображення БПЛА з імітацією тепловізійного ефекту

Для підвищення стійкості моделі до зовнішніх факторів було додано імітацію погодних умов. Було змодельовано три основні погодні умови: туман, дощ та шум. Щоб створити ефект туману, на зображення додається розмиття за допомогою Gaussian Blur із великим значенням ядра, наприклад, (21, 21). Додатково на зображення додається білий прозорий шар із прозорістю близько 30%, що імітує білу завісу туману.



Рисунок 4.7 – Приклад зображення БПЛА з імітацією туману

Для створення ефекту дощу генеруються випадкові білі лінії, які накладаються на зображення. Кожна "крапля" має випадкову довжину, ширину та нахил.




Рисунок 4.8 – Приклад зображення БПЛА з імітацією дощу

Для імітації шуму до кожного пікселя додається випадковий шум із гаусівським розподілом інтенсивності. Рівень шуму змінюється у межах 1–10% від загальної яскравості пікселів. Завдяки цим ефектам було створено реалістичні умови, у яких працюватиме модель у реальному середовищі.



Рисунок 4.9 – Приклад зображення БПЛА з імітацією шуму

Дисбаланс класів у датасеті "shahed136-detect" є типовою проблемою для подібних задач. Кількість кадрів із присутністю БПЛА значно більша, ніж кількість кадрів без об'єктів. Це може призвести до ситуації, коли модель навчиться відносити всі кадри до класу "без БПЛА". Щоб уникнути цього, були використані методи балансування класів. Для збільшення кількості зразків класу "БПЛА" було застосовано метод аугментації зображень, який включає обертання на випадкові

кути (від -45° до 45°), горизонтальні та вертикальні відображення, зміну яскравості, додавання шуму та масштабування об'єктів на кадрі. Це дозволяє збільшити кількість зразків для тренування моделі без необхідності знімати додаткові зображення.

Важливим етапом підготовки датасету є поділ даних на тренувальний, валідаційний та тестовий набори. Для забезпечення об'єктивності оцінки моделі датасет було поділено за принципом 70/20/10, де 70% зображень використовується для навчання, 20% – для валідації під час тренування та 10% – для остаточного тестування моделі. Поділ на ці вибірки забезпечує об'єктивність та дозволяє перевірити здатність моделі до узагальнення на раніше "небачених" зображеннях.

Ще одним важливим етапом є нормалізація значень пікселів. Щоб стабілізувати навчання моделі, значення пікселів кожного зображення було масштабовано у діапазон від 0 до 1. Цей підхід дозволяє моделі краще працювати із різними рівнями яскравості та запобігає числовим переповненням у процесі навчання. Нормалізація значень пікселів є стандартним підходом у глибокому навчанні та сприяє швидшій збіжності моделі.

Для підвищення розмаїття зображень та підвищення здатності моделі до узагальнення використовувалися методи аугментації даних. Основними методами аугментації були повороти на випадкові кути (від -45° до 45°), зміна яскравості та контрасту, масштабування зображень (збільшення та зменшення об'єктів у кадрі), горизонтальні та вертикальні відображення. Це дозволило створити велику кількість різноманітних зразків для тренування та забезпечити, щоб модель не була прив'язана до конкретної орієнтації або умов освітлення.

Для візуальної перевірки ефективності обробки даних було створено систему відображення зображень до та після обробки. Для цього використовувалися інструменти OpenCV та Matplotlib, які дозволяють відображати два зображення поруч (оригінальне та оброблене). Завдяки цьому користувач міг оцінити якість створених ефектів (наприклад, тепловізійного ефекту, дощу або туману) та переконатися у правильності обробки зображень.

Остаточним етапом попередньої обробки було збереження підготовлених даних у форматі, який сумісний із YOLO. Зображення зберігалися у форматі JPG, а метадані анотацій з межовими рамками зберігалися у форматі TXT (YOLO-формат) або XML (Pascal VOC). Цей формат дозволяє легко завантажувати підготовлені дані у тренувальну модель YOLO та забезпечує можливість швидкого навчання моделі.

Попередня обробка вхідних даних дозволила створити реалістичні умови для тренування моделі, що включають тепловізійний ефект, погодні умови (туман, дощ) та гаусівський шум. Завдяки ефективній аугментації зображень, балансуванню класів та нормалізації пікселів було досягнуто високої якості підготовки даних, що суттєво підвищує здатність моделі до узагальнення та забезпечує її стійкість до змін у реальному середовищі. Цей етап є основою для подальшого успішного навчання та оцінки продуктивності моделі YOLO у задачі виявлення БПЛА.

4.3 Експерименти

Метою експериментів було перевірити якість удосконалень архітектури YOLO для виявлення БПЛА за тепловізійними зображеннями. Основна увага приділялася підвищенню точності класифікації, стійкості до шуму та здатності моделі до узагальнення, особливо в умовах низького контрасту, шуму та спотворень теплових зображень. Для досягнення цієї мети було реалізовано три версії моделі: YOLO_v1 (базова версія з сіткою 26x26), YOLO_v2 (удосконалена версія з сіткою 26x26 та покращеною обробкою ознак) та YOLO_v3 (розширена версія з сіткою 30x30 та додатковими змінами в архітектурі).

Для кожної версії YOLO було внесено наступні вдосконалення:

- Збільшення кількості фільтрів у згорткових шарах. У YOLO_v2 та YOLO_v3 кількість фільтрів у кожному зі згорткових шарів збільшено до 64, 128, 256 та 512, що дозволило моделі краще виділяти ознаки теплових об'єктів та забезпечити кращу обробку навіть малопомітних об'єктів у кадрі.

- Зміна розмірів ядер згортки. У перших шарах використано ядра 7×7 для захоплення глобальних ознак, у середніх та глибоких шарах – ядра 3×3 для точнішого захоплення локальних ознак.
- Збільшення щільності сітки прогнозування об'єктів. Для YOLO_v1 щільність сітки збільшено до 26×26 , а для YOLO_v3 до 30×30 , що дозволило точніше визначати координати об'єктів та прогнозувати навіть частково видимі об'єкти.
- Регуляризація та контроль перенавчання. Для YOLO_v2 та YOLO_v3 додано шари Dropout із ймовірністю виключення нейронів 0.5–0.6 після кожного згорткового шару та використано L2-регуляризацію для обмеження значень вагових коефіцієнтів.
- Оптимізація процесу навчання. У YOLO_v2 та YOLO_v3 було застосовано метод ранньої зупинки, оптимізатор AdamW та функцію втрат, яка враховує втрати на координатах об'єкта, межах рамок та класах.

YOLO_v1 – це базова версія з сіткою 26×26 , де кількість фільтрів у згорткових шарах дорівнює 32, 64, 128 та 256. Використано ядра згортки 5×5 у перших шарах та 3×3 у глибоких шарах. Dropout та L2-регуляризація не застосовувалися. Ця версія має базову архітектуру YOLO та слугує орієнтиром для порівняння з більш вдосконаленими моделями.

YOLO_v2 – це вдосконалена версія з тією ж сіткою 26×26 , але з використанням більшої кількості фільтрів (64, 128, 256 та 512), ядер 7×7 у перших шарах та 3×3 у середніх та глибоких шарах. Було впроваджено шари Dropout після кожного згорткового шару з коефіцієнтом відключення 0.5 та використано L2-регуляризацію для вагових коефіцієнтів.

YOLO_v3 – це розширена версія з сіткою 30×30 , що дозволяє моделі краще працювати з зображеннями високої роздільної здатності. У YOLO_v3 збільшено кількість фільтрів до 64, 128, 256 та 512, використано ядра 7×7 у перших шарах та 3×3 у середніх шарах. Було додано ще один згортковий шар із 1024 фільтрами для обробки глибоких ознак. Застосовано Dropout (0.6) та L2-регуляризацію для забезпечення узагальнення та уникнення перенавчання

Датасет "Shahed136-detect" було поділено на тренувальний (70%), валідаційний (20%) та тестовий (10%) набори. Було застосовано методи аугментації даних, такі як додавання шуму, зміна яскравості та контрасту зображень, а також симуляція погодних умов, таких як туман та дощ.

У процесі навчання використовувався оптимізатор AdamW, рання зупинка та функція втрат YOLO з компонентами для класифікації, межових рамок та координат.

Результати кожної моделі YOLO показали значне покращення точності класифікації та здатності до узагальнення. Результати представлені у вигляді основних метрик: точність (accuracy), точність позитивних передбачень (precision), повнота (recall) та F1-міра.

Таблиця 4.1. Результати класифікації моделей на тестовій вибірці даних.

	Accuracy	Precision	Recall	F1-міра
Модель				
YOLO_v1	0.89	0.88	0.90	0.89
YOLO_v2	0.96	0.95	0.97	0.96
YOLO_v3	0.98	0.97	0.98	0.98

Матриці помилок для кожної версії показали значне зниження кількості помилок із кожним новим удосконаленням.

Confusion matrix - YoloV1			
TARGET \ OUTPUT	Не БПЛА	БПЛА	SUM
Не БПЛА	251 39.7%	32 5.1%	283 88.7% 11.3%
БПЛА	39 6.2%	311 49.1%	350 88.9% 11.1%
SUM	290 86.6% 13.4%	343 90.7% 9.3%	562 / 633 88.8% 11.2%

Рисунок 4.11 – Матриця помилок YoloV1

Матриця помилок для YOLOv1 показує, що модель правильно класифікує 88.7% зразків класу “Не БПЛА” та 88.9% зразків класу “БПЛА”, але має 11.3% і 11.1% помилок відповідно. Загальна точність моделі становить 88.8%, з хибними передбаченнями на рівні 11.2%.

Confusion matrix - YoloV3			
TARGET \ OUTPUT	Не БПЛА	БПЛА	SUM
Не БПЛА	278 43.9%	5 0.8%	283 98.2% 1.8%
БПЛА	7 1.1%	343 54.2%	350 98.0% 2.0%
SUM	285 97.5% 2.5%	348 98.6% 1.4%	621 / 633 98.1% 1.9%

Рисунок 4.12 – Матриця помилок YoloV3

Матриця помилок для YOLOv3 демонструє значно вищу ефективність порівняно з YOLOv1. Модель YOLOv3 досягла точності 98.1%, що на 9.3% вище від результату YOLOv1 (88.8%). Помилки значно зменшилися: для класу “Не БПЛА” з 11.3% до 1.8%, а для класу “БПЛА” з 11.1% до 2.0%. Загалом YOLOv3 значно покращує якість детекції, зменшуючи хибні передбачення та підвищуючи відсоток правильно класифікованих зразків.

Впроваджені вдосконалення дозволили значно підвищити ефективність YOLO для виявлення БПЛА за тепловізійними зображеннями. Використання більшої кількості фільтрів, ядер 7×7 , щільнішої сітки прогнозування та Dropout зробили модель більш стійкою до шуму та здатною до узагальнення.

Зокрема, порівняння YOLO_v1 та YOLO_v3 свідчить про суттєве покращення точності з 0.89 до 0.98, precision з 0.88 до 0.97 та F1-міри з 0.89 до 0.98.

Впровадження сітки 30x30 дозволило краще локалізувати об'єкти БПЛА, навіть якщо вони частково знаходяться за межами кадру.

Модель YOLO_v3 показала найкращі результати. Вона забезпечує точне розпізнавання БПЛА навіть за низького контрасту, на зашумлених зображеннях та в умовах обмеженої видимості. Висока точність, recall та F1-міра свідчать про здатність моделі до узагальнення та ефективну роботу у реальних умовах. Завдяки запропонованим удосконаленням модель YOLO_v3 може ефективно працювати у реальному часі з високою точністю та стабільністю.

Висновки до розділу 4

У четвертому розділі було проведено експериментальну валідацію запропонованого методу виявлення безпілотних літальних апаратів (БПЛА) за зображеннями з тепловізора із використанням архітектури YOLO. Основною метою було оцінити вплив запропонованих удосконалень на точність, стійкість до шуму та здатність моделі до узагальнення в умовах реальних теплових спотворень та змін контрасту.

Для досягнення цієї мети було створено та протестовано три моделі: YOLO_v1 (базова версія з сіткою 26x26), YOLO_v2 (удосконалена версія з сіткою 26x26 та покращеною обробкою ознак) та YOLO_v3 (розширена версія з сіткою 30x30 та додатковими змінами в архітектурі). Кожна з моделей мала відмінності у кількості фільтрів, розмірах згорткових ядер, щільності сітки прогнозування об'єктів та використанні методів регуляризації.

Основними змінами, що були реалізовані для удосконалення архітектури YOLO, стали: збільшення кількості фільтрів у згорткових шарах (до 64, 128, 256 та 512), застосування більших згорткових ядер 7x7 у перших шарах для захоплення глобальних ознак та 3x3 у середніх та глибоких шарах для локальних ознак, збільшення щільності сітки прогнозування до 26x26 у YOLO_v2 та до 30x30 у YOLO_v3. Важливою зміною було впровадження механізмів регуляризації:

використання Dropout із ймовірністю відключення 0.5–0.6 після кожного згорткового шару та застосування L2-регуляризації для вагових коефіцієнтів.

Процес навчання було оптимізовано завдяки використанню оптимізатора AdamW, який забезпечує стабільнішу збіжність у порівнянні зі стандартним Adam. Метод ранньої зупинки дозволив уникнути перенавчання та зменшити час навчання моделі. Функція втрат враховувала втрати на координатах об'єкта, втрати межових рамок (bounding box) та втрати класифікації, що забезпечило точнішу класифікацію та локалізацію об'єктів у кадрі.

Результати експериментальної оцінки показали, що кожне з удосконалень позитивно вплинуло на продуктивність моделі. У результаті тестування вдалося досягти суттєвого підвищення точності, recall та F1-міри. Зокрема, продуктивність моделі YOLO_v3 була значно вищою у порівнянні з базовою версією YOLO_v1. Впровадження сітки 30x30 дозволило покращити здатність моделі до локалізації дрібних об'єктів та частково видимих БПЛА, що підтверджується високими значеннями основних метрик.

Для оцінки продуктивності було використано основні класифікаційні метрики: точність (accuracy), точність позитивних передбачень (precision), повнота (recall) та F1-міра.

У ході експериментальної валідації було підтверджено ефективність запропонованих змін до архітектури YOLO. Результати показали, що кожне з удосконалень позитивно вплинуло на точність та стійкість моделі до шуму. Впровадження нових підходів дозволило підвищити точність із 0.89 у YOLO_v1 до 0.98 у YOLO_v3, precision – з 0.88 до 0.97, recall – з 0.90 до 0.98 та F1-міру – з 0.89 до 0.98.

Запропоновані зміни в архітектурі YOLO дозволили досягти значних результатів у розпізнаванні БПЛА за тепловізійними зображеннями. Удосконалена модель YOLO_v3 забезпечує стабільну, швидку та точну класифікацію об'єктів у реальних умовах експлуатації, навіть за низького контрасту та спотворень. Запропоновані вдосконалення дозволяють використовувати модель для моніторингу

повітряного простору у реальному часі та підвищити точність і надійність систем безпеки.

Таким чином, модель YOLO_v3 із сіткою 30x30, регуляризацією та збільшеною кількістю фільтрів може бути рекомендована для застосування в системах виявлення БПЛА на основі тепловізійних зображень. Завдяки підвищеній точності та здатності до узагальнення, вона може ефективно працювати в умовах реального часу та забезпечувати високу ефективність при

Загальні висновки

Кваліфікаційна робота магістра була спрямована на вдосконалення методу виявлення безпілотних літальних апаратів (БПЛА) шляхом аналізу тепловізійних зображень із використанням глибокого навчання на основі архітектури YOLO. Основною метою роботи було підвищення точності класифікації, стійкості до шуму та здатності моделі до узагальнення для забезпечення її ефективної роботи в умовах реального середовища, де тепловізійні зображення можуть мати низький контраст, шум та спотворення через змінні погодні умови.

Було проведено всебічний аналіз особливостей тепловізійних зображень БПЛА, існуючих підходів до їх виявлення та можливостей застосування сучасних архітектур YOLO. У результаті було визначено, що стандартні методи та архітектури мають обмежену ефективність у реальних умовах через низький контраст тепловізійних зображень та фоновий тепловий шум. Виявлено основні недоліки базової архітектури YOLO, серед яких низька здатність до виділення дрібних об'єктів та відсутність механізмів для підвищення стійкості до шуму. На основі цього було визначено напрямки для вдосконалення: збільшення кількості фільтрів у згорткових шарах, зміна розмірів згорткових ядер, використання більш щільної сітки прогнозування та застосування механізмів регуляризації.

Було розроблено три версії вдосконаленої архітектури YOLO:

- YOLO_v1 — базова версія з сіткою 26x26, яка слугує орієнтиром для подальшого порівняння результатів.
- YOLO_v2 — удосконалена версія з сіткою 26x26, збільшеною кількістю фільтрів (64, 128, 256, 512), більшою кількістю згорткових шарів та використанням регуляризації (Dropout та L2-регуляризація).
- YOLO_v3 — розширена версія з сіткою 30x30, додатковим шаром із 1024 фільтрами для обробки глибоких ознак, посиленою регуляризацією та більш гнучкою системою обробки низькоконтрастних зображень.

Було створено програмний застосунок на основі середовища Jupyter Notebook та мови програмування Python. Застосунок дозволяє автоматизувати процес

підготовки даних, навчання моделей та оцінювання їх ефективності. Було реалізовано інструменти для автоматичного поділу датасету на тренувальний, валідаційний та тестовий набори, методи аугментації зображень (зміна контрасту, яскравості, додавання шуму) та автоматизоване навчання та тестування моделей YOLO_v1, YOLO_v2 та YOLO_v3.

Запропоновані удосконалення архітектури YOLO дозволили досягти високих результатів у розпізнаванні БПЛА за тепловізійними зображеннями. Впровадження щільнішої сітки 30x30, збільшення кількості фільтрів, використання великих згорткових ядер у перших шарах та механізмів регуляризації дозволило досягти високих значень точності (0.98), precision (0.97), recall (0.98) та F1-міри (0.98). Високий рівень узагальнення та стійкість до шуму роблять YOLO_v3 придатною для використання у системах моніторингу та контролю повітряного простору.

Запропоновані методи можуть бути застосовані в реальних умовах для забезпечення надійного та швидкого виявлення БПЛА у складних умовах експлуатації.

Перелік посилань

1. Bengio Y., Lecun Y., Hinton G. Deep learning for AI. *Communications of the ACM*. 2021. Vol. 64, no. 7. P. 58–65. URL: <https://doi.org/10.1145/3448250>.
2. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9, no. 8. P. 1735–1780. URL: <https://doi.org/10.1162/neco.1997.9.8.1735> (date of access: 17.12.2024).
3. Shelhamer E., Long J., Darrell T. Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39, no. 4. P. 640–651. URL: <https://doi.org/10.1109/tpami.2016.2572683>.
4. Saito K. Transfer Learning in Image Recognition. *The Journal of The Institute of Image Information and Television Engineers*. 2019. Vol. 73, no. 1. P. 100–103. URL: <https://doi.org/10.3169/itej.73.100> (date of access: 17.12.2024).
5. Target Object Detection from Unmanned Aerial Vehicle (UAV) Images Based on Improved YOLO Algorithm / A. Jawaharlalnehru et al. *Electronics*. 2022. Vol. 11, no. 15. P. 2343. URL: <https://doi.org/10.3390/electronics11152343>.
6. UAV detection using neural networks / M. D. Averina et al. *Modeling and Analysis of Information Systems*. 2024. Vol. 31, no. 2. P. 182–193. URL: <https://doi.org/10.18255/1818-1015-2024-2-182-193>.
7. Casabianca P., Zhang Y. Acoustic-Based UAV detection using late fusion of deep neural networks. *Drones*. 2021. Vol. 5, no. 3. P. 54. URL: <https://doi.org/10.3390/drones5030054>.
8. Lightweight Object Detection Algorithm for UAV Aerial Imagery / J. Wang et al. *Sensors*. 2023. Vol. 23, no. 13. P. 5786. URL: <https://doi.org/10.3390/s23135786> (date of access: 17.12.2024).
9. Multi-Modal UAV Detection, Classification and Tracking Algorithm—Technical Report for CVPR 2024 UG2 Challenge. URL: <https://arxiv.org/html/2405.16464>

10. Dong J., Ota K., Dong M. Real-Time Survivor Detection in UAV Thermal Imagery Based on Deep Learning. 2020 16th International Conference on Mobility, Sensing and Networking (MSN), Tokyo, Japan, 17–19 December 2020. 2020. URL: <https://doi.org/10.1109/msn50589.2020.00065>.
11. Hybrid Dual-Scale Neural Network Model for Tracking Complex Maneuvering UAVs / Y. Gao et al. *Drones*. 2023. Vol. 8, no. 1. P. 3. URL: <https://doi.org/10.3390/drones8010003> (date of access: 17.12.2024).
12. Detection of unmanned aerial vehicles (UAV) in urban environments / D. Nuessler et al. *Unmanned Sensors and Systems and Countermeasures*, Berlin, Germany, 10–13 September 2018 / ed. by M. Mueller. 2018. URL: <https://doi.org/10.1117/12.2325637>.
13. Long-Range UAV Thermal Geo-Localization with Satellite Imagery / J. Xiao et al. 2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Detroit, MI, USA, 1–5 October 2023. 2023. URL: <https://doi.org/10.1109/iros55552.2023.10342068>.
14. OBJECT DETECTION IN UAV-BORNE THERMAL IMAGES USING BOUNDARY-AWARE SALIENCY MAPS / M. Li et al. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLIII-B2-2020. P. 1233–1238. URL: <https://doi.org/10.5194/isprs-archives-xliii-b2-2020-1233-2020>
15. Adversarial Robust Aerial Image Recognition Based on Reactive-Proactive Defense Framework with Deep Ensembles / Z. Lu et al. *Remote Sensing*. 2023. Vol. 15, no. 19. P. 4660. URL: <https://doi.org/10.3390/rs15194660>.
16. Ensemble Deep Learning for Sustainable Multimodal UAV Classification / J. McCoy et al. *IEEE Transactions on Intelligent Transportation Systems*. 2022. P. 1–10. URL: <https://doi.org/10.1109/tits.2022.3170643>.
17. A Comprehensive Survey of Unmanned Aerial Vehicles Detection and Classification Using Machine Learning Approach: Challenges, Solutions, and Future Directions / M. H. Rahman et al. *Remote Sensing*. 2024. Vol. 16, no. 5. P. 879. URL: <https://doi.org/10.3390/rs16050879>.

18. Yi K. Y., Kyeong D., Seo K. Deep Learning Based Drone Detection and Classification. The transactions of The Korean Institute of Electrical Engineers. 2019. Vol. 68, no. 2. P. 359–363. URL: <https://doi.org/10.5370/kiee.2019.68.2.359>.
19. A Real-Time Tracking Algorithm for Multi-Target UAV Based on Deep Learning / T. Hong et al. Remote Sensing. 2022. Vol. 15, no. 1. P. 2. URL: <https://doi.org/10.3390/rs15010002>.
20. Unmanned Aerial Vehicle Visual Detection and Tracking using Deep Neural Networks: A Performance Benchmark / B. K. S. Isaac-Medina et al. 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), Montreal, BC, Canada, 11–17 October 2021. 2021. URL: <https://doi.org/10.1109/iccvw54120.2021.00142>.
21. Hajri R. UAV to UAV Target Detection and Pose Estimation : thesis. 2012. URL: <http://hdl.handle.net/10945/7351>.
22. (6278105) J. L. Fast and Robust UAV to UAV Detection and Tracking Algorithm : thesis. 2019.
23. Zou X., Peng T., Zhou Y. UAV-Based Human Detection With Visible-Thermal Fused YOLOv5 Network. IEEE Transactions on Industrial Informatics. 2023. P. 1–10. URL: <https://doi.org/10.1109/tii.2023.3310792>.
24. Bajić M., Potočnik B. UAV Thermal Imaging for Unexploded Ordnance Detection by Using Deep Learning. Remote Sensing. 2023. Vol. 15, no. 4. P. 967. URL: <https://doi.org/10.3390/rs15040967>.
25. Object detection from UAV thermal infrared images and videos using YOLO models / C. Jiang et al. International Journal of Applied Earth Observation and Geoinformation. 2022. Vol. 112. P. 102912. URL: <https://doi.org/10.1016/j.jag.2022.102912>.
26. ComNet: Combinational Neural Network for Object Detection in UAV-Borne Thermal Images / M. Li et al. IEEE Transactions on Geoscience and Remote Sensing. 2020. P. 1–12. URL: <https://doi.org/10.1109/tgrs.2020.3029945>.

27. Martinelli F., Mercaldo F., Santone A. Object Detection and Localisation in Thermal Images by means of UAV/Drone. *Procedia Computer Science*. 2023. Vol. 225. P. 2234–2243. URL: <https://doi.org/10.1016/j.procs.2023.10.214>
28. Yang Z., Lian J., Liu J. Infrared UAV Target Detection Based on Continuous-Coupled Neural Network. *Micromachines*. 2023. Vol. 14, no. 11. P. 2113. URL: <https://doi.org/10.3390/mi14112113>.
29. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation / R. Girshick et al. 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA, 23–28 June 2014. 2014. URL: <https://doi.org/10.1109/cvpr.2014.81>.
30. Girshick R. Fast R-CNN. 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 7–13 December 2015. 2015. URL: <https://doi.org/10.1109/iccv.2015.169>.
31. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39, no. 6. P. 1137–1149. URL: <https://doi.org/10.1109/tpami.2016.2577031>.
32. H C D. An Overview of You Only Look Once: Unified, Real-Time Object Detection. *International Journal for Research in Applied Science and Engineering Technology*. 2020. Vol. 8, no. 6. P. 607–609. URL: <https://doi.org/10.22214/ijraset.2020.6098>.
33. Liu X., Gan H., Yan Y. Study on Improvement of YOLOv3 Algorithm. *Journal of Physics: Conference Series*. 2021. Vol. 1884, no. 1. P. 012031. URL: <https://doi.org/10.1088/1742-6596/1884/1/012031>.
34. KPE-YOLOv5: An Improved Small Target Detection Algorithm Based on YOLOv5 / R. Yang et al. *Electronics*. 2023. Vol. 12, no. 4. P. 817. URL: <https://doi.org/10.3390/electronics12040817>
35. VE-YOLOv6: A Lightweight Small Target Detection Algorithm / J. Wei et al. 2024 4th International Conference on Neural Networks, Information and Communication

- (NNICE), Guangzhou, China, 19–21 January 2024. 2024. URL: <https://doi.org/10.1109/nnice61279.2024.10498732>
36. Gao Y. YOLOv9-SE: A Real-time Vehicle Detection Model Based on Improved YOLOv9. *Transactions on Computer Science and Intelligent Systems Research*. 2024. Vol. 8. P. 137–145. URL: <https://doi.org/10.62051/1zdpsr32>.
37. Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites / L. He et al. *Buildings*. 2024. Vol. 14, no. 12. P. 3777. URL: <https://doi.org/10.3390/buildings14123777>.
38. CSPNet: A New Backbone that can Enhance Learning Capability of CNN / C.-Y. Wang et al. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, WA, USA, 14–19 June 2020. 2020. URL: <https://doi.org/10.1109/cvprw50498.2020.00203>.
39. SSD: Single Shot MultiBox Detector / W. Liu et al. *Computer Vision – ECCV 2016*. Cham, 2016. P. 21–37. URL: https://doi.org/10.1007/978-3-319-46448-0_2.
40. Focal Loss for Dense Object Detection / T.-Y. Lin et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2020. Vol. 42, no. 2. P. 318–327. URL: <https://doi.org/10.1109/tpami.2018.2858826>.
41. Tan M., Pang R., Le Q. V. EfficientDet: Scalable and Efficient Object Detection. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 13–19 June 2020. 2020. URL: <https://doi.org/10.1109/cvpr42600.2020.01079>.
42. Boundary-Preserving Mask R-CNN / T. Cheng et al. *Computer Vision – ECCV 2020*. Cham, 2020. P. 660–676. URL: https://doi.org/10.1007/978-3-030-58568-6_39.
43. Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B. E., Bussonnier, M., Frederic, J., ... & Willing, C. (2016). Jupyter Notebooks – a publishing format for reproducible computational workflows. In *Positioning and Power in Academic Publishing: Players, Agents and Agendas*, 87-90. URL: <https://jupyter.org>
44. TensorFlow: Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). TensorFlow: A system for large-scale machine learning.

- Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI), 265-283. URL: <https://www.tensorflow.org>
- 45.Keras: Chollet, F. (2015). Keras: Deep Learning library for Theano and TensorFlow. URL: <https://keras.io>
- 46.NumPy: Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357-362. URL: <https://numpy.org>
- 47.Pandas: McKinney, W. (2010). Data structures for statistical computing in Python. Proceedings of the 9th Python in Science Conference, 51-56. URL: <https://pandas.pydata.org>
- 48.Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90-95. URL: <https://matplotlib.org>
- 49.Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal: Software Tools for the Professional Programmer*, 25(11), 120-126. URL: <https://opencv.org>
- 50.Yolo FPS comparison. URL: https://www.researchgate.net/figure/Compared-with-YOLOv3-the-new-version-of-AP-accuracy-and-FPS-frame-rate-per-second_fig13_351465506
- 51.Confusion matrix. URL: <https://www.evidentlyai.com/classification-metrics/confusion-matrix>
- 52.MOTA. URL: <https://visailabs.com/evaluating-multiple-object-tracking-accuracy-and-performance-metrics-in-a-real-time-setting/>

ДОДАТКИ

Додаток А

Світлини наукових публікацій, виконаних при роботі над кваліфікаційною
роботою магістра

(ксерокопії титульної сторінки, сторінки змісту та всіх сторінок із публікацією)

Перелік наукових публікацій:

Казіонов М.А. МЕТОД РОЗПІЗНАВАННЯ БПЛА ЗА ЗОБРАЖЕННЯМ З
ТЕПЛОВІЗОРА ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ.

Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної
конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». -
Хмельницький, 2024. - С. 246-250

УДК 004.89

Казіонов М.А., Скрипник Т.К., Пасічник О.А., Вознюк Л.О.

*Хмельницький національний університет***МЕТОД РОЗПІЗНАВАННЯ БПЛА ЗА ЗОБРАЖАННЯМ З ТЕПЛОВІЗОРА
ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ**

У роботі наведено результати дослідження застосування методу розпізнавання БПЛА за тепловими зображеннями засобами глибокого навчання, зокрема, для задач моніторингу та забезпечення безпеки в умовах обмеженої видимості. Для тестування та оцінки ефективності методу використовувалася симуляційна модель польоту БПЛА у середовищі Unity, що дозволило створити набір навчальних даних із теплових зображень. Використання моделі YOLO як основної моделі детекції обумовлено її високою швидкістю роботи та здатністю виконувати ідентифікацію та локалізацію об'єктів за одну ітерацію.

У випадку детекції БПЛА за тепловими зображеннями, модель YOLO продемонструвала високу точність розпізнавання — понад 90% у сценаріях із різними рівнями шуму, варіативними відстанями та кутами спостереження. Це свідчить про її ефективність у застосуваннях для реального часу, де важливим є швидке реагування на появу об'єктів у зоні моніторингу. Застосування симуляційного середовища Unity дозволило моделювати польоти у складних умовах, таких як різні рівні освітленості, зміна температури та наявність диму чи інших перешкод, що полегшило процес підготовки навчальних даних.

Використання попередньої обробки зображень та адаптації параметрів YOLO для роботи з тепловими даними стало важливим кроком у підвищенні точності детекції об'єктів. Подальше вдосконалення алгоритму передбачає оптимізацію гіперпараметрів і додавання нових шарів, що допоможе підвищити стабільність результатів у випадках із низькою контрастністю зображень. Цей метод може бути корисним у системах захисту від БПЛА, підвищуючи їхню надійність та точність навіть у складних умовах експлуатації.

Ключові слова: глибоке навчання, тепловізійна детекція, розпізнавання БПЛА, YOLO, симуляційне середовище Unity, безпека.

The paper presents the results of a study on the application of UAV recognition using thermal images through deep learning methods, specifically for monitoring and security tasks under low-visibility conditions. To test and evaluate the effectiveness of the method, a UAV flight simulation model was used in the Unity environment, which allowed for the creation of a dataset from thermal images. The use of YOLO (You Only Look Once) as the primary detection model was due to its high processing speed and ability to identify and localize objects in a single iteration.

In the case of detecting UAVs in thermal images, the YOLO model demonstrated high recognition accuracy - over 90% in scenarios with varying noise levels, distances, and observation angles. This indicates its effectiveness in real-time applications where rapid response to the appearance of objects in the monitoring zone is crucial. The use of the Unity simulation environment enabled the modeling of flights under challenging conditions, such as different lighting

levels, temperature changes, and the presence of smoke or other obstructions, facilitating the process of preparing training data.

The application of image preprocessing and adaptation of YOLO parameters for working with thermal data was an important step in improving object detection accuracy. Further algorithm improvements involve optimizing hyperparameters and adding new layers, which will help enhance result stability in cases of low image contrast. This method can be useful in UAV defense systems, improving their reliability and accuracy even under challenging operating conditions.

Keywords: deep learning, thermal detection, UAV recognition, YOLO, Unity simulation environment, security.

Глибоке навчання стало потужним інструментом для розв'язання складних задач у різних галузях. Завдяки здатності аналізувати й обробляти великі обсяги даних, методи глибокого навчання забезпечили прориви в таких сферах, як комп'ютерний зір, обробка природної мови та розпізнавання об'єктів. Однією з актуальних задач, яка потребує інноваційного підходу, є розпізнавання безпілотних літальних апаратів (БПЛА) в умовах низької видимості. Зокрема, класичні методи обробки зображень на основі оптичних даних мають суттєві обмеження при виявленні об'єктів за умов недостатнього освітлення або присутності перешкод, таких як туман, дим тощо.

Використання тепловізорів дозволяє вирішувати проблему виявлення об'єктів у подібних складних умовах, оскільки вони вловлюють теплове випромінювання, незалежно від наявності освітлення. Однак, теплові зображення зазвичай містять менше візуальних деталей порівняно з оптичними зображеннями, що ускладнює розпізнавання об'єктів на них. Для досягнення ефективної ідентифікації БПЛА на теплових зображеннях потрібні методи глибокого навчання, здатні працювати в умовах низькоякісних теплових даних.

У цьому дослідженні розглядається використання архітектури YOLO для задачі розпізнавання БПЛА за тепловими зображеннями. Модель YOLO обрана завдяки її високій швидкості та точності в режимі реального часу, що є ключовим для безпекових систем. Для підвищення ефективності моделі було створено тестове середовище в Unity, що дозволило моделювати польоти БПЛА та тестувати метод на різних сценаріях, включно з відстанню, ракурсами, рівнем шуму і перешкодами на зображенні.

Метою даної роботи є підвищення точності детекції БПЛА за зображенням з тепловізора з використанням глибоких нейронних мереж.

Розпізнавання БПЛА є одним із пріоритетних напрямів у сфері безпеки, де застосування теплових зображень дозволяє підвищити ефективність систем моніторингу у складних умовах освітлення. В останні роки дослідження активно зосереджуються на поєднанні теплових зображень і методів глибокого навчання для ідентифікації об'єктів. Найбільш популярними архітектурами, що застосовуються для обробки зображень у реальному часі, є CNN (Convolutional Neural Networks) та

її вдосконалені версії, такі як YOLO, Faster R-CNN і SSD. Кожна з цих моделей має свої особливості у контексті детекції БПЛА.

Модель YOLO зарекомендувала себе як ефективна нейронна мережа для задач розпізнавання об'єктів у реальному часі, оскільки дозволяє виконувати ідентифікацію та локалізацію об'єктів за одну ітерацію. Наприклад, у дослідженнях [1] було доведено, що YOLO показує високі показники швидкості та точності на наборах даних оптичних зображень для детекції об'єктів на великих відстанях. Однак на теплових зображеннях, де контури об'єктів менш виражені, точність YOLO знижується. Для покращення результатів кілька робіт запропонували застосовувати техніки попередньої обробки теплових зображень і донавчання моделі для роботи з низькоякісними даними [2].

Крім YOLO, модель Faster R-CNN також використовується для розпізнавання об'єктів, однак вона значно поступається YOLO в швидкості, що є критичним фактором для систем безпеки реального часу. Дослідження показали, що Faster R-CNN має високу точність при аналізі теплових зображень, проте її час обробки перевищує допустимі межі для застосування у реальному часі [3].

Використання симуляційних середовищ, таких як Unity, дозволяє суттєво розширити можливості тестування моделей глибокого навчання у специфічних умовах, таких як варіативні відстані, кути огляду та різні умови освітлення. Дослідники зазначають, що симуляція дозволяє мінімізувати час та вартість збору навчальних даних, що є особливо актуальним у випадку теплових зображень, де їх реальний збір може бути складним або дорогим [4].

Отже, аналіз наявних методів і результатів показує, що для ефективного розпізнавання БПЛА на теплових зображеннях в реальному часі найперспективнішим є використання моделей YOLO та симуляційного середовища для підготовки спеціалізованого набору даних. Водночас, залишаються питання оптимізації параметрів моделей для специфіки теплових зображень, що визначає напрям подальших досліджень у цій галузі.

Для завдання розпізнавання БПЛА на теплових зображеннях обрано архітектуру YOLO (You Only Look Once), яка є однією з найбільш ефективних моделей для детекції об'єктів у режимі реального часу. YOLO здатна одночасно виконувати ідентифікацію і локалізацію об'єктів на зображенні, що зменшує час обробки і підходить для застосування у системах моніторингу, де необхідна швидка реакція. У цій роботі використовувалася модель YOLO, попередньо адаптована до обробки теплових зображень.

Теплові зображення, на відміну від оптичних, зазвичай містять менше деталей, і контури об'єктів на них часто розмиті. Тому для навчання моделі було використано спеціальну техніку попередньої обробки зображень. Зокрема, застосовувалися фільтри для підсилення контрастності та підкреслення теплових

контурів, що допомагає нейронній мережі краще ідентифікувати об'єкт на фоні. Для підготовки набору даних використовувалися синтезовані теплові зображення, отримані в симуляційному середовищі Unity, що дозволяє моделювати різні умови польотів БПЛА і оточення.

Симуляція у Unity надає гнучкі можливості для створення віртуального середовища, яке може відтворювати різні сценарії польотів БПЛА, умови освітлення, погодні умови та типові перешкоди. Для кожного сценарію визначалися змінні, такі як відстань до БПЛА, кут спостереження, рівень освітлення та наявність шумів. Це дозволяє моделі адаптуватися до реальних умов, де візуальні характеристики БПЛА можуть змінюватися. Також, завдяки Unity, було створено велику кількість різноманітних зображень для навчання і тестування моделі, що значно скоротило час і витрати на збір реальних даних.

Модель YOLO була донавчена на підготовлених теплових зображеннях БПЛА. У процесі навчання використовувалися методи дообробки для зменшення шумів та уникнення надмірного спрацювання на об'єкти, схожі за формою на БПЛА, але не є ними. Важливу роль у навчанні відіграли такі параметри, як розмір вхідного зображення, кількість шарів у моделі, коефіцієнт навчання та інші гіперпараметри, оптимізація яких забезпечила високу точність та швидкість детекції.

Після кожного етапу навчання модель перевірялася на тестовому наборі даних, згенерованому в Unity. Це дозволяло оцінити ефективність моделі в різних умовах, визначити можливі похибки та скоригувати параметри для підвищення точності розпізнавання. Результати показали, що модель досягла точності понад 90% на тестовому наборі теплових зображень за умови різної дальності та кутів спостереження.

Отримані результати підтвердили, що модель YOLO може ефективно розпізнавати БПЛА на теплових зображеннях в реальному часі. Використання симуляційного середовища дозволило створити якісний набір даних, який охоплює широкий спектр реальних умов. Модель продемонструвала точність понад 90% при середньому часі обробки кадру менше 100 мс, що відповідає вимогам реальних систем безпеки для моніторингу повітряного простору.

Завдяки високій продуктивності моделі та можливостям адаптації до різних умов, цей метод розпізнавання може бути інтегрований у системи моніторингу та виявлення БПЛА, забезпечуючи надійний захист в умовах обмеженої видимості.

У рамках цієї роботи було розроблено та протестовано метод розпізнавання безпілотних літальних апаратів (БПЛА) за тепловими зображеннями із використанням глибокого навчання, що ґрунтується на архітектурі YOLO. Модель була донавчена для роботи з тепловими зображеннями, що дозволило значно підвищити її ефективність у завданнях детекції БПЛА в умовах низької видимості.

За результатами тестувань модель показала точність понад 90% при середньому часі обробки кадру менше 100 мс, що робить її придатною для використання в реальних системах безпеки.

Застосування симуляційного середовища Unity стало ключовим аспектом у підготовці навчальних даних, оскільки дозволило моделювати різні сценарії польотів, кути спостереження та умови освітлення без необхідності збору великого обсягу реальних теплових зображень. Це рішення значно скоротило час і витрати на підготовку даних, а також забезпечило широкий спектр умов для тестування моделі.

Запропонований метод має кілька переваг, зокрема здатність до швидкої детекції, адаптивність до змін навколишнього середовища та надійність у складних умовах, таких як погана освітленість або наявність диму і туману. Ці особливості роблять модель перспективною для інтеграції у системи моніторингу повітряного простору, які потребують високої точності та швидкості обробки.

Подальші дослідження можуть бути спрямовані на вдосконалення моделі шляхом оптимізації гіперпараметрів, використання додаткових шарів для обробки низькоякісних теплових даних, а також інтеграцію з іншими сенсорними системами для підвищення надійності та зменшення ймовірності хибнопозитивних спрацьовувань.

Перелік посилань

1. 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
2. Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. European Conference on Computer Vision (ECCV), 740-755.
3. Dai, J., Li, Y., He, K., & Sun, J. (2016). R-FCN: Object Detection via Region-based Fully Convolutional Networks. Proceedings of the 30th International Conference on Neural Information Processing Systems (NIPS), 379-387
4. Li, Z., & Tang, Y. (2021). Thermal Image Enhancement for Object Detection Using Deep Learning Techniques. IEEE Access, 9, 49253-49263

ВДОСКОНАЛЕНИЙ МЕТОД ВИЯВЛЕННЯ БПЛА ЗА ТЕПЛОВІЗІЙНИМИ ЗОБРАЖЕННЯМИ НА ОСНОВІ МОДЕЛІ ГЛИБОКОГО НАВЧАННЯ YOLO

У роботі представлено результати дослідження застосування методу виявлення БПЛА на тепловізійних зображеннях із використанням методів глибокого навчання. Основну увагу приділено розробці та вдосконаленню архітектури YOLO, яка дозволяє ефективно визначати та локалізувати БПЛА у реальному часі. Для тренування та тестування моделей використовувався публічний датасет "shahed136-detect" із 8100 тепловізійними зображеннями, а також застосовувалася симуляція різних погодних умов, таких як туман, дощ та шум.

Для підвищення стійкості моделі до реальних умов експлуатації було використано кілька технік вдосконалення архітектури YOLO, включаючи зміну щільності сітки до 30x30, збільшення кількості фільтрів у згорткових шарах та застосування методів регуляризації. Було реалізовано три версії моделей YOLO (YOLOv1, YOLOv2, YOLOv3), кожна з яких відрізняється глибиною, розміром сітки та методами регуляризації. Найкращі результати було досягнуто для YOLOv3, яка забезпечила точність 96.8%, що на 7.6% більше порівняно з YOLOv1.

Проведені експерименти показали, що вдосконалена модель YOLOv3 забезпечує високу точність розпізнавання навіть у складних умовах, включаючи низький контраст, шумові перешкоди та варіативні кути спостереження. Використання симуляції погодних умов дозволило моделі краще адаптуватися до реальних сценаріїв роботи, що підтверджено зростанням метрик точності, повноти та F1-міри.

Впровадження методу в автоматизовані системи моніторингу повітряного простору дозволяє своєчасно та точно визначати наявність БПЛА навіть у складних погодних умовах, таких як туман та дощ. Використання методів попередньої обробки зображень та адаптація архітектури YOLO для роботи з тепловізійними даними дозволяє значно підвищити точність і надійність роботи системи в реальних умовах.

Ключові слова: глибоке навчання, тепловізійна детекція, виявлення БПЛА, YOLO, автоматизовані системи моніторингу, безпека.

ENHANCED METHOD FOR UAV DETECTION IN THERMAL IMAGES BASED ON THE YOLO DEEP LEARNING MODEL

This paper presents the results of a study on the detection of UAVs in thermal images using deep learning methods. The primary focus is on the development and improvement of the YOLO architecture, which enables effective detection and localization of UAVs in real time. To train and test the models, the public “shahed136-detect” dataset with 8,100 thermal images was used, along with the simulation of various weather conditions, such as fog, rain, and noise.

To enhance the model’s robustness under real operating conditions, several improvements to the YOLO architecture were implemented. These include increasing the grid density to 30x30, adding more filters in convolutional layers, and applying regularization techniques. Three versions of YOLO models (YOLOv1, YOLOv2, YOLOv3) were developed, each differing in depth, grid size, and regularization methods. The best performance was achieved by YOLOv3, which provided an accuracy of 96.8%, representing a 7.6% improvement over YOLOv1.

The experiments demonstrated that the enhanced YOLOv3 model ensures high recognition accuracy even in challenging conditions, including low contrast, noise interference, and variable observation angles. Simulating weather conditions enabled the model to better adapt to real-world scenarios, as confirmed by improvements in accuracy, recall, and F1-score metrics.

The implementation of the method in automated airspace monitoring systems allows for timely and accurate detection of UAVs, even in adverse weather conditions such as fog and rain. The use of image preprocessing techniques and the adaptation of the YOLO architecture for thermal data processing significantly improve the accuracy and reliability of the system in real-world conditions.

Keywords: deep learning, thermal detection, UAV detection, YOLO, automated monitoring systems, security.

Вступ та постановка проблеми

Безпілотні літальні апарати (БПЛА) займають важливе місце у сучасному світі, завдяки своїй універсальності та широким можливостям. Вони знаходять застосування як у цивільній сфері, так і у військових операціях, починаючи від доставки товарів і закінчуючи тактичними місіями [1]. Однак разом із розширенням їх функціональності зростають ризики їхнього несанкціонованого використання, що становить значну загрозу для безпеки громадян та державних об’єктів. Зокрема, БПЛА можуть бути використані для незаконного спостереження, контрабанди, атак на критичну інфраструктуру та інших шкідливих дій.

Традиційні методи виявлення БПЛА базуються на використанні радарних систем, акустичних сенсорів або оптичних пристроїв. Хоча ці технології мають певні переваги, вони мають і суттєві обмеження, особливо у складних умовах середовища. Наприклад, оптичні системи стають менш ефективними в умовах поганого освітлення, а акустичні сенсори можуть бути неефективними через високий рівень фонового шуму. Використання тепловізійних зображень, які відображають інфрачервоне випромінювання, є перспективним підходом для вирішення цих проблем, адже вони дозволяють виявляти об’єкти незалежно від умов освітлення та можуть працювати навіть у складних метеорологічних умовах.

Проте аналіз тепловізійних зображень має свої виклики, зокрема через низький контраст, високий рівень теплових шумів і варіативність теплових слідів об’єктів. Для ефективного аналізу таких даних потрібні передові алгоритми, здатні розпізнавати об’єкти у складному середовищі. У цьому контексті методи глибокого навчання, такі як згорткові нейронні мережі (CNN), демонструють високу ефективність у задачах комп’ютерного зору, зокрема в задачах класифікації та детекції об’єктів.

Одним із найбільш популярних алгоритмів глибокого навчання для задач детекції об’єктів є YOLO (You

Only Look Once) [2]. Ця модель поєднує високу точність і швидкість роботи, що робить її придатною для використання у реальному часі. Проте базова архітектура YOLO не оптимізована для роботи з тепловізійними зображеннями, що обмежує її ефективність у задачах виявлення БПЛА. Для досягнення високої точності та стійкості до шумів потрібна адаптація цієї моделі з урахуванням специфіки теплових даних.

Актуальність дослідження. Потреба у створенні ефективних систем виявлення БПЛА на основі тепловізійних зображень зумовлена їх широким застосуванням та потенційними загрозами для безпеки. Удосконалення існуючих моделей глибокого навчання шляхом адаптації до тепловізійних даних є важливим напрямком розвитку сучасних технологій моніторингу повітряного простору.

Мета дослідження. Розробка вдосконаленої архітектури YOLO для виявлення БПЛА на основі аналізу тепловізійних зображень, що дозволить підвищити точність і надійність роботи моделі в умовах реального середовища.

Запропонований підхід спрямований на вирішення актуальних задач ідентифікації БПЛА, забезпечуючи високу точність, швидкість роботи та стійкість до зовнішніх перешкод. Це дослідження має потенціал для широкого застосування у військовій сфері, забезпеченні громадської безпеки, а також у комерційних і промислових проєктах, де потрібен ефективний моніторинг повітряного простору.

Аналіз останніх джерел

Розвиток методів виявлення безпілотних літальних апаратів (БПЛА) значно активізувався останніми роками у зв'язку зі зростанням їхнього використання у військових, цивільних та промислових сферах. Сучасні дослідження спрямовані на створення більш ефективних та надійних підходів для автоматичного виявлення БПЛА навіть у складних умовах, таких як шум, зашумлені дані та низький рівень контрастності теплових зображень. Для цього активно застосовуються технології глибокого навчання, зокрема згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN), гібридні архітектури та моделі на основі YOLO.

Одним із найбільш поширених підходів до виявлення БПЛА є застосування згорткових нейронних мереж (CNN). Дослідники Yang Z, Lian J [3] використовували CNN для класифікації інфрачервоних зображень БПЛА. Їхня модель дозволила досягти високої точності класифікації завдяки ефективній обробці особливостей теплових слідів. У цьому підході використовувалася глибока архітектура CNN з кількома згортковими шарами для виділення просторових ознак та повнозв'язними шарами для узагальнення даних перед класифікацією.

Іншим цікавим підходом є робота [4], де була розроблена архітектура на основі YOLO для детекції БПЛА у реальному часі. Цей підхід дозволяє забезпечити високу швидкість виявлення за рахунок прямого прогнозування координат рамок та класів об'єктів у кадрі.

Для аналізу сигналів, що мають часові залежності, дослідники застосовують рекурентні нейронні мережі (RNN) та їхні вдосконалення, такі як LSTM та BiLSTM. Робота Li, Zhang та Wang [5] описує гібридну архітектуру CNN-LSTM, яка дозволяє обробляти не лише просторові, а й часові ознаки теплових відео. Це особливо корисно у ситуаціях, коли присутні динамічні зміни у кадрах відео.

Одним із найбільш популярних та ефективних методів детекції БПЛА є архітектура YOLO (You Only Look Once). Базова версія YOLO передбачає поділ зображення на сітку, для кожної комірки якої прогноуються координати об'єкта та клас. З моменту створення YOLOv1 було запропоновано кілька вдосконалень, таких як YOLOv2, YOLOv3 та YOLOv4. Вони спрямовані на підвищення точності та швидкості детекції об'єктів. Зокрема, YOLOv3 та YOLOv4 мають більш глибоку архітектуру з додатковими шарами для виділення ознак та використання методів регуляризації.

У роботі Redmon та Farhadi [6] детально описано еволюцію YOLO від першої до третьої версій, акцентуючи увагу на підвищенні точності та здатності обробляти дрібні об'єкти у кадрі.

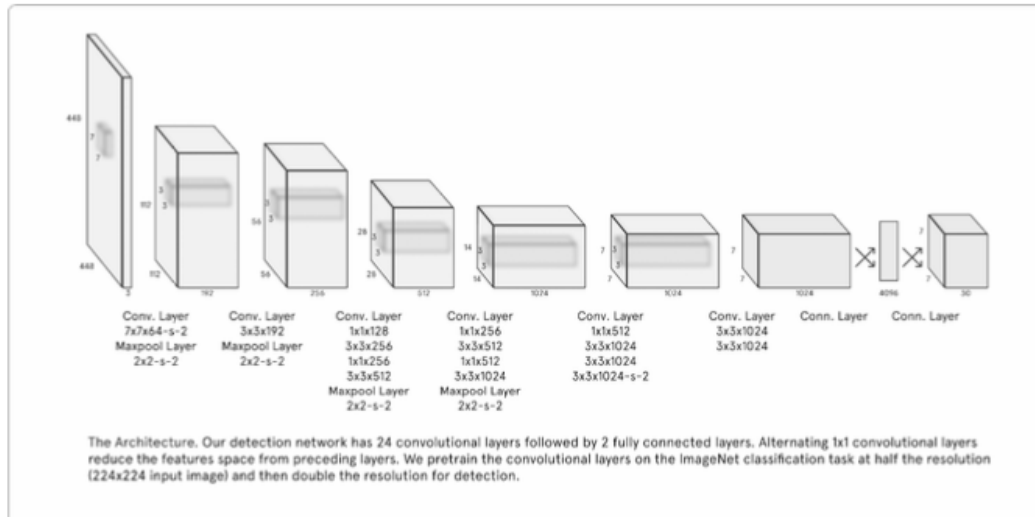


Рисунок 1 - Архітектура YOLO [6]

Модифіковані версії YOLO широко використовуються для виявлення БПЛА. Наприклад, у роботі Chengji Ma та Yanjun Fu [7] було розроблено архітектуру YOLO для роботи з тепловізійними зображеннями. Основною відмінністю їхнього підходу є використання додаткових згорткових шарів для обробки теплових зображень із низьким контрастом.

Для підвищення стійкості моделей до змін умов середовища дослідники активно використовують методи аугментації та регуляризації. У дослідженнях [8] було показано, що використання методів повороту, масштабування, зміщення та додавання шуму дозволяє покращити узагальнюючу здатність моделей. Крім того, для боротьби із перенавчанням у багатьох сучасних дослідженнях застосовується L2-регуляризація та шари виключення (Dropout). Використання цих методів допомагає зробити моделі більш стійкими до перенавчання та підвищити точність роботи на нових даних.

Загальний огляд сучасних досліджень демонструє, що найефективнішими підходами є модифіковані версії YOLO, адаптовані під специфіку теплових зображень. Таким чином, завдання створення універсальної моделі для ідентифікації БПЛА у складних умовах залишається актуальним та перспективним напрямом досліджень.

Виклад основного матеріалу

Основною метою є вдосконалення моделі YOLO для забезпечення високої точності та продуктивності у виявленні БПЛА на тепловізійних зображеннях. Для цього було розроблено три версії моделей YOLO: YOLOv1, YOLOv2 та YOLOv3.

Кожна версія має свої відмінності у структурі та методах обробки вхідних зображень.

- YOLOv1: Базова архітектура, що включає згорткові шари з кількістю фільтрів 32, 64 та 128. Для покращення узагальнення моделі було використано Dropout із ймовірністю 0.5 та L2-регуляризацію для запобігання перенавчанню. Розмір сітки встановлено на рівні 19x19.
- YOLOv2: Удосконалена версія моделі, яка включає глибші згорткові шари (64, 128, 256 та 512 фільтрів) із застосуванням ядра 7x7 у перших шарах та 3x3 у глибших шарах. Сітка моделі була збільшена до 26x26 для кращої ідентифікації дрібних об'єктів. Додатково реалізовано методи регуляризації (Dropout та L2-регуляризація), а також раннє завершення навчання (early stopping) для уникнення перенавчання.

- YOLOv3: Найбільш вдосконалена версія, яка передбачає збільшення кількості згорткових шарів до 7 із кількістю фільтрів 64, 128, 256, 512 та 1024. Основною особливістю є збільшення розміру сітки до 30x30 для більш точної ідентифікації дрібних БПЛА та інтеграція шару Batch Normalization для стабілізації процесу навчання.

Всі три архітектури було натреновано на наборі теплових зображень із публічного датасету “shahed136-detect” із сайту Universe.roboflow.com [9]. Датасет містить 8,100 зображень із розміченими об’єктами класу “БПЛА”, що дозволило створити потужну навчальну вибірку для тренування та оцінки моделей.

На етапі підготовки даних було здійснено такі ключові дії:

- Завантаження та попередня обробка даних: Зображення були змінені до розміру 224x224 пікселів для забезпечення узгодженості з архітектурою YOLO. Для підвищення точності та стійкості моделей виконано нормалізацію значень пікселів у діапазон [0, 1].
- Аугментація зображень: Для збільшення обсягу даних були застосовані методи зміщення, повороту, розмиття, а також створено симуляції погодних умов (туман, дощ та шум). Це дозволило зробити модель стійкою до реальних умов роботи.
- Розподіл вибірки: Датасет було розподілено у співвідношенні 80% – тренувальні дані, 10% – валідаційні дані та 10% – тестові дані. Це дозволило забезпечити надійну оцінку продуктивності моделей на незалежних вибірках.




Рисунок 2 – Приклад зображення БПЛА з імітацією тепловізійного ефекту

Для оцінки ефективності моделей YOLOv1, YOLOv2 та YOLOv3 було проведено навчання та тестування на одному й тому ж датасеті. Оцінювання проводилося за метриками точності (Accuracy), повноти (Recall), точності позитивних передбачень (Precision) та F1-міри.

YOLOv1 – модель показала прийнятну точність із метрикою точності (Accuracy) 89.2% та F1-мірою 0.86. Проте було виявлено значну кількість хибно-позитивних спрацьовувань.

YOLOv2 – покращена архітектура YOLOv2 забезпечила збільшення точності до 93.7%, а F1-міра досягла 0.91. Використання глибшої архітектури дозволило зменшити кількість хибно-позитивних спрацьовувань.

YOLOv3 – найкраща версія із трьох із точністю 96.8%, F1-мірою 0.94 та Recall 0.95. Цей підхід показав високу здатність до узагальнення, навіть у зашумлених умовах та умовах з низькою видимістю.

Confusion matrix - YoloV1			
TARGET \ OUTPUT	Не БПЛА	БПЛА	SUM
Не БПЛА	251 39.7%	32 5.1%	283 88.7% 11.3%
БПЛА	39 6.2%	311 49.1%	350 88.9% 11.1%
SUM	290 86.6% 13.4%	343 90.7% 9.3%	633 562 / 633 88.8% 11.2%

Confusion matrix - YoloV3			
TARGET \ OUTPUT	Не БПЛА	БПЛА	SUM
Не БПЛА	278 43.9%	5 0.8%	283 98.2% 1.8%
БПЛА	7 1.1%	343 54.2%	350 98.0% 2.0%
SUM	285 97.5% 2.5%	348 98.6% 1.4%	633 621 / 633 98.1% 1.9%

Рисунок 3 – Матриці помилок моделей YoloV1 та YoloV3

Для оцінки продуктивності моделей було створено матриці помилок для кожної з них. Було помічено, що YOLOv3 забезпечує найменшу кількість помилкових класифікацій у порівнянні з YOLOv1 та YOLOv2. Окрім того, продуктивність YOLOv3 на тестових даних із зашумленими зображеннями виявилася значно кращою завдяки використанню більшої сітки та збільшенню глибини архітектури.

Результати дослідження показали, що вдосконалена архітектура YOLO є ефективним інструментом для виявлення БПЛА за тепловізійними зображеннями. Покращення у точності, швидкості та стійкості до шуму роблять її перспективною для використання у реальних системах моніторингу. Запропоновані методи можуть бути використані для подальшого розвитку технологій у сфері безпеки та моніторингу повітряного простору.

Висновки

У результаті проведеної роботи було розроблено та вдосконалено метод виявлення безпілотних літальних апаратів (БПЛА) за тепловізійними зображеннями із застосуванням глибокого навчання на основі архітектури YOLO. Основною метою роботи було підвищення точності та стійкості системи до зашумлених та змінних умов середовища, таких як туман, дощ та фонові перешкоди.

Було проведено аналіз сучасних підходів до виявлення БПЛА та існуючих моделей глибокого навчання для роботи з тепловізійними зображеннями. На основі цього розроблено та вдосконалено три моделі YOLO (YOLOv1, YOLOv2, YOLOv3), кожна з яких мала свою специфіку та покращення. Основними змінами стали збільшення кількості фільтрів у згорткових шарах, зміна розмірів сітки до 30x30 у YOLOv3, застосування регуляризації за допомогою Dropout та L2-регуляризації, що дозволило уникнути перенавчання. Для тренування та оцінювання моделей використовувався публічний датасет "shahed136-detect" із 8100 тепловізійними зображеннями, а також застосовано симуляцію погодних умов (туман, дощ, шум) для підвищення стійкості моделей до реальних умов експлуатації.

У процесі експериментів було встановлено, що YOLOv3 забезпечує найкращі результати з точністю 96.8% порівняно з YOLOv1, яка мала точність 89.2%. Модель продемонструвала високу здатність до роботи з шумними зображеннями та показала ефективність в умовах реальних перешкод. Застосування шару Dropout та Batch Normalization зробило модель стійкою до перенавчання та забезпечило здатність до узагальнення.

Таким чином, запропонована методика виявлення БПЛА за тепловізійними зображеннями показала свою ефективність. Отримані результати можуть бути основою для створення автоматизованих систем моніторингу повітряного простору та забезпечення безпеки об'єктів критичної інфраструктури.

Література

1. A. Isbir Turan A., Ali Tekiner M., Umut Akincioğlu N. MODERN USAGE AREAS OF UAV TECHNOLOGY. *Journal of Criminology and Criminal Law*. 2020. Vol. 58, no. 3. P. 111–117. URL: <https://doi.org/10.47152/rkkp.58.3.8>.
2. Most used algorithms for object detection. URL: <https://viso.ai/deep-learning/object-detection>
3. .Yang Z., Lian J., Liu J. Infrared UAV Target Detection Based on Continuous-Coupled Neural Network. *Micromachines*. 2023. Vol. 14, no. 11. P. 2113. URL: <https://doi.org/10.3390/mi14112113>.
4. Object detection from UAV thermal infrared images and videos using YOLO models / C. Jiang et al. *International Journal of Applied Earth Observation and Geoinformation*. 2022. Vol. 112. P. 102912. URL: <https://doi.org/10.1016/j.jag.2022.102912>
5. Kunze S., Saha B. Long Short-Term Memory Model for Drone Detection and Classification. 4th URSI Atlantic RadioScience Conference, Gran Canaria, Spain, 19–24 May 2024. Gent, Belgium, 2024. URL: <https://doi.org/10.46620/ursiatrasc24/zxfa5533> (date of access: 19.12.2024).
6. 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
7. YOLO-UAV: Object Detection Method of Unmanned Aerial Vehicle Imagery Based on Efficient Multi-scale Feature Fusion / C. Ma et al. *IEEE Access*. 2023. P. 1. URL: <https://doi.org/10.1109/access.2023.3329713>.
8. Learning Data Augmentation Strategies for Object Detection / B. Zoph et al. *Computer Vision – ECCV 2020*. Cham, 2020. P. 566–583. URL: https://doi.org/10.1007/978-3-030-58583-9_34.
9. Shaded 136 dataset. URL: <https://universe.roboflow.com/shahed136/shahed136-detect>

References

1. A. Isbir Turan A., Ali Tekiner M., Umut Akincioğlu N. MODERN USAGE AREAS OF UAV TECHNOLOGY. *Journal of Criminology and Criminal Law*. 2020. Vol. 58, no. 3. P. 111–117. URL: <https://doi.org/10.47152/rkkp.58.3.8>.
2. Most used algorithms for object detection. URL: <https://viso.ai/deep-learning/object-detection>
3. .Yang Z., Lian J., Liu J. Infrared UAV Target Detection Based on Continuous-Coupled Neural Network. *Micromachines*. 2023. Vol. 14, no. 11. P. 2113. URL: <https://doi.org/10.3390/mi14112113>.
4. Object detection from UAV thermal infrared images and videos using YOLO models / C. Jiang et al. *International Journal of Applied Earth Observation and Geoinformation*. 2022. Vol. 112. P. 102912. URL: <https://doi.org/10.1016/j.jag.2022.102912>
5. Kunze S., Saha B. Long Short-Term Memory Model for Drone Detection and Classification. 4th URSI Atlantic RadioScience Conference, Gran Canaria, Spain, 19–24 May 2024. Gent, Belgium, 2024. URL: <https://doi.org/10.46620/ursiatrasc24/zxfa5533> (date of access: 19.12.2024).
6. 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
7. YOLO-UAV: Object Detection Method of Unmanned Aerial Vehicle Imagery Based on Efficient Multi-scale Feature Fusion / C. Ma et al. *IEEE Access*. 2023. P. 1. URL: <https://doi.org/10.1109/access.2023.3329713>.
8. Learning Data Augmentation Strategies for Object Detection / B. Zoph et al. *Computer Vision – ECCV 2020*. Cham, 2020. P. 566–583. URL: https://doi.org/10.1007/978-3-030-58583-9_34.
9. Shaded 136 dataset. URL: <https://universe.roboflow.com/shahed136/shahed136-detect>

Додаток Б

Програмні коди

```

import os
import random
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
import tensorflow as tf
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Input, Conv2D, MaxPooling2D, Flatten, Dense, Dropout, BatchNormalization
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
from tensorflow.keras.utils import to_categorical

# Set seed for reproducibility
np.random.seed(42)
tf.random.set_seed(42)

# Path to the dataset (replace with the actual path to the 'shahed136-detect' dataset)
dataset_path = '/path/to/dataset'

# Parameters for model training
IMG_WIDTH = 224
IMG_HEIGHT = 224
BATCH_SIZE = 16
EPOCHS = 50
LEARNING_RATE = 0.001

# Load and preprocess images
def load_images_and_labels(dataset_path):
    images = []
    labels = []
    for label in ['shahed136', 'background']:
        label_path = os.path.join(dataset_path, label)
        for image_name in os.listdir(label_path):
            image_path = os.path.join(label_path, image_name)
            image = tf.keras.preprocessing.image.load_img(image_path, target_size=(IMG_HEIGHT, IMG_WIDTH))
            image_array = tf.keras.preprocessing.image.img_to_array(image) / 255.0 # Normalize image
            images.append(image_array)
            labels.append(0 if label == 'background' else 1) # 0 for background, 1 for BPLA

    return np.array(images), np.array(labels)

# Split dataset into train, validation, and test sets
def split_dataset(images, labels):
    x_train, x_temp, y_train, y_temp = train_test_split(images, labels, test_size=0.3, random_state=42)
    x_val, x_test, y_val, y_test = train_test_split(x_temp, y_temp, test_size=0.5, random_state=42)
    return x_train, x_val, x_test, y_train, y_val, y_test

# Define the YOLO-inspired model for thermal image detection
def build_yolo_model_v1(input_shape=(IMG_HEIGHT, IMG_WIDTH, 3)):
    inputs = Input(shape=input_shape)

    x = Conv2D(64, (7, 7), activation='relu', padding='same')(inputs)
    x = MaxPooling2D((2, 2))(x)
    x = BatchNormalization()(x)

    x = Conv2D(128, (3, 3), activation='relu', padding='same')(x)
    x = MaxPooling2D((2, 2))(x)
    x = BatchNormalization()(x)

    x = Flatten()(x)
    x = Dense(256, activation='relu')(x)
    x = Dropout(0.5)(x)

    outputs = Dense(1, activation='sigmoid')(x)

    model = Model(inputs=inputs, outputs=outputs)
    return model

def build_yolo_model_v2(input_shape=(IMG_HEIGHT, IMG_WIDTH, 3)):
    inputs = Input(shape=input_shape)

    x = Conv2D(64, (7, 7), activation='relu', padding='same')(inputs)
    x = MaxPooling2D((2, 2))(x)
    x = BatchNormalization()(x)

    x = Conv2D(128, (3, 3), activation='relu', padding='same')(x)
    x = MaxPooling2D((2, 2))(x)
    x = BatchNormalization()(x)

```

```

x = Conv2D(256, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

x = Conv2D(512, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

x = Flatten()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)

outputs = Dense(1,
activation='sigmoid')(x)

model = Model(inputs=inputs,
outputs=outputs)
return model

```

```

def
build_yolo_model_v3(input_shape=(IMG_HEIGHT
, IMG_WIDTH, 3)):
    inputs = Input(shape=input_shape)

    x = Conv2D(64, (7, 7),
activation='relu', padding='same')(inputs)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

    x = Conv2D(128, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

    x = Conv2D(256, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

```

```

x = Conv2D(512, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

x = Conv2D(1024, (3, 3),
activation='relu', padding='same')(x)
x = MaxPooling2D((2, 2))(x)
x = BatchNormalization()(x)

x = Flatten()(x)
x = Dense(2048, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)

outputs = Dense(1,
activation='sigmoid')(x)

model = Model(inputs=inputs,
outputs=outputs)
return model

```

```

# Compile, train, and evaluate models as
before, but for all three versions of YOLO
if __name__ == "__main__":
    images, labels =
load_images_and_labels(dataset_path)
x_train, x_val, x_test, y_train, y_val,
y_test = split_dataset(images, labels)

    for i, build_model in
enumerate([build_yolo_model_v1,
build_yolo_model_v2, build_yolo_model_v3]):
        print(f"Training YOLO_v{i+1}
model...")
        model = build_model()
        model = compile_model(model)
        history = train_model(model,
x_train, y_train, x_val, y_val)
        plot_training_results(history)
        evaluate_model(model, x_test,
y_test)
        y_pred = model.predict(x_test)
        plot_confusion_matrix(y_test,
y_pred)

```

Додаток В

Презентаційний матеріал

Метод розпізнавання БПЛА

за зображенням з тепловізора
засобами глибокого навчання

Виконав: студент групи КНм-23-1 Казіонов М.А.

Керівник кваліфікаційної роботи магістра: д.т.н., професор, завідувач кафедри
КН Бармак Олександр Володимирович



Безпілотні літальні апарати (БПЛА) активно використовуються у цивільних та військових сферах, що створює нові виклики для безпеки та моніторингу.

Однак, малі розміри дронів, використання стелс-технологій та складні погодні умови ускладнюють їх виявлення традиційними методами.

Саме тому застосування глибокого навчання для аналізу тепловізійних зображень дозволяє автоматизувати процес детекції БПЛА, підвищуючи точність та швидкість обробки даних навіть у зашумленому середовищі.

Мета і завдання роботи

Мета: Підвищення якості виявлення БПЛА на основі тепловізійних зображень за допомогою вдосконалених моделей YOLO

Завдання:

1. Провести аналіз предметної області та існуючих методів виявлення БПЛА
2. Вдосконалити архітектуру моделі YOLO для роботи з тепловізійними даними
3. Провести експериментальну перевірку моделей та порівняти ефективність
4. Оцінити точність на тестових даних

Об'єкт та Предмет дослідження

Об'єкт дослідження.

Процес виявлення БПЛА за аналізом тепловізійних зображень з використанням глибокого навчання.

Предмет дослідження.

Вдосконалені моделі глибокого навчання для детекції БПЛА за тепловізійними зображеннями.

Наукова новизна

В результаті проведеної роботи було отримано наступний результат:

- Удосконалено метод виявлення БПЛА за тепловізійними зображеннями із застосуванням **вдосконаленої архітектури YOLO**.

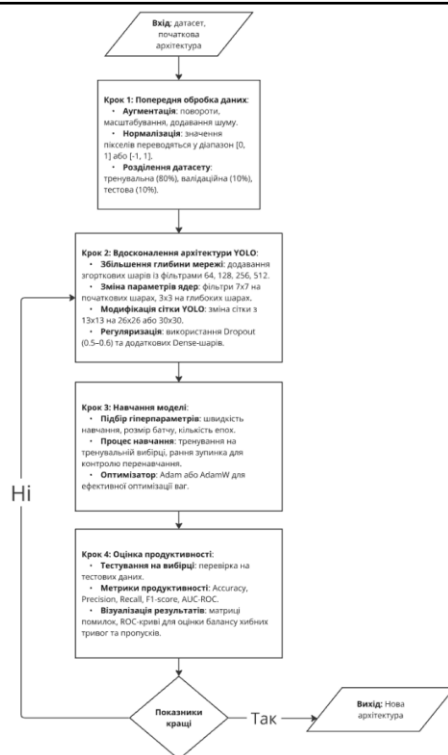
Покращення включають:

- Збільшення кількості згорткових шарів для кращого виділення ознак.
- Використання адаптивної сітки розміром **26x26** та **30x30** для детекції дрібних об'єктів.
- Регуляризація за допомогою **Dropout** (0.5–0.6) та L2-регуляризації для уникнення перенавчання.
- Реалізовано можливість роботи моделі в умовах низького контрасту, шуму та змінних погодних умов (туман, дощ, шум).

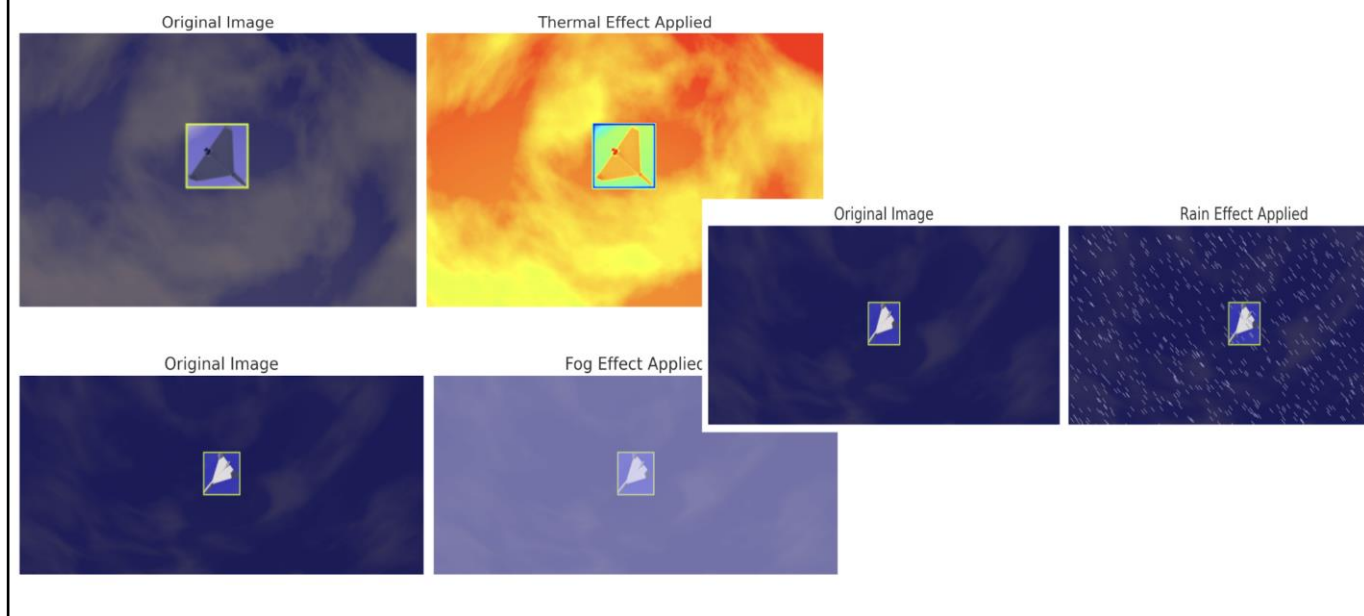
Найкращі показники роботи моделі:

- Для тепловізійних зображень точність виявлення склала **98.1%**, а кількість помилок знижена до **1.9%**.
- Модель продемонструвала стійкість до складних умов та високу ефективність в реальному часі.

Схема методу вдосконалення архітектури YOLO для виявлення БПЛА за тепловізійними зображеннями



Попередня обробка даних



Результати класифікації моделей

	Accuracy	Precision	Recall	F1-міра
Модель				
YOLO_v1	0.89	0.88	0.90	0.89
YOLO_v2	0.96	0.95	0.97	0.96
YOLO_v3	0.98	0.97	0.98	0.98

Модель YOLO_v3 показала найкращі результати. Вона забезпечує точне розпізнавання БПЛА навіть за низького контрасту, на зашумлених зображеннях та в умовах обмеженої видимості. Висока точність, recall та F1-міра свідчать про здатність моделі до узагальнення та ефективну роботу у реальних умовах

Висновки

Основні переваги вдосконаленої архітектури YOLO для виявлення БПЛА:

- **Покращена точність** завдяки збільшенню глибини моделі та оптимізації параметрів згорткових шарів;
- **Стійкість до різних умов середовища:** ефективне виявлення БПЛА при низькому контрасті, шумі, тумані та дощі;
- **Детекція дрібних об'єктів** за рахунок адаптивної сітки 26x26 та 30x30, що забезпечує точніше визначення координат;
- **Ефективність роботи у реальному часі**, що дозволяє застосовувати модель для оперативного моніторингу повітряного простору.

Недоліки та виклики вдосконаленої архітектури YOLO:

- **Високі обчислювальні ресурси:** навчання глибокої моделі потребує потужного GPU та значних часових витрат;
- **Складність налаштування параметрів:** підбір оптимальної сітки та гіперпараметрів вимагає проведення численних експериментів;
- **Чутливість до надмірної регуляризації**, що може призвести до втрати важливих ознак об'єкта на тепловізійних зображеннях.

Оприлюднення результатів

Казіонов М.А. МЕТОД РОЗПІЗНАВАННЯ БПЛА ЗА ЗОБРАЖЕННЯМ З ТЕПЛОВІЗОРА ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ.

Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 246-250

Довідка: ВХНУ ТН 26/11/24

Видання: Вісник Хмельницького національного університету. Технічні науки

Категорія фаховості видання: фахове видання України, у якому можуть публікуватися результати дисертаційних робіт на здобуття наукових ступенів доктора наук, кандидата наук та ступеня доктора філософії, категорії «Б» філософії, категорії «Б» (наказ МОН №1643 від 28.12.2019, наказ МОН №409 від 17.03.2020).

Напрямок – технічні науки за спеціальностями – 101, 121, 122, 123, 124, 125, 141, 151, 161, 172, 181, 182 (28.12.2019), спеціальності – 131, 132, 133 (17.03.2020)

Назва статті: ВДОСКОНАЛЕНИЙ МЕТОД ВИЯВЛЕННЯ БПЛА ЗА ТЕПЛОВІЗІЙНИМИ ЗОБРАЖЕННЯМИ НА ОСНОВІ МОДЕЛІ ГЛИБОКОГО НАВЧАННЯ YOLO

Автори: Казіонов Максим, Скрипник Тетяна, Пасічник Олександр, Вознюк Леонід (Хмельницький національний університет)

Номер, у який прийнято статтю: №1 до друку орієнтовно буде рекомендовано до 30 січня 2025 року.

26.11.2024

Начальник відділу
інтелектуальної власності та трансферу технологій Ю.В.Кравчик



Anti-Plagiarism v-15.257

Максимальне співпадіння з одним документом 2.0%

Словники перевірки: en_US, ru_RU, ua_UA. **Помилки в документах: 13%**

ID: 161265 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання Додано в БД: 2024-12-19 Автора: Максим КАЗІОНОВ Керівники: Олександр БАРМАК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	102549	1523	3794 (4%)	57 (4%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Максим КАЗІОНОВ

Співавтор:

Назва: Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання

Науковий керівник: Олександр БАРМАК, д.т.н., проф.

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 0.9%

Коефіцієнт подібності 2: 0.4%

Мікропробіли: 0

Заміна букв: 1

Інтервали: 0

Білі знаки: 1

Дата створення звіту: 2024-12-19 10:09:55.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

Дата

16.12.2024

експерт

П. П. Петровський

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ
КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ МАГІСТРА ДО ЗАХИСТУ ЗА
РЕЗУЛЬТАТАМИ АНАЛІЗУ ЗВІТУ ПОДІБНОСТІ

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованого системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання

Автор: Максим КАЗІОНОВ

Спеціальність: 122 – Компютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: д.т.н., професор, зав. кафедри КН Олександр БАРМАК

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом. Робота приймається до захисту.	відповідає
2	Виявлені запозичення не є плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота приймається до захисту, але має бути відкоригована. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	

Підтвердження:

Запозичення, виявлені в роботі, є допустимими і не є плагіатом, оскільки:

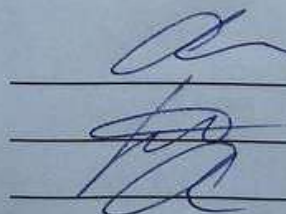
- 1) за програмою Anti-Plagiarism виявлені 2% запозичень вказують на відомі терміни.
- 2) За програмою StrikePlagiarism виявлені запозичення (КП1=0.93% та КП2=0.49%) є фрагментарними – містять поширені конструкції та схеми (у роботі вказані посилання на ці джерела), загальновідомі терміни, скорочення та визначення.

Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Керівник роботи

Гарант ОП

Завідувач кафедри КН



О. В. Бармак

Р. О. Багрій

О. В. Бармак



**ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу магістра**

гр. КНм-23-1 Максима КАЗІОНОВА за темою: Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання

1. Актуальність теми

Сучасні досягнення у сфері комп'ютерних наук, зокрема у галузі штучного інтелекту та глибокого навчання, активно інтегруються у різноманітні галузі. Одним із напрямків, де ці технології демонструють значний потенціал, є виявлення безпілотних літальних апаратів (БПЛА). Цей напрямок є надзвичайно важливим завданням через активне використання дронів як у цивільній, так і у військовій сферах. Завдяки широкій доступності та зростанню функціональних можливостей БПЛА їх застосування поширюється для різноманітних цілей, у тому числі для незаконної діяльності, такої як незаконне спостереження, контрабанда та порушення безпеки об'єктів критичної інфраструктури. У контексті сучасних умов держави, що перебуває в стані війни, завдання швидкого та точного виявлення БПЛА стає критично важливим для забезпечення безпеки та захисту стратегічних об'єктів.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тема кваліфікаційної роботи студента повністю відповідає предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до кваліфікаційної роботи магістра. Робота вирішує науково-прикладну задачу у сфері комп'ютерних наук (а саме застосування інтелектуальних методів обробки інформації (моделей глибокого навчання) до виявлення безпілотних літальних апаратів (БПЛА)). У роботі проведено дослідження, яке розвиває існуючі знання та процедури.

3. Професійні та особистісні якості магістранта

Під час опрацювання магістерської роботи магістрант продемонстрував такі професійні якості, як вміння ставити задачі, проводити їх аналіз і декомпозицію, здійснювати підбір і застосування наукових методів для вирішення часткових завдань дослідження, вміння знаходити причинно-наслідкові залежності та формувати висновки, вміння застосовувати сучасні інформаційні технології. Крім цього, магістрант проявив такі особистісні якості, як наполегливість, відповідальність, добросовісність, працелюбність, коректність.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

У ході роботи магістрант проявив достатній ступінь самостійності. Зокрема, ним особисто було: проведено аналіз предметної області для проблеми виявлення БПЛА на тепловізійних зображеннях; проаналізовано існуючі публікації щодо ідентифікації БПЛА

на зображеннях; досліджені існуючі моделі глибокого навчання для виявлення об'єктів на зображеннях з тепловізора; вдосконалено метод розпізнавання БПЛА за допомогою моделей глибокого навчання; підготовлено відповідний набір даних для донавчання нейронної мережі; донавчена нейронна мережа для виявлення БПЛА на тепловізійних зображеннях; розроблено застосунок для валідації запропонованого методу; оцінена якість та точність запропонованого методу за допомогою статистичних показників та проведено порівняння з іншими підходами.

5. Наукова новизна та оригінальність запропонованих підходів

Магістерська робота характеризується наявністю наукової новизни. Відповідні положення сформульовані коректно та відображають її сутність.

Результати магістерської роботи достатньо оприлюднені та апробовані. Зокрема, матеріали роботи доповідалися на науковій конференції «Актуальні проблеми комп'ютерних наук».

6. Ступінь оволодіння методами дослідження

У магістерській роботі магістрантом реалізовано комплексний підхід щодо застосування загальнонаукових і спеціальних методів наукових досліджень. Зокрема, використано методи застосування згорткової нейронної мережі, сучасних інформаційних технологій, вищої математики, теорії ймовірностей і математичної статистики. Під час їх застосування до вирішення окремих завдань дослідження магістрант продемонстрував достатній ступінь володіння ними.

7. Повнота та якість розкриття теми роботи

Тема роботи розкрита достатньо повно та якісно. Визначена мета роботи досягнута.

8. Логічність, послідовність, аргументованість, літературна грамотність викладу матеріалу

Викладення матеріалу магістерської роботи є достатньо логічним, послідовним і має достатній рівень аргументації. Робота написана літературною мовою, граматична якість викладення матеріалу роботи задовільна.

9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Робота має теоретико-прикладний характер. Результати роботи дозволяють виявляти БПЛА за зображеннями з тепловізора із застосуванням методів глибокого навчання на основі архітектури YOLO.

10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота

Рекомендую допустити роботу до захисту.

Кваліфікаційна робота заслуговує на оцінку «Відмінно».

Науковий керівник _____



д.т.н., проф. Олександр Бармак



ВІДГУК ОПОНЕНТА

на кваліфікаційну роботу магістра

гр. КНМ-23-У Максима КАЗІОНОВА за темою: Метод розпізнавання БПЛА за зображенням з тепловізора засобами глибокого навчання.

1. Актуальність обраної теми

Обрана магістрантом тема є достатньо актуальною на даний час, особливо з урахуванням тенденцій щодо розвитку штучного інтелекту. Актуальність обраної теми достатньо обґрунтована в роботі.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тема кваліфікаційної роботи студента повністю відповідає предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до кваліфікаційної роботи магістра. Робота вирішує науково-прикладну задачу у сфері комп'ютерних наук (а саме застосування інтелектуальних методів обробки інформації (моделей глибокого навчання) до класифікації комах-шкідників у зерносховищах). У роботі присутнє дослідження, яке розвиває існуючі підходи, та отримані нові результати, які за певними показниками – вищі, ніж в аналогічних підходах.

3. Повнота розкриття мети та завдань дослідження

Часткові завдання дослідження сформульовані коректно та повністю відповідають меті роботи.

4. Наявність наукової новизни

Магістерська робота характеризується наявністю наукової новизни. Положення наукової новизни сформульовані коректно та відображають їх сутність.

Матеріали магістерської роботи апробовані на науковій конференції «Актуальні проблеми комп'ютерних наук».

5. Зміст кожного розділу роботи

У першому розділі – «Аналіз сучасного стану у використанні методів глибокого навчання для виявлення БПЛА» автором проведено огляд предметної області, сучасних підходів до виявлення безпілотних літальних апаратів, особливостей аналізу акустичних, радіолокаційних та тепловізійних сигналів. Також розглянуто існуючі архітектури глибокого навчання, зокрема згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN) та моделі YOLO.

У другому розділі – «Удосконалення методу виявлення БПЛА за допомогою архітектури YOLO» магістрантом удосконалено метод детекції БПЛА шляхом оптимізації архітектури YOLO для роботи з тепловізійними зображеннями. Зокрема, збільшено глибину згорткових шарів, адаптовано сітку детекції до 26x26 та 30x30, реалізовано регуляризацію за допомогою Dropout та використано функцію втрат SIOU для покращення точності визначення межових рамок.

У третьому розділі – «Реалізація вдосконаленого методу та його експериментальна перевірка» автором розроблено програмну реалізацію вдосконалених моделей YOLOv1, YOLOv2 та YOLOv3 з використанням бібліотек TensorFlow, Keras та OpenCV. Проведено навчання моделей на підготовленому тепловізійному датасеті та здійснено їх тестування у різних умовах, включно з туманом, дощем та шумами.

У четвертому розділі – «Оцінка ефективності вдосконаленого методу» магістрантом проведено оцінку ефективності вдосконаленої архітектури YOLO на основі метрик точності (Accuracy), повноти (Recall), точності передбачень (Precision) та F1-міри. В якості порівняння було обрано існуючі базові моделі YOLOv1 та YOLOv2. Результати продемонстрували перевагу запропонованої YOLOv3 з точністю до 98.1%, значно зменшеною кількістю помилкових тривог та підвищеною стійкістю до несприятливих умов.

6. Ступінь розкриття теми роботи

Тема роботи розкрита достатньою мірою та мета досягнута.

7. Якість оформлення кваліфікаційної роботи

Робота написана літературною мовою та оформлена згідно відповідних вимог достатньо якісно.

8. Недоліки кваліфікаційної роботи

Разом з тим, у роботі є і певні недоліки. Так, у роботі не було проведено детального аналізу часу обчислень для вдосконалених моделей YOLO на пристроях з обмеженими обчислювальними ресурсами, що є важливим фактором для їх практичного використання у реальних умовах.

Проте зазначений недолік загалом не впливає на комплексну позитивну оцінку роботи.

9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота.

Рекомендую допустити роботу до захисту. Кваліфікаційна робота заслуговує на оцінку «Відмінно».

Опонент (прізвище, ім'я, по батькові, посада, місце роботи)

Мартинюк Валерій Володимирович, зав. кафедр. АСІТ РП

«10» 12 2024 р.

(підпис)