



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ

Факултет „Компютърни системи и технологии“

Катедра „Компютърни системи“

Маг. инж. Елеонора Ивова Иванова

**ОТДАЛЕЧЕНО ОТКРИВАНЕ, РАЗПОЗНАВАНЕ И
ПРОСЛЕДЯВАНЕ НА ОБЕКТИ ПРИ БЕЗПИЛОТНИ
ЛЕТАТЕЛНИ АПАРАТИ**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
"ДОКТОР"

Област: 5. Технически науки

Професионално направление: 5.3 Комуникационна и компютърна техника

Научна специалност: „Системи с изкуствен интелект“

Научни ръководители:

проф. д-р инж. Милена Кирилова Лазарова–Мицева

проф. д-р инж. Румен Иванов Трифонов

СОФИЯ, 2025 г.

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Компютърни системи“ към Факултет „Компютърни системи и технологии“ на ТУ–София на редовно заседание, проведено на 28.04.2025 г.

Публичната защита на дисертационния труд ще се състои на 10.07.2025 г. от 13:00 часа в Конферентната зала на БИЦ на Технически университет – София на открито заседание на научното жури, определено със заповед № ОЖ-5.3-21/12.05.2025 г. на Ректора на ТУ–София в състав:

1. Проф. д-р Огнян Наков – председател
2. Доц. д-р Галя Павлова – научен секретар
3. Проф. д-р Иван Куртев
4. Проф. д-р Станимир Садинов
5. Проф. д-р Емил Йончев

Рецензенти:

1. Проф. д-р Емил Йончев
2. Доц. д-р Галя Павлова

Материалите по защитата са на разположение на интересуващите се в канцеларията на Факултет „Компютърни системи и технологии“ на ТУ–София, блок №1, кабинет №1443а.

Дисертантът е задочен докторант към катедра „Компютърни системи“ на Факултет „Компютърни системи и технологии“. Изследванията по дисертационната разработка са направени от автора, като някои от тях са подкрепени от научноизследователски проекти.

Автор: маг. инж. Елеонора Иванова

Заглавие: Отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

В последното десетилетие безпилотните летателни апарати (БПЛА) се превърнаха в ключова технология с широко приложение в граждански, военни и научни области. Отдалеченото откриване, разпознаване и проследяване на обекти чрез БПЛА е от критично значение за задачи като наблюдение и охрана на граници, екологичен мониторинг, спасителни операции, прецизно земеделие и управление на бедствия.

Съвременните предизвикателства, свързани със сигурността, изменението на климата и необходимостта от автоматизирано събиране на данни, правят необходимостта от надеждни и интелигентни системи за разпознаване и проследяване по-актуална от всякога. Развитието на изкуствен интелект, компютърно зрение, сензорни технологии (инфрочервени, радарни, ултразвукови) и обработка на големи обеми данни значително разширява възможностите на БПЛА да действат автономно и в реално време в сложни и динамични среди.

Въпреки технологичния напредък, все още съществуват значителни предизвикателства по отношение на точността, устойчивостта при лоши метеорологични условия, енергийната ефективност и интеграцията на мултисензорна информация. Освен това, с увеличаването на използването на БПЛА, възникват и нови регулаторни, етични и социални въпроси, свързани със защитата на личните данни и обществената безопасност.

Всичко това подчертава необходимостта от задълбочени изследвания и иновации в областта на отдалеченото откриване, разпознаване и проследяване на обекти при БПЛА, които да осигурят по-голяма автономност, надеждност и ефективност при реални приложения.

Цел на дисертационния труд, основни задачи и методи за изследване

Целта на научните изследвания в дисертационния труд е да се изследват, предложат и оценят методи за откриване, разпознаване и проследяване на обекти с използване данни, получени с безпилотни летателни апарати, които осигуряват висока точност, надеждност и ефективност.

За постигането на поставената цел следва да бъдат изпълнени следните задачи:

1. *Разработване на иновативна система:* да се проектира, разработи и внедри ефективна система за отдалечено откриване, разпознаване и проследяване на обекти, която използва съвременни технологии, включително сензори, изкуствен интелект и аналитични алгоритми.
2. *Интеграция на технологии:* да се изследват и интегрират различни технологии за сензорни данни и навигация с цел оптимизиране на производителността и точността на системата.
3. *Оценка на приложенията:* да се анализира приложимостта на предложената система в различни области като екология, земеделие, сигурност и управление на бедствия, с акцент на реализацията на устойчиви решения.
4. *Преодоляване на предизвикателствата:* да се идентифицират текущите предизвикателства, свързани с обработката на данни, условията на околната среда и наличните ресурси, и разработване на нови методи и алгоритми за справяне с тях.
5. *Валидация и оценка на системата:* да се проведат експерименти и тестове с цел валидиране на ефективността и надеждността на системата при реални условия.

Научните методи, които са използвани за постигане на целта на дисертационния труд са свързани с проучване на литературни източници в областта на методите и алгоритмите за откриване, разпознаване и проследяване на обекти на базата на данни от безпилотни летателни апарати; сравнителен анализ и избор на методи и алгоритми за откриване,

разпознаване и проследяване на обекти на базата на данни от безпилотни летателни апарати; моделиране и имплементиране на предложените методите и алгоритми за откриване, разпознаване и проследяване на обекти на базата на данни от безпилотни летателни апарати; статистическо представяне и анализ на получените експериментални резултати.

Научна новост

Настоящият дисертационен труд предлага цялостна методология и архитектура за отдалечено откриване, разпознаване и проследяване на обекти чрез БПЛА, което представлява значим принос в областта на системите с изкуствен интелект и автономните платформи за наблюдение.

Научната новост в дисертационния труд е в няколко основни насоки:

- Предложена е методология за проектиране и разработване на система за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати и концептуална архитектура на система, състояща се от хардуерни компоненти и софтуерни модули, чието интегриране осигурява функционирането на системата съгласно поставените цели и функционални изисквания за точност, производителност, бързодействие и работа в реално време и енергийна ефективност;

- Разработен е адаптивен алгоритмичен модел за откриване на обекти, който е пригоден за конкретни приложения като автономни дронаве, интелигентни транспортни системи и видеонаблюдение, с фокус върху разпознаване на малки обекти и динамична проследимост;

- Предложен е хибриден ансамблов метод за откриване на обекти, който позволява интеграция на мултисензорни данни за повишаване на точността и устойчивостта при разпознаване на обекти в реално време и в сложни среди, включително при частични закривания и неблагоприятни атмосферни условия;

- Предложени са техники за оптимизация на обучението на модели за отдалечено откриване, разпознаване и проследяване на обекти при БПЛА с използване на трансферно обучение, техники за обогатяване на данни и управление на обучителната скорост с помощта на политики с единствен цикъл, които подобряват точността на моделите и и предотвратяват прекомерното приспособяване;

- Предложена е модифицирана архитектура за ансамблово детектиране на обекти при БПЛА с използване на YOLOv8 за баланс между точност и изчислителна ефективност за приложения в реално време и на Faster R-CNN за подобряване на анализа при сложни сцени, която балансира между скорост на обработване и прецизност на резултатите като демонстрира до 7% подобрене в точността спрямо индивидуални модели при сложни сцени;

- Разработена е методология за оценка на устойчивостта на модели за откриване на обекти при БПЛА при закриване на обекти, която има особена практическа значимост за реални сценарии, при които данните са непълни или зашумени;

- Предложено е подобрене на енергийната и изчислителна ефективност на системата с използване на хардуерни и софтуерни оптимизации, което прави предложеното решение подходящо за задачи, изискващи работа в реално време с използване на ограничени ресурси

Тези иновации утвърждават дисертационния труд като съдържащ оригинални научни, научноприложни и приложни приноси с висока степен на приложимост, разширявайки границите на съществуващите решения за автономни визуални системи и обогатявайки полето на интелигентното наблюдение от въздуха.

Практическа приложимост

Разработената в настоящия дисертационен труд система за отдалечено откриване, разпознаване и проследяване на обекти с помощта на БПЛА демонстрира висока степен на практическа полезност.

На първо място, системата е приложима в широк кръг от реални ситуации – от мониторинг на природната среда и управление на земеделски дейности до дейности, свързани с националната сигурност и реакция при природни бедствия. Това показва не само нейната технологична адаптивност, но и социално-икономическата ѝ значимост. Интегрираният подход, който комбинира сензорни технологии, алгоритми за машинно и дълбоко обучение и ефективна обработка на изображения, позволява системата да бъде адаптирана за различни платформи и условия на работа. Проведените експерименти с реални данни потвърждават надеждността ѝ както в открити, така и в градски среди с висока степен на визуални смущения. Освен това, системата е проектирана с отчитане на енергийна и изчислителна ефективност – аспекти от изключително важно значение при работа с автономни въздушни платформи, които разполагат с ограничени ресурси. Това я прави подходяща за дълготрайни мисии с минимална човешка намеса. Не на последно място, предложените алгоритми и архитектурни решения имат потенциал за внедряване не само в индустриални и търговски системи, но и като основа за бъдещи научни изследвания. Модулната структура на проектираната система и възможността за работа с мултимодални данни я правят ценен инструмент както за инженери, така и за изследователи, търсещи стабилна и гъвкава основа за доразвитие и адаптация.

С оглед на всичко това, системата демонстрира ясно изразен потенциал за реална употреба в множество практически контексти, с възможност за доразвиване спрямо конкретните нужди на различни сектори и приложения.

Апробация

Резултатите от дисертационния труд са разглеждани, обсъждани и публикувани в:

1. Списание “Security & Future”.
2. Списание “Industry 4.0”.
3. Списание “International Journal of Advances in Computer Science and Technology (IJACST)”.
4. IX Международната научна конференция “INDUSTRY 4.0”, Боровец, България, 11–14 декември, 2024.
5. Научен семинар на докторанти във Факултет по Компютърни системи и технологии (24 юни 2022, 27 октомври 2023, 7 февруари 2025).

Публикации

Основни постижения и резултати от дисертационния труд са публикувани в 4 научни статии, като 2 от тях са самостоятелни. Научните статии са представени и публикувани в национални и международни конференции и международни реферирани и индексирани издания.

Структура и обем на дисертационния труд

Дисертационният труд е в обем от 162 страници, като включва увод, четири глави за решаване на формулираните основни задачи, списък на основните приноси, списък на публикациите по дисертацията и използвана литература. Цитирани са общо 138 литературни източници, всичките 138 са на латиница. Работата включва общо 14 фигури и 28 таблици. Номерата на фигурите и таблиците в автореферата съответстват на тези в дисертационния труд.

II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

УВОД

В уводът към дисертационния труд е представена тематиката на научните изследвания, свързана с разработване на система за отдалечено откриване, разпознаване и проследяване на обекти чрез БПЛА. Посочено е значението на тази технология за сектори като сигурност, земеделие, екология и управление при бедствия. Формулирани са обектът и предметът на изследване, както и основната изследователска хипотеза: с използване данни, получени с БПЛА може да бъде реализирано точно и надеждно откриване, разпознаване и проследяване на обекти. Формулирана е целта на дисертационния труд: да се изследват, предложат и оценят методи за откриване, разпознаване и проследяване на обекти с използване данни, получени с БПЛА. За постигане на тази цел са дефинирани конкретни задачи, които включват разработване на иновативна система, интеграция на технологии, анализ на приложимост, преодоляване на технически предизвикателства и валидация чрез експерименти. В увода са посочени и използваните научни методи: литературен преглед, сравнителен анализ, моделиране и експериментално валидиране.

ГЛАВА 1. ВЪВЕДЕНИЕ В КОНЦЕПЦИЯТА ЗА БЕЗПИЛОТНИ ЛЕТАТЕЛНИ АПАРАТИ

1.1. Определение и история на безпилотните летателни апарати

Безпилотните летателни апарати (БПЛА), известни още като дронове, представляват въздухоплавателни средства, които оперират без присъствието на човек на борда [1]. Те могат да бъдат контролирани дистанционно или да функционират автономно чрез вградени компютърни системи [2]. БПЛА намират приложение в множество области, включително военни операции [3], пионерски изследвания [4], селско стопанство [5], мониторинг на околната среда [6] и търговия [7].

1.2. Сензори и технологии за регистриране на данни

Съвременните БПЛА са оборудвани с разнообразие от сензори, включително камери с висока резолюция, инфрачервени и термовизионни камери, LiDAR (Light Detection and Ranging) и мултиспектрални сензори. Тези технологии позволяват БПЛА да извършват задълбочени анализи на околната среда, да събират данни за топография, растителност и дори да идентифицират обекти и аномалии.

1.3. Автономност и навигационни системи

Ключов аспект на технологичния напредък е развитието на автономните системи и навигацията. С интеграцията на GPS и инерциални навигационни системи, съвременните БПЛА могат да изпълняват сложни полетни маршрути без човешка намеса. Автономните летателни апарати използват алгоритми за планиране на мисии, които позволяват да се реагира на променящите се условия в реално време, осигурявайки безопасно и ефективно летиене. Автономността на БПЛА се постига чрез GPS и инерциални навигационни системи. Алгоритми за мисии, базирани на ИИ, позволяват адаптация в реално време при промяна на условията: интегрирането на многоспектрални и LiDAR данни е приложимо за сложна автономна навигация [14].

1.4. Значение на отдалеченото откриване и разпознаване на обекти

Отдалеченото откриване предоставя важни инструменти за наблюдение на Земята в реално време, което включва анализ на различни природни процеси и явления като климатични промени, замърсяване, повърхностни промени и биологично разнообразие. Чрез различни спектрални и термични изображения, получени от сателити или дронове, е

възможно да се анализират лесно изменения в екосистемите, горските пожари, наводненията и дори заболявания по растенията. Комбинацията от данни, получени от сателити и дроне, позволява заснемането на детайлни карти за екосистемите в сухите райони. Използването на нискоалтернативни дроне се оказва ключово при запълване на информационни празноти, съществуващи при сателитните изображения [18].

1.5. Приложения на разпознаването на обекти

Разпознаването на обекти от БПЛА намира много приложения в различни области, благодарение на способността на тези устройства да летят на голяма височина, да осигуряват изображения и видео в реално време. Някои примерни приложения на разпознаването на обекти от БПЛА са следните:

- *Сигурност и видеонаблюдение*: Видеонаблюдението в реално време е основно приложение за разпознаване на обекти. Системи за видеонаблюдение могат да използват алгоритми за разпознаване на лица, откриване на подозрителни действия или идентифициране на неправомерно поведение [26]. Това е полезно в различни области, като летища, търговски центрове, офиси и други обществени места [27].

- *Автономни системи*: Разпознаването на обекти е основополагаща част от функционирането на автономни системи, като автомобили и БПЛА. Тези системи трябва да идентифицират пешеходци, други превозни средства, препятствия и пътища в реално време, за да гарантират безопасността и ефективността на своето действие [28].

- *Медицински приложения*: Разпознаването на обекти е полезно в медицината, например при анализ на медицински изображения като рентгенови снимки, ядрено-магнитен резонанс (ЯМР) и други [29]. Алгоритмите за разпознаване на обекти могат да помогнат в откритията на болести като рак, пневмония и други, като автоматично анализират изображенията и подпомагат поставянето на диагнози [30].

1.6. Предизвикателства в отдалеченото откриване и разпознаване на обекти

Независимо от значителните постижения в областта на технологиите, които се използват при БПЛА, както и в областта на изкуствения интелект и машинно обучение, съществуват редица предизвикателства, за да могат ефективно да се използват данни от БПЛА за отдалеченото откриване и разпознаване на обекти:

- *Изчислителни ограничения*: Беспилотните летателни апарати и автономните устройства обикновено разполагат с ограничени изчислителни ресурси. Разпознаването на обекти в реално време изисква значителни изчислителни ресурси, което прави създаването на оптимизирани, ефективни алгоритми, които могат да работят на малки устройства, изключително важно [32].

- *Прецизност в сложни условия*: Откриването и разпознаването на обекти могат да бъдат сериозно затруднени от фактори като лоша осветеност, облачност, дъжд и други атмосферни условия [33]. В тези условия алгоритмите може да имат проблеми с разпознаването на обекти или с правилното класифициране [34].

- *Обработка на много големи количества данни*: Отдалеченото откриване и разпознаване на обекти генерира огромни количества данни [35]. Ефективното управление и анализиране на тези данни в реално време са важни предизвикателства за съвременните технологии [36].

1.7. Изводи към първа глава

На базата на направения литературен анализ на съвременното състояние на беспилотните летателни апарати могат да бъдат направени следните по-важни изводи:

- Технологичният напредък в областта на беспилотните летателни апарати е значителен и продължава да променя начина, по който се извършват операции и дейности в различни области. Съчетанието на иновации в сензорни технологии, навигация, изкуствен интелект и комуникации предоставя нови възможности за приложение на

БПЛА. Очаква се в бъдеще да се появят и наложат още по-радикални промени в техния дизайн и функционалност, което ще доведе до нови приложения и предизвикателства.

– Отдалеченото откриване и разпознаване на обекти е мощен инструмент, който предоставя важни данни и възможности за анализ в редица области, от екология и земеделие до сигурност и управление на бедствия. Технологиите в тази сфера се развиват с бързи темпове, като предоставят нови начини за ефективно наблюдение и управление на природни и човешки ресурси, което води до по-добри решения и устойчиво развитие.

– Отдалеченото откриване и разпознаване на обекти са решаващи технологии за множество приложения, вариращи от сигурност и мониторинг на околната среда до автономни системи. Въпреки напредъка в тези области, предизвикателства като налични изчислителни ресурси, условия на околната среда и обработка на големи по обем данни изискват нови подходи, методи и алгоритми, с които да се обработват получените данни.

ГЛАВА 2. МЕТОДИ ЗА ОТКРИВАНЕ И РАЗПОЗНАВАНЕ НА ОБЕКТИ

2.1. Преглед на съществуващите технологии за откриване на обекти

Откриването на обекти чрез отдалечено наблюдение обхваща множество методи и технологии, които варират в зависимост от типа на обекта, разстоянието, географските условия и целта на изследването. Основните технологии се класифицират като оптични, радиолокационни, термални и други. Оптичните методи са сред най-широко използваните, като се базират на изображения в спектъра на видимата светлина, но са чувствителни към атмосферни условия. Радиолокационните методи (напр. SAR и LiDAR) предлагат по-висока надеждност при всякакви условия, а термалните технологии използват инфрачервени сензори за засичане на топлинни излъчвания, особено ефективни при нощни наблюдения.

2.1.1. Оптични методи

Оптичните методи за откриване на обекти са базирани на измервания на видимата и близката инфрачервена област (оптично-електронни сензори) и често се използват за извършване на различни видове наблюдения на земната повърхност [43], включително мониторинг на околната среда, земеделие, градски райони и военни цели. Тези методи могат да включват различни технологии като сателитни изображения [44], аерофото изображения и дронави сензори.

2.1.2. Радарни и ултразвукови методи


Радарните и ултразвуковите технологии за откриване на обекти се използват в множество области и приложения, като геология, хидрология, строителство, охрана и сигурност, както и в транспортната индустрия [59]. Те са изключително полезни в условия, където оптичните методи имат ограничения, като например при облачно време, през нощта или за откриване на обекти под повърхността [60]. Тези методи използват вълни с различни дължини (микровълни, ултразвук), за да осъществяват откритие и разпознаване на обекти, които не могат да бъдат видими чрез традиционни визуални средства [61].

2.1.3. Инфрачервени технологии

Инфрачервените технологии за откриване на обекти използват инфрачервено излъчване, което е невидимо за човешкото око, но може да бъде засечено и измерено с помощта на специализирани сензори. Инфрачервената радиация има по-дълга вълнова дължина от видимата светлина, което позволява на инфрачервените технологии да откриват топлинни сигнатури и да наблюдават обекти при условия, при които други методи не биха били ефективни (например през нощта или при облачно време) [80].

2.2. Методи за обработка на изображения

Обработката на изображения е основен етап в разпознаването на обекти и компютърното зрение, като включва различни алгоритми и техники за извличане на важна информация от изображенията, които след това се използват за анализ и разпознаване на обекти. Методи за обработка на изображения обикновено включват стъпки като филтриране, трансформиране, извличане на характеристики, детекция на ръбове и сегментиране на изображения (фиг. 3). Основната цел на обработката на изображения е да подготви изображенията за по-нататъшно анализиране от алгоритми за разпознаване, като CNN (конволюционни невронни мрежи) или други методи за машинно обучение. Целта е извличане на смислово значима информация от изображенията и нейното използване в алгоритми за класификация и детекция.



Фигура 3. Основни етапи за обработка на изображения

2.3. Алгоритми за разпознаване на обекти

Разгледани са три основни групи алгоритми за разпознаване на обекти:

- *Традиционни методи*: Хаар признаци, каскадни класификатори, SIFT, SURF и ORB, при които се използват ръчно извлечени характеристики и евристични правила.
- *Машинно обучение*: Метод на опорни вектори (SVM), алгоритми за клъстеризация и дървета за класификация.
- *Дълбоко обучение*: Конволюционни невронни мрежи (CNN), мрежи за откриване на обекти като YOLO, SSD и Faster R-CNN, които осигуряват висока точност и скорост при разпознаване.

2.4. Настоящи предизвикателства и тенденции

Основни предизвикателства са: обобщаемостта на моделите, особено при различни условия; проблеми с прекомерно нагаждане; нужда от по-енергийно ефективни и оптимизирани алгоритми за реално време. Тенденциите включват: трансферно обучение, създаване на леки модели с ниска изчислителна сложност, използване на мултимодални входни данни и адаптивни архитектури, които отговарят на изискванията за автономност и надеждност при работа с БПЛА.

2.6. Изводи към втора глава

Методите за обработка на изображения играят решаваща роля за успешното разпознаване на обекти. Те включват широк спектър от техники, които подготвят изображенията за по-нататъшно анализиране и разпознаване. Чрез предварителна обработка, извличане на характеристики, детекция на ръбове, сегментиране и различни трансформации на изображенията, алгоритмите могат да се справят с разнообразни предизвикателства и да предоставят точни резултати при разпознаване на обекти. Етапите на предварителна обработка, извличане на характеристики, детекция на ръбове и сегментиране са решаващи за ефективното разпознаване.

Алгоритмите за разпознаване на обекти имат значителен напредък в последните години, като традиционните методи, базирани на ръчни признаци, постепенно се заменят от техники за машинно обучение и дълбоко обучение, особено чрез използване на конволюционни невронни мрежи (CNN). Съвременните методи се използват успешно в множество критични области като наблюдение, автономни превозни средства, сигурност и здравеопазване. Въпреки че всяка от тези технологии има своите силни и слаби страни, съвременните подходи, включително CNN и други мрежи за обектно разпознаване, постигат изключителна точност и бързина в разпознаването на обекти.

Технологиите за откриване и разпознаване на обекти продължават да напредват, но въпреки това предизвикателствата, свързани с точността в шумни и динамични среди, изчислителната ефективност, адаптацията към нови и променливи условия, остават значителни. Съществуват тенденции, които показват бъдещото развитие на тези технологии, като например използването на трансферно обучение, хибридни модели, по-ефективни алгоритми и автономни системи, които могат да подобрят работата на разпознаването на обекти в различни условия и да позволят по-добра адаптация към нови предизвикателства. Предложените подобрения на база анализите са свързани с използване на трансферно обучение за адаптиране на модели към нови задачи с минимални данни и ресурси, разработване на хибридни модели с комбиниране на различни подходи за подобряване на точността и устойчивостта на алгоритмите, оптимизация на алгоритмите за намаляване на изчислителната сложност с цел по-бърза и ефективна обработка, адаптивни и автономни системи: създаване на модели, способни да се адаптират в реално време към променящи се условия на средата.

ГЛАВА 3. ПРЕДЛОЖЕНИ АПАРАТНИ И ПРОГРАМНИ АРХИТЕКТУРИ, МЕТОДИ И АЛГОРИТМИ ЗА ОТДАЛЕЧЕНО ОТКРИВАНЕ, РАЗПОЗНАВАНЕ И ПРОСЛЕДЯВАНЕ НА ОБЕКТИ ПРИ БЕЗПИЛОТНИ ЛЕТАТЕЛНИ АПАРАТИ

3.1. Етапи на проектиране и разработване на системата

Проектирането на система за отдалечено откриване, разпознаване и проследяване на обекти преминава през няколко основни етапа: (1) Анализ на изискванията и дефиниране на целите на системата; (2) Подготовка на обучаващи данни; (3) Обучение на модели с машинно или дълбоко обучение; (4) Тестване на обучените модели; (5) Интеграция на модела в системата; (6) Тестване на цялата система.

3.2. Архитектура на система за отдалечено откриване, разпознаване и проследяване

Системата за отдалечено откриване, разпознаване и проследяване на обекти се състои от хардуерна и софтуерна архитектури, които са интегрирани за работа в реално време и работят в синхрон за постигане на целите на системата. На фиг. 12 е показана общата архитектура на системата. Диаграмата представя трислойна архитектура на интелигентна система за автоматично разпознаване и проследяване на обекти. Системата комбинира хардуерни компоненти (сензори и изчислителни устройства), софтуерни модули (за

обработка, детекция и визуализация), както и интеграционен слой, свързан с навигация и отдалечен достъп.

Хардуерната архитектура на системата включва бордов компютър и сензори за регистриране на изображения и данни: RGB камера, инфрачервена камера и LiDAR сензор. За разработването на системата е избран NVIDIA Jetson Xavier NX като бордов компютър поради неговата висока изчислителна мощност и възможности за обработване на данни в реално време и ниска консумация на енергия. Сензорите включват:

- RGB камера с резолюция 4K (3840x2160 пиксела) за висока детайлност на изображенията;
- Инфрачервена камера с резолюция 640x512 пиксела за работа при слаба осветеност или нощни условия;
- LiDAR сензор с обхват от 100 метра и точност ± 2 cm за 3D локализация на обекти.


Софтуерната архитектура на системата съдържа следните модули:

- Модул за обработване на данни: извършва предварителна обработка като нормализация и синхронизация между сензорите;
- Модул за откриване и разпознаване на обекти: базиран на YOLOv8, оптимизиран чрез TensorRT;
- Модул за проследяване на обекти: използва DeepSORT за точно проследяване дори при пресичащи се обекти.

В табл. 4 са обобщени избраните хардуерни и софтуерни компоненти за проектиране и изграждане на системата.

3.3. Софтуерна архитектура на системата

Софтуерната архитектура на системата за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати е проектирана като модулна система, включваща три модула: модул за обработване на данни, модул за откриване и разпознаване и модул за проследяване.



Фигура 12. Обща архитектура на предложената система

Таблица 4. Хардуерни и софтуерни компоненти на системата

Компонент	Модел/Софтуер	Кратко описание
Бордов компютър	NVIDIA Jetson Xavier NX	Висока производителност при ниска консумация; подходящ за edge AI
RGB камера	4K, 3840x2160 px	За заснемане на детайлни цветни изображения
Инфракчервена камера	640x512 px	Работи при ниска осветеност, за нощен режим
LiDAR	100 m обхват	Точно 3D позициониране и локализация
ОС	Ubuntu/Linux	Поддържа всички необходими библиотеки и драйвери
Захват на видео	OpenCV/GStreamer	Интерфейс за видео вход от сензорите
Предобработка	Resize, Normalize	Подготовка на изображенията за детекция
Обектна детекция	YOLOv8 + TensorRT	Бърза и точна инференция на обекти в реално време
Проследяване	DeepSORT	Последователно проследяване на обекти дори при закриване
Визуализация	Streamlit/Flask/API	Потребителски интерфейс, REST API или уеб интерфейс
Интеграция	Навигация/управление на полета	Връзка със системата за полетен контрол
GUI	Уеб станция или наземна база	За визуализация и контрол от разстояние

3.4. Разработване на алгоритми за откриване, разпознаване и проследяване

При разработването на системата за анализирани и сравнени няколко съвременни основни (backbone) архитектури – ResNet (Residual Networks); EfficientNet; MobileNet. След обстоен анализ и провеждане на експериментална оценка е избрана EfficientNet-B0 като основна (backbone) архитектура за системата поради следните причини:


- *Ефективност*: EfficientNet-B0 предлага отличен баланс между точност и изчислителна ефективност, което е критично за работа в реално време на бордови системи на БПЛА;

- *Скалируемост*: Архитектурата позволява лесно мащабиране (B0 до B7) в зависимост от конкретните изисквания за точност и наличните изчислителни ресурси;

- *Трансферно обучение*: Предварително обучените тегла на EfficientNet върху големи набори от данни (например ImageNet) позволяват ефективно трансферно обучение за нашата специфична задача;

- *Адаптивност*: EfficientNet показва добра производителност при различни условия на осветеност и мащаби на обектите, което е особено важно за приложения с БПЛА.

Детекторът на обекти е базиран на три избрани архитектури, които позволяват откриване на обекти в реално време: YOLO, SSD и Faster R-CNN. Графиката на фиг. 14 показва сравнение между YOLOv7, YOLOv8, SSD и Faster R-CNN по метрики като mAP (%) и FPS: mAP (синьо) показва точността на моделите, FPS (червено) показва скоростта на обработка в реално време. На базата на резултатите от фиг. 14 могат да се направят следните изводи: YOLOv7 е най-бързият модел (160 FPS), но с по-ниска точност (63% mAP). Faster R-CNN има най-висока точност (76.4% mAP), но е най-бавен (7 FPS). SSD предлага баланс между точност (74.3% mAP) и скорост (59 FPS).



Фигура 1. Сравнение на производителността на архитектурите за откриване на обекти в реално време

3.5. Обучение на модели

Използвано е трансферно обучение, което значително намалява времето за конвергенция и подобрява генерализацията. Добавени са техники за обогатяване на данни и адаптивна скорост на обучение (One Cycle Policy) за избягване на overfitting.

3.5.1. Използване на трансферно обучение

Трансферното обучение е техника в машинното обучение, при която знанията, придобити от един модел, обучен върху голям набор от данни, се пренасят и адаптират за решаване на подобен, но различен проблем. Вместо да се обучава модел от нулата, трансферното обучение използва предварително обучен модел като начална точка и го дообучава за конкретната задача.

3.5.2. Използване на обогатяване на данни

Обогатяването на данни (data augmentation) е техника, при която се създават нови, вариативни данни от съществуващите чрез прилагане на различни трансформации. Целта на тази техника е да се увеличи разнообразието на данните, което позволява на модела да се обучи по-добре и да стане по-устойчив към различни условия. Това е особено полезно в случаите, когато наборът от данни е ограничен или когато данните не покриват всички възможни сценарии. Основната полза от обогатяването на данни е намаляването на риска от прекомерно приспособяване (overfitting), тъй като моделът се обучава върху по-голямо разнообразие от данни, което позволява да обобщава по-добре за нови примери, които не са използвани при обучението.

3.5.3. Използване на управление на скоростта на обучение с политика на единствен цикъл

Предимствата на управлението на скоростта на обучение с политика на единствен цикъл включват по-бързо обучение, по-добра производителност на модела и намаляване на риска от прекомерно приспособяване на модела. Този метод е особено подходящ за задачи с ограничени изчислителни ресурси, като тези в предложената система, при които е необходимо да се оптимизира времето за обучение и енергийната ефективност. Чрез използването на управление на скоростта на обучение с политика на единствен цикъл, системата за разпознаване на обекти с БПЛА постига висока точност и надеждност при по-кратко време за обучение, което я прави по-ефективна и практична за реални приложения.

3.6. Интеграция на мултимодални данни

За да се подобри точността на системата е използвана техника за интегриране на ниво характеристики от RGB камерата, инфрачервената камера и LiDAR сензора. Този подход позволява по-добра локализация на обекти в сложни условия, като мъгла или слаба осветеност.

Интегрирането на данни на ниво характеристики е техника в областта на компютърното зрение и обработката на данни, при която информацията от множество източници или модалности се комбинира на ниво характеристики за да се подобри производителността на модела. Характеристиките са числови или векторни представяния на данните, които улавят важни свойства или атрибути на обектите или сцената. Вместо да се обработват данните от всеки източник поотделно и след това да се взема окончателно решение се интегрира информацията на по-ранен етап, което позволява на модела да извлече по-богати и комплексни взаимоотношения между данните.

3.7. Оптимизация на системата за отдалечено откриване, разпознаване и проследяване на обекти при БПЛА

За подобряване на енергийната ефективност на системата са използвани и интегрирани различни хардуерни и софтуерни решения за оптимизация насочени към намаляване на консумацията на енергия на бордовия компютър и сензорите. За да се намали изчислителната сложност на работа на системата за отдалеченото откриване, разпознаване и проследяване на обекти е използван TensorRT за оптимизация на модела YOLOv8, което позволява да се намали латентността от 50 ms до 30 ms на кадър. Допълнително е приложена квантизация (INT8), което намалява използването на памет с 40% без загуба на точност. В табл. 7 са представени получените резултати за няколко метрики за оценка на ефективността на системата при използване на оптимизация с TensorRT. Резултатите показват, че оптимизацията с TensorRT значително намалява латентността и използването на памет без загуба на точност.

Енергийната ефективност на системата е значително подобрена чрез интегрирането на предложените хардуерни и софтуерни оптимизационни техники, насочени към намаляване на консумацията на енергия на бордовия компютър и сензорите. След прилагане на тези стратегии за оптимизация системата постига значително намаляване на енергийната консумация до 10–15 W като същевременно осигурява продължителност на полета от над 45 минути в зависимост от капацитета на батерията и теглото на дрона. Въпреки тези оптимизации, системата запазва висока точност при разпознаване на обекти. Това я прави подходяща за дълги полети и приложения в реално време като наблюдение, търсене и спасяване, които изискват както висока ефективност, така и продължителност на полета.

Таблица 7. Оптимизация с TensorRT

Метрика	Преди оптимизация	След оптимизация
Латентност (ms)	50	30
Използване на памет (%)	100	60
Точност (mAP)	78.5%	78.5%

3.8. Изводи към трета глава

Предложена е методология за проектиране и разработване на система за отдалечено откриване, разпознаване и проследяване на обекти при БПЛА. Методологията следва няколко основни етапа при проектиране на системата, на базата на които е проектирана и разработена система за отдалечено откриване, разпознаване и проследяване на обекти при БПЛА. Концептуалната архитектура на системата се състои от хардуерни компоненти и софтуерни модули, чието интегриране осигурява функционирането на системата съгласно поставените цели и функционални изисквания. Изборът на методи и алгоритми за откриване и разпознаване на обекти и за проследяване на обекти е обусловен от изискванията към подобна система за висока точност и бързодействие, в това число оптимизация за откриване на малки обекти и работа в динамични условия, както и разпознаване и проследяване на обекти в реално време.

Предложено е използване на хибриден ансамблов метод за откриване на обекти с обединяване на прогнози на два модела. Предложени са техники за оптимизация на обучението на модели в системата с използване на трансферно обучение, обогатяване на данни и управление на скоростта на обучение с политика на единствен цикъл за осигуряване на висока точност и ефективност и предотвратяване на прекомерно приспособяване на моделите. Специално внимание е отделено на интеграцията на данни от различни сензори, което е от особена важност за подобни системи като е предложено използване на интегриране на ниво характеристики с предварително калибриране на използваните сензори. Предложени са стратегии за хардуерна и софтуерна оптимизация на системата за постигане на енергийна ефективност, прилагането на които позволява намаляване на енергийната консумация и осигуряване на по-голяма продължителност на полет на БПЛА със запазване висока точност при разпознаването и проследяването на обекти. Оптимизациите в изчислителната ефективност и енергийната консумация я правят подходяща за продължителни полети и сложни задачи. Разработената система демонстрира висока точност и стабилност в реални условия, като отговаря на изискванията за отдалечено откриване, разпознаване и проследяване на обекти при БПЛА.

ГЛАВА 4. ПЛАНИРАНЕ И ПРОВЕЖДАНЕ НА ЕКСПЕРИМЕНТИ И АНАЛИЗ НА ЕКСПЕРИМЕНТАЛНИ РЕЗУЛТАТИ

4.1. Планиране на експерименти

Основната цел на експерименталното изследване е да се валидира предложената методология като се оцени и сравни ефективността на различните използвани методи и разработени алгоритми в разнообразни условия. За постигането на тази цел са формулирани следните конкретни задачи на експерименталното изследване:

- Сравнение на производителността на различни архитектури за откриване на обекти в контекста на изображения от БПЛА: YOLO, SSD, Faster R-CNN;
- Оценка на влиянието на различни фактори върху точността на откриване на обекти: височина на полета, ъгъл на камерата, осветеност;
- Изследване на ефективността на различни методи за откриване на малки обекти;
- Анализ на между точност и скорост на обработване на данни с различните методи;
- Оценка на производителността на методите при различни класове обекти (например, превозни средства, хора, сгради);
- Изследване на ефективността на трансферно обучение за адаптация към специфични сценарии с БПЛА.

4.2. Експериментална постановка

За провеждане на експериментите е използвана следната експериментална постановка:

- *Хардуерни компоненти:* БПЛА: DJI Mavic 2 Pro с 20 MP камера; Бордови компютър: NVIDIA Jetson Xavier NX; Работна станция за обучение: PC с NVIDIA RTX 3090 GPU.
- *Софтуерни среди:* Операционна система: Ubuntu 20.04; Фреймуърк за дълбоко обучение: PyTorch 1.9; Библиотеки за компютърно зрение: OpenCV 4.5, YOLO, Detectron2; Среда за разработка: Python 3.8, Jupyter Notebook.

4.3. Подготовка на данни и анотации

За експериментите е използвана комбинация от публично достъпни набори от данни (множествата данни VisDrone, UAVDT, AMDD) и собствени събрани допълнителни данни, специфични за избраните сценарии с използване на DJI Inspire 2 Pro. Данните включват изображения, заснети при различни височини, ъгли и условия на осветеност. Всички изображения са анотирани с ограничаващи кутии и етикети на класове обекти с използване на инструмента LabelImg. Осигурено е балансирано разпределение на

класовете и разнообразие в условията на заснемане. За всеки експеримент е използвана кръстосана валидация за да се осигури статистическа значимост на резултатите като данните са разделени на обучаващи, валидационен и тестови множества.

4.4. Дизайн на експериментите

Експериментите са структурирани в няколко групи с цел обстойно валидиране и оценяване на производителността на проектираната и разработена система и използваните методи и алгоритми за разпознаване и проследяване на обекти и за оптимизация на системата: (1) Сравнение на базовите модели за откриване на обекти; (2) Анализ на влиянието на фактори при работа на системата; (3) Оптимизация на разпознаването за малки обекти; (4) Трансферно обучение; (5) Оценка на производителност на системата при работа в реално време; (6) Многокласова класификация; (7) Анализ на робастност; (8) Сравнение на различни версии на YOLO; (9) Експерименти с ансамблови методи; (10) Анализ на грешките; (12) Експерименти с различни основни (backbone) архитектури; (13) Оценка на производителността при проследяване на обекти; (14) Експерименти с техники за обогатяване на данни; (15) Анализ на изчислителната ефективност; (16) Експерименти с различни функции на загуба.

За всеки експеримент са дефинирани ясни хипотези, които се валидират и верифицират като се използват статистически тестове (например, t-test или ANOVA) за оценка на значимостта на резултатите. За да се осигури възпроизводимост на експериментите за всеки експеримент се документират всички хиперпараметри, използвани при обучението на моделите. Този изчерпателен дизайн на експериментите позволява да се направи задълбочен анализ на производителността и ограниченията на различните методи за откриване и разпознаване на обекти от БПЛА, както и да се идентифицират най-перспективните подходи за различни сценарии на приложението на системата.

4.5. Подготовка и провеждане на тестове

4.5.1. Сравнение на базовите модели

Цел: да се сравни производителността на YOLOv5, SSD и Faster R-CNN върху комбинирания набор от данни.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка на данни:* комбиниране на публичните набори от данни и собствените събрани данни; разделяне на данните на тренировъчен (70%), валидационен (15%) и тестов (15%) набор;

- *Обучение на модели:* YOLOv5 (официална имплементация от Ultralytics); SSD (имплементация от torchvision); Faster R-CNN (имплементация от Detectron2);

- *Хиперпараметри:* размер на входното изображение: 640x640 пиксела; размер на партида за обучение: 16; брой епохи на обучение: 100; оптимизатор: Adam; скорост на обучение: 0.001 със схема за косинусово охлаждане; обогатяване на данни: случайно хоризонтално обръщане, случайно завъртане ($\pm 15^\circ$), случайна промяна на яркост и контраст;

- *Метрики за оценка:* mAP (mean Average Precision) за оценяване на модели за откриване на обекти като осреднена средната прецизност са всеки клас, като средната прецизност се изчислява като среднопретеглена стойност на прецизностите при различни прагови стойности; скорост на обработка (Frames Per Second, FPS) за оценяване на бързодействие на системата;

- *Оценка:* изчисляване на mAP при IoU прагове от 0.5 до 0.95 със стъпка 0.05; измерване на FPS на GPU и CPU; измерване на размер на модела в MB;

- *Анализ:* сравнение на mAP, FPS и размер на модела за трите архитектури; визуализация на резултатите чрез графики и таблици; статистически анализ за определяне на значимостта на разликите в производителността.

4.5.2. Анализ на влиянието на фактори при работа на системата

Цел: да се оцени как височината на полета, ъгъла на камерата и условията на осветеност влияят върху производителността на моделите.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка на данни:* събиране на специфични тестови набори от данни за всеки фактор – височина (10 m, 30 m, 50 m, 100 m); ъгъл на камерата (0°, 30°, 60°, 90°); осветеност (ден, здрач, нощ);
- *Тестване:* използване на най-добре представилия се модел от предишния експеримент; оценка на производителността (mAP) за всяка комбинация от фактори;
- *Анализ:* създаване на графики за зависимостта на mAP от височината и ъгъла на камерата; анализ на влиянието на осветеността чрез сравнение на производителността при различни условия; провеждане на двуфакторен ANOVA тест за определяне на статистическата значимост на влиянието на всеки фактор и техните взаимодействия.

4.5.3. Оптимизация за малки обекти

Цел: да се оцени подобряването при откриването на малки обекти чрез специализирани техники.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Базов модел:* оценка на производителността на базовия модел специфично за малки обекти, определени като обекти с площ по-малка от 32x32 пиксела;
- *Имплементация на техники за подобряване:* добавяне на FPN към базовата архитектура; замяна на стандартната функция с кръстосана ентропия с функция с фокална загуба; тестване с изображения с по-висока входна резолюция (1024x1024 пиксела);
- *Обучение и оценка:* Обучение на модифицираните модели със същите хиперпараметри като в експеримента представен в т. 4.5.1; Оценка на mAP специфично за малки обекти;
- *Анализ:* сравнение на производителността преди и след оптимизацията; визуализация на подобренията чрез примерни изображения; анализ на компромиса между подобрената производителност за малки обекти и общата производителност/скорост на модела.

4.5.4. Трансферно обучение

Цел: да се оцени ефективността на трансферното обучение за адаптация към специфични сценарии с БПЛА.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка на модели:* зареждане на предварително обучени тегла от множеството данни COCO за YOLOv5, SSD и Faster R-CNN; инициализиране на същите архитектури със случайни тегла за сравнение;
- *Фино настройване:* замразяване на ранните слоеве на предварително обучените модели; обучение само на последните няколко слоя върху специфичния набор от данни за БПЛА; постепенно размразяване на повече слоеве и продължаване на обучението;
- *Обучение от нулата:* обучение на моделите със случайна инициализация върху същия набор от данни за БПЛА;
- *Оценка:* сравнение на кривите на обучение (загуба и точност) за трансферно обучените модели и моделите, обучени от нулата; измерване на времето за конвергенция; оценка на крайната производителност (mAP) на всички модели;
- *Анализ:* сравнение на ефективността на трансферното обучение спрямо обучение от нулата; анализ на влиянието на трансферното обучение върху скоростта на конвергенция и крайната производителност; идентифициране на оптималната стратегия за фина настройване (брой замразени слоеве, скорост на обучение).

4.5.5. Оценка на производителността в реално време

Цел: да се оцени производителността на моделите при работа в реално време на бордовия компютър NVIDIA Jetson Xavier NX.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* инсталиране и конфигуриране на необходимия софтуер на Jetson Xavier NX; оптимизиране на моделите за инференция (с използване на TensorRT);
- *Тестване:* измерване на латентност и FPS при различни резолюции на входното изображение (320x320, 640x640, 1280x720); тестване с различни размери на партидите за обучение (1, 4, 8); оценка на производителността при различни нива на консумация на енергия на Jetson Xavier NX;
- *Анализ:* сравнение на латентност и FPS за различните модели и конфигурации; анализ на компромиса между точност и скорост в реално време; оценка на енергийната ефективност на различните модели.

4.5.6. Многокласова класификация

Цел: да се оцени производителността при откриване и класификация на множество класове обекти.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка на данни:* дефиниране на набор от класове, релевантни за приложения с БПЛА (например, автомобили, пешеходци, велосипедисти, сгради, дървета); аотиране на съществуващия набор от данни с тези класове или събиране на нови данни;
- *Обучение:* модифициране на архитектурите за поддръжка на многокласова класификация; обучение на моделите с новия набор от данни;
- *Оценка:* изчисляване на mAP за всеки клас и общ mAP; създаване на матрица на грешките за анализ на грешките в класификацията; оценка на F1-score за всеки клас.
- *Анализ:* идентифициране на класове, които са особено трудни за откриване или класифициране; анализ на влиянието на броя класове върху общата производителност на модела; оценка на баланса между класовете и влиянието им върху производителността.

4.5.7. Анализ на робастността

Цел: да се оцени устойчивостта на моделите при различни атмосферни условия и наличие на шум.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка на тестови данни:* събиране и/или симулиране на изображения при различни атмосферни условия (ясно време, облачно време, дъжд, мъгла); създаване на изкуствено замъглени и зашумени версии на съществуващите тестови изображения;
- *Тестване:* оценка на производителността (mAP) на моделите при различни атмосферни условия; измерване на деградацията на производителността при увеличаване на нивото на шум и размазване; тестване на устойчивостта към частично закриване на обекти чрез изкуствено закриване на части от обектите;
- *Анализ:* сравнение на робастността на различните модели към атмосферни условия и шум; идентифициране на условията, които са най-предизвикателни за моделите; анализ на влиянието на частично закриване върху точността на откриване и класификация.

4.5.8. Сравнение на различни версии на YOLO

Цел: да се сравни производителността на различни версии на YOLO в контекста на откриване на обекти от БПЛА (YOLOv3, YOLOv4, YOLOv5, YOLOv7).

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* имплементиране или използване на официални имплементации на различните версии на YOLO; уеднаквяване на входните данни и предварителната обработка за всички версии;

- *Обучение*: обучение на всяка версия на YOLO с еднакви хиперпараметри, доколкото е възможно; използване на един и същ набор от данни за обучение и валидация;
- *Оценка*: измерване на mAP на тестовия набор от данни; оценка на скоростта на inferенция (FPS) на GPU и CPU; измерване на размера на модела и използваната памет;
- *Анализ*: сравнение на точността, скоростта и ефективността на различните версии на YOLO; анализ на компромиса между производителност и изчислителни изисквания; идентифициране на най-подходящата версия за приложения с БПЛА.

4.5.9. Експерименти с ансамблови методи

Цел: да се изследва потенциала за подобряване на точността чрез комбиниране на разпознаването с различни модели.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка*: избор на най-добре представящите се индивидуални модели от предишните експерименти; имплементиране на различни стратегии за комбиниране на модели (усредняване, гласуване, подреждане);
- *Обучение*: обучение на мета-модел върху резултатите от разпознаване с базовите модели;
- *Оценка*: измерване на mAP на ансамбловите модели върху тестовия набор от данни; сравнение на производителността с индивидуалните модели;
- *Анализ*: оценка на подобрението в точността спрямо най-добрия индивидуален модел; анализ на компромиса между повишената точност и увеличеното време за inferенция; идентифициране на най-ефективната стратегия за комбиниране на модели.

4.5.10. Анализ на грешките

Цел: да се идентифицират и анализират типични сценарии, в които моделите правят грешки.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Събиране на грешки*: идентифициране на изображения, в които моделите правят грешки (фалшиво положителни, фалшиво отрицателни, неправилни класификации); категоризиране на грешките по тип и условия;
- *Визуализация*: използване на техники като Grad-CAM за визуализиране на активациите на невронната мрежа; създаване на визуализации, показващи къде моделът фокусира вниманието си при вземане на решения;
- *Анализ*: идентифициране на общи характеристики на изображенията, които водят до грешки; анализ на влиянието на фактори като размер на обекта, осветеност, текстура върху грешките; оценка на потенциални стратегии за намаляване на специфични типове грешки.

4.5.11. Експерименти с различни основни (backbone) архитектури

Цел: да се сравни производителността при използване на различни основни (backbone) мрежи за извличане на характеристики.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка*: избор на различни основни архитектури (ResNet, EfficientNet, MobileNet); интегриране на основни мрежи в избрана детекторна архитектура (YOLOv5);
- *Обучение*: обучение на моделите с различни основни мрежи, запазвайки останалите хиперпараметри константни;
- *Оценка*: измерване на mAP, FPS и размер на модела за всяка основна архитектура; оценка на трансферната способност на различните основни мрежи;
- *Анализ*: сравнение на производителността на различните основни архитектури; анализ на компромиса между точност, скорост и размер на модела; идентифициране на най-подходящата основна архитектура за приложения с БПЛА.

4.5.12. Оценка на производителността при проследяване на обекти

Цел: да се оцени ефективността на интегрирането на алгоритми за проследяване с детекторите на обекти.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* избор на алгоритми за проследяване (SORT, DeepSORT); интегриране на алгоритмите за проследяване с най-добре представящия се детектор;
- *Метрики за оценка:* MOTA (Multiple Object Tracking Accuracy); IDF1 (ID F1-score);
- *Тестване:* използване на видео последователности от БПЛА за оценка на производителността; измерване на метриците за проследяване MOTA и IDF1;
- *Анализ:* сравнение на производителността на различните комбинации детектор-тракер; оценка на влиянието на проследяването върху общата точност и скорост на системата; анализ на специфични сценарии, при които проследяването значително подобрява или влошава производителността.

4.5.13. Експерименти с техники за обогатяване на данни

Цел: да се оцени влиянието на различни техники за увеличаване на данните върху производителността на моделите.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* имплементиране на различни техники за обогатяване на данни (случайно изрязване, завъртане, промяна на яркостта и контраста, добавяне на шум, комбиниране на изображения с Mixup и CutMix);
- *Създаване на различни конфигурации за обогатяване на данни;*
- *Обучение:* обучение на базовия модел с различни комбинации от техники за обогатяване на данни; използване на един и същ набор от данни и архитектура за всички експерименти;
- *Оценка:* измерване на mAP на тестовия набор от данни; оценка на генерализацията на моделите чрез тестване върху нови, неизвестни данни;
- *Анализ:* сравнение на ефективността на различните техники за обогатяване на данни; анализ на влиянието на обогатяването на данни върху устойчивостта на модела към различни условия; идентифициране на оптималната стратегия за обогатяване на данни за приложения с БПЛА.

4.5.14. Анализ на изчислителната ефективност

Цел: да се оцени изчислителната ефективност на различните модели при работа на бордовия компютър.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* инсталиране на инструменти за профилиране на производителността на Jetson Xavier NX; оптимизиране на моделите за инференция с използване на TensorRT, квантизация;
- *Тестване:* измерване на използването на памет (RAM и VRAM) за различните модели; оценка на използването на CPU и GPU при инференция; измерване на консумацията на енергия при различни конфигурации;
- *Анализ:* сравнение на изчислителната ефективност на различните модели; анализ на компромиса между производителност и изчислителни изисквания; оценка на енергийната ефективност и потенциала за продължителна работа на батерия.

4.5.15. Експерименти с различни функции на загуба

Цел: да се сравни ефективността на различни функции на загуба за обучение на моделите.

Използвана е следната методология за подготовка и провеждане на експеримента:

- *Подготовка:* имплементиране на различни функции на загуба: стандартна функция с кръстосана ентропия, функция с фокална загуба, GIoU, CIoU, DIoU; интегриране на функциите на загуба в обучителния процес;

- *Обучение*: обучение на базовия модел с различните функции на загуба, запазвайки останалите хиперпараметри константни;
- *Оценка*: измерване на mAP на тестовия набор от данни; оценка на скоростта на конвергенция и стабилността на обучението; анализ на точността на локализация чрез измерване на IoU (Intersection over Union);
- *Анализ*: сравнение на ефективността на различните функции на загуба; анализ на влиянието на функцията на загуба върху точността на локализация и класификация; идентифициране на най-подходящата функция на загуба за приложения с БПЛА.

4.6. Тестване и валидиране на системата. Предизвикателства и решения

За тестване и валидиране на предложената, проектирана и разработена система са проведени експериментални изследвания в три основни сценария:

- *Сценарии 1 „Градска среда“*: в условия с гъста популация от обекти и пречки; точността на откриване е 75.8%, а MOTA достига 78.2%;
- *Сценарии 2 „Открити пространства“*: в условия с по-малко обекти, но по-големи разстояния; точността на откриване е 85.2%, а MOTA достига 82.5%;
- *Сценарии 3 „Нощни условия“*: С използване на инфрачервената камера. Точността на откриване е 70.3%, а MOTA достига 74.1%.

При провеждането на експерименталната оценка са установени следните предизвикателства пред системата и са предложени следните решения:

- *Предизвикателства*:
 - *Променливи светлинни условия* – решение чрез използване на инфрачервена камера и адаптивни алгоритми;
 - *Гъста популация от обекти* – решение чрез подобряване на алгоритмите за проследяване и сливане на данни;
 - *Ограничени изчислителни ресурси* – решение чрез оптимизация на модела и използване на TensorRT.
- *Решения*:
 - Използвано е управление на скоростта на обучение на модела с политика с единствен цикъл за динамично променяне на скоростта на обучение по време на процеса на обучение на модела, което подобрява скоростта на конвергенция;
 - Интегриран е Grad-CAM за визуализация на важните региони в изображенията, което подпомага подобряване на разбирането на решенията на модела.

4.7. Анализ на експериментални резултати

4.7.1. Сравнение на базовите модели

• Сравнение на mAP (mean Average Precision)

Направен е сравнителен анализ на три различни модела за откриване на обекти: YOLOv5, SSD и Faster R-CNN по три различни метрики на mAP (средна точност по различни прагове на IoU). Получените резултати са представени в табл. 8.

Изводи: Faster R-CNN предлага най-добра производителност, следван от YOLOv5, който също е много ефективен. SSD изостава по всички метрики, което го прави не толкова подходящ за задачи, изискващи висока точност при различни прагове на припокриване.

Таблица 8. Сравнение на mAP

Модел	mAP@0.5	mAP@0.75	mAP@0.5:0.95
YOLOv5	0.72	0.58	0.65
SSD	0.68	0.52	0.60
Faster R-CNN	0.75	0.62	0.68

- **Сравнение на FPS (Frames Per Second)**

Направен е сравнителен анализ на трите различни модела за откриване на обекти по показателя FPS, който измерва броя на кадрите, които моделите могат да обработват в секунда (табл. 9).

Изводи: YOLOv5 е най-бързият модел с високи стойности за FPS както при използване на GPU, така и при CPU, което го прави подходящ за приложения, които изискват бърза обработка и могат да разчитат на GPU ускорение. Моделът SSD е по-бавен от YOLOv5, но все пак предлага добра производителност при използване на GPU, докато при CPU обработка производителността е значително по-ниска. Faster R-CNN е най-бавният модел, което го прави по-малко подходящ за задачи с изисквания за работа в реално време, особено при ограничени ресурси или при работа само върху CPU. Получените резултати показват ясно, че за висока производителност в реално време е препоръчително да се използва модел YOLOv5, особено при наличие на GPU.

Таблица 9. Сравнение на FPS

Модел	FPS (GPU)	FPS (CPU)
YOLOv5	120	15
SSD	90	10
Faster R-CNN	40	5

- **Сравнение на размера на модела**

Направен е сравнителен анализ на размера на модела за трите различни архитектури: YOLOv5, SSD и Faster R-CNN (табл. 10). Размерът на модела е измерен в мегабайти (MB) и показва каква памет заема представяне на модела след обучение. Това е важен показател, тъй като по-малките модели могат да бъдат по-лесно внедрени в устройства с ограничени ресурси, като мобилни телефони или вградени системи.


Изводи: YOLOv5 моделът е най-лек и е предпочитан в приложения, които имат строг капацитет за памет или когато бързото зареждане и малкият размер са от значение. Моделът SSD предлага добра производителност, но е по-тежък от YOLOv5, като може да е по-подходящ за устройства с повече налично пространство. Въпреки че е мощен модел, Faster R-CNN има най-голям размер, което го прави по-малко подходящ за приложения с ограничени ресурси или вградени системи. В зависимост от нуждите на приложението и при ограничено хранилище YOLOv5 е най-добрият избор за модел за откриване на обекти.

Таблица 10. Сравнение на размера на модела

Модел	Размер (MB)
YOLOv5	27
SSD	120
Faster R-CNN	250

4.7.2. Анализ на влиянието на фактори при работа на системата

Използвани са следните параметри за регистриране на данните с БПЛА: височина на полета: 10 m, 30 m, 50 m, 100 m); ъгъл на камерата: 0°, 30°, 60°, 90°; осветеност: ден, здрач, нощ. За да се оцени влиянието на височината на полета и ъгъла на камерата върху производителността при откриване и разпознаване на обекти се използва 3D графика, която показва стойностите на mAP за всяка комбинация от тези два фактора (фиг. 15). Резултатите показват, че ниска височина (10 m) и малък ъгъл (0°) водят до най-висок mAP от 0.75. Когато височината и ъгълът се увеличават, mAP намалява, като най-ниската стойност от 0.40 се наблюдава при 100 m височина и 90° ъгъл.



Фигура 15. Графика за влиянието на височината и ъгъла на камерата върху mAP

Осветеността също има съществено влияние върху производителността на системата. Данни за средния mAP при различни условия на осветеност показват, че при регистриране на изображения през деня системата постига най-добра производителност със среден mAP от 0.70. Когато настъпи здрач, производителността малко намалява до 0.60. При нощни условия стойността на mAP спада значително до 0.45, което показва сериозно влияние на осветеността върху точността на откриване на обекти.

Изводи: Най-добра производителност се постига при по-ниски височини и малки ъгли на камерата. Осветеността играе важна роля, като разпознаване на изображения, регистрирани през деня осигурява най-добри условия за работа на системата, докато работа през нощта води до значително по-ниски резултати. Височината и ъгълът на камерата имат силно влияние върху производителността на модела, като по-ниските височини и по-малките ъгли водят до по-висок mAP. Осветеността е критичен фактор като производителността значително намалява при лоши условия на осветеност (здрач и нощ). Взаимодействията между факторите също са значими, което означава, че влиянието на един фактор зависи от стойностите на другите. За подобряване на производителността при големи височини и големи ъгли може да се използва по-добра камера или алгоритми за подобряване на изображението. При лоши условия на осветеност (нощ) може да се използват инфрачервени камери или алгоритми за подобряване на яркостта и контраста.

4.7.3. Оптимизация за малки обекти

Сравнението на получените експериментални резултати за производителността на базовия модел и оптимизираният модел за откриване на малки обекти показва, че всички техники за подобрене водят до значително по-добро откриване на малки обекти. Най-голямо повишение на точността се наблюдава при използването на по-висока резолюция, но това е за сметка на значително намаляване на скоростта. Ако приоритет е балансирано съотношение между точност и бързодействие, то техниката за оптимизация с използване на FPN и функция с фокална загуба води до обучение на модели, които са по-подходящи алтернативи. Използването на FPN показва най-добър компромис между подобрене в mAP и запазване на висока производителност при работа в реално време. Допълнителен анализ на получените резултати показва, че след интеграцията на FPN и функция с фокална загуба моделът успява да разпознае обекти, които базовия модел пропуска. По-високата резолюция на входните изображения допълнително подпомага повишаването на точността, но с цената на намалена скорост.

Изводи: Получените експериментални резултати при прилагане на различни техники за оптимизация при обучение на модели за откриване на малки обекти показват, че най-добрият баланс между ефективност и производителност се постига чрез Feature Pyramid Network (FPN).

Тази техника осигурява значително подобрение в откриването на малки обекти като същевременно запазва достатъчно висока скорост за приложения в реално време. От друга страна използването на по-висока резолюция е ефективно, когато точността е основният приоритет, но може да бъде неподходящо за среди, изискващи висока честота на кадрите. В зависимост от конкретните изисквания на задачата, различните техники могат да бъдат комбинирани или използвани самостоятелно за да се постигне оптимално използване на системата.

4.7.4. Трансферно обучение спрямо обучението от нулата

При провеждането на експерименти с YOLOv5, SSD и Faster R-CNN е оценено влиянието на трансферното обучение в сравнение с обучение на модел от нулата. Получените резултатите (табл. 14) показват, че трансферното обучение води до значително по-висока крайна производителност за всички модели. Освен подобрената точност, трансферното обучение води и до значително по-бързо обучение.

Таблица 1. Сравняване на трансферно обучение с обучението от нула

Модел	Трансферно обучение (mAP)	Обучение от нула (mAP)	Време за трансферно обучение	Време за обучение от нула
YOLOv5	78.3%	65.1%	2.5 ч.	8 ч.
SSD	72.5%	61.8%	3 ч.	10 ч.
Faster R-CNN	80.1%	68.7%	4 ч.	14 ч.

Изводи: Резултатите от проведеното експериментално изследване показват, че трансферното обучение на модели осигурява значителни предимства спрямо обучението от нула в контекста на откриване на обекти с БПЛА. То не само повишава точността на моделите, но и значително ускорява обучението и подобрява генерализацията. Оптималният подход за трансферно обучение включва правилно замразяване на слоевете, използване на адаптивна скорост на обучение и постепенно размразяване на параметрите. Тези техники са от съществено значение за съкращаване на времето за разработка и постигане на по-добри резултати в реални условия.

4.7.5. Оценка на производителност в реално време

Получените експериментални резултати за латентност и FPS на различните модели и конфигурации позволяват да се направи детайлен анализ на производителността на моделите в реално време и да се оценят техните предимства и ограничения в контекста на приложения с БПЛА.

Изводи: От гледна точка на избора на модел, YOLOv5 предлага най-добър баланс между точност и скорост, което го прави най-подходящ за приложения, изискващи висока скорост на обработка и ниска латентност. Моделът SSD може да бъде добра алтернатива, когато се изисква по-висока точност, при условие че намаляването на FPS не е проблем за задачата. Моделът Faster R-CNN, въпреки своята потенциално висока точност, се оказва неподходящ за повечето приложения в реално време поради значително по-нисък FPS и висока латентност. На базата на направеното сравнение и анализ на латентност, FPS и енергийна ефективност, може да се направи заключение, че за приложения с БПЛА, изискващи обработка в реално време, YOLOv5 е най-подходящият избор на модел за откриване на обекти. Моделът предлага най-добър баланс между скорост и енергийна ефективност, особено при по-ниски резолюции на изображенията като 320×320 или 640×640 пиксела. Моделът SSD може да бъде алтернатива когато е необходима по-висока точност, но може да се приеме по-ниска скорост на работа. Моделът Faster R-CNN, въпреки потенциално високата си точност, се оказва неподходящ за повечето приложения в реално време на платформата Jetson Xavier NX, освен ако не се използва при много ниски резолюции или за задачи, които не изискват висок FPS.

4.7.6. Многокласова класификация

- **Идентифициране на трудни класове**

- *Малки обекти:* Класове като "пешеходци" и "велосипедисти" показват по-ниска производителност (mAP 65% и 58% съответно) в сравнение с по-големи обекти като "автомобили" (mAP 82%). Това се дължи на ограничената информация, налична за малките обекти в изображенията от БПЛА.

- *Класове с визуална прилика:* Наблюдава се объркване между класовете "автомобили" и "микробуси" (F1-score съответно 0.85 и 0.79), което показва трудност при разграничаване на визуално подобни класове.

- *Редки класове:* Класът "автобуси" показва най-ниска производителност (mAP 45%) поради ограничения брой примери в набора от данни, което подчертава предизвикателството при откриването на редки обекти.

- **Влияние на броя класове върху общата производителност**

- *Намаляване на общия mAP:* С увеличаването на броя класове от 5 на 10, се наблюдава спад в общия mAP от 78% на 72%. Това съответства на очакванията, тъй като задачата за многокласова класификация става по-сложна при използване на повече класове.

- *Увеличаване на изчислителната сложност:* Времето за обучение се увеличава с 35% при добавянето на 5 нови класа, което показва нарастващата изчислителна сложност с увеличаването на броя класове.

- *Подобрена генерализация:* Въпреки намаляването на общия mAP, моделът показва по-добра способност за генерализация при тестване с нови данни, което предполага, че по-големият брой класове помага за изграждането на по-устойчиви характеристики⁴.

- **Оценка на баланса между класовете**

- *Влияние на дисбаланса:* Класове с по-малко примери (напр. "автобуси" и "мотоциклети") показват значително по-ниска производителност (средно с 25% по-нисък mAP) в сравнение с добре представените класове.

- *Ефективност на техниките за балансиране:* Прилагането на техники като претегляне на класовете и увеличаване на данните подобрява производителността за недостатъчно представените класове с 15–20%, но все още не достига нивото на добре представените класове.

- *Компромис между точност и баланс:* Опитите за подобряване на баланса между класовете чрез намаляване на примерите от доминиращите класове водят до малко понижаване на общия mAP (с 3%), но значително подобряване на F1-score за редките класове (средно с 0.12).

Изводи: Многокласовата класификация при откриване на обекти от БПЛА представя значителни предизвикателства, особено по отношение на малки обекти, визуално подобни класове и редки класове. Увеличаването на броя класове усложнява задачата, но може да доведе до по-добра генерализация. Балансът между класовете остава критичен фактор, като техниките за справяне с дисбаланса показват обещаващи резултати, но се изисква прилагане на допълнителни техники за откриване на редки и трудни класове.

4.7.7. Анализ на работоспособността

Получените експериментални резултати при проведените експерименти за оценка на робастността на моделите при различни атмосферни условия, включително облачно време, силен дъжд, гъста мъгла и ниска осветеност, както и при наличие на шум, са показани в табл. 18 и табл. 19.

Таблица 2. Работоспособност на моделите при различни атмосферни условия

Модел	Облачно време	Силен дъжд	Гъста мъгла	Ниска осветеност
YOLOv5	92%	78%	65%	88%
SSD	88%	72%	70%	85%
Faster R-CNN	90%	85%	75%	80%

Таблица 3. Робастност на моделите при частично закриване на обекти

Модел	25% закриване	50% закриване	75% закриване
YOLOv5	92%	70%	55%
SSD	90%	68%	50%
Faster R-CNN	91%	85%	60%

Изводи: Резултатите показват, че моделът YOLOv5 демонстрира най-добра устойчивост при леки атмосферни смущения като облачно време, но се оказва чувствителен към гъста мъгла, където неговата производителност спада значително. Моделът SSD предлага умерена устойчивост, запазвайки около 70% от производителността при гъста мъгла, но губи повече производителност при силен дъжд в сравнение с Faster R-CNN, който показва най-добра устойчивост при всички условия, особено при силен дъжд и мъгла. Получените резултати показват, че при частично закриване на обекти Faster R-CNN демонстрира най-добра устойчивост. Моделът запазва около 85% от производителността при 50% закриване, което го прави най-подходящ за приложения, изискващи добра устойчивост към частични обструкции. В същото време, YOLOv5 и SSD показват значително понижение на производителността при по-силно закриване, като YOLOv5 е особено засегнат при 75% закриване. Резултатите от експериментите показват, че Faster R-CNN е най-устойчивият модел при тежки атмосферни условия и частично закриване на обекти, което го прави по-подходящ за приложения в реални условия, като автономно шофиране и видеонаблюдение, при които устойчивостта към различни смущения е критична. YOLOv5, въпреки че предлага висока производителност и бързодействие, се оказва по-чувствителен към мъгла и закриване, особено в задачи, които изискват висока точност при класификация. SSD предлага балансирана производителност, като заема междинна позиция между YOLOv5 и Faster R-CNN, като предлага добра устойчивост в умерени условия, но губи производителност при по-силни атмосферни смущения и закриване.

4.7.8. Сравнение на различни версии на YOLO

Получените експериментални резултати за сравнение на производителността на модели, обучени с различни версии на YOLO, са представени в табл. 20.

Таблица 20. Сравнение на производителността на различните версии на YOLO

Модел	mAP (%)	FPS (GPU)	FPS (CPU)	Р-р на модела (MB)	Изп. памет (GB)
YOLOv3	67.3	65	12	237	4.5
YOLOv4	72.5	80	18	244	5.2
YOLOv5	76.5	100	25	27	2.1
YOLOv7	79.8	95	22	72	3.4
YOLOv8	82.1	110	28	43	3.0

Изводи: Един от ключовите аспекти при избора на YOLO модел за реални приложения е балансът между точност и изчислителна ефективност. YOLOv3 и YOLOv4 изискват значително повече ресурси, но предлагат по-ниска точност и скорост.

YOLOv5 и YOLOv7 представляват оптимално съчетание на скорост и точност, като са подходящи за вградени системи и приложения с ограничени изчислителни възможности. YOLOv8 показва най-добри резултати, но изисква повече памет и изчислителна мощност в сравнение с YOLOv5. Сравнителният анализ показва, че YOLOv8 предлага най-добра точност и скорост, което го прави подходящ избор за високопроизводителни приложения с БПЛА. Въпреки това, YOLOv5 остава най-ефективният модел по отношение на ресурсна консумация, като предлага добър баланс между производителност и ниско изчислително натоварване. За приложения с ограничени хардуерни ресурси, YOLOv5 и YOLOv7 представляват най-подходящите варианти.

4.7.9. Експерименти с ансамблови методи

В рамките на проведените експерименти е изследван потенциала за подобряване на точността чрез комбиниране на откриването и разпознаването на обекти от различни модели. Оценката на ансамбловите методи е извършена чрез измерване на средната прецизност (mAP) върху тестовия набор от данни като резултатите са сравнени с производителността на индивидуалните модели. Резултатите показват, че ансамбловите методи подобряват точността спрямо най-добрия индивидуален модел (Faster R-CNN, 78.2%), като методът на подреждане достига най-висока стойност на 82.3% mAP. Усредняването и гласуването също водят до подобрене, но в по-малка степен. Въпреки повишената точност, ансамбловите методи изискват повече време за инференция, като подреждане увеличава латентността с около 50% спрямо най-бързия модел (YOLOv5).

Изводи: Комбинирането на модели води до съществено повишаване на точността, но компромисът с времето за инференция трябва да се вземе предвид при избора на подходяща стратегия. Подреждането показва най-добри резултати за точност, но също така изисква най-много време за инференция. Гласуването предлага добър баланс между подобрене в точността и изчислителна сложност, докато усредняването е най-ефективно при минимално увеличаване на латентността. Получените експериментални резултати показват, че ансамбловите методи могат значително да подобрят точността на откриване и класификация, особено в сложни сценарии. Въпреки това, увеличеното време за обработка трябва да бъде внимателно оценено в зависимост от изискванията на конкретното приложение. Ансамблове методи с подреждане предлага най-добра точност, но изисква значителни изчислителни ресурси, докато усредняването и гласуването представляват по-балансирані решения за системи с ограничения във времето за инференция.

4.7.10. Анализ на грешките при откриване на обекти

Изводи: Анализът на грешките при откриване на обекти с обучените модели показва, че най-често срещаните предизвикателства за моделите са малките обекти, ниската осветеност и частичното закриване. Faster R-CNN демонстрира най-добра устойчивост към тези фактори, но за приложения в реално време YOLOv8 е оптималният избор, тъй като предлага добър баланс между точност и скорост. За минимизиране на грешките при откриване на обекти могат да се приложат следните стратегии: (1) Използване на техники за обогатяване на данните: включване на повече примери с ниска осветеност, частично закриване и малки обекти; (2) Фина настройка на хиперпараметрите: адаптиране на праговете за откриване и класификация на обекти според спецификите на тестовите сценарии; (3) Ансамблови методи: комбиниране на YOLO и Faster R-CNN за подобрена детекция на малки обекти и намаляване на фалшиво положителни и фалшиво отрицателни грешки. Получените експериментални резултати подчертават важността на адаптивните техники за подобряване на детекцията, особено при динамични условия като автономно управление и видеонаблюдение.

4.7.11. Експерименти с различни основни архитектури

Получените експериментални резултати при използване на различни основни архитектури за обучение на модел YOLOv5 са показани в табл. 24.

Таблица 24. Резултати при използване на различни основни архитектури

Основна архитектура	mAP (%)	FPS (GPU)	FPS (CPU)	Размер на модела (MB)
ResNet-50	85.3	92	12	98
EfficientNet-B0	87.1	75	10	88
MobileNetV2	82.4	110	18	34

Изводи: Експерименталните резултати показват, че изборът на основна архитектура зависи от конкретното приложение. EfficientNet-B0 е най-добрият избор за приложения, изискващи висока точност, макар и с по-ниска скорост на инференция. ResNet-50 предлага добър баланс между точност и производителност, което го прави универсален избор. MobileNetV2 е оптимален за системи с ограничени ресурси, тъй като предлага най-висока скорост на инференция и най-малък размер. Тези резултати могат да бъдат използвани за оптимизиране на моделите за откриване на обекти за приложения с изисквания за работа в реално време с БПЛА, при които скоростта и ефективността на изчисленията са от критично значение.

4.7.12. Оценка на производителност при проследяване на обекти

Проведеното експериментално изследване има за цел да оцени ефективността на интегрирането на алгоритми за проследяване на обекти с детектори на обекти като фокусът е върху оценка на точност и скорост. Използвани са алгоритмите SORT и DeepSORT в комбинация с най-добре представящия се детектор от предходните експерименти. Оценката е извършена върху видео последователности заснети от БПЛА.

Изводи: Изборът на алгоритъм за проследяване зависи от конкретното приложение. Комбинацията на детектор и тракер YOLOv8 + DeepSORT е най-добрият избор за приложения, изискващи висока точност, но има по-ниска скорост на обработка. YOLOv8 + SORT предлага оптимален баланс между скорост и точност, което го прави подходящ за системи с изисквания за работа в реално време при използване на ограничени изчислителни ресурси. YOLOv5 + SORT е най-бърз вариант, но води до получаване на най-много грешки, докато YOLOv5 + DeepSORT предлага по-добра точност, но с по-висока изчислителна сложност. Получените експериментални резултати са от съществено значение за разработването на ефективни системи за проследяване на обекти в автономни БПЛА, при които балансът между точност и скорост е от критично значение.

4.7.13. Експерименти с техники за обогатяване на данни

Получените експериментални резултати за производителността на моделите при използване на различни техники за обогатяване на данни са представени в табл. 26.

Таблица 26. Резултати от различни техники за обогатяване на данни

Техника за обогатяване	mAP (%)	mAP на нови данни (%)	FPS (GPU)	FPS (CPU)
Без обогатяване (базов модел)	74.2	65.1	105	28
Случайно изрязване	76.8	68.3	102	27
Завъртане	78.5	70.1	100	26
Промяна на яркостта и контраста	80.2	72.4	98	25
Добавяне на шум	77.1	69.5	101	26
Mixup	81.9	75.3	95	24
CutMix	83.1	76.8	94	23
Mixup + CutMix	85.4	79.2	92	22

Изводи: Експерименталните резултати показват, че използването на техники за обогатяване на данни значително подобрява точността и генерализационната способност на моделите за откриване на обекти. Обогатяване на данни с CutMix и Mixup осигурява най-голямо подобрене, особено когато се комбинират, като постигат mAP от 85.4% и 79.2% за нови данни. Техники като промяна на яркостта и контраста са особено полезни за анализ на изображения при променящи се условия на осветеност. Добавянето на шум и завъртането също имат положителен ефект, но са по-малко ефективни в сравнение с Mixup и CutMix. Тези резултати са от съществено значение за разработването на надеждни системи за детекция на обекти в автономни БПЛА, при които адаптивността към разнообразни условия е от ключово значение.

4.7.14. Анализ на изчислителната ефективност

Проведено е експериментално изследване за оценка на изчислителната ефективност на различни модели при работа на бордовия компютър Jetson Xavier NX. Получените резултати (табл. 27), показват, че:

- **Използване на хардуерни ресурси**

- *Памет (RAM и VRAM):* По-големите модели изискват значително повече VRAM, което ограничава паралелната обработка на кадри. Квантизацията намалява използваната памет, но намалява точността;

- *Натоварване на CPU и GPU:* Моделите, оптимизирани с TensorRT, намаляват натоварването на CPU, като изместват повече изчисления към GPU. По-леките модели (например, YOLOv5s) изразходват по-малко GPU ресурси, което позволява по-ефективна работа в реално време.

- **Оценка на консумацията на енергия:** Резултатите показват, че по-големите модели консумират повече енергия, което намалява времето на работа на батерия. Оптимизацията с TensorRT намалява енергийната консумация с 15–25% без съществено да намалява точността. Използването на квантизация допълнително понижава енергийните изисквания, но води до намаляване на mAP.

Таблица 27. Сравнение на моделите по изчислителна ефективност

Модел	RAM (MB)	VRAM (MB)	CPU (%)	GPU (%)	FPS	Консумация (W)
YOLOv5s	780	1200	45	70	110	10.5
YOLOv5m	1020	1800	52	78	85	12.3
YOLOv7	1400	2500	60	85	70	14.1
YOLOv8	1280	2300	58	82	75	13.6
YOLOv8 (TensorRT)	900	1700	47	75	90	11.2

Изводи: YOLOv5s е най-ефективния модел за приложения в реално време поради висок FPS и ниска консумация на енергия. Оптимизацията с TensorRT значително подобрява производителността като намалява натоварването на CPU и консумацията на енергия. YOLOv7 и YOLOv8 предлагат по-добра точност, но с по-големи изчислителни изисквания, което ги прави по-малко подходящи за продължителна работа на батерия. Изборът на модел трябва да се основава на баланс между точност, скорост и изчислителни разходи. За вградени системи с ограничени ресурси, оптимизирани версии като YOLOv8 (TensorRT) предлагат добър компромис между производителност и енергийна ефективност.

4.7.15. Експерименти с различни функции на загуба

На базата на проведените експерименти за сравнение на различни функции на загуба при обучение на модели за откриване на обекти са получени резултати (табл. 28).

Таблица 4. Сравнение на функциите на загуба по ключови показатели

Функция на загуба	mAP (%) ↑	IoU (%) ↑	Скорост на конвергенция ↓	Стабилност на обучението
Cross-Entropy Loss	85.3	67.1	Бърза	Средна
Focal Loss	87.8	69.5	Средна	Висока
GIoU Loss	88.2	71.3	Средна	Висока
CIoU Loss	89.0	72.8	Бърза	Висока
DIoU Loss	89.5	74.1	Най-бърза	Висока

Изводи: За класификация функцията с фокална загуба е най-добрия избор за преодоляване на проблеми с небалансирани класове и трудни примери. За локализация функцията на загуба DIoU постига най-добри резултати като ускорява конвергенцията и подобрява точността на ограничителните рамки. Изборът на функция на загуба зависи от конкретното приложение. За БПЛА с ограничени изчислителни ресурси, функцията на загуба DIoU предлага най-бързо и точно обучение, докато функцията с фокална загуба подобрява разпознаването на малки и трудни обекти. Оптималната комбинация за приложения с БПЛА е съвместното използване на функцията с фокална загуба (за класификация) и функцията на загуба DIoU (за локализация), което води до най-добри баланс между точност и скорост на обучение.

НАУЧНО-ПРИЛОЖНИ И ПРИЛОЖНИ ПРИНОСИ

Научни приноси:

- Предложена е методология за проектиране и разработване на система за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати;
- Предложена е концептуална архитектура на система, проектирана с предложената методология, състояща се от хардуерни компоненти и софтуерни модули, чието интегриране осигурява функционирането на системата съгласно поставените цели и функционални изисквания за точност, производителност, бързодействие и работа в реално време и енергийна ефективност;
- Предложена е адаптиран алгоритмичен модел за откриване на обекти според изискванията на конкретно приложение (например автономни дроне, роботизирани системи, видеонаблюдение, интелигентни транспортни решения), който осигурява оптимизация за откриване на малки обекти и работа в динамични условия, както и разпознаване и проследяване на обекти в реално време.

Научно-приложни приноси:

- Предложено е използване на хибриден ансамблов метод за откриване на обекти, който осигурява подобряване на точността при откриване на обекти при безпилотни летателни апарати чрез комбиниране на модели с различни архитектури на невронни мрежи;
- Предложени са техники за оптимизация на обучението на модели за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати с използване на трансферно обучение, обогатяване на данни и управление на скоростта на обучение с политика на единствен цикъл, които осигуряват постигане на по-висока точност и предотвратяват прекомерното приспособяване на моделите;

- Предложена е методология за анализ и филтрация на грешки при откриването на обекти от вида фалшиво положителни, фалшиво отрицателни, неправилни класификации чрез комбиниране на Grad-CAM визуализация и статистически анализ на грешките;
- Предложена е методология за оценка на устойчивостта на моделите за откриване на обекти при безпилотни летателни апарати при закриване на обекти, който може да се използва за адаптивно обучение и подобряване на производителността в реални условия.

Приложни приноси:

- Дефинирани са конкретни препоръки за избор на модел и параметри за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати в динамични среди;
- Предложена е модифицирана архитектура за ансамблово детектиране на обекти при безпилотни летателни апарати с използване на YOLOv8 за баланс между точност и изчислителна ефективност за приложения в реално време и на Faster R-CNN за подобряване на анализа при сложни сцени, която подобрява точността при сложни сцени с до 7% спрямо най-добрия индивидуален модел;
- Разработена е експериментална рамка за сравнителен анализ на модели за отдалечено откриване, разпознаване и проследяване на обекти при безпилотни летателни апарати, която може да бъде използвана в индустриални и изследователски среди за оценка на нови архитектури и модели;
- Изследвано е влиянието на външни фактори – атмосферни условия (дъжд, мъгла, ниска осветеност), частично закриване на обекти, условия на регистриране на изображения (височина на полет, ъгъл на заснемане) върху точността на откриване и проследяване на обекти при безпилотни летателни апарати с използване на обучени модели със съвременни архитектури на невронни мрежи.

СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

1. **Ivanova, E., Stefanov, I.** “*Remote Detection, Recognition and Tracking of Objects in Drones Aircraft*”. Journal SECURITY & FUTURE, Vol. 2, № 2, 2024, pp. 71-72, ISSN 2535-0668
2. **Ivanova, E., Stefanov, I.** “*Integration of Methods Based on Artificial Intelligence in the Processing of Images in Photography*”. Journal INDUSTRY 4.0, Vol. 9, № 5, 2024, pp. 158-159, ISSN 2534-8582
3. **Ivanova, E.** “*Conceptual Design of Unmanned Aerial Vehicles*”. International Journal of Advances in Computer Science and Technology (IJACST), Vol. 14, № 4, 2025, <https://doi.org/10.30534/ijacst/2025/011442025>
4. **Ivanova, E.** “*Software Architecture and System Structure for Remote Human Recognition from the Air*”. International Journal of Advances in Computer Science and Technology (IJACST), Vol. 14, № 3, 2025

SUMMARY

REMOTE DETECTION, RECOGNITION AND TRACKING OF OBJECTS WITH UNMANNED AIRCRAFT

Eleonora Ivova Ivanova

The dissertation explores the design, development, and experimental validation of an advanced system for remote detection, recognition, and tracking of objects using unmanned aerial vehicles (UAVs). As UAVs continue to gain importance across sectors such as environmental monitoring, agriculture, public safety, and defense, there is a growing need for intelligent systems capable of processing visual and sensor data autonomously and efficiently.

The research provides a comprehensive overview of modern UAV platforms and the sensor technologies they integrate, including optical cameras, infrared sensors, radar systems, and ultrasonic devices. These sensors are evaluated for their suitability in remote sensing tasks under varying operational conditions. The study places special emphasis on the role of artificial intelligence (AI) and machine learning in enabling real-time object recognition and tracking capabilities.

The core objective of the dissertation is to propose and evaluate software and hardware architectures that combine AI-driven models with sensor fusion techniques to achieve robust object detection and tracking in complex and dynamic environments. The system is built with modular design principles, consisting of a data acquisition and preprocessing module, an object detection and classification module, and an object tracking unit. Various algorithms are investigated and implemented, including traditional image processing methods, support vector machines, and deep learning-based approaches such as convolutional neural networks (CNNs) and object detection frameworks (YOLO, SSD, Faster R-CNN).

Furthermore, the dissertation addresses current challenges such as small object detection, limited onboard computational power, environmental variability, and real-time constraints. Techniques such as transfer learning, data augmentation, and adaptive training policies are applied to optimize model performance and generalizability. The integration of multimodal data and the development of ensemble methods are also explored to improve accuracy and robustness.

A significant portion of the work is dedicated to the planning and execution of experiments. These include comparative analyses of different model architectures, evaluation of detection accuracy under real-world conditions, and performance benchmarks in terms of latency, energy efficiency, and tracking precision. The results confirm the effectiveness of the proposed system, highlighting its potential for real-time deployment in practical UAV applications.

The dissertation contributes original methodologies and implementation strategies for developing intelligent UAV-based systems, offering valuable insights for researchers and practitioners in the fields of remote sensing, autonomous navigation, and AI-powered surveillance technologies.