

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет інформаційних радіотехнологій та технічного захисту інформації
(повна назва)

Кафедра медіаінженерії та інформаційних радіоелектронних систем
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

рівень вищої освіти другий (магістерський)
(позначення документа)

Методи виявлення безпілотних літальних апаратів

(тема)

Виконав:

студент 2 курсу, групи СТМм-21-1
Владислав ВОРОПАЄВ

(прізвище, ініціали)

Спеціальність 171 Електроніка

(код і повна назва спеціальності)

Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи, технології і комп'ютерні засоби мультимедіа
(повна назва освітньої програми)

Керівник проф. Олег СИТНИК
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

Володимир КАРТАШОВ
(прізвище, ініціали)

2022 р.

Харківський національний університет радіоелектроніки

Факультет Інформаційних радіотехнологій та технічного захисту інформації

Кафедра Медіаінженерії та інформаційних радіоелектронних систем

Рівень вищої освіти другий (магістерський)

Спеціальність 171 Електроніка

(код і повна назва)

Тип програми освітньо-професійна

(освітньо-професійна або освітньо-наукова)

Освітня програма "Системи, технології і комп'ютерні засоби мультимедіа"

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

« ____ » _____ 20 ____ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

Студентові Воропасву Владиславу Юрійовичу

(прізвище, ім'я, по батькові)

1. Тема роботи Методи виявлення безпілотних літальних апаратів

затверджена наказом по університету від " 21 " 11 2021 р. № 1503СТ

2. Термін подання студентом роботи 08.12.2021 р.

3. Вихідні дані до проекту (роботи) Виконати огляд і аналіз існуючих методів виявлення і спостереження БПЛА. Проаналізувати відомі методи розпізнавання БПЛА за даними оптичного локаційного інформаційного каналу. Розробити структурну схему оптичної системи виявлення БПЛА, вибрати детектор виявлення, мову програмування. Провести розрахунок параметрів оптичних камер. Розробити алгоритм рішення задачі виявлення БПЛА за результатами обробки відеозображення. Проаналізувати алгоритми підвищення можливості виявлення та відстеження БПЛА

4. Перелік питань, що потрібно опрацювати в роботі

ВСТУП

1. Аналітичний огляд методів виявлення БПЛА

2. Аналіз виявлення та відстеження БПЛА за допомогою оптичних камер

3. Розроблення алгоритму розв'язання задачі виявлення БПЛА

4. Аналіз алгоритмів підвищення можливості виявлення та відстеження БПЛА

ВИСНОВКИ

ПЕРЕЛІК ПОСИЛАНЬ

ДОДАТКИ

5. Перелік графічного матеріалу із зазначенням обов'язкових креслеників, схем, плакатів, комп'ютерних ілюстрацій:

Принцип дії алгоритму YOLO – 3 арк


Виявлення БПЛА оптичним інформаційним каналом – 1 арк

Алгоритм виявлення БПЛА – 5 арк

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термин виконання етапів роботи	Примітка
1.	Аналітичний огляд методів виявлення БПЛА	21.11.22–28.11.22	
2.	Аналіз виявлення та відстеження БПЛА за допомогою оптичних камер	21.11.22–28.11.22	
3.	Розроблення алгоритму розв'язання задачі виявлення БПЛА	23.11.22–02.12.22	
4.	Аналіз алгоритмів підвищення можливості виявлення та відстеження БПЛА	01.12.21–05.12.22	
5.	Графічна частина роботи	07.12.21–08.12.22	
6.	Перевірка керівником	07.12.22-08.12.22	
7.	Перевірка на академічний плагіат	08.12.22-09.12.22	
8.	Перевірка завідувачем кафедри, рецензування	09.12.22-10.12.22	

Дата видачі завдання _____ 21.11.2021 р.

Студент _____  _____ Владислав ВОРОПАЄВ
(підпис)

Керівник роботи _____ проф. Олег СИТНИК
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи має: 74 с., 25 рис., 4 табл., 3 додатків, 80 джерел.

БПЛА, КАМЕРА, ОПТИЧНІ СИСТЕМИ, АЛГОРИТМ, PYTHON, ФУНКЦІЯ, БАЗА ДАНИХ, НЕЙРОННІ МЕРЕЖІ, ДЕСКРИПТОР, YOLO

Об'єкт дослідження – безпілотні літальні апарати.

Предмет дослідження – виявлення безпілотних літальних апаратів.

Мета кваліфікаційної роботи – розробити алгоритм програми для виявлення безпілотних літальних апаратів.

Методи дослідження – теоретичний аналіз, розробка алгоритмів для рішення задачі.

У даній роботі наведено класифікацію методів виявлення безпілотних літальних апаратів, детальний огляд і аналіз існуючих методів виявлення і спостереження БПЛА, проаналізовано відомі методи розпізнавання БПЛА за даними оптичного локаційного інформаційного каналу. Проведено розрахунок параметрів оптичних камер. Розроблено структурну схему оптичної системи виявлення БПЛА, вибрано детектор виявлення, мову програмування. Розроблено алгоритм рішення задачі виявлення БПЛА за результатами обробки відеозображення. Проведено аналіз алгоритмів підвищення можливості виявлення та відстеження БПЛА.

ABSTRACT

The explanatory note of the qualification work has: 74 pages, 25 figures, 4 tables, 3 appendices, 80 sources.

UAV, CAMERA, OPTICAL SYSTEMS, ALGORITHM, PYTHON, FUNCTION, DATABASE, NEURAL NETWORKS, DESCRIPTOR, YOLO

The object of research is unmanned aerial vehicles.

The subject of the research is the detection of unmanned aerial vehicles.

The meta-qualification work of the work is to develop a program algorithm for the detection of unmanned aerial vehicles.

Research methods – theoretical analysis, development of algorithms for problem solving.

This paper provides a classification of UAV detection methods, a detailed review and analysis of existing BPLA detection and surveillance methods, and an analysis of known BPLA recognition methods based on optical location information channel data. The parameters of the optical cameras were calculated. The structural diagram of the UAV optical detection system was developed, the detection detector and the programming language were selected. An algorithm for solving the UAV problem based on the results of video image processing has been developed. An analysis of algorithms for increasing the capabilities and tracking of UAVs was carried out.

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

БПЛА - безпілотний літальний апарат
RCS - Radar Cross Section
m-D - micro-Doppler
STFT - Short Time Fourier Transform
CNN - Convolutional Neural Networks
DNN - Deep Neural Networks
CASR - Computational Auditory Scene Recognition
GPU - Graphic Processing Units
MFCC - Mel-Frequency Cepstral Coefficients
SVM - Support Vector Machine
FPS - Frames Per Second
R-CNN - Region-Based Convolutional Neural Network
YOLO - You Only Look Once
SSD - Single-Shot Multi-box Detector
CSP - Cross-Stage Partial
CmBN - Cross mini-Batch Normalization
SAT - Self-Adversarial Training
NMS - Non Max Suppression
IoU - Intersection over Union
AP - Average Precision
BoF - Bag of Freebies
BoS - Bag of Specials
FL - Focal loss
CE - Cross Entropy
MS COCO - Microsoft Common Objects in Context
FoV - Field of View
ML - Machine Learning
AI - Artificial Intelligence
CBL - Convolution with Batch normalization and Leaky ReLU
SPP - Spatial Pyramid Pool

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	6
Зміст	7
ВСТУП	9
1 АНАЛІТИЧНИЙ ОГЛЯД МЕТОДІВ ВИЯВЛЕННЯ БПЛА.....	12
1.1 Огляд та аналіз існуючих датчиків радіолокації	12
1.1.1 Традиційні методи виявлення та класифікації БПЛА для радіолокаційних датчиків.....	12
1.1.2 Методи виявлення та класифікації радіолокаційних датчиків на основі глибокого навчання.....	14
1.2 Огляд та аналіз існуючих оптичних датчиків	16
1.2.1 Гіперспектральні датчики зображення	17
1.3 Огляд та аналіз існуючих термодатчиків	19
1.4 Огляд та аналіз існуючих акустичних датчиків.....	20
1.5 Огляд та аналіз існуючих лидарних датчиків	23
1.6 Огляд та аналіз існуючих радіосенсорних датчиків датчиків	25
2 АНАЛІЗ ВИЯВЛЕННЯ ТА ВІДСТЕЖЕННЯ БПЛА ЗА ДОПОМОГОЮ ОПТИЧНИХ КАМЕР.....	27
2.1 Виявлення та відстеження БПЛА	27
2.2 Двоетапні детектори об'єктів	27
2.3 Одноетапні детектори об'єктів.....	29
2.3.1 Алгоритм YOLO.....	30
2.4 Матеріали та методи	35
2.4.1 Bag of freebies	35
2.4.2 Bag of Specials.....	36
2.4.3 CSPDarknet5	37

	8
2.5 Розрахунок параметрів камери	39
2.6 Основна архітектура системи	42
3 РОЗРОБЛЕННЯ АЛГОРИТМУ РОЗВ'ЯЗАННЯ ЗАДАЧІ ВИЯВЛЕННЯ БПЛА	45
3.1 Вибір програмного забезпечення	45
3.2 Алгоритм програми виявлення та відстеження БПЛА	48
3.3 Результат роботи програми виявлення та відстеження БПЛА.....	55
4 АНАЛІЗ АЛГОРИТМІВ ПІДВИЩЕННЯ МОЖЛИВОСТІ ВИЯВЛЕННЯ ТА ВІДСТЕЖЕННЯ БПЛА	57
4.1 Підвищення можливості виявлення та відстеження БПЛА	57
4.2 Додання тепловізійних та камер нічного бачення.....	57
4.3 Виявлення та відстеження БПЛА за допомогою поєднання акустичних даних і даних зображення	58
4.3.1 Виділення ознак.....	59
4.3.2 Моделі глибокого навчання	60
ВИСНОВКИ.....	62
ПЕРЕЛІК ПОСИЛАНЬ.....	65
Додатки.....	75
ДОДАТОК А.....	76
ДОДАТОК Б	79
ДОДАТОК В.....	87

ВСТУП

Безпілотні літальні апарати (БПЛА) стають частиною повсякденного життя громадян. БПЛА довели свою автономність і гнучкість у різноманітних середовищах і завданнях, і вони приносять постійне зростання ринку завдяки зростаючій кількості корисних програм. Сьогодні БПЛА використовуються від державних органів для виконання таких завдань, як охорона кордонів, правоохоронна діяльність і спостереження за лісовими пожежами, до комерційних завдань, які використовуються цивільними особами, наприклад у будівництві, сільському господарстві, страхуванні, інтернет-зв'язку та загальному кінематографі. Однак ця універсальність і простота використання також сприяє швидкому розвитку загроз з боку зловмисників, які можуть використовувати БПЛА для злочинної діяльності, перетворюючи їх на пасивні або активні загрози. В'язниці, аеропорти, спортивні об'єкти, громадські будівлі та інші чутливі об'єкти піддаються серйозній небезпеці, і правильне розуміння безлічі викликів, які представляють БПЛА, є ключовим для ефективного захисту критичної інфраструктури та громадян. Необхідність захисту від загроз з боку БПЛА принесла прогрес у застосуванні протидії БПЛА [1-9].

Останні досягнення в рішеннях протидії БПЛА (с-БПЛА) пропонують системи [10], які включають мультисенсорний арсенал для надійної підтримки ситуаційної обізнаності та захисту критичної інфраструктури або важливої події. Ці програми включають численні інтегровані датчики для виявлення загрози, головним чином за допомогою радарних та/або електрооптичних/теплових (EO-IR) датчиків і рідше за допомогою акустичних, радіочастотних (RF) та LiDAR датчиків. Як електрооптичні, так і тепловізійні камери пропонують високі можливості класифікації з точною локалізацією та визначенням дальності, коли використовується кілька датчиків. Електрооптичні камери, як правило, дешеві, а теплові камери дорожчі, але обидві вони чутливі до параметрів навколишнього середовища.

З іншого боку, акустичні датчики, як правило, стійкі до умов навколишнього середовища, але їх обмежений ефективний діапазон робить їх менш поширеним варіантом. Тривимірні хмари точок, отримані датчиками LiDAR (виявлення світла та визначення дальності), виявилися хорошою основою для виявлення об'єктів, наприклад, людей, автомобілів або кораблів. Доступні сьогодні системи сканування LiDAR представляють собою компроміс між прийнятною роздільною здатністю, реальною частотою оновлення та полем огляду, але БПЛА зазвичай мають малий поперечний переріз лазерного радара, низька роздільна здатність більшості датчиків LiDAR робить їх непридатними для виявлення БПЛА. Нарешті, радіолокаційні датчики є найпоширенішим рішенням для частини виявлення через точну локалізацію та велику дальність у поєднанні з гідними можливостями класифікації, які працюють незалежно від налаштувань середовища.

Неавтоматичні системи, до складу яких входять кінцеві користувачі, які відстежують і підтверджують класифікаційну мітку виявленої цілі, як правило, мають найкращі можливості класифікації, але зазвичай мають високі експлуатаційні витрати через навчання персоналу та обслуговування системи. Система може бути повністю автоматичною завдяки використанню останніх досягнень у техніці об'єднання даних без значних компромісів у можливостях класифікації. З цією метою виникає багато складних завдань, таких як виявлення об'єктів, класифікація, відстеження об'єктів в автономному режимі. В останні роки дослідники використовували методології глибокого навчання для вирішення цих завдань для загальних об'єктів і досягли помітного прогресу, однак застосування глибокого навчання для виявлення та класифікації БПЛА вважається новою концепцією.

Повне рішення протидії БПЛА має бути здатним автоматично виявляти вторгнення потенційно кількох БПЛА, ідентифікувати їхній тип і можливе корисне навантаження, а також відстежувати їхній рух послідовно всередині зони спостереження.

Основною метою кваліфікаційної роботи є аналіз методів виявлення безпілотних літальних апаратів.

Для досягнення цієї цілі були поставлені такі задачі:

- Проведення аналізу предметної області;
- Проведення аналізу методів виявлення та відстеження БПЛА за допомогою оптичних камер;
- Проведення розрахунків параметрів камери;
- Розробка структури системи виявлення та відстеження БПЛА;
- Створення алгоритму для виявлення безпілотних літальних апаратів;
- Розробка та створення програмного коду на основі алгоритму для виявлення безпілотних літальних апаратів;
- Проведення аналізу алгоритмів підвищення можливості виявлення та відстеження бпла.

1 АНАЛІТИЧНИЙ ОГЛЯД МЕТОДІВ ВИЯВЛЕННЯ БПЛА

1.1 Огляд та аналіз існуючих датчиків радіолокації

Радар є традиційним датчиком для виявлення літальних апаратів. Порівняно з іншими системами виявлення, радар, в принципі, єдиний, який здатний забезпечити виявлення на великих відстанях (від кількох кілометрів до десятків кілометрів, залежно від радіолокаційного поперечного перерізу (radar cross section (RCS)) цілі [11]) і практично не змінює роботу при несприятливому освітленні та погодних умовах. Однак радіолокаційні датчики, призначені для виявлення стандартних (пілотованих) літальних апаратів з відносно великою RCS і високою швидкістю, не підходять для виявлення дуже малих і повільно рухомих об'єктів, що летять на низькій висоті, таких як БПЛА [12]. Крім того, БПЛА мають спільні ключові характеристики з птахами, і надійна класифікація між двома цілями є ще одним ключовим викликом, який слід розглянути. Тому для цього вимогливого застосування були створені спеціально розроблені архітектури радарів. Типовий конвеєр виявлення та класифікації полягає у виконанні алгоритмів обробки радіолокаційних сигналів для виявлення цілей і виділення властивих ознак з обробленого сигналу для автоматичної класифікації за допомогою алгоритму машинного навчання [13]. Конвеєри на основі глибокого навчання включають обробку необроблених даних до більш значущого представлення, придатного як вхідні дані для мережі глибокого навчання для автоматичного виявлення та класифікації цілей [14].

1.1.1 Традиційні методи виявлення та класифікації БПЛА для радіолокаційних датчиків

Методи на основі мікродоплера. Найбільш часто використовуваною характеристикою радіолокаційного сигналу для автоматичної класифікації

цілей є мікродоплерівська (micro-Doppler (m-D)) сигнатура [15]. Сигнатура m-D використовувалася для автоматичної класифікації цілей, таких як класифікація рухомих цілей [16], виявлення кораблів [17], розпізнавання ходи людини [18] і класифікація діяльності людини [19]. Останніми роками це була активна область досліджень у сфері застосування радарів проти БПЛА. Власні рухи цілей можуть описувати обертання лопатей гвинта гвинтокрилого БПЛА або гелікоптера, рушійної турбіни реактивного літака, помаху крил птаха та можуть бути статистично описані радіолокаційною сигнатурою m-D [20,21].

Серед перших, хто використав сигнатуру m-D для класифікації БПЛА, були [20,21]. Автори запропонували створити m-D сигнатуру за допомогою спектрограми (Short Time Fourier Transform (STFT)) у [20] та за допомогою кепстрограми [22]. Вони зосередили свої дослідження на процесі виділення ознак, щоб отримати ключові характеристики з радіолокаційного сигналу, такі як швидкість обертання, швидкість на кінці лопаті, діаметр ротора та кількість роторів для класифікації між різними безпілотними літальними апаратами типу гвинтокрила.

Крім типових радарів з однією антеною для приймача і передавача, також використовуються мультистатичні радари з більш ніж однією антеною. У [23] автори запропонували надати наивному Байєсу та класифікатору дискримінантного аналізу [24] функції, засновані на доплерівському центроїді та центроїді пропускнуї здатності m-D сигнатур. Експерименти включали реальні вимірювання вертокрилого БПЛА, як завантаженого, так і розвантаженого з потенційним корисним навантаженням.

Радари спостереження та методи на основі руху. Радар спостереження працює з обертовою антеною для виявлення та відстеження кількох цілей. Він призначений для постійного сканування простору для пошуку нових цілей [13]. Через те, що радар постійно сканує простір, час, який використовується для виявлення цілі, як правило, дуже малий, що не дозволяє отримати m-D сигнатуру [25]. Отже, класифікація виявлених цілей

виконується за ознаками, що описують сигнатуру цілі, наприклад RCS або рух цілі.

На основу радару спостереження використовується метод оцінки імовірнісної моделі руху, заснований на обчисленні дисперсії у часовій області ймовірності появи моделі для класифікації між БПЛА та птахами за даними, що надходять із радара. Інформацію про напрямок руху, швидкість і положення цілі використовується для побудови моделей оцінки руху за допомогою алгоритму згладжування на основі відстеження фільтра Калмана, щоб збільшити розрив між оцінками частоти перетворення моделі цілі для птахів і БПЛА. Вони перевірили свій підхід на змодельованих і реальних даних, показавши багатообіцяючі результати [26].

1.1.2 Методи виявлення та класифікації радіолокаційних датчиків на основі глибокого навчання

За останні кілька років методології, засновані на глибокому навчанні, були найуспішнішими підходами для багатьох завдань із зображеннями, відео та аудіо. Однак типові системи на основі глибокого навчання зазвичай вимагають великої кількості даних, які легко створюються та є широко доступними для звичайних датчиків, таких як камери та мікрофони, але їх мало для радарних датчиків. Крім того, радіолокаційні дані може виконувати лише фахівець у цій галузі. Нарешті, отримання необроблених даних від радіолокаційного датчика може бути недостатньо, оскільки для модифікації подання даних зазвичай потрібна складна обробка радіолокаційного сигналу з метою вилучення просторово-часової та внутрішньої інформації, яка матиме значення для навчання архітектури глибокого навчання. Незважаючи на всі ці проблеми, в останні роки спостерігається збільшення використання радіолокаційних даних для глибокого навчання.

Першою роботою, в якій використовувалися згорткові нейронні мережі (Convolutional Neural Networks (CNN)) для навчання безпосередньо на

спектрограмах сигнатур m-D і класифікації БПЛА, була [27]. Автори використовували GoogleNet [28] і навчили його за допомогою спектрограм реальних вимірювань БПЛА з радіолокатора безперервної частотної модуляції. Крім того, вони запропонували метод усунення недоліків m-D сигнатури шляхом об'єднання її з представленням її частотної області, а саме діаграмою швидкості каденції. Вони успішно провели випробування в двох різних середовищах з двома дронами, які літали під різною кількістю працюючих двигунів і під різними кутами.

Радарна система має перевагу у великій дальності виявлення та хороших можливостях класифікації за допомогою мікродопплера, але має і деякі недоліки, такі як низька вертикальна дальність виявлення на близькій відстані та високі вимоги до розміщення датчиків. Радарній системі потрібен чіткий огляд у повному діапазоні виявлення 360 градусів, навіть верхівки дерев можуть засліпити датчик відлунням.

Для використання радіолокаційного виявлення в принципі є два варіанти: або їх можна використовувати як класифіковане виявлення, яке передбачає, що існує висока впевненість, що виявлений дрон є справжнім дроном, а атрибути виявлення, головним чином позиція, швидкість і напрямок, поєднуються з секретними виявленнями того самого дрона, зробленими іншими сенсорними станціями. Або інший варіант полягає у використанні виявлення радару для наведення інших датчиків, наприклад оптичних. Радарна система забезпечує нижчий рівень помилкових спрацьовувань завдяки інтегрованій класифікації БПЛА, ніж CNN.

Слід зазначити, що радар працює в 2D-просторі, тобто у вихідних даних радару немає інформації про висоту, лише приблизна оцінка за допомогою вертикального кута променя та відстані. Геометрично це не проблема на великих відстанях. На ближній і середній відстані мале вертикальне поле зору радару є недоліком. Але в загальній системі це компенсується поєднанням використанням радару та системи візуального оптичного виявлення.

1.2 Огляд та аналіз існуючих оптичних датчиків

Завдяки нещодавнім досягненням нейронних мереж і алгоритмів глибокого навчання, оптичні дані, є цінним джерелом інформації, для виявлення, відстеження та класифікації БПЛА. Більшість систем, які використовують глибокі нейронні мережі (deep neural networks (DNN)) для визначення того, чи об'єкт є БПЛА, використовують загальну архітектуру виявлення об'єктів із потужною DNN як моделлю класифікації для БПЛА [29]. З цією метою DNN попередньо навчаються загальним даним, щоб їх можна було точно налаштувати за допомогою даних БПЛА, таким чином регулюючи їхні параметри для розпізнавання дронів. Деякі приклади даних БПЛА, отриманих за допомогою стандартної візуальної оптичної камери, представлені на рис 1.1 [30].



Рисунок 1.1 – Зображення з БПЛА отриманих за допомогою оптичної камери [30]

Було проведено багато експериментів з використанням Faster-RCNN (VGG-16 [32], ZF-net [33] тощо) для цілей виявлення БПЛА [31]. Дослідники прийшли до висновку, що VGG-16 працює найкраще серед інших варіантів базової DNN. Крім того, вони стверджували, що існування птахів може поставити під сумнів продуктивність детектора через збільшення хибнопозитивних виявлень. Щоб вирішити цю проблему, вони запропонували, щоб птахи не залишалися поміченими в процесі навчання, а скоріше вони повинні бути частиною процесу навчання як окремий клас, щоб

стимулювати мережу до вивчення більш детальних моделей між БПЛА та птахами, таким чином розрізняти їх більш ефективно.

1.2.1 Гіперспектральні датчики зображення

Датчики гіперспектрального зображення збирають інформацію як набір зображень по всьому електромагнітному спектру. Кожне зображення представляє вузький діапазон довжин хвиль електромагнітного спектру, також відомий як спектральна смуга. Ці зображення об'єднуються, щоб сформувати тривимірний (x, y, λ) гіперспектральний куб даних для обробки й аналізу, де x і y представляють два просторові виміри сцени, а λ представляє спектральний вимір (включаючи діапазон довжин хвиль). [34]. Метою гіперспектрального зображення є отримання спектру для кожного пікселя на зображенні сцени з метою пошуку об'єктів, ідентифікації матеріалів або виявлення процесів. Застосування гіперспектральних зображень включає виявлення конкретних особливостей рельєфу та рослинності [35], мінералів або типів ґрунтів для управління ресурсами [36], виявлення штучних матеріалів на природному фоні [37] та виявлення транспортних засобів або катери для цілей оборони та розвідки [38]. Ці датчики часто встановлюються на БПЛА для програм виявлення бортових об'єктів, таких як сільськогосподарський моніторинг [39].

Наскільки відомо, ці датчики ще не використовувалися в завданні вивчення БПЛА. Однак їх використання може бути цінною рекомендацією для такої системи. У урбанізованому середовищі БПЛА може летіти нижче, ніж зазвичай, на фоні будівель або землі (наприклад, перед пагорбом), щоб уникнути ефективних зон основних датчиків, таких як радари. Радари зазвичай розміщують на дахах будівель в урбанізованому середовищі, щоб уникнути безладу, створеного відображеннями інших будівель, а також щоб мінімізувати вплив випромінювання від антени радара на місце проживання людей. Таким чином, надійна система протидії БПЛА повинна

мати можливість реагувати на сценарій вторгнення на низькому польоті за допомогою інших датчиків. Це складний випадок для традиційної RGB (Red Green Blue) або навіть тепловізійної камери. Тим не менш, гіперспектральний датчик зображення може надавати сигнали про зовнішній вигляд на будь-якій довжині хвилі, які відсутні в RGB-камері, для швидкого виявлення несприятливої події.

Загальні алгоритми виявлення об'єктів на гіперспектральних зображеннях можуть бути використані для виявлення та класифікації БПЛА. Для цього знадобиться достатня кількість даних із камери гіперспектрального зображення, яка фіксує польоти БПЛА, щоб налаштувати існуючі методи. До ери глибокого навчання дослідники зосереджувалися на розробці алгоритмів для виявлення цілей на даних гіперспектрального зображення, використовуючи класичну теорію виявлення та моделі сигналів на основі фізики.

З розвитком глибокого навчання і, зокрема, CNN, дослідники скористалися перевагами потужнішої можливості представлення, яку надають CNN, і досягли чудових результатів у виявленні та класифікації об'єктів при використанні гіперспектральних зображень. Було запропоновано 5-шарову 3D-модель CNN, навчену в певній схемі паралельних графічних процесорів (блоків обробки графіки) для оптимізації швидкості навчання, яка використовує всю просторово-спектральну інформацію гіперспектрального зображення одночасно для класифікації сільськогосподарських культур і типу землі як а також класифікація об'єктів у міському середовищі [40]. Автори довели, що спільний розгляд спектральної інформації разом із просторовою інформацією забезпечує кращі результати класифікації, ніж ті, які досягають традиційні нейронні мережі, які включають лише спектральну інформацію.

1.3 Огляд та аналіз існуючих термодатчиків

На відміну від оптичних датчиків, термодатчики працюють у невидимому електромагнітному спектрі. Теплові камери здатні вловлювати інфрачервоне випромінювання, що випромінюється всіма об'єктами у вигляді тепла. Вони чутливі до довгого інфрачервоного діапазону електромагнітного спектру з довжиною хвилі від 9 до 14 мкм. Головною перевагою використання тепловізійної камери в додатках, пов'язаних із забезпеченням безпеки, є можливість візуалізації навколишнього середовища незалежно від зовнішнього освітлення чи погодних умов і навіть у повній темряві. Крім того, у порівнянні з традиційними RGB-камерами теплові камери пропонують підвищену стійкість до змін освітлення. Навпаки, теплові камери зазвичай дають зображення з нижчою роздільною здатністю та коштують дорожче. Таким чином, спочатку вони використовувалися лише у військових цілях, але останні досягнення в технології знизили їхню вартість і дозволили використовувати їх у промисловості та дослідницьких секторах. Приклад теплового панорамного зображення високої роздільної здатності зображено на рис.1.2 [29].



Рисунок 1.2 – Теплове панорамне зображення [29]

У системі протидії БПЛА, яка захищає безпечну територію, таку як в'язниця, теплові камери, швидше за все, будуть розташовані або на землі, або на інших структурах (наприклад, будівлях, вежах спостереження). Деякі приклади теплових зображень захоплених БПЛА представлені на рис 1.3 [29].




Рисунок 1.3 – Приклади БПЛА, знятих тепловою камерою [29]

У останніх дослідженнях тепловізійних зображень використовуються методи глибокого навчання, які виявилися більш ефективними порівняно з традиційними методами обробки зображень. Точніше, останні методики зазвичай використовують CNN для вирішення багатьох і різноманітних завдань. Вони включають класифікацію всього вхідного зображення або пропозицій регіону, отриманих іншими методами, виявлення та локалізацію цілей у більшому кадрі або автоматичне виділення ознак зовнішнього вигляду. Залежно від застосування та наявності навчальних даних, використовувані CNN можуть бути або попередньо навчені на великих загальних і багатоцільових наборах даних, таких як ImageNet [41], точніше налаштовані, або навчені з нуля, використовуючи дані, що стосуються конкретного завдання.

1.4 Огляд та аналіз існуючих акустичних датчиків

Обчислювальне звукове розпізнавання сцени (Computational Auditory Scene Recognition (CASR)) — це галузь досліджень, яка фокусується на

розпізнаванні контексту або середовища, а не на аналізі та інтерпретації окремих звукових подій [42]. Застосування CASR включають виявлення навколишніх звуків, інтелектуальні переносні пристрої та слухові апарати, які відчують навколишнє середовище та відповідно регулюють режим роботи. Загальна система виявлення звукових подій (рис. 1.4 [29]) складається з трьох основних модулів: виявлення, виділення ознак і класифікація. Модуль виявлення стосується захоплення цільового звуку в реальному шумовому записі. Вилучення функцій відноситься до створених людиною функцій, які можна виділити для функцій, щоб використовувати як вхідні дані для класифікатора, або автоматично витягнути функції із необробленого сигналу під час використання нейронних мереж. Нарешті, модуль класифікації призначає ймовірності вилучених ознак відповідному класу [29].

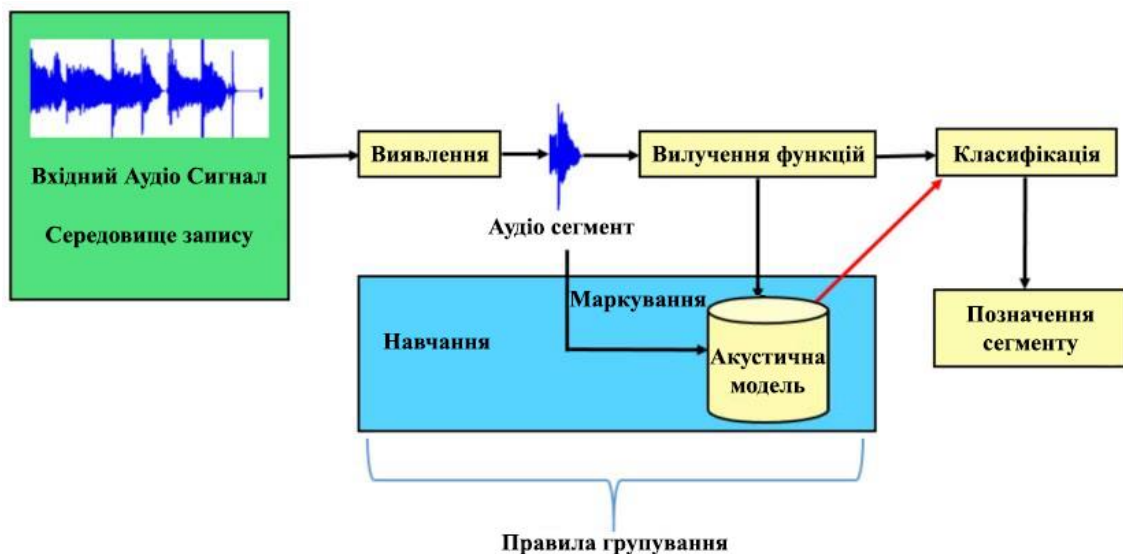


Рисунок 1.4 – Загальна система виявлення звукових подій [29]

Здатність мереж глибокого навчання отримувати унікальні функції з необроблених даних і висока швидкість обробки сучасних графічних процесорів (Graphic Processing Units (GPU)) призводять до того, що ці мережі привертають велику увагу в широкому діапазоні наукових галузей, таких як

обробка природної мови, зображення /класифікація та сегментація відео, навчання з підкріпленням і виявлення звукових подій.

Протягом останніх кількох років багато дослідників працювали над класифікацією акустичних сцен, розпізнаючи окремі події в монофонічних записах [43] і кілька одночасних подій у поліфонічних записах [44]. Були досліджені різні методи вилучення ознак [45], збільшення даних [46], використання гібридних класифікаторів із нейронними мережами [47] і дуже глибокі нейронні моделі [48]. Однак проблема виявлення подій на основі звуку залишається складним завданням. Це пов'язано з тим, що функції та класифікатори або підходи до глибокого навчання, які надзвичайно добре працюють для певного набору даних, можуть виявитися неефективними для іншого.

Що стосується виявлення безпілотних літальних апаратів на основі звуку, дослідники використовували мікрофони, оскільки методи виявлення зображень містять кілька недоліків. По-перше, алгоритми, розроблені для виявлення зображень, потребують камер з високою роздільною здатністю для більш високої точності класифікації, що призводить до компромісу між вартістю та точністю. По-друге, на зображення, зняті цими камерами високої роздільної здатності, значною мірою впливає час доби та погода. З іншого боку, вищезазначені проблеми можна вирішити за допомогою недорогих мікрофонних масивів з одноплатними комп'ютерами для завдань цифрової обробки сигналів [49]. Інші дослідники [50] запропонували структуру виявлення дронів за допомогою аудіовідбитків і кореляції. Недоліком цих підходів було те, що вони не могли працювати в режимі реального часу і працювали в дуже обмеженому наборі даних. Автори [51] запропонували систему, яка використовує комбінацію радарних і акустичних датчиків і прямої нейронної мережі для виявлення та відстеження ідентифікованих БПЛА роторного типу. У порівнянні з традиційними кепстральними коефіцієнтами мел-частоти (mel-frequency cepstral coefficients (MFCC)) іншими авторами використані, які зазвичай використовуються в області

розпізнавання мови, і класифікатор Support Vector Machine (SVM) для виявлення БПЛА [52]. Нещодавно була представлена система виявлення та моніторингу дронів у режимі реального часу, використовуючи один мікрофон [53]. Ця система використовувала k -найближчих сусідів і креслила алгоритми навчання зображень, щоб вивчати властивості спектрів швидкого перетворення Фур'є. Автори розширили свою роботу [54] і підвищили точність класифікації запропонованої ними системи з 83% до 86%, використовуючи штучну нейронну мережу.

Існує гостра потреба в зборі реальних аудіоданих БПЛА, які могли б слугувати еталоном для дослідників для розробки їхніх алгоритмів. Двовимірні нейронні мережі комп'ютерного зору слід тестувати за допомогою необроблених короточасних спектрограм перетворення Фур'є або мел-спектрограм, щоб мати надійну систему виявлення на основі звуку БПЛА.

1.5 Огляд та аналіз існуючих лідарних датчиків

Тривимірні хмари точок, отримані датчиками LiDAR (виявлення світла та визначення дальності), виявилися хорошою основою для виявлення об'єктів, наприклад, людей [55], автомобілів [56] або кораблів [57]. Доступні сьогодні системи сканування LiDAR представляють собою компроміс між прийнятною роздільною здатністю, реальною частотою оновлення та полем огляду (FOV). Оскільки БПЛА зазвичай мають малий поперечний переріз лазерного радара (laser radar cross-section (LRCS)) [58], низька роздільна здатність більшості датчиків LiDAR робить їх непридатними для виявлення БПЛА. З іншого боку, методи виявлення на основі LiDAR демонструють багато переваг: відокремити об'єкт від переднього чи заднього плану порівняно легко, точне 3D-положення об'єкта стає відомим миттєво після його виявлення, а датчик не залежить від денного світла. умови. Автори статті [59] оцінили потенціал датчиків LiDAR для виявлення БПЛА.

Алгоритм виявлення та відстеження об'єктів використовує щільну впорядковану структуру хмар точок, що відповідає одному обертанню лазерного сканера на 360° (організовані хмари). Кожен кадр отриманий за допомогою сканування складається з n рядків або рядків сканування і m стовпців (m залежить від частоти повторення імпульсів і частота обертання головки сканера). За допомогою датчиків генеруються окремі кадри таким чином, що для кожного випромінюваного лазерного імпульсу записується значення даних. Завдяки цій упорядкованій структурі даних для кожної точки можна легко визначити значення діапазону її сусідніх точок у межах однієї скан-лінії, подібно до зображення діапазону.

Через невеликий розмір БПЛА та обмежену роздільну здатність сканера LiDAR кількість точок на БПЛА невелика навіть на коротких відстанях. У зв'язку з цим подальший геометричний аналіз об'єктів хмари точок (решти 3D кластерів) малоперспективний. Кращим підходом для подальшої класифікації об'єкта (БПЛА/не БПЛА) є аналіз його руху. Для цього потрібне відстеження 3D-кластерів.

Безперервний потік даних кожного датчика LiDAR записується таким чином, що він підрозділяється на окремі 360° сканування (кадри). Об'єкт, виявлений в останньому кадрі, має знаходитися в поточному кадрі в позиції поблизу його останньої позиції або екстрапольованої наступної позиції. Для цього створюється трек-лист із усіма виявленими об'єктами першого кадру. Для всіх наступних кадрів координати всіх виявлених 3D-об'єктів порівнюються з об'єктами в трек-листі. Кожен новий об'єкт призначається об'єкту списку треків з мінімальною відстанню. Якщо немає об'єкта списку треків із відстанню, нижчою за порогове значення, новий об'єкт встановлюється як новий об'єкт списку треків. Для кожного об'єкта списку треків розраховується прогноз його подальшого руху за допомогою фільтра Калмана. Для кожного об'єкта зі списку треків можна обчислити поточну швидкість і загальний рух, а об'єкти, які не рухаються, можна класифікувати як не-БПЛА.

Автори [59] показали, що можна виявити БПЛА з високою ймовірністю, якщо БПЛА знаходиться в полі зору датчика, а відстань між датчиком і БПЛА не надто велика. Вплив форми, структури та матеріалу різних літальних апаратів слід додатково вивчити.

1.6 Огляд та аналіз існуючих радіосенсорних датчиків датчиків

Більшість комерційних дронів сьогодні використовують радіозв'язок для дистанційного керування, телеметрії та передачі даних датчиків (переважно відео). Таким чином, виявлення типового зв'язку дронів достатньо для виявлення цих дронів. Це приносить деякі переваги, оскільки умови розповсюдження тут набагато зручніші для виявлення. Безпілотник з активним радіозв'язком можна виявити на землі задовго до того, як його буде видно в небі. Також для локалізації існує довга історія систем, які визначають місцезнаходження активного радіочастотного передавача [60].

Іншим моментом виявлення та локалізації дронів є аспект IT-безпеки. Оскільки досить багато дронів використовують стандартизовані засоби зв'язку, для телеметрії та відео. Маючи можливість підключитися до цього зв'язку, можливо отримати позицію та іншу інформацію аж до відеопотоку, який доставляється безпосередньо з дрона в систему протидії БПЛА. Але доступність цих даних залежить від конкретної моделі дрона та версії мікропрограми, що використовується.

Огляд літературних джерел показав, що системи радару використовуються протягом десятиліть для виявлення повітряного судна, але зазвичай неможливо виявити невеликі комерційні БПЛА. Крім того, вони літають із порівняно набагато меншими швидкостями, що зменшує величину сигналу отриманого з ефекту доплера. Як правило, системи радар не класифікують інші повітряні об'єкти, такі як птахи та фоновий безлад. Отже, системи радар не розглядалася як ефективне рішення боротьби з безпілотниками, особливо для автономних конфігурацій.

Акустичні датчики також використовується для виявлення безпілотників за допомогою мікрофонних решіток. Метою є класифікація специфічного звуку роторів безпілотників, однак їм не вдається досягти високої точності та робочого діапазону. Максимальний діапазон аудіосистем не перевищує 200–250 м. Іншим недоліком системи є проблема розпізнавання в міських або галасливих умовах, таких як аеропорти.

Проблеми, котрі пов'язані з термодатчиками більш економічного характеру: дешеві термодатчики доволі мають низьку роздільну здатність та вразливі до параметрів навколишнього середовища, таких як волога повітря, тому для усунення цих завад необхідна більш якісна та відповідно дорога камера. Додатково до ціни подібних камер додається ще й складність їх отримання, оскільки більшість таких моделей використовується у воєнних цілях.

Основною перевагою виявлення БПЛА на основі LiDAR є автоматично створена тривимірна координата БПЛА. Крім того, LiDAR стійкий до змін освітленості та умов навколишнього середовища. До недоліків можна віднести зниження рівня виявлення на відстанях понад 30 м, що можна простежити через низьку щільність точок на цілях. Крім того, розрив між лініями сканування дозволяє БПЛА залишатися непоміченими на цих відстанях.

Попри всі переваги радіовідстеження та локалізації, слід зазначити, що сьогодні технічно можливо побудувати безпілотник, який взагалі не потребує зв'язку.

На основі проведеного аналізу, а також через зручність роботи та велику кількість досягнень комп'ютерного зору, у якості суб'єкту для відстеження було обрано оптичні датчики, котрі компенсують свої недоліки зручністю отримання і обробки даних, високої можливості виявлення та класифікації об'єктів та мають більш приємлиму ціну.

2 АНАЛІЗ ВИЯВЛЕННЯ ТА ВІДСТЕЖЕННЯ БПЛА ЗА ДОПОМОГОЮ ОПТИЧНИХ КАМЕР

2.1 Виявлення та відстеження БПЛА

Глибоке навчання — це найсучасніша техніка, яка показала великі перспективи в області комп'ютерного зору та розпізнавання образів. Методи, засновані на згорткових нейронних мережах (CNN), можуть розпізнати клас та створити обмежувальні рамки, витягуючи з об'єкта глибокі ознаки високого рівня, процес, відомий як виявлення об'єкта. CNN корисні для виконання завдань виявлення, розпізнавання та сегментації [61]. Вони дотримуються підходів на основі шарів, де нижні шари виділяють низькорівневі характеристики, такі як краї, шари середнього рівня виділяють краплеподібні структури, а шари верхнього рівня визначають об'єкт [62]. Методи виявлення об'єктів на основі глибокого навчання можна розділити на два типи: двоетапні та одноетапні.

2.2 Двоетапні детектори об'єктів

Двоетапні детектори об'єктів в основному є Region-Based Convolutional Neural Network (R-CNN). R-CNN спочатку використовують алгоритм вибіркового пошуку, щоб створити велику кількість ймовірностей регіону. Потім CNN використовується для виділення ознак із ймовірності кожного регіону. Нарешті, R-CNN класифікує різні класи та визначає обмежувальні рамки [63]. Щоб прискорити такі обчислення, були запропоновані Fast R-CNN [64], Faster R-CNN [64].

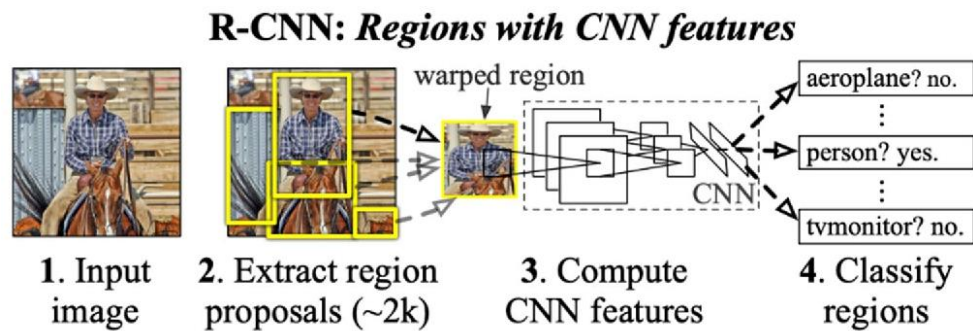


Рисунок 2.1 – Архітектура R-CNN [66]

Щоб подолати повільність R-CNN, [64] розробили алгоритм під назвою Fast R-CNN. Fast R-CNN відрізняється від R-CNN тим, що він не поділяє регіони на жодні ймовірності регіонів. Спочатку застосовується CNN, а потім розподіляє оцінку регіону на карту властивостей нейронної мережі. Для остаточної класифікації він використовує Softmax, а не SVM. Якщо CNN використовується тільки один раз, швидкість алгоритму збільшується.

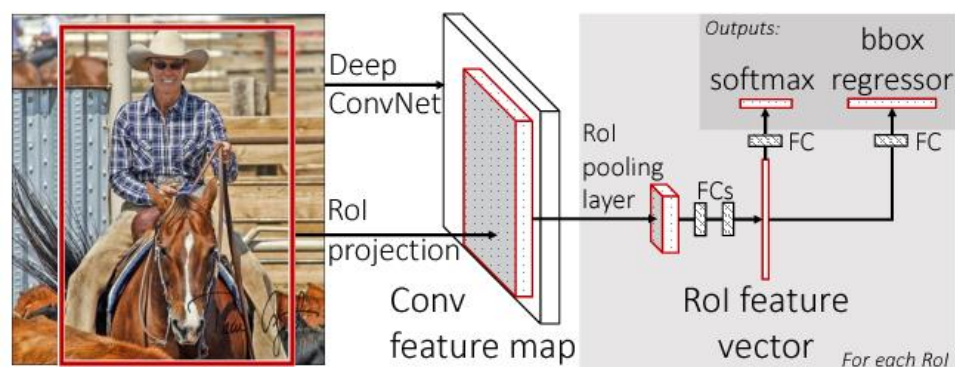


Рисунок 2.2 – Архітектура Fast R-CNN [67]

Щоб ще більше покращити час оцінки, [65] запропонував Faster R-CNN. Як і Fast R-CNN, він спочатку застосовує CNN, а потім створює карту функцій. Faster R-CNN не проводить жодних рекомендацій щодо регіону (як і Fast R-CNN). Замість цього він використовує алгоритм вибіркового пошуку, а решта підходів подібні до Fast R-CNN.




Рисунок 2.3 – Архітектура Faster R-CNN [66]

2.3 Одноетапні детектори об'єктів

На відміну від регіональних підходів, одноетапні методи переглядають зображення лише один раз. You Only Look Once (YOLO) є популярним прикладом такого підходу. Він включає в себе єдину нейронну мережу, навчену наскрізно, яка приймає зображення як вхідні дані та безпосередньо передбачає обмежувальні рамки та мітки класів. Техніка пропонує нижчу точність прогнозування (наприклад, більше помилок локалізації), але працює зі швидкістю від 45 до 155 кадрів на секунду (frames per second (FPS)), забезпечуючи оптимізовану за швидкістю версію моделі [68]. Двоетапні методи виявлення об'єктів витрачають порівняно більше часу на отримання ймовірностей. Таким чином, одноступінчасті детектори об'єктів і Single-Shot Multi-box Detector (SSD) використовуються в різних програмах виявлення об'єктів у реальному часі, таких як сцени руху [69], високовольтні ізолятори [70] і виявлення літаків [71]. Автори [68] запропонували першу версію YOLO, яка забезпечує прогнозування класу з обмежувальними рамками та ймовірностями класу. Пізніше [72] запропонував YOLOv2, який перевершив першу версію YOLO за швидкістю та точністю. Щоб ще більше підвищити точність, [73] запропонував більшу мережу YOLO, відому як YOLOv3, яка досягла вищої точності, ніж попередні версії. Автори [178] запропонували

YOLOv4, який враховує такі універсальні параметри, як зважені залишкові з'єднання, cross-stage partial (CSP) з'єднання, cross mini-batch normalization (CmBN), self-adversarial training (SAT), активація Mish, мозаїчні дані аугментація, регуляризація DropBlock і втрати CIOU. Насправді YOLOv4 перевершує свої попередні версії як з точки зору точності, так і швидкості.

2.3.1 Алгоритм YOLO

YOLO алгоритм не тільки розпізнає об'єкт, а також встановлює обмежувальні рамки на основі центроїдів (центральної точки розпізаного об'єкту). За кожною зоною зображення встановлено вектор параметрів (Рис 2.4), а саме: P_c – маркер котрий позначає було знайдено об'єкт у площині чи ні, може приймати значення 0 чи 1. B_x , B_y – параметри, котрі вказують на позицію центроїда відносно початку відстежуваної зони (верхній лівий кут), B_w B_h – параметри, що вказують на розміри обмежувальної рамки, $C_1...C_n$ – маркери, котрі позначають належність об'єкту до конкретного класу, можуть приймати значення від 0 до 1.

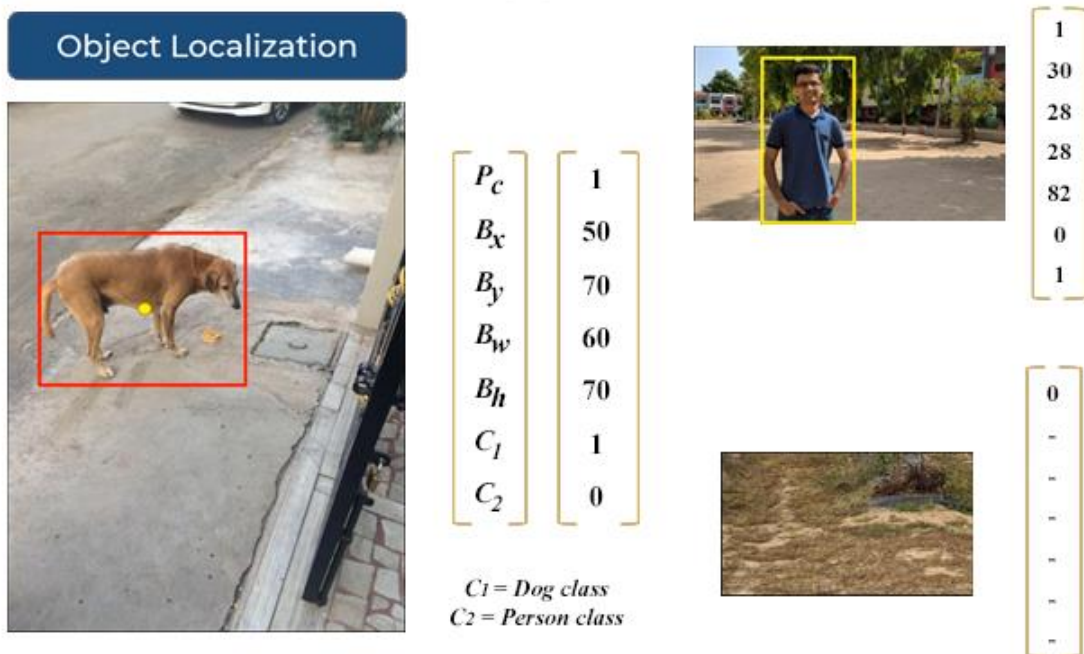


Рисунок 2.4 - Основні позначення у YOLO



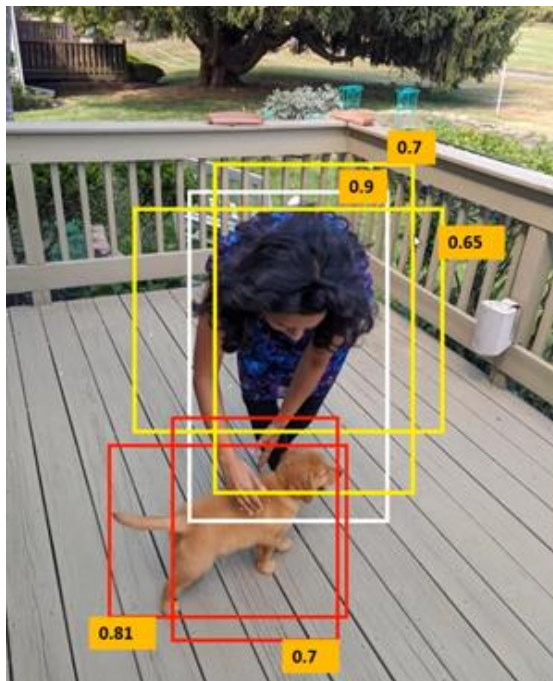


Рисунок 2.6 – Розпізнавання декількох об’єктів відразу

Оскільки алгоритм перевіряє усі клітини відразу, що надає йому перевагу у швидкості порівняно з іншими алгоритмами, може виникнути ситуація, коли один об’єкт розпізнається одразу у декількох клітинах і на базі цього генерується декілька обмежувальних коробок для одного зображення. Щоб запобігти даного інциденту було встановлено обмеження. Належність до класу розраховується від 0 до 1, іншими словами кажучи, як ймовірність, тому коли виникає декілька коробок для одного об’єкту вони маркуються відповідно до ймовірностей. Далі в діло вступає алгоритм non max suppression (NMS).

Алгоритм NMS починає з вибору рамки з найбільшим показником ймовірності (для зручності позначимо її як X), після цього зони покриття інших рамки стають параметрами для розрахунку. Відбувається розрахунок параметра intersection over union (IoU) по формулі (Рис. 2.7), де intersect area - це зона перетину обмежувальних коробок, union area - загальна зона покриття коробок. Результат дії записується до IoU і порівнюється з ймовірністю коробки X . Якщо $X > \text{IoU}$, коробки, параметри котрих були

використані для розрахунку не відображаються. Таким чином зони котрі відображують меншу кількість інформації ігноруються.



Intersection over union = $\text{intersect area} / \text{union area}$

Intersection over union : IOU

Рисунок 2.7 – NMS алгоритм

Інша проблема, котра може виникати – це декілька центроїдів об'єктів у межах однієї клітини. Вирішується ця ситуація методом створення збільшеного вектора параметрів (Рисунки 2.8, 2.9). Називається цей метод anchor boxes. Слід зауважити, що чим меншими є клітини тим менш вигідно використовувати цей метод, оскільки ймовірність знаходження декількох об'єктів на одній площини зменшується.

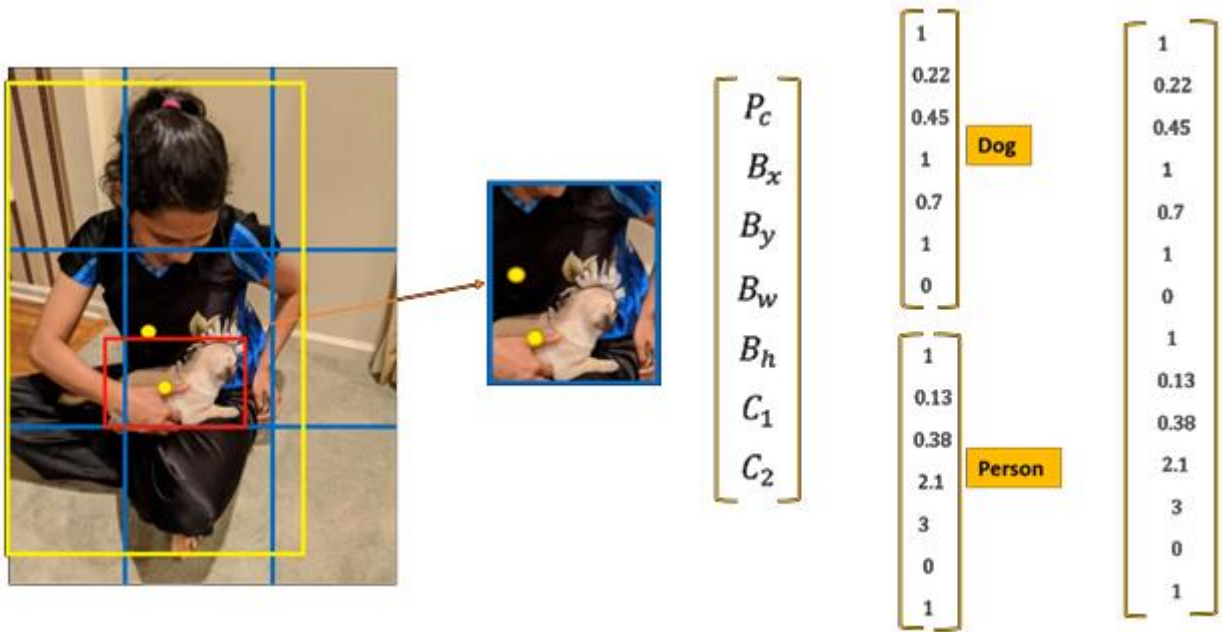


Рисунок 2.8 – Метод Anchor boxes




Рисунок 2.9 – Вигляд вектору у разі двох об'єктів

У кваліфікаційній роботі було вирішено використовувати найсучасніший алгоритм виявлення об'єктів YOLO-v4 через його можливості виявлення в реальному часі, високу швидкість і точність.

2.4 Матеріали та методи

YOLOv4 [74] представляє нові універсальні функції у поєднанні для досягнення високої середньої точності (average precision (AP)) і FPS. YOLOv4 використовує одноступінчасту архітектуру детектора, що складається з чотирьох частин: input, backbone, neck та dense prediction або head. Input — це набір даних, які ми хочемо виявити. Backbone відповідає за вилучення функцій і використовує набір даних зображення, щоб зробити детектор об'єктів масштабованим і надійним. Він складається з трьох частин: bag of freebies (BoF), bag of specials (BoS) і CSPDarknet53. Head використовує ту ж стратегію, що й YOLOv3 [73].

2.4.1 Bag of freebies

BoF — це стратегія, яка використовується для навчання детектора об'єктів в автономному режимі без збільшення вартості висновків. Існують різні стратегії, доступні в комп'ютерному зорі для досягнення мети BoF, але YOLOv4 використовує спеціальні методи як для backbone, так і для детектора. Важливі стратегії BoF, які використовуються в YOLOv4, включають CutMix, збільшення мозаїчних даних, згладжування міток, втрати IoU та регуляризацію DropBlock.

Доповнення даних використовується для підвищення надійності моделі виявлення об'єктів. Результатом є збільшення мінливості зображень, тому невідоме середовище не створюватиме проблем для моделі детектора. Налаштування яскравості, контрастності, відтінку, насиченості та шуму зображення допомагає подолати фотометричне спотворення. Довільне

гортання, масштабування, обрізання та обертання використовуються для подолання геометричних спотворень. Окрім таких піксельних коригувань, також можна використовувати випадкове стирання, MixUp, CutMix, передачу стилю, GAN тощо.

VoF використовує фокусні втрати (focal loss (FL)), щоб вирішити проблему дисбалансу даних. У задачах класифікації використовується функція втрат cross entropy (CE). Однак CE не може безперешкодно обробляти неправильно класифіковані цілі. Таким чином, представлено FL, який в основному є модифікованою версією CE. У FL використовується додатковий коефіцієнт $(1 - p_t)^{\gamma}$.

$$CE(p_t) = -\log(p_t) \quad (2.1)$$

$$FL(p_t) = -(1 - p_t)^{\gamma} \log(p_t) \quad (2.2)$$

Згладжування міток введено в YOLOv4, що в основному є концепцією дистиляції. Згладжування міток перетворює жорсткі мітки на м'які, створюючи надійність моделі. Іншим важливим удосконаленням у YOLOv4 є включення втрати IoU. У звичайних моделях виявлення об'єктів втрати l_1 або l_2 обчислюються для того, щоб оцінити передбачення обмежувальної рамки, для мінімізації помилки на малих об'єктах і великих обмежувальних рамках. Втрата IoU вирішує цю проблему в YOLOv4 завдяки математичному представленню.

$$l_2 \text{ loss} = \|(\text{Predicted Bounding Box}) - (\text{Ground truth Bounding Box})\|_2^2 \quad (2.3)$$

$$\text{IoU loss} = -\ln \frac{\text{Intersection (Predicted Bounding Box, Ground truth Bounding Box)}}{\text{Union (Predicted Bounding Box, Ground truth Bounding Box)}} \quad (2.4)$$

2.4.2 Bag of Specials

YOLOv4 представляє набір стратегій під назвою BoS для підвищення точності виявлення об'єктів шляхом невеликого збільшення витрат на логічні

висновки. Для впровадження VoS використовуються різні методи, але найбільш значні вдосконалення включають активацію Mish, з'єднання CSP, SPP-блок і блок агрегації шляхів PAN. Активація Mish враховує негативну інформацію, таким чином вирішуючи феномен вмирання ReLU та забезпечуючи сильний ефект регуляризації під час навчання, щоб подолати проблему надмірного оснащення. Функція активації Mish показана на рис. 2.10 [75].

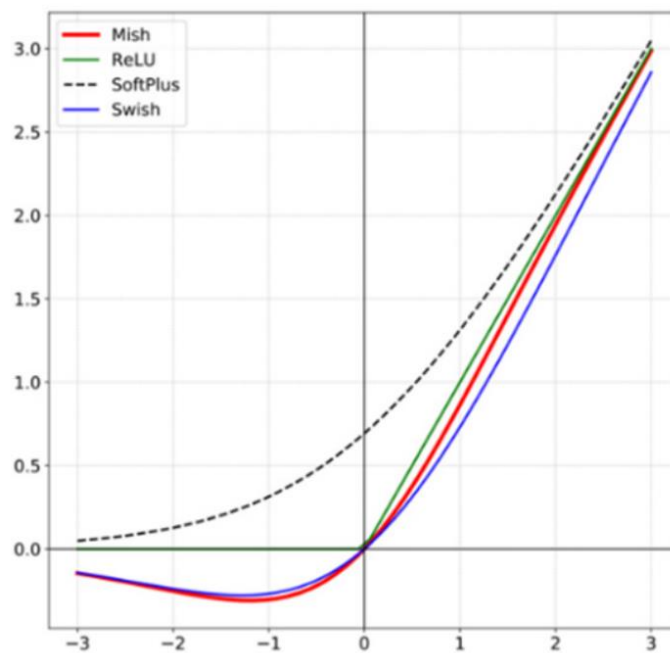


Рисунок 2.10 – Порівняння активації Mish з ReLU, Swish і SoftPlus [75]

2.4.3 CSPDarknet5

YOLOv4 використовує CSPDarknet53 як свою архітектуру виявлення. Хоча CSPResNext50 працює краще для класифікації об'єктів у ILSVRC2012 (ImageNet), CSPDarknet53 працює краще під час виявлення об'єктів у наборах даних Microsoft Common Objects in Context (MS COCO) [74]. Графік продуктивності оригінального YOLOv4 показано на рис. 2.11 [74].




Рисунок 2.11 – Порівняння продуктивності YOLOv4 (оригінал) з іншими детекторами об’єктів [74]

На рис. 2.11 показники оцінки продуктивності, кадри в секунду та AP порівнюються з іншими методами. Продуктивність YOLOv4 показано зеленим кольором і позначено як «YOLO (ours)». Рисунок 2.11 з оригінальної статті YOLOv4 показує кращу продуктивність порівняно з іншими методологіями виявлення об’єктів і був однією з причин вибору використовувати YOLOv4 для цілей виявлення. CSPDarknet53 складається з 29 шарів фільтрів 3×3 , 725×725 рецептивних полів і 27,6 М параметрів. Ця архітектура виявилася кращою за конкурентну архітектуру CSPResNext50 [74]. Додавання блоку SPP до CSPDarknet53 значно підвищує продуктивність сприйнятливого поля, виявляючи контекстні функції. FPN YOLOv3 замінено на PANet у YOLOv4 як метод агрегації параметрів. Остаточна head YOLO базується на стратегії YOLOv3. Коротше кажучи, head YOLO працює в три кроки. По-перше, все зображення ділиться на $N \times N$ сіток. Кожна сітка має п’ять параметрів (тобто x, y, w, h і c ; `object_confidenc_score`), де (x, y) — це значення зсуву між блоком передбачення та межею відповідної клітинки

сітки, (w, h) — ширина та висота від вікна передбачення до всього зображення, а `object_confidence_score` виражає ймовірність об'єкта класу. CNN витягує функцію та прогнозує класи з балами ймовірності класу. Нарешті, немаксимальне придушення використовується для усунення повторюваних обмежувальних рамок і створення єдиної обмежувальної рамки для кожного класу. Загальна архітектура виявлення для YOLOv4 наведена нижче на рис. 2.12 [76].

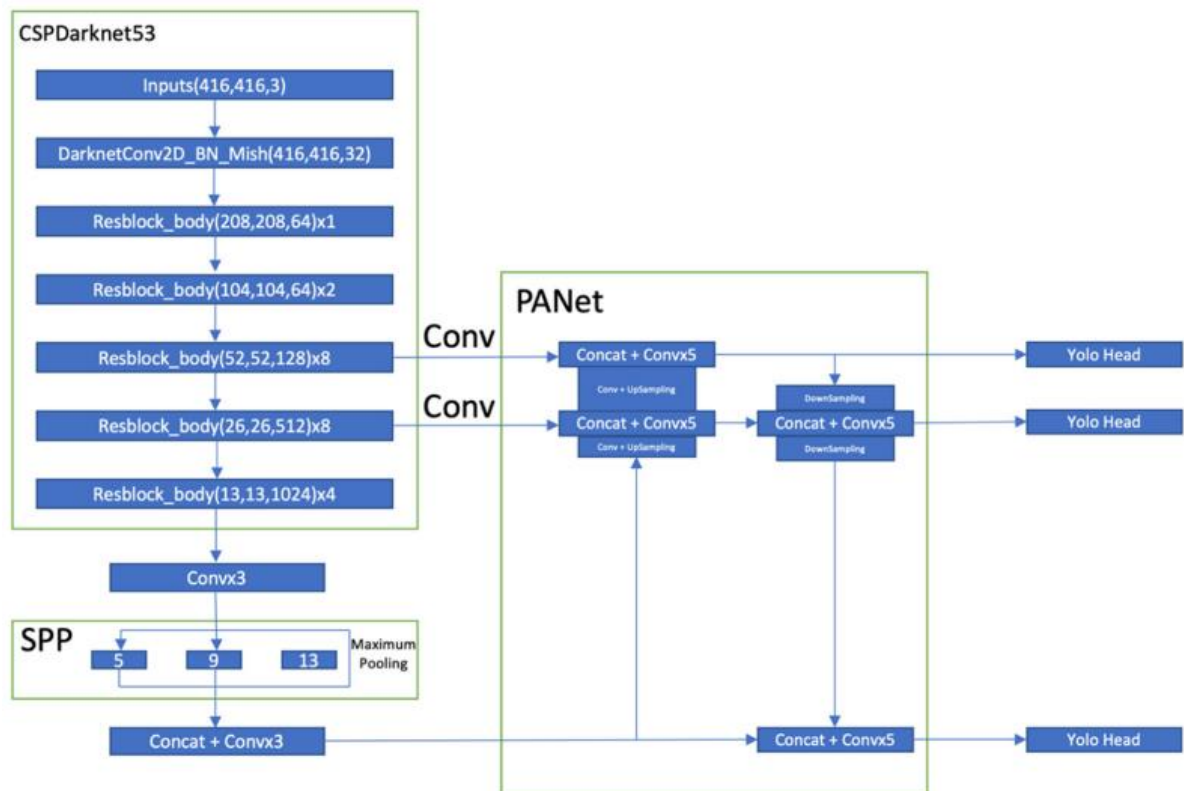


Рисунок 2.12 – Архітектура виявлення YOLOv4 [76]

2.5 Розрахунок параметрів камери

Згідно з завданням розробки системи виявлення та відстеження БПЛА необхідно провести розрахунок основних параметрів оптичних камер.

Знаючи розмір матриці, можливо обчислити фокусну відстань об'єктива за такими формулами (77):

$$f = A \cdot R/L \quad (2.5)$$

f – фокусна відстань об'єктива.

R – метрична відстань до об'єкта, що вимірюється у метрах.

A – розмір у міліметрах однієї із сторін матриці; приймається та, що визначає площину спостереження: вертикальна чи горизонтальна зона спостереження.

L – розміри об'єкта у метрах; приймаються відповідно до розмірної сторони матриці: по вертикалі або горизонталі.

Таблиця 2.1 – Розмір у міліметрах однієї із сторінки матриці

Розмір матриці	1/2"	1/3"	1/4"
По горизонталі, мм	6,4	4,8	3,2
По вертикалі, мм	4,8	3,6	2,4

Таким чином, буде розрахований фокус/кут спостереження, при якому об'єкт займатиме майже весь екран монітора. Беручи до уваги важливість об'єкта і доцільність спостереження території навколо нього, визначається в % та частина екрану, яку може займати предмет, що охороняється.

При цьому остаточна формула набуває вигляду:

$$f = A \cdot R/(100 \cdot L/h) \quad (2.6)$$

h – повний розмір об'єкта на екрані, виражений у відсотках;

Для проведення розрахунку встановимо, що для виявлення ширококутною камерою міні дрону з габаритним розміром $1,5 \times 0,6$ м,

необхідно 5% від загального розміру зображення, таким чином фокусна відстань на різних відстанях до БПЛА для матриць з різними діагоналями матиме наступні значення:

Таблиця 2.2 – Фокусна відстань об'єктиву для ширококутної камери

Діагональ матриці	Розмір матриці, мм	Відстань до БПЛА, м							
		10	20	50	80	100	150	200	250
1/2"	6,4	2,1	4,3	10,7	17,1	21,3	32,0	42,7	53,3
1/3"	4,8	1,6	3,2	8,0	12,8	16,0	24,0	32,0	40,0
1/4"	3,2	1,1	2,1	5,3	8,5	10,7	16,0	21,3	26,7

Також встановимо, що для точного розпізнання вузькокутною камерою камерою міні дрону з габаритним розміром 1,5×0,6 м, необхідно 50% від загального розміру зображення, таким чином фокусна відстань на різних відстанях до БПЛА для матриць з різними діагоналями матиме наступні значення:

Таблиця 2.3 – Фокусна відстань об'єктиву для вузькокутної камери

Діагональ матриці	Розмір матриці, мм	Відстань до БПЛА, м							
		10	20	50	80	100	150	200	250
1/2"	6,4	21,33	42,67	106,7	170,7	213,3	320	426,7	533,3
1/3"	4,8	16	32	80	128	160	240	320	400
1/4"	3,2	10,67	21,33	53,33	85,33	106,7	160	213,3	266,7

Знаючи фокусну відстань об'єктиву, можливо розрахувати зону огляду (field of view (FoV)) камери за такими формулами (77):

$$\alpha = 2\arctg \frac{A}{2f} \quad (2.7)$$

де α – кут огляду камери; A – розмір матриці в мм; f - ефективна фокусна відстань об'єктива.

Згідно до формули 2.7 було проведено розрахунок FoV об'єктиву матриці з діагоналлю 1/3, що має горизонтальний розмір 6,4 мм, для ширококутної та вузькокутної камери:

Таблиця 2.4 – FoV об'єктиву камер з діагоналлю матриці 1/3

Тип камери	Зона огляду, °							
	136,4	102,7	53,13	34,71	28,07	18,92	14,25	11,42
Ширококутна	136,4	102,7	53,13	34,71	28,07	18,92	14,25	11,42
Вузькокутна	14,3	7,2	2,9	1,8	1,4	1,0	0,7	0,6

2.6 Основна архітектура системи

Як показано на рис. 2.13, система складається із статичної ширококутної камери, розміщеної на нерухомій платформі з відрегульованим кутом та положенням відповідно до попиту, обертової башти, де на ній встановлена вузькокутна, збільшена камера RGB та основний обчислювальний блок (ПК з Linux або вбудована платформа з графічним процесором NVIDIA) підключений до них через Ethernet. Обидві камери RGB - це високопродуктивні промислові камери з однаковими характеристиками та моделлю, за винятком тієї, що встановлена на башті обертання має зовнішній професійний зум-об'єktiv. Камери мають забезпечувати роздільну здатність 1920×1080 пікселів із приблизно 25 кадрів в секунду. Ширококутна камера має об'єktiv з фокусною відстанню 3,2 мм, що відповідає приблизно 100° поля зору field of view (FoV). Камера на обертовій башті має об'єktiv 300 мм, таким чином, діагональ FoV становить близько 1,2°. Можна помітити, що вузькокутова камера має масштабування більше ніж $\times 35$, оскільки ми хочемо виявляти БПЛА як можна меншими і одночасно мати можливість їх ідентифікувати на великій відстані.



Рисунок 2.13 – Загальне налаштування системи відстеження дронів

Система складається з трьох ключових взаємоп'єднаних компонентів: статична ширококутна камера, обертаюча вежа з малокутовою камерою, головний управляючий комп'ютер на базі Linux.

Виявлення БПЛА відбувається на основі архітектури YOLOv4. На першому етапі допустимі помилкові тривоги до певної міри, коли вони відстежуються, на основі рухів і візуальних сигнатур їх можна перевірити, повернувши вежу і проаналізувавши за допомогою вузькокутної камери.

Система використовує python як основну мову програмування завдяки своїй універсальності та високій продуктивності. Алгоритми глибокого навчання виконуються в графічному процесорі основного обчислювального блоку, який є 2 Гб пам'яті NVIDIA Geforce K620.

Спочатку система намагається виявити невеликі БПЛА, спостерігаючи за горизонтом за допомогою ширококутної статичної камери. В окремих випадках, недостатнього розпізнання об'єкту, використовується камера на обертальній башті з професійним зум-об'єктивом, для більш точного оцінювання виявленого об'єкту. Було використано алгоритм YOLO для виявлення та класифікації завдяки його високій продуктивності та швидкості

обробки. На відміну від інших згорткових нейронних мереж, YOLO використовує підхід на основі регресії для визначення об'єктів на зображенні, що робить процес набагато швидшим. Для того, щоб бути узгодженим із квадратною вхідною формою архітектури YOLO, спочатку алгоритм переробляє вихідні зображення, що надходять із ширококутної камери, на 1600×1600 пікселів. Алгоритм YOLO передбачає клас із локалізацією, використовуючи лише один прохід по зображенню. Крім того, YOLOv4 представляє різноманітні нові функції, такі як WRC, CSP, CmBN, активація mish, збільшення мозаїчних даних і повне перетин через втрату об'єднання (втрата CIoU), і ці нові функції роблять це швидким.

У ході аналізу, для системи виявлення БПЛА оптичним методом було обрано алгоритм YOLO. Алгоритм ураховує наявність інших літаючих об'єктів, котрі можуть нагадувати БПЛА, має у запасі двоетапну перевірку на загальному та окремих випадках. Було проведено розрахунок параметрів фокусної відстані та кута зони огляду для ширококутної та вузькокутної камери. Також була представлена архітектура системи виявлення БПЛА з використанням оптичних камер, структурна схема системи та опис роботи системи.

3 РОЗРОБЛЕННЯ АЛГОРИТМУ РОЗВ'ЯЗАННЯ ЗАДАЧІ ВИЯВЛЕННЯ БПЛА

3.1 Вибір програмного забезпечення

Програмне забезпечення машинного навчання (Machine learning (ML)) створено для використання програмами штучного інтелекту (artificial intelligence (AI)). За допомогою машинного навчання штучний інтелект може навчатися та покращувати свої прогнози, функціонування та досвід користувача. І штучний інтелект, і машинне навчання можуть сьогодні покращити бізнес-процеси багатьох компаній. У 2021 році 57% клієнтів відзначили, що їхній досвід користувача покращився (78). Все більше компаній почали впроваджувати штучний інтелект і машинне навчання, щоб випередити своїх конкурентів.

Однак справа не лише в машинному навчанні. Як технологія ML також використовує різні мови та інструменти для продуктивності. Однією з мов, яка найкраще підходить для машинного навчання, є Python.

Штучний інтелект (Artificial intelligence) — це імітація функціонування людського мозку в машинах шляхом програмування їх мислити як люди та повторювати людські дії. Наприклад, на сьогодні існує 4 види ШІ:

1. Реактивні машини (Reactive machines) реагують лише на поточні сценарії. Вони не використовують дані, яких їх навчили або вони згадали. Прийняття такого рішення неможливе. Реактивні машини працюють з картами або будь-чим іншим, що вимагає попереднього планування. Їхні спостереження зосереджені на живому середовищі.

2. Теорія розуму (Theory of mind). У AI це обладнання для комп'ютерів, яке набагато краще розуміє об'єкти, з якими взаємодіє. Це можуть бути автономні автомобілі, здатні передбачати поведінку як пішоходів, так і водіїв.

3. Обмежена пам'ять (Limited memory) - це тип штучного інтелекту, який навчається на основі минулого досвіду та створює знання на основі минулих спостережень. Окрім попередньої отриманої інформації (історичної, спостережної), обмежена пам'ять використовує також попередньо запрограмовані дані для прогнозування та класифікації (особливо, якщо завдання складне). Наприклад безпілотні автомобілі. Ці автомобілі зберігають останню швидкість, відстань, обмеження швидкості та іншу інформацію про автомобілі на дорозі, щоб мати можливість правильно орієнтуватися.

4. Самосвідомість (Self-aware). Самосвідомі машини - це роботи, які можуть сприймати свій внутрішній стан, емоції та поведінку інших. Цей тип штучного інтелекту ще занходиться у розробці. Звичайно, можливо почути про розумних роботів, які швидко реагують, але їм все одно бракує людських навичок.

Штучний інтелект також поділяється на підмножини, що включають машинне навчання, великі дані та обробку природної мови. Машинне навчання (Machine learning), у свою чергу, є різновидом штучного інтелекту. Завдяки ML програмне забезпечення точніше прогнозує результати. Машинне навчання базується на моделюванні та алгоритмах, які потребують історичних даних, щоб передбачити щось нове. Штучний інтелект використовує машинне навчання, щоб навчатися та передбачати майбутні події.

Python – це швидше динамічна мова, з відкритим кодом, яка є універсальним, високорівневим, має відмінну читабельністю коду та інтерпретована або, як відомо, скомпільована з байт-кодом. Завдяки об'єктно-орієнтованості він дозволяє писати чіткий і лаконічний код, який використовується в малих і корпоративних проектах. Також python використовується для машинного навчання. І є щонайменше 4 вагомні причини використовувати Python для машинного навчання:

1. Простота і послідовність. Алгоритми AI та моделі ML — це складні технології прогнозування, які Python може спростити, завдяки чіткому коду та численним бібліотекам, призначеним для машинного навчання, можна перенести фокус з мови на алгоритми. Крім того, він досить простий у вивченні, послідовний та інтуїтивно зрозумілий.

2. Різноманітність бібліотек і фреймворків. Існує величезна база даних бібліотек і фреймворків, які Python використовує для машинного навчання:

- NumPy працює з масивами, у деяких частинах лінійної алгебри та різними матрицями.

- Keras, який є API глибокого навчання, що працює на Tensorflow, дає змогу швидко експериментувати.

- Tensorflow – безкоштовна бібліотека з відкритим кодом для машинного навчання та штучного інтелекту, яка зосереджена на навчанні та глибоких нейронних мережах.

- Matplotlib — це бібліотека, яка дозволяє створювати візуалізації (статичні, анімовані, інтерактивні) на Python.

- Seaborn – бібліотека візуалізації даних на основі Python, яка дає можливість малювати графіку (статистику), яка є привабливою та якісною.

- PyTorch — це бібліотека ML з відкритим кодом, яка використовується для створення програм комп'ютерного зору та обробки природної мови.

3. Незалежність від платформи. Програмні рішення, розроблені за допомогою Python, можна створювати, а також працювати на кількох платформах операційних систем. Наприклад, Linux, Windows, Mac, Solaris тощо. Це робить ML програмування Python набагато зручнішим.

4. Велика громада. Подібно до спільнот любителів JavaScript, існує спільнота, що належить до Python, до можливо отримати доступ майже до всього, що потрібно, враховуючи розвиток, а також отримати відповідь на незрозумілі питання.

Основою є статистичних даних, широкій відомості, зручності у написанні коду та великій кількості бібліотек, створених для розробки у

направленнях AI та ML, було обрано мову Python. На відміну від інших мов, котрі можуть бути використані у даних напрямках, Python надає можливості для більш гнучкого та адаптивного програмування, що збільшує діапазон можливостей для даної сфери діяльності.

3.2 Алгоритм програми виявлення та відстеження БПЛА

У цьому розділі розглядається загальний алгоритм для роботи з розпізнаванням об'єктів з використанням нейронних мереж, ключовою відмінністю є те, що в даному проєкті була використана IP камера.

Для початку розглянемо методи і алгоритми розпізнавання обличчя, оскільки задача розпізнавання обличчя дуже складна і має багато рішень і можливостей в цій роботі ми будемо адаптувати її до розпізнавання дронів.

Загальний алгоритм роботи програми, представлений на рис. 3.1.

Блоки 1-9 (Вікно програми рис. 3.2): для створення вікна програми було обрано бібліотеку tkinter, оскільки вона надає широкий спектр функціональних здібностей для роботи з графічним інтерфейсом. У вікні створюються 2 кнопки та 2 області: перша для фото шуканої персони, друга для відеофрагменту. Також у цій частині коду встановлюються параметри голосового помічника за допомогою бібліотеки pyttsx3. Його було обрано оскільки це голосовий помічник Google асистент, тому він має дуже широкий спектр можливостей: різноманітні голоси, 78 мов, можливість синтезувати різноманітний текст.

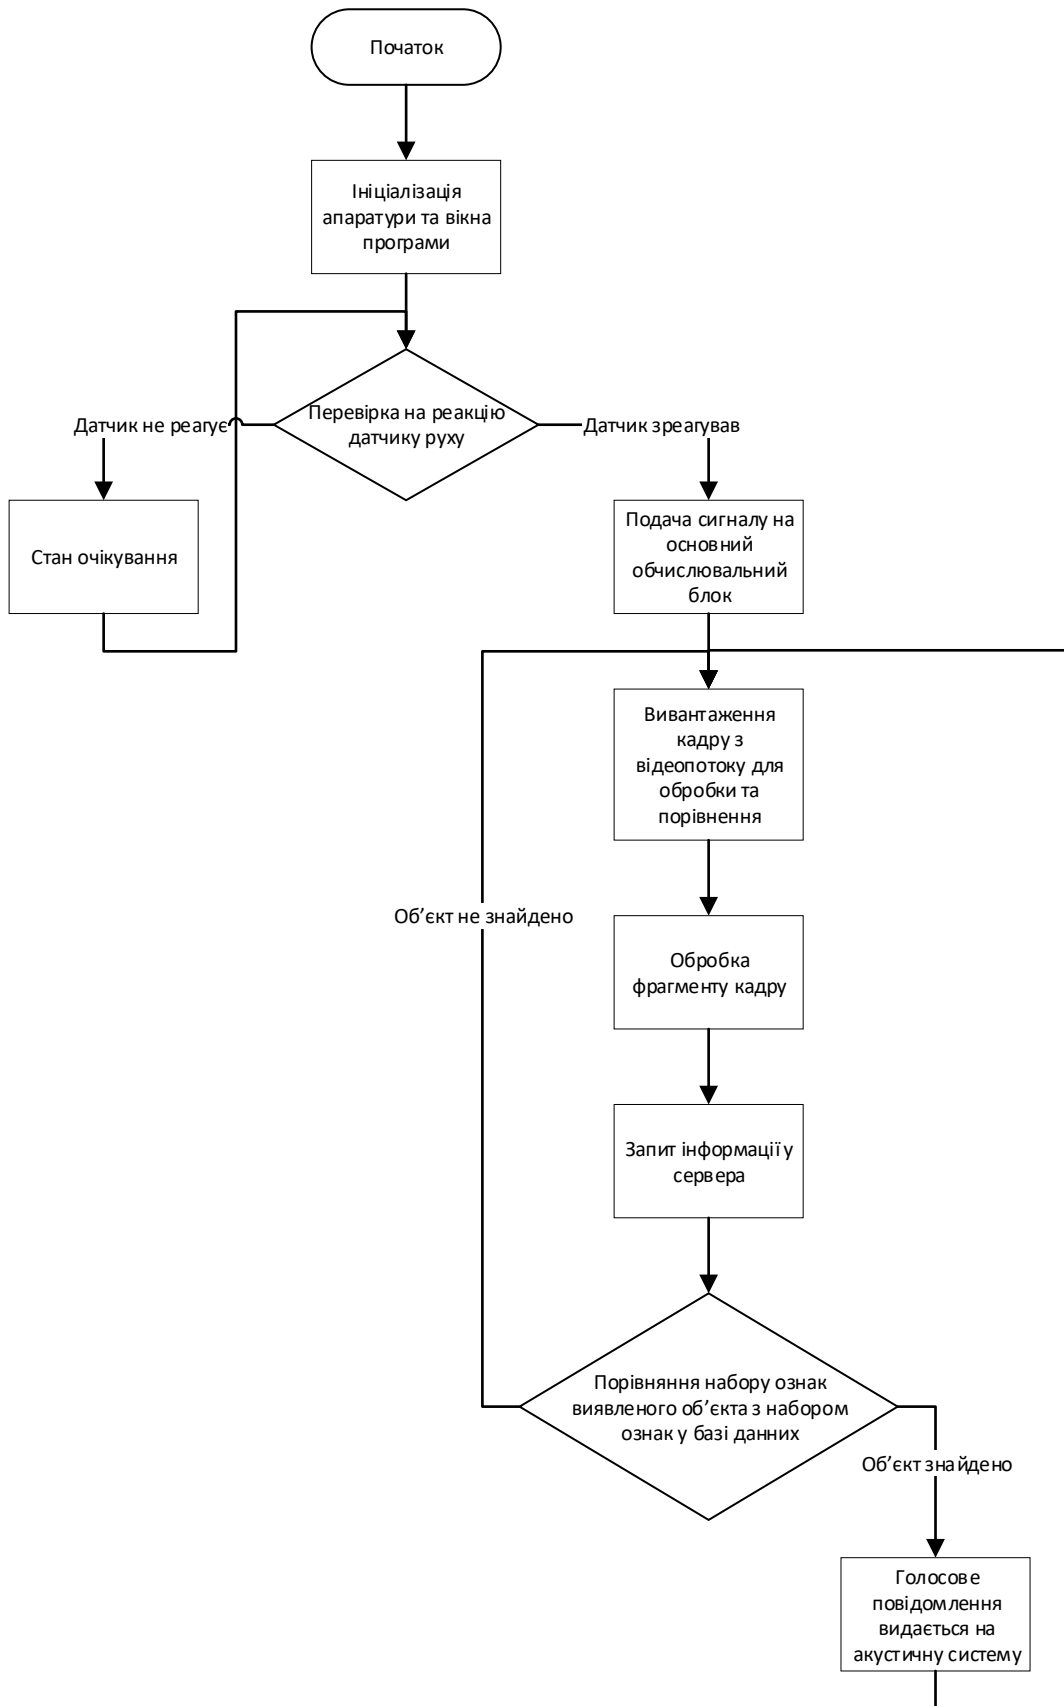


Рисунок 3.1 - Схема алгоритму загальної роботи

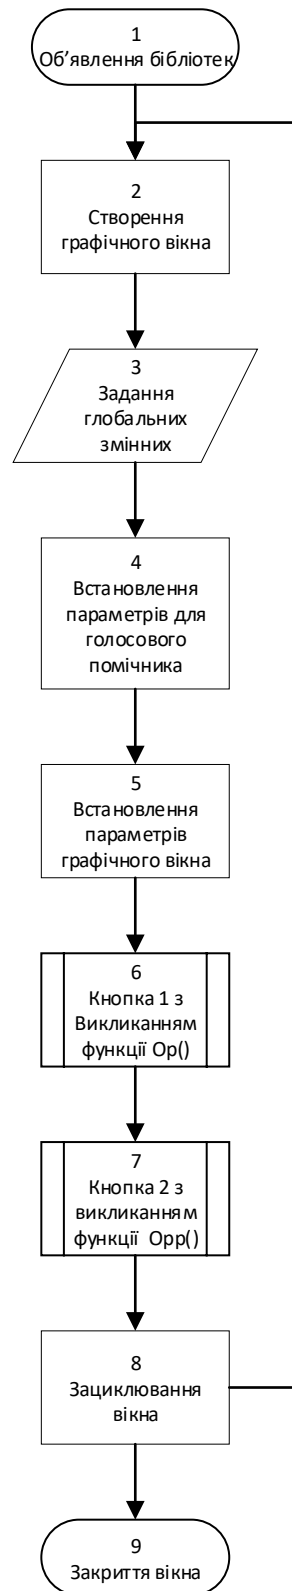


Рисунок 3.2 - Схема алгоритму роботи вікна програми

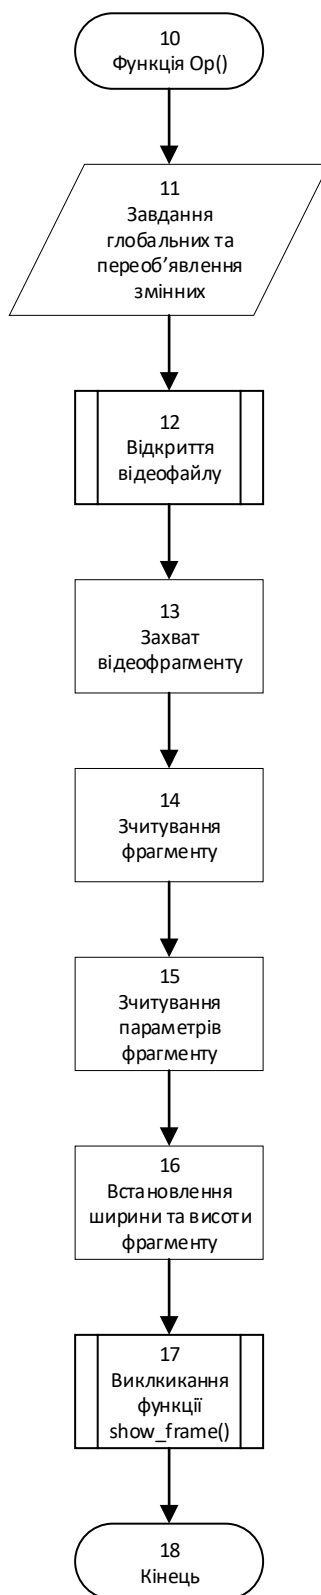


Рисунок 3.3 - Алгоритм захоплення відеофрагменту

Блоки 10-18 (Захоплення відеофрагменту рис. 3.3): Завантажується відеофайл за допомогою бібліотеки `tkinter`; далі за допомогою бібліотеки `cv2` зчитується фрагмент відео, встановлюються його висота та ширина, а далі

передається у функцію порівняння та знаходження шуканого об'єкта(Блоки 33-53).

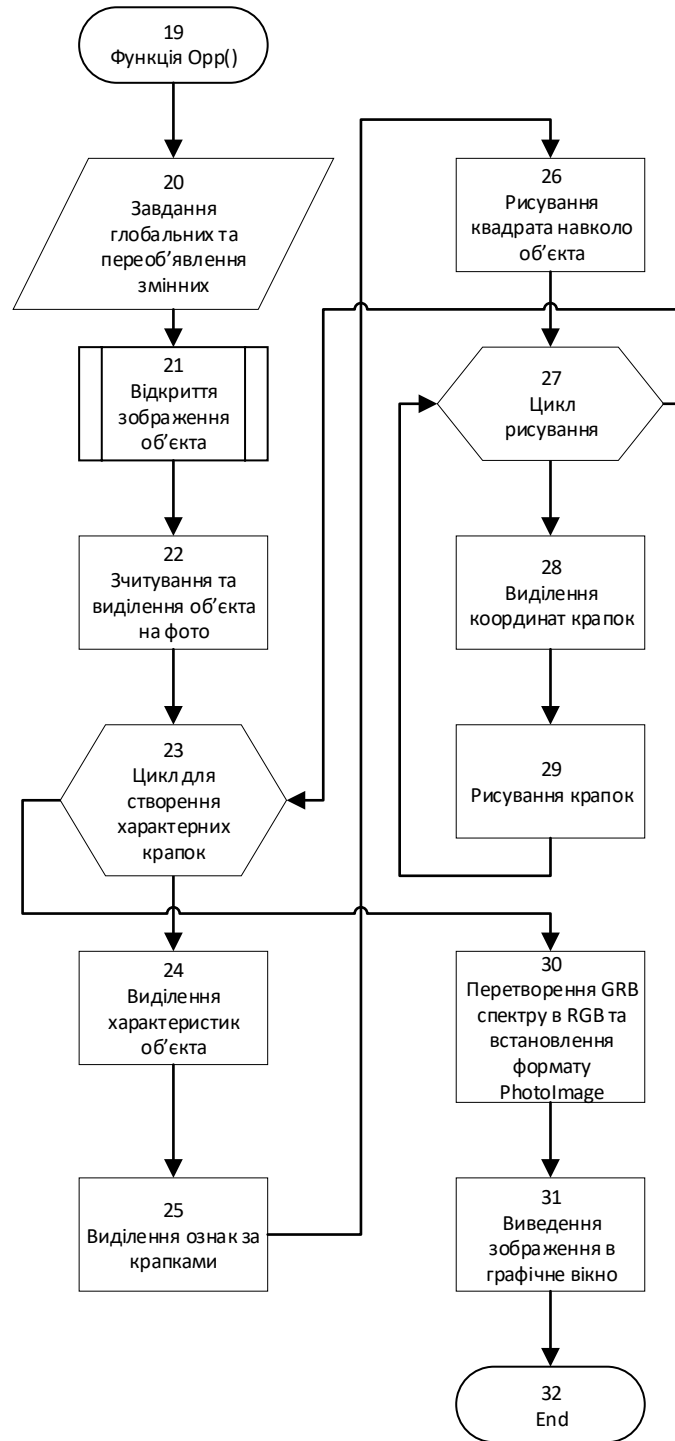


Рисунок 3.4 - Алгоритм завантаження фото шуканої об'єкта та виділення його особливостей

Блоки 19-32 (Завантаження фото та виділення БПЛА рис. 3.4): Як і у попередніх блоках завантаження фотографії відбувається за допомогою тих же бібліотек, далі використовується бібліотека `dlib`, вона необхідна для підключення нейромережі для пошуку характерних відмінностей об'єкта та формування на їх основі характерних ознак. Пропустивши фото через нейромережу, отримується дескриптор фото, котрий буде використано для знаходження об'єкта на відеофрагменті. Також у цій функції рисується квадрат з характерними крапками на фото. Для відображення фото на вікні програми використовуються наступні дії:

- Перетворення фото з BGR спектру в RGB за допомогою бібліотеки `cv2`;
- За допомогою бібліотеки `PIL` форматування зображення до формату, котрий зчитується методами з бібліотеки `tkinter`;
- Виведення за допомогою `tkinter` зображення на вікно програми.

Блоки 33-53 (Обробка кадру та пошук БПЛА рис. 3.5): Оскільки відеофрагмент можна розглядати як зображення, послідовність дій для його обробки та створення його дескриптору така ж як і у попередньому блоці, різниця тільки в тому, що тут змінюються розміри відеофрагменту для того щоб його було зручно відображати. Після створення дескриптору відеофрагменту за допомогою функції з бібліотеки `dlib` визначається Евклідова відстань між фото шуканого об'єкта та фрагментом з відеоряду, якщо цей параметр менше 0.6 тоді використовуються ті самі методи, що й для виведення зображення з минулого блоку.

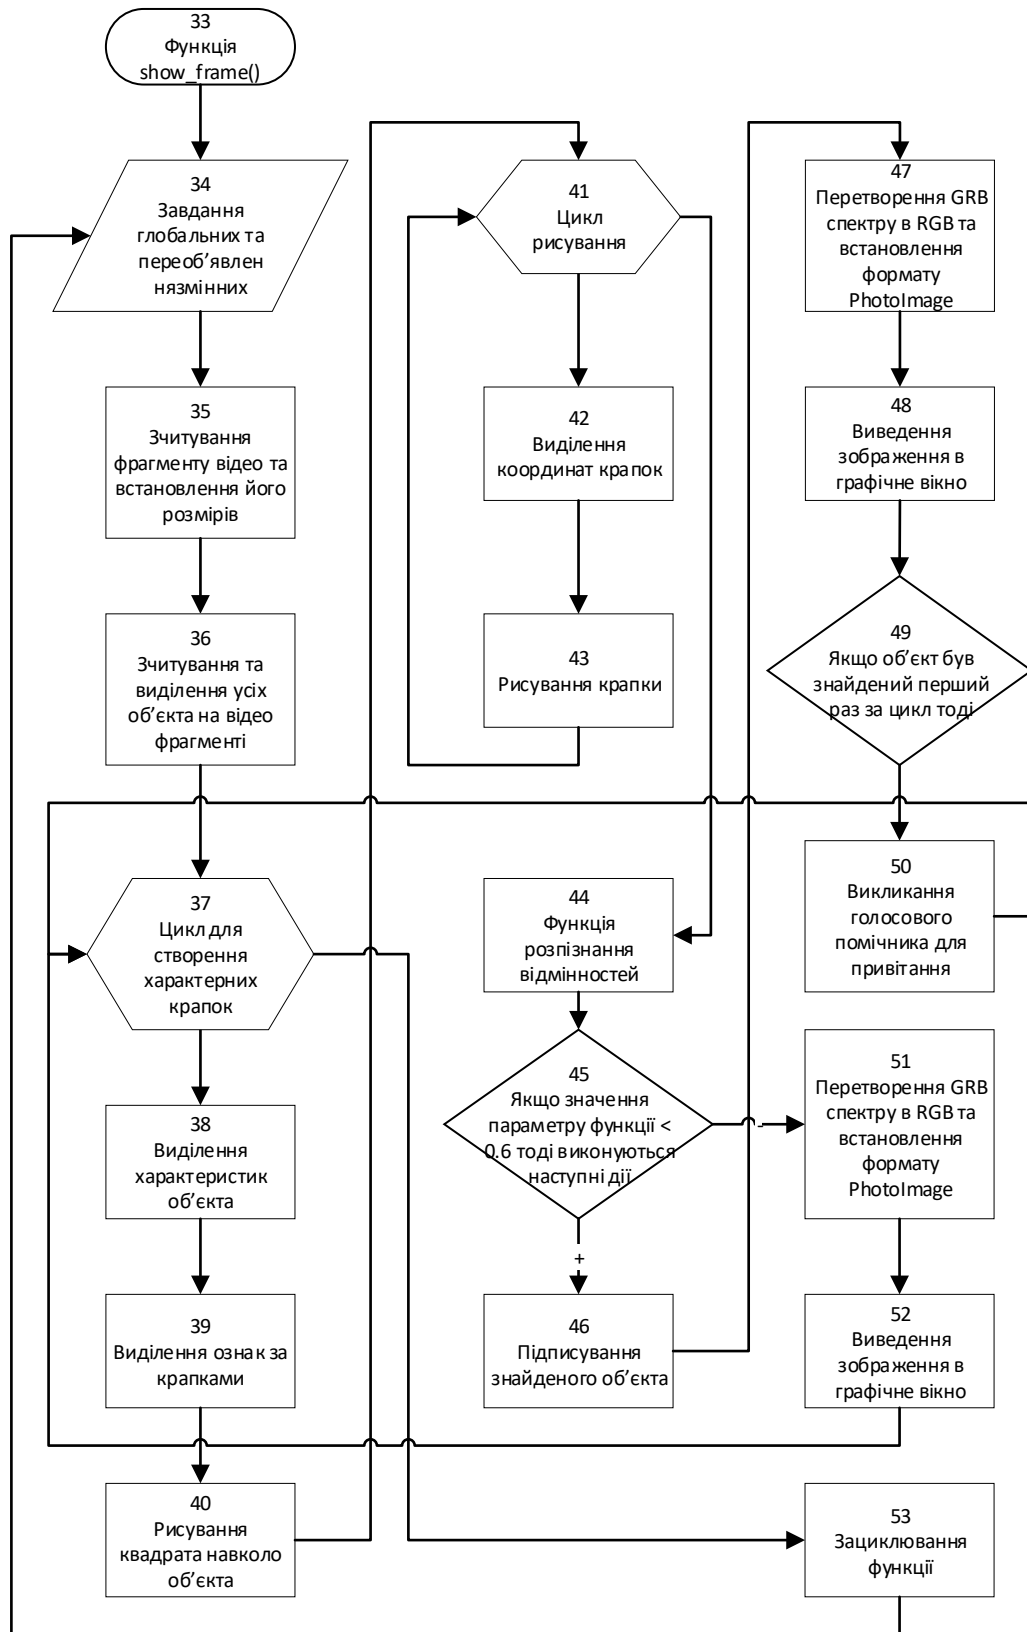


Рисунок 3.5 - Алгоритм обробки кадру та пошуку об'єкта

На основі алгоритму робочої програми було розроблено код.

Створення вікна відбувається за допомогою бібліотеки tkinter. Після встановлення необхідних параметрів вікна та розташування необхідних віджетів завантажується файл, котрий містить загальні для БПЛА ознаки, а далі створюється його екземпляр. Далі завантажується файл з вагами нейронної мережі, за допомогою якого буде проводитися розпізнавання БПЛА на відеофрагменті. Далі налаштовуються параметри голосового помічника, а саме: гучність, швидкість говору, вибір голосу. Кнопки, котрі знаходяться на вікні викликають функції.

Перша кнопка викликає функцію відкриття шуканого об'єкта. При її натисканні відкривається «провідник», у якому обирається файл. Далі для зображення використовується алгоритм об'єкта за допомогою екземплярів файлів створених раніше. У ході роботи цього алгоритму створюється дескриптор для пошуку об'єкта на відеофрагменті. Дане зображення виводиться на екран з відображенням на ньому результатів роботи алгоритму.

Друга кнопка викликає функцію відкриття відеофрагменту. В ході виконання цієї функції з відеофрагменту виділяється власне кажучи фрагмент, та оброблюється як зображення. Далі в ході виконання викликається підпрограма, котра створює дескриптор з цього зображення (За допомогою алгоритму, котрий використовувався раніше) та порівнює з раніше створеним, якщо евклідова відстань між ознаками зображеннями менше 0.6 тоді виконується алгоритм з виведенням зображення на екран з підписом знайденого об'єкта, а також викликається функція голосового повідомлення.

3.3 Результат роботи програми виявлення та відстеження БПЛА

Програму було протестовано з вже навченим класифікатором. Програма знаходить на зображенні БПЛА, виділяє його в обмежувальну рамку та розраховує ймовірність класу об'єкту.




Рисунок 3.6 – Результат роботи програми

Загальний алгоритм послідовності дій може бути адаптовано до окремих випадків, зі внесенням або доданням деяких змін, а саме: використання іншого дескриптора нейронної мережі, змінення графічного інтерфейсу, котрий був створений за допомогою бібліотеки tkinter, вибір іншого голосового помічника, а також налаштування його під конкретні цілі. Також при доданні другої камери у даний алгоритм необхідно буде внести обробку та виділення фрагменту для другого відеоряду, а також встановити необхідні обмеження для використання даних. Головна ж послідовність залишиться незмінною: знаходження об'єкту на відеофрагменті, використання до фрагменту алгоритму порівняння за допомогою нейронної мережі, виконання встановлених дій при знаходженні об'єкту.

4 АНАЛІЗ АЛГОРИТМІВ ПІДВИЩЕННЯ МОЖЛИВОСТІ ВИЯВЛЕННЯ ТА ВІДСТЕЖЕННЯ БПЛА

4.1 Підвищення можливості виявлення та відстеження БПЛА

Для підвищення можливості виявлення та відстеження БПЛА є необхідним використання в одній системі одразу декількох видів датчиків та об'єднання всіх отриманих даних. Об'єднання даних з кількох датчиків має на меті об'єднати дані з різних модальностей для створення висновків, які були б неможливі з одного датчика [146]. Найцікавішим завданням у злитті даних є досягнення спільного представлення мультисенсорних даних. В останні роки штучний інтелект і глибокі нейронні мережі стали дуже привабливими для представлення мультисенсорних даних [147]. Загалом мультимодальне навчання є громіздким, оскільки дані надходять у різних представленнях. Як наслідок проблем мультимодального навчання, є деякі можливі рішення, такі як поєднання окремих моделей навчання для окремих модальностей на вищому та абстрактному рівні.

4.2 Додання тепловізійних та камер нічного бачення

Так як, запропонована у цій роботі система виявлення та відстеження БПЛА в своїй основі використовує оптичний інформаційний канал, додання інших типів камер є найпростішим варіантом покращення системи. В своїй основі алгоритм виявлення БПЛА залишається не змінним, але є проблема навчання нейронної мережі алгоритму даним отриманим для кожного виду камер, які необхідно підготувати.

4.3 Виявлення та відстеження БПЛА за допомогою поєднання акустичних даних і даних зображення

Авторами [79] була запропонована система виявлення БПЛА за допомогою мікрофона та камери шляхом навчання моделей глибокого навчання на основі зображень і акустичних характеристик. Для оцінки використовуються три методи: візуальний, аудіо та об'єднання обох функцій. Поєднання аудіо- та візуальних функцій використовується для отримання вищої продуктивності при виявленні безпілотників. Зображення та аудіодані були зібрані з дрона-детектора за допомогою двох безпілотних літальних апаратів у небі на фіксованій евклідовій відстані 20 метрів. Крім того, для дослідження оптимальної продуктивності застосовуються методи глибокого навчання. CNN (Convolutional Neural Network) використовувався для акустичних даних, а YOLOv5 – для комп'ютерного зору. Згідно з результатом, об'єднання аудіо- та відеофункцій показало найвищу точність серед трьох методів оцінювання.

Дані про безпілотники були розділені на два класи: безпілотники та безпілотники. Класифікація дронів була проведена для ідентифікації існування дронів. Необхідний потік обробки можна сегментувати на п'ять частин, показаних на рис. 4.1 [79]. Пропонована система має одну камеру і мікрофон.




Рисунок 4.1 – Огляд системи виявлення БПЛА [79]

4.3.1 Виділення ознак

Акустичні дані розбиваються на одну секунду для сегментації звуку. Для класифікації звуку дрону використовується MFCC, який є нелінійним відображенням вихідної частоти відповідно до слухового механізму людського вуха. Також MFCC широко використовується для класифікації аудіо та успішно використовується з машинним навчанням і глибоким навчанням. Крім того, MFCC пропонує корисні функції для захоплення періодичності від основних частот, викликаних лопатями ротора дрона. Акустичні характеристики MFCC витягуються за допомогою Librosa [80] з пакету Python.

Для навчання моделі виявляти безпілотники оптичним методом, автори [79] спочатку позначили всі наземні об'єкти на зображеннях. Цей набір даних позначається за допомогою «LabelImg», який є інструментом з відкритим кодом.

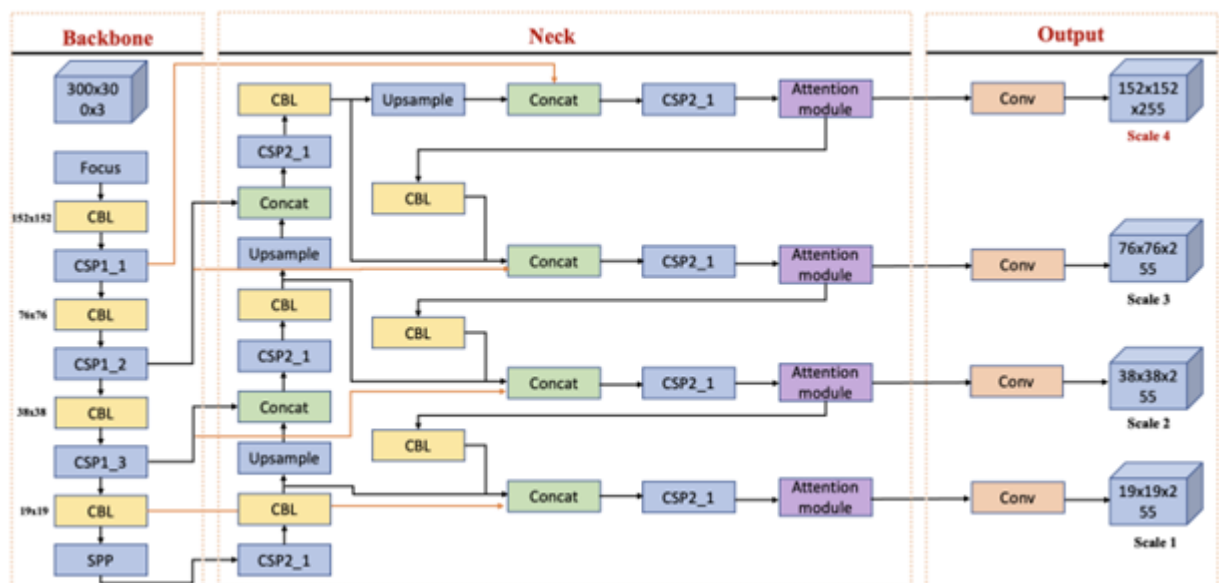


Рисунок 4.2 – Архітектура YOLOv5 [79]

Для виділення характеристик зображення CBL (Convolution with Batch normalization and Leaky ReLU), SPP (Spatial Pyramid Pooling) і CSP

використовувалися в базовому шарі YOLOv5. Магістральна мережа витягує карти функцій різних розмірів із вхідних зображень через шар згортки та рівень об'єднання. Загальна структура показана на рис. 4.2 По-перше, CBL — це блок, який, використовується для вилучення функцій, що складаються з шару згортки, пакетної нормалізації та витоків ReLU. SPP покращує продуктивність, об'єднуючи різні розміри карт функцій із фільтрами, а потім знову об'єднуючи їх. CSP ділить карту функцій базового шару на дві частини, щоб зменшити важкі обчислення, викликані дублюванням інформації про градієнт. Таким чином, інформація про розширений градієнт може мати велику кореляційну різницю шляхом перемикання кроків конкатенації та трансформації. Крім того, CSP може значно зменшити обчислювальні зусилля та підвищити швидкість і точність висновків.

Використовується 5 магістральних мереж - YOLOv5-n,s,m,l,x. Кожна модель відрізняється кратністю глибини і кратністю ширини. Чим більше кратне значення глибини, тим більше BottleneckCSP() повторюється, щоб стати глибшою моделлю. Чим більше кратне значення ширини, тим вищий номер фільтра згортки відповідного шару.

4.3.2 Моделі глибокого навчання

Для аудіо виявлення серед різних класифікаторів CNN використовується MFCC, який показує високу продуктивність у класифікації аудіосигналів із такими спектральними характеристиками.

Швидкість навчання встановлено на 0,0001 за допомогою оптимізатора TensorFlow Keras, Adam. Крім того, Early Stopping використовується для запобігання переобладнанню моделі. Дві функції активації, sigmoid і softmax, використовуються для оцінки кінцевої продуктивності. Найкраще працює функція активації Sigmoid.

Для оптичного методу класифікація зазвичай стосується зображень, на яких видно та аналізується лише один об'єкт. Навпаки, виявлення об'єктів включає завдання класифікації та локалізації для аналізу більш реалістичних ситуацій, коли на зображенні можуть бути присутні кілька об'єктів.

Модель виявлення об'єкта можна розділити на два основні типи: одноетапну модель і двоетапну модель. У порівнянні з іншими двоетапними моделями виявлення об'єктів, включаючи R-CNN і Faster R-CNN, одноступеневі моделі, такі як YOLO, можуть обчислювати досить швидко, щоб виконувати завдання виявлення об'єктів у реальному часі. Тому YOLOv5 обрано як відповідну модель для виявлення дронів у цьому дослідженні. Оскільки виявлення об'єктів для CUAS має бути реалізовано в режимі реального часу.

Модель YOLOv5 може бути представлена YOLOv5-n,s,m,l,x залежно від ємності моделі та кількості параметрів. Моделі з великою ємністю, такі як YOLOv5x, можуть підвищити точність, але мають повільну роботу. І навпаки, легка модель, така як YOLOv5n, є швидкою, але не може отримати видатну продуктивність у точності.

У ході аналізу було розглянуто методи підвищення можливості виявлення та відстеження БПЛА, шляхом додання до системи нових типів датчиків. Додання інших типів камер є найпростішим варіантом удосконалення системи. В своїй основі алгоритм виявлення БПЛА залишається не змінним, але є проблема навчання нейронної мережі алгоритму даним отриманим для кожного виду камер. Також було розглянуто метод виявлення та відстеження БПЛА за допомогою поєднання акустичних даних і даних зображення, для підвищення можливостей виявлення дронів.

ВИСНОВКИ

Огляд літературних джерел показав, що радіолокаційні системи використовуються протягом десятиліть для виявлення повітряного судна, але зазвичай неможливо виявити невеликі комерційні БПЛА. Крім того, вони літають із порівняно набагато меншими швидкостями, що зменшує величину сигналу отриманого з ефекту доплера. Як правило, системи радару не класифікують інші повітряні об'єкти, такі як птахи та фоновий безлад. Отже, радіолокаційні системи не розглядалися як ефективне рішення боротьби з безпілотниками, особливо для автономних конфігурацій.

Акустичні датчики також використовуються для виявлення безпілотників за допомогою мікрофонних решіток. Метою є класифікація специфічного звуку роторів безпілотників, однак їм не вдається досягти високої точності та робочого діапазону. Максимальний діапазон аудіосистем не перевищує 200–250 м. Іншим недоліком системи є проблема розпізнавання в міських або галасливих умовах, таких як аеропорти.

Проблеми, котрі пов'язані з термодатчиками більш економічного характеру: дешеві термодатчики доволі мають низьку роздільну здатність та вразливі до параметрів навколишнього середовища, таких як волога повітря, тому для усунення цих завад необхідна більш якісна та відповідно дорога камера. Додатково до ціни подібних камер додається ще й складність їх отримання, оскільки більшість таких моделей використовується у воєнних цілях.

Основною перевагою виявлення БПЛА на основі LiDAR є автоматично створена тривимірна координата БПЛА. Крім того, LiDAR стійкий до змін освітленості та умов навколишнього середовища. До недоліків можна віднести зниження рівня виявлення на відстанях понад 30 м, що можна простежити через низьку щільність точок на цілях. Крім того, розрив між лініями сканування дозволяє БПЛА залишатися непоміченими на цих відстанях.

Попри всі переваги радіовідстеження та локалізації, слід зазначити, що сьогодні технічно можливо побудувати безпілотник, який взагалі не потребує зв'язку.

На основі проведеного аналізу, а також через зручність роботи та велику кількість досягнень комп'ютерного зору, у якості суб'єкту для відстеження було обрано оптичні датчики, котрі компенсують свої недоліки зручністю отримання і обробки даних, високої можливості виявлення та класифікації об'єктів та мають більш приємливу ціну.

Проаналізувавши обраний метод виявлення БПЛА за допомогою камер, можна підсумувати, що алгоритм є доволі надійним методом відстеження, оскільки ураховує наявність інших літаючих об'єктів, котрі можуть нагадувати БПЛА, має у запасі двоетапну перевірку на загальному та окремих випадках. Було проведено розрахунок параметрів фокусної відстані та кута зони огляду для ширококутної та вузькокутної камери. Також була представлена архітектура системи виявлення БПЛА з використанням оптичних камер, структурна схема системи та опис роботи системи.

В якості програмного забезпечення для рішення задачі виявлення БПЛА було обрано мову Python для написання програми виявлення об'єктів на відео, основується на статистичних даних, широкій відомості, зручності у написанні коду та великій кількості бібліотек, створених для розробки у напрямленнях AI та ML, було обрано мову Python. На відміну від інших мов, котрі можуть бути використані у даних напрямленнях, Python надає можливості для більш гнучкого та адаптивного програмування, що збільшує діапазон можливостей для даної сфери діяльності.

Було розроблено загальний алгоритм розв'язання задачі виявлення БПЛА на відео. Даний алгоритм послідовності дій може бути адаптовано до окремих випадків, зі внесенням або доданням деяких змін, а саме: використання іншого дескриптора нейронної мережі, змінення графічного інтерфейсу, котрий був створений за допомогою бібліотеки tkinter, вибір іншого голосового помічника, а також налаштування його під конкретні цілі.

Також при доданні другої камери у даний алгоритм необхідно буде внести обробку та виділення фрагменту для другого відеоряду, а також встановити необхідні обмеження для використання даних. Головна ж послідовність залишиться незмінною: знаходження об'єкту на відеофрагменті, використання до фрагменту алгоритму порівняння за допомогою нейронної мережі, виконання встановлених дій при знаходженні об'єкту.

У ході аналізу було розглянуто методи підвищення можливості виявлення та відстеження БПЛА, шляхом додання до системи нових типів датчиків. Додання інших типів камер є найпростішим варіантом вдосконалення системи. В своїй основі алгоритм виявлення БПЛА залишається не змінним, але є проблема навчання нейронної мережі алгоритму даним отриманим для кожного виду камер. Також було розглянуто метод виявлення та відстеження БПЛА за допомогою поєднання акустичних даних і даних зображення, для підвищення можливостей виявлення дронів.

ПЕРЕЛІК ПОСИЛАНЬ

1. Application of Fast Frequency Shift Measurement Method for INS in Navigation of Drones / D. Avalos-Gonzalez, D.H. Balbuena, V. Tyrsa, V.M. Kartashov, M. Kolendovska, S. Sheiko, O. Sergiyenko, V. Melnyk, F.N. Murrieta-Rico // IECON 2018 – 44th Annual Conference of the IEEE Industrial Electronics Society. – P. 3159–3164.
2. Cuauhtémoc Mariscal-García; Wendy Flores-Fuentes; Daniel Hernández-Balbuena; Julio C. Rodríguez-Quiñonez; Oleg Sergiyenko. "Classification of Vehicle Images through Deep Neural Networks for Camera View Position Selection," 2020 IEEE 29th International Symposium on Industrial Electronics (ISIE), Delft, Netherlands, 17-19 of June 2020, pp. 1376-1380, doi: 10.1109/ISIE45063.2020.9152440.
<https://ieeexplore.ieee.org/abstract/document/9152440>
3. Experimental estimation of direction finding to unmanned air vehicles algorithms efficiency by their acoustic emission, /Oleynikov, V., Zubkov, O., Kartashov, V., ...Sheiko, S., Babkin, S.//2019 IEEE International Scientific-Practical Conference: Problems of Infocommunications Science and Technology, PIC S and T 2019 - Proceedings, 2019, стр. 175-178, 9061337
4. Features of acoustic noise of small unmanned aerial vehicles / Semenets, V.V., Kartashov, V.M., Leonidov, V.I. //Telecommunications and Radio Engineering (English translation of *Elektrosvyaz* and *Radiotekhnika*), 2020, 79(11), стр. 985-995
5. Jonathan J. Sanchez-Castro; Julio C. Rodríguez-Quiñonez; Luis R. Ramírez-Hernández; Guillermo Galaviz; Daniel Hernández-Balbuena; Gabriel Trujillo-Hernández; Wendy Flores-Fuentes; Paolo Mercorelli; Wilmar Hernández-Perdomo; Oleg Sergiyenko; Félix Fernando González-Navarro. "A Lean Convolutional Neural Network for Vehicle Classification," 2020 IEEE 29th International Symposium on Industrial Electronics (ISIE), Delft,

Netherlands, 17-19 of June 2020, pp. 1365-1369, doi: 10.1109/ISIE45063.2020.9152274.

<https://ieeexplore.ieee.org/abstract/document/9152274>

6. Lindner, L., Sergiyenko, O., Rivas-López, M., (...), Gurko, A., Kartashov, V.M. Machine vision system for UAV navigation; IEEE, 2016 International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles and International Transportation Electrification Conference, ESARS-ITEC, 2016; pp.1–6. DOI: 10.1109/ESARS-ITEC.2016.7841356.
7. Optical detection of unmanned air vehicles on a video stream in a real-time/Kartashov, V., Oleynikov, V., Zubkov, O., Sheiko, S.// 2019 International Conference on Information and Telecommunication Technologies and Radio Electronics, UkrMiCo 2019 - Proceedings, 2019, 9165362/
8. Spatial-Temporal Processing Of Acoustic Signals Of Unmanned Aerial Vehicles /Kartashov V.M., Oleinikov V.N., Zubkov O.V., Sheiko S.A., Kolendovska M.M.// Telecommunications And Radio Engineering (English Translation Of Elektrosvyaz And Radiotekhnika), 2020, ISSN Print: 0040-2508, ISSN Online: 1943-6009, DOI: 10.1615/Telecomradeng.v79.i9.40, p. 769-780
9. Use of Acoustic Signature for Detection, Recognition and Direction Finding of Small Unmanned Aerial Vehicles/Kartashov, V., Oleynikov, V., Koryttsev, I., ...Babkin, S., Selieznov, I.//Proceedings - 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering, TCSET 2020, 2020, p. 377-380/
10. Anti-Drone. Anti-Drone System Overview and Technology Comparison. 2016. Available online: <https://anti-drone.eu/blog/anti-drone-publications/anti-drone-system-overview-and-technology-comparison.html> (accessed on 6 May 2019).

11. Knott, E.F.; Schaeffer, J.F.; Tulley, M.T. Radar Cross Section; SciTech Publishing: New York, NY, USA, 2004.
12. Molchanov, P.; Harmanny, R.I.; de Wit, J.J.; Egiazarian, K.; Astola, J. Classification of small UAVs and birds by micro-Doppler signatures. *Int. J. Microw. Wirel. Technol.* 2014, 6, 435–444.
13. Tait, P. Introduction to Radar Target Recognition; IET: London, UK, 2005; Volume 18.
14. Jokanovic, B.; Amin, M.; Ahmad, F. Radar fall motion detection using deep learning. In Proceedings of the 2016 IEEE Radar Conference (RadarConf), Philadelphia, PA, USA, 1–6 May 2016; pp. 1–6.
15. Chen, V.C.; Li, F.; Ho, S.S.; Wechsler, H. Micro-Doppler effect in radar: Phenomenon, model, and simulation study. *IEEE Trans. Aerosp. Electron. Syst.* 2006, 42, 2–21.
16. Al Hadhrami, E.; Al Mufti, M.; Taha, B.; Werghi, N. Transfer learning with convolutional neural networks for moving target classification with micro-Doppler radar spectrograms. In Proceedings of the 2018 International
17. Chen, X.; Guan, J.; Bao, Z.; He, Y. Detection and extraction of target with micromotion in spiky sea clutter via short-time fractional Fourier transform. *IEEE Trans. Geosci. Remote Sens.* 2013, 52, 1002–1018.
18. Tahmoush, D.; Silvius, J. Radar micro-Doppler for long range front-view gait recognition. In Proceedings of the 2009 IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems, Washington, DC, USA, 28–30 September 2009; pp. 1–6.
19. Li, Y.; Peng, Z.; Pal, R.; Li, C. Potential Active Shooter Detection Based on Radar Micro-Doppler and Range-Doppler Analysis Using Artificial Neural Network. *IEEE Sens. J.* 2018, 19, 1052–1063.
20. De Wit, J.M.; Harmanny, R.; Premel-Cabic, G. Micro-Doppler analysis of small UAVs. In Proceedings of the 2012 9th European Radar Conference, Amsterdam, The Netherlands, 31 October–2 November 2012; pp. 210–213.

21. Harmanny, R.; De Wit, J.; Cacic, G.P. Radar micro-Doppler feature extraction using the spectrogram and the cepstrogram. In Proceedings of the 2014 11th European Radar Conference, Cincinnati, OH, USA, 11–13 October 2014; pp. 165–168.
22. Bogert, B.P. The quefreny alanysis of time series for echoes; Cepstrum, pseudo-autocovariance, cross-cepstrum and saphe cracking. *Time Ser. Anal.* 1963, 15, 209–243.
23. Fioranelli, F.; Ritchie, M.; Griffiths, H.; Borrion, H. Classification of loaded/unloaded micro-drones using multistatic radar. *Electron. Lett.* 2015, 51, 1813–1815.
24. Hastie, T.; Tibshirani, R.; Friedman, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*; Springer Series in Statistics; Springer: Berlin/Heidelberg, Germany, 2009.
25. Patel, J.S.; Fioranelli, F.; Anderson, D. Review of radar classification and RCS characterisation techniques for small UAVs ordrones. *IET Radar Sonar Navig.* 2018, 12, 911–919.
26. Chen, W.; Liu, J.; Li, J. Classification of UAV and bird target in low-altitude airspace with surveillance radar data. *Aeronaut. J.* 2019, 123, 191–211.
27. Kim, B.K.; Kang, H.S.; Park, S.O. Drone classification using convolutional neural networks with merged Doppler images. *IEEE Geosci. Remote Sens. Lett.* 2016, 14, 38–42.
28. Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. Going deeper with convolutions. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 7–12 June 2015; pp. 1–9.
29. Samaras S., Diamantidou E., Ataloglou D., Sakellariou N., Vafeiadis A., Magoulianitis V., Lalas A., Dimou A., Zarpalas D., Votis K., Daras P., Tzouvaras D. Deep learning on multi sensor data for counter UAV

- applications — a systematic review. *Sensors*. 2019;19(22):4837. doi: 10.3390/s19224837.
- 30.Svanström, F.; Alonso-Fernandez, F.; Englund C. A dataset for multi-sensor drone detection. Center for Applied Intelligent Systems Research (CAISR), Halmstad University, Halmstad SE 301 18, Sweden, 2021.
- 31.Saqib, M.; Khan, S.D.; Sharma, N.; Blumenstein, M. A study on detecting drones using deep convolutional neural networks. In Proceedings of the 2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), Lecce, Italy, 29 August–1 September 2017.
- 32.Simonyan, K.; Zisserman, A. Very deep convolutional networks for large-scale image recognition. arXiv 2014, arXiv:1409.1556.
- 33.Zeiler, M.D.; Fergus, R. Visualizing and understanding convolutional networks. In Proceedings of the European Conference on Computer Vision, Zurich, Switzerland, 6–12 September 2014; pp. 818–833.
- 34.Chang, C.I. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*; Springer Science & Business Media: New York, NY, USA, 2003; Volume 1.
- 35.Wang, D.; Vinson, R.; Holmes, M.; Seibel, G.; Bechar, A.; Nof, S.; Tao, Y. Early Detection of Tomato Spotted Wilt Virus by Hyperspectral Imaging and Outlier Removal Auxiliary Classifier Generative Adversarial Nets (OR-AC-GAN). *Sci. Rep.* 2019, 9, 4377.
- 36.Lu, Y.; Perez, D.; Dao, M.; Kwan, C.; Li, J. Deep learning with synthetic hyperspectral images for improved soil detection in multispectral imagery. In Proceedings of the IEEE Ubiquitous Computing, Electronics & Mobile Communication Conference, New York, NY, USA, 20–22 October 2018; pp. 8–10.
- 37.Liang, J.; Zhou, J.; Tong, L.; Bai, X.; Wang, B. Material based salient object detection from hyperspectral images. *Pattern Recognit.* 2018, 76, 476–490.

38. Freitas, S.; Silva, H.; Almeida, J.; Silva, E. Hyperspectral imaging for real-time unmanned aerial vehicle maritime target detection. *J. Intell. Robot. Syst.* 2018, 90, 551–570.
39. Pham, T.; Takalkar, M.; Xu, M.; Hoang, D.; Truong, H.; Dutkiewicz, E.; Perry, S. Airborne Object Detection Using Hyperspectral Imaging: Deep Learning Review. In *Proceedings of the International Conference on Computational Science and Its Applications, Saint Petersburg, Russia, 1–4 July 2019*; pp. 306–321.
40. Paoletti, M.; Haut, J.; Plaza, J.; Plaza, A. A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS J. Photogramm. Remote Sens.* 2018, 145, 120–147.
41. Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M.; et al. Imagenet large scale visual recognition challenge. *Int. J. Comput. Vis.* 2015, 115, 211–252.
42. Patel, S.N.; Robertson, T.; Kientz, J.A.; Reynolds, M.S.; Abowd, G.D. At the flick of a switch: Detecting and classifying unique electrical events on the residential power line (nominated for the best paper award). In *Proceedings of the International Conference on Ubiquitous Computing, Innsbruck, Austria, 16–19 September 2007*; pp. 271–288.
43. Barchiesi, D.; Giannoulis, D.; Stowell, D.; Plumbley, M.D. Acoustic scene classification: Classifying environments from the sounds they produce. *IEEE Signal Process. Mag.* 2015, 32, 16–34.
44. Parascandolo, G.; Heittola, T.; Huttunen, H.; Virtanen, T. Convolutional Recurrent Neural Networks for Polyphonic Sound Event Detection. *IEEE/ACM Trans. Audio Speech Lang. Process.* 2017, 25, 1291–1303.
45. Eghbal-Zadeh, H.; Lehner, B.; Dorfer, M.; Widmer, G. CP-JKU submissions for DCASE-2016: A hybrid approach using binaural i-vectors and deep convolutional neural networks. In *Proceedings of the 2017 IEEE 25th European Signal Processing Conference (EUSIPCO), Kos, Greece, 28 August–2 September 2017*; pp. 2749–2753.

46. Salamon, J.; Bello, J.P. Deep convolutional neural networks and data augmentation for environmental sound classification. *IEEE Signal Process. Lett.* 2017, 24, 279–283.
47. Liu, J.; Yu, X.; Wan, W.; Li, C. Multi-classification of audio signal based on modified SVM. In *Proceedings of the IET International Communication Conference on Wireless Mobile and Computing (CCWMC 2009)*, Shanghai, China, 7–9 December 2009; pp. 331–334.
48. Li, J.; Dai, W.; Metze, F.; Qu, S.; Das, S. A comparison of Deep Learning methods for environmental sound detection. In *Proceedings of the 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, New Orleans, LA, USA, 5–9 March 2017; pp. 126–130.
49. Chowdhury, A.S.K. Implementation and Performance Evaluation of Acoustic Denoising Algorithms for UAV. Master's Thesis, University of Nevada, Las Vegas, NV, USA, 2016.
50. Mezei, J.; Molnár, A. Drone sound detection by correlation. In *Proceedings of the 2016 IEEE 11th International Symposium on Applied Computational Intelligence and Informatics (SACI)*, Timisoara, Romania, 12–14 May 2016; pp. 509–518.
51. Park, S.; Shin, S.; Kim, Y.; Matson, E.T.; Lee, K.; Kolodzy, P.J.; Slater, J.C.; Scherreik, M.; Sam, M.; Gallagher, J.C.; et al. Combination of radar and audio sensors for identification of rotor-type unmanned aerial vehicles (uavs). In *Proceedings of the 2015 IEEE SENSORS*, Busan, Korea, 1–4 November 2015; pp. 1–4.
52. Liu, H.; Wei, Z.; Chen, Y.; Pan, J.; Lin, L.; Ren, Y. Drone detection based on an audio-assisted camera array. In *Proceedings of the 2017 IEEE Third International Conference on Multimedia Big Data (BigMM)*, Laguna Hills, CA, USA, 19–21 April 2017; pp. 402–406.
53. Kim, J.; Park, C.; Ahn, J.; Ko, Y.; Park, J.; Gallagher, J.C. Real-time UAV sound detection and analysis system. In *Proceedings of the 2017 IEEE*

- Sensors Applications Symposium (SAS), Glassboro, NJ, USA, 13–15 March 2017; pp. 1–5.
54. Kim, J.; Kim, D. Neural Network based Real-time UAV Detection and Analysis by Sound. *J. Adv. Inf. Technol. Converg.* 2018, 8, 43–52.
55. Spinello, L., Luber, M., Arras, K. O., “Tracking People in 3D Using a Bottom-Up Top-Down Detector,” in *IEEE Int. Conf. on Robotics and Automation (ICRA)*, 2011.
56. Li, B., Zhang, T., Xia, T., “Vehicle Detection from 3D Lidar Using Fully Convolutional Network,” In *Robotics: Science and Systems*, 2014.
57. Armbruster, W. Hammer, M., “Segmentation, classification, and pose estimation of maritime targets in flash-lidar imagery,” in *SPIE Proceedings, Volume 8542, Signal and Image Processing I*, 2012.
58. Laurenzis, M., Bacher, E., Christnacher F., “Experimental and Rendering-based Investigation of Laser Radar Cross-Sections of small Unmanned Aerial Vehicles,” *Optical Engineering*, 56, 124106, 2017.
59. Hammer, M.; Hebel, M.; Borgmann, B.; Laurenzis, M.; Arens, M. Potential of lidar sensors for the detection of UAVs. *SPIE Defense + Security*, 2018, Orlando, Florida, United States, 2018.
60. Müller, T.; Widak, H.; Kollmann, M.; Buller, A.; Sommer, L.; Spraul, R.; Kröker, A.; Kaufmann, I.; Zube, A.; Segor, F.; Perschke, T.; Lindner, A.; Tchouchenkov I. Drone detection, recognition, and assistance system for counter-UAV with VIS, radar, and radio sensors. *SPIE Defense + Commercial Sensing*, 2022, Orlando, Florida, United States, 2022.
61. Behera, D.K.; Raj, A.B. Drone Detection and Classification Using Deep Learning. In *Proceedings of the 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, India, 13–15 May 2020; IEEE: Piscataway Township, NJ, USA; pp. 1012–1016.
62. Albawi, S.; Mohammed, T.A.; Al-Zawi, S. Understanding of a Convolutional Neural Network. In *Proceedings of the 2017*

63. Hu, Y.; Wu, X.; Zheng, G.; Liu, X. Object Detection of UAV for Anti-UAV Based on Improved YOLO V3. In Proceedings of the 2019 Chinese Control Conference (CCC), Guangzhou, China, 27–30 July 2019; pp. 8386–8390.
64. Girshick, R. Fast R-CNN. In Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 7–13 December 2015; pp. 1440–1448.
65. Ren, S.; He, K.; Girshick, R.; Sun, J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2017, 39, 1137–1149. *Drones* 2021, 5, 95 20 of 20
66. Lee, W.; Kang, M.-H.; Song, J.; Hwang, K. The Design of Preventive Automated Driving Systems Based on Convolutional Neural Network. *Electronics* 2021, 10, 1737.
67. R. Girshick. Fast R-CNN. arXiv:1504.08083, 2015
68. Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You Only Look Once: Unified, Real-Time Object Detection. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016; pp. 779–788.
69. Tao, J.; Wang, H.; Zhang, X.; Li, X.; Yang, H. An Object Detection System Based on YOLO in Traffic Scene. In Proceedings of the 2017 6th International Conference on Computer Science and Network Technology (ICCSNT), Dalian, China, 21–22 October 2017; pp. 315–319.
70. Sadykova, D.; Pernebayeva, D.; Bagheri, M.; James, A. IN-YOLO: Real-Time Detection of Outdoor High Voltage Insulators Using UAV Imaging. *IEEE Trans. Power Deliv.* 2020, 35, 1599–1601. [CrossRef]
71. Kharchenko, V.; Chyrka, I. Detection of Airplanes on the Ground Using YOLO Neural Network. In Proceedings of the 2018 IEEE 17th International Conference on Mathematical Methods in Electromagnetic Theory (MMET), Kyiv, Ukraine, 2–5 July 2018; pp. 294–297.

- 72.Redmon, J.; Farhadi, A. YOLO9000: Better, Faster, Stronger. In Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 21–26 July 2017; pp. 6517–6525.
- 73.Redmon, J.; Farhadi, A. YOLOv3: An Incremental Improvement. arXiv 2018, arXiv:1804.02767.
- 74.Bochkovskiy, A.; Wang, C.-Y.; Liao, H.-Y.M. YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv 2020, arXiv:2004.10934.
- 75.Misra, D. Mish: A Self Regularized Non-Monotonic Activation Function. arXiv 2020, arXiv:1908.08681.
- 76.Shi, Q.; Li, J. Objects Detection of UAV for Anti-UAV Based on YOLOv4. In Proceedings of the 2020 IEEE 2nd International Conference on Civil Aviation Safety and Information Technology (ICCASIT), Weihai, China, 14–16 October 2020; pp. 1048–1052.
- 77.Системи контролю доступу. [Електронний ресурс]
URL: <https://skd.lviv.ua/all-about-cctv-cameras> (дата звернення: 23.11.2022)
- 78.INOXOFT. Why use python for machine learning [Електронний ресурс]
URL: <https://inoxoft.com/blog/why-use-python-for-machine-learning/> (дата звернення: 23.11.2022)
- 79.Kim, J.; Lee, D.; Kim, Y.; Shin, H.; Heo, Y.; Wang, Y.; T. Matson, E. Deep Learning Based Malicious Drone Detection Using Acoustic and Image Data, EasyChair Preprint no. 9335, November 18, 2022.
- 80.McFee, Brian, Colin Raffel, Dawen Liang, Daniel PW Ellis, Matt McVicar, Eric Battenberg, and Oriol Nieto. “librosa: Audio and music signal analysis in python.” In Proceedings of the 14th python in science conference, pp. 18-25. 2015.