


Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук


КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА


на тему Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань
Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності
Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент 2 курсу, група КНм-23-2  Володимир БАЙДИЧ
Курс, група виконавця Підпис Ім'я, прізвище

Керівник: д.т.н., проф., завідувач кафедри КН  Олександр БАРМАК
Науковий ступінь, посада Підпис Ім'я, прізвище

Нормоконтроль: к.т.н., доцент кафедри КН  Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, прізвище

До захисту допускаю:
Зав. кафедри КН, д.т.н., професор  Олександр БАРМАК
Підпис Ім'я, прізвище

09 грудня 2024 р.

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

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук



(підпис)

д.т.н., професор Олександр БАРМАК
« 01 » вересня 2024 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА**

1. Тема кваліфікаційної роботи магістра: «Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання»

2. Завдання видано студенту Володимиру БАЙДИЧУ
(Ім'я, прізвище)

3. Керівник роботи д.т.н., проф. Олександр БАРМАК
(Ім'я, прізвище)

4. Затверджені наказом університету від « 26 » серпня 2024 р. № 60

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

Мета кваліфікаційної роботи магістра – підвищення якості виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання.
Для досягнення поставленої мети потрібно виконати наступні задачі: провести аналіз предметної області для проблеми виявлення БПЛА, існуючих публікацій щодо виявлення БПЛА та існуючих моделей глибокого навчання для виявлення БПЛА; вдосконалити метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання; визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з іншими відомими підходами.

Реферат

Кваліфікаційна робота магістра присвячена розробці методу виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання.

Актуальність теми. Виявлення безпілотних літальних апаратів є важливим напрямком у сучасному світі через зростання їхнього використання як у цивільній, так і у військовій сферах. Широка доступність та функціональність БПЛА сприяють їх застосуванню в різноманітних цілях, зокрема для незаконної діяльності, такої як несанкціоноване спостереження, порушення конфіденційності, контрабанда або нанесення шкоди об'єктам критичної інфраструктури. У зв'язку з цим, задача розпізнавання БПЛА є надзвичайно важливою з точки зору мінімізації потенційної шкоди, що може бути нанесена живим та неживим об'єктам з використанням дронів. Особливої актуальності ця проблема набуває в сучасних реаліях держави, що знаходиться в стані війни.

Варіативність БПЛА, їхнього технічного функціоналу та методів їх використання робить завдання ідентифікації складним та багаторівневим. Сучасні дрони можуть досягати найменших розмірів, використовувати різноманітні стелс-технології для зменшення видимості на багатьох спектрах спостереження, таким чином обробка різних типів сигналів дронів є одним з ключових факторів точного виявлення БПЛА. В контексті даної задачі використання засобів глибокого навчання для аналізу акустичних та радіолокаційних сигналів дронів є кращим рішенням останніх років, адже воно дозволяє автоматизувати процеси аналізу, підвищує точність та швидкість обробки даних. Нейронні мережі дають можливість обробляти та інтерпретувати складні акустичні та радіолокаційні сигнали, забезпечуючи виявлення дронів навіть у зашумленому середовищі або за умов складного фонового сигналу.

Інтеграція нейронних мереж в системи аналізу акустичних та радіолокаційних сигналів є новим підходом, що дозволяє суттєво підвищити ефективність систем виявлення. Дослідження в цьому напрямку сприяє розвитку сучасних технологій безпеки та може мати значний вплив на подальший розвиток засобів протидії БПЛА.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання. Для досягнення поставленої мети потрібно виконати наступні завдання:

- 1) провести аналіз: предметної області для проблеми виявлення БПЛА; існуючих публікацій щодо виявлення БПЛА; існуючих моделей глибокого навчання для виявлення БПЛА;
- 2) вдосконалити метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання;
- 3) визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з іншими відомими підходами.

Об'єкт дослідження процес виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання.

Предмет дослідження. Моделі глибокого навчання.

Методи дослідження. Моделі глибокого навчання для аналізу акустичних та радіолокаційних сигналів.

Наукова новизна одержаних результатів. Удосконалено метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання, який відрізняється від існуючих вдосконаленням архітектури шляхом збільшення кількості згорткових шарів, використанням послідовних шарів двонаправлених LSTM, доповненням додатковими шарами Dropout та Dense, що дозволило забезпечити високу якість класифікації для різних типів сигналу.

Апробація результатів кваліфікаційної роботи магістра та публікації. За темою роботи підготовлені тези на наукову конференцію: Байдич В.В. Метод виявлення бпла за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 26-28

Структура та обсяг роботи. Кваліфікаційна робота магістра складається з завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків,

переліку посилань із 43 найменувань та 3 додатків. Загальний обсяг дипломної роботи магістра становить 104 сторінки, з них 81 сторінка основного тексту та 23 сторінки додатків. У роботі наведено 35 рисунків, 10 формул та 7 таблиць.

Ключові слова: БПЛА, виявлення об'єктів, глибоке навчання, акустичний сигнал, радіолокаційний сигнал, згортково-рекурентні мережі.

Зміст

Перелік скорочень	3
Вступ.....	4
РОЗДІЛ 1 Аналіз сучасного стану у використанні методів глибокого навчання для виявлення БПЛА.....	7
1.1 Аналіз предметної області.....	7
1.2 Аналіз існуючих публікацій щодо виявлення БПЛА.....	9
1.3. Аналіз існуючих моделей глибокого навчання для вирішення задачі виявлення БПЛА за аналізом акустичних та радіолокаційних даних.....	18
1.4 Постановка задачі.....	20
РОЗДІЛ 2. Вдосконалення методу виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів	21
2.1 Модель глибокого навчання для виявлення БПЛА.....	22
2.1.1. Огляд архітектури згортково-рекурентних мереж.....	22
2.1.2. Архітектура моделі для аналізу акустичних сигналів БПЛА.....	23
2.2 Вдосконалення моделі для виявлення БПЛА.....	25
2.2.1 Огляд цілей та вимог до покращень.	25
2.2.2 Збільшення глибини згорткових шарів та зміна параметрів.....	26
2.2.3. Використання двонаправлених LSTM для покращення обробки послідовностей.	28
2.2.4. Додаткові повнозв'язні та шари виключення для стабілізації та вдосконалення класифікації.....	33
2.2.5. Модифікація моделі для роботи з радіолокаційними даними.	35
2.3 Налаштування процесу навчання моделей для виявлення БПЛА.	38
2.4 Метрики для оцінювання якості виявлення БПЛА.	40
Висновки до розділу 2	45
РОЗДІЛ 3 Основні кроки методу по вдосконаленню та використанню згортково-рекурентної мережі	47
3.1 Основні кроки методу по вдосконаленню архітектури глибокого навчання	47
3.2. Модифікація вдосконаленої архітектури для задачі класифікації радіолокаційного сигналу БПЛА.....	49
3.3. Використання отриманих моделей для виявлення БПЛА.	50

РОЗДІЛ 4 Експериментальна валідація запропонованого вдосконалення методу виявлення БПЛА.....	52
4.1 Опис застосунку для проведення експериментів.	52
4.2 Опис датасету.	53
4.2.1 Опис наборів радіолокаційних та акустичних сигналів БПЛА.....	53
4.2.2. Попередня обробка вхідних даних.....	57
4.3 Експерименти.	60
4.3.1. Результати вдосконалення архітектури згортково-рекурентної мережі для аналізу акустичних сигналів БПЛА.	60
4.3.2. Результати модифікації вдосконаленої згортково-рекурентної мережі для задачі виявлення БПЛА за радіолокаційним сигналом.	68
Висновки до розділу 4	74
Загальні висновки.....	76
Перелік посилань.....	78
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
БПЛА	Безпілотний літальний апарат
FMCW	Частотно-модульована безперервна хвиля
MFCC	Мел-частотні кепстральні коефіцієнти
CNN	Згорткова нейронна мережа
RNN	Рекурентна нейронна мереж
BiLSTM	Двонаправлена довготривала короткочасна пам'ять
CRNN	Згортково-рекурентна нейронна мереж
DL	Глибоке навчання

Вступ

Актуальність теми. Виявлення безпілотних літальних апаратів є важливим напрямком у сучасному світі через зростання їхнього використання як у цивільній, так і у військовій сферах. Широка доступність та функціональність БПЛА сприяють їх застосуванню в різноманітних цілях, зокрема для незаконної діяльності, такої як несанкціоноване спостереження, порушення конфіденційності, контрабанда або нанесення шкоди об'єктам критичної інфраструктури. У зв'язку з цим, задача розпізнавання БПЛА є надзвичайно важливою з точки зору мінімізації потенційної шкоди, що може бути нанесена живим та неживим об'єктам з використанням дронів. Особливої актуальності ця проблема набуває в сучасних реаліях держави, що знаходиться в стані війни.

Варіативність БПЛА, їхнього технічного функціоналу та методів їх використання робить завдання ідентифікації складним та багаторівневим. Сучасні дрони можуть досягати найменших розмірів, використовувати різноманітні стелс-технології для зменшення видимості на багатьох спектрах спостереження, таким чином обробка різних типів сигналів дронів є одним з ключових факторів точного виявлення БПЛА. В контексті даної задачі використання засобів глибокого навчання для аналізу акустичних та радіолокаційних сигналів дронів є кращим рішенням останніх років, адже воно дозволяє автоматизувати процеси аналізу, підвищує точність та швидкість обробки даних. Нейронні мережі дають можливість обробляти та інтерпретувати складні акустичні та радіолокаційні сигнали, забезпечуючи виявлення дронів навіть у шумному середовищі або за умов складного фонового сигналу.

Інтеграція нейронних мереж в системи аналізу акустичних та радіолокаційних сигналів є новим підходом, що дозволяє суттєво підвищити ефективність систем виявлення. Дослідження в цьому напрямку сприяє розвитку сучасних технологій безпеки та може мати значний вплив на подальший розвиток засобів протидії БПЛА.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами

глибокого навчання. Для досягнення поставленої мети потрібно виконати наступні завдання:

- 1) провести аналіз: предметної області для проблеми виявлення БПЛА; існуючих публікацій щодо виявлення БПЛА; існуючих моделей глибокого навчання для виявлення БПЛА;
- 2) вдосконалити метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання;
- 3) визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з іншими відомими підходами.

Об'єкт дослідження процес виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання.

Предмет дослідження. Моделі глибокого навчання.

Методи дослідження. Моделі глибокого навчання для аналізу акустичних та радіолокаційних сигналів.

Наукова новизна одержаних результатів. Удосконалено метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання, який відрізняється від існуючих вдосконаленням архітектури шляхом збільшення кількості згорткових шарів, використанням послідовних шарів двонаправлених LSTM, доповненням додатковими шарами Dropout та Dense, що дозволило забезпечити високу якість класифікації для різних типів сигналу.

Апробація результатів кваліфікаційної роботи магістра та публікації.
Апробація результатів кваліфікаційної роботи магістра та публікації. За темою роботи підготовлені тези на наукову конференцію: Байдич В.В. МЕТОД ВИЯВЛЕННЯ БПЛА ЗА АНАЛІЗОМ АКУСТИЧНИХ ТА РАДІОЛОКАЦІЙНИХ СИГНАЛІВ ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ. Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 26-28

Структура та обсяг роботи. Кваліфікаційна робота магістра складається з завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань із 43 найменувань та 3 додатків. Загальний обсяг дипломної роботи

магістра становить 104 сторінки, з них 81 сторінка основного тексту та 23 сторінки додатків. У роботі наведено 35 рисунків, 10 формул та 7 таблиць.

РОЗДІЛ 1 Аналіз сучасного стану у використанні методів глибокого навчання для виявлення БПЛА.

1.1 Аналіз предметної області.

Безпілотний літальний апарат (БПЛА), також відомий як дрон, – це літальний механічний пристрій, який виконує політ без присутності пілота на борту. Керування БПЛА може здійснюватися дистанційно оператором або виконуватися автономно за допомогою програмного забезпечення, яке використовує датчики та системи позиціонування, такі як GPS. БПЛА можуть бути різних типів, зокрема багатороторні, крилаті, гелікоптерні, і використовуються в різних сферах, таких як військова справа, картографія, доставка товарів, аерофотозйомка, спостереження та інші. Сильними сторонами дронів є їхня маневреність, можливість виконання завдань у важкодоступних місцях та відсутність ризику для життя пілота.

Основні методи виявлення БПЛА базуються розпізнаванні його ознак – характеристик, що роблять його видимим для спостерігача. До ознак, що роблять БПЛА помітним можна віднести його сигнали в радіочастотному, інфрачервоному, оптичному та акустичному спектрах.

В контексті виявлення БПЛА, акустичний сигнал — це звуковий відбиток, який виникає внаслідок роботи його механічних та електричних компонентів, зокрема роторів, двигунів та пропелерів, що забезпечують політ. Ці компоненти генерують звукові хвилі, які можуть поширюватися в повітрі на різні відстані, залежно від типу та потужності дрона. Наприклад, багатороторні дрони, що працюють на електричних двигунах, створюють характерний високочастотний гул, тоді як більш габаритні апарати з бензиновими двигунами можуть генерувати нижчі й гучніші звуки. Особливості акустичного сигналу БПЛА залежать від багатьох факторів: кількість та тип двигунів, їхня потужність, частота обертів пропелерів, а також аеродинамічні характеристики самого пристрою. Сам звуковий сигнал можна проаналізувати за такими параметрами як: амплітуда, фаза, тембр тощо. Одне з найбільш вичерпних та

зручних представлень акустичних сигналу це – функцію залежності амплітуди звукової хвилі від часу.

В цифровому форматі, аудіо-сигнал являє собою результат перетворення аналогового звукового сигналу в дискретну форму, яка може бути збережена, оброблена або передана комп'ютерними системами. Процес оцифрування звуку складається з двох основних етапів: дискретизації та квантування. Дискретизація – процес перетворення безперервної хвилі на дискретну послідовність значень. Звук, який є безперервним сигналом, фіксується через певні проміжки часу, після чого для кожної вибірки визначається амплітуда звукового сигналу. Квантування — це процес заокруглення реальних значень амплітуд кожного зразка у приблизні значення (оскільки значення амплітуди це величина безперервна, не існує можливості записати його реальним числом). Амплітудний діапазон звукового сигналу розбивається на певну кількість рівнів (кількість рівнів залежить від розрядності — наприклад, 16 біт дає 65 536 рівнів). Вибірка амплітуди округлюється до найближчого рівня, створюючи невеликі похибки, які можуть бути мінімізовані за рахунок підвищення розрядності. Після оцифрування звук зберігається як потік даних (набір бітів) у одному з аудіо-форматів (.mp3, .wav, WMA). Вибір формату для збереження аудіо-даних залежить від якості звуку, розміру файлу (стиснені чи не стиснені формати), сумісності з пристроями та програмами для роботи з ними та цільового призначення.

Радіолокаційний сигнал радару – це електромагнітна хвиля, яку радар випромінює для виявлення об'єктів. Сигнал поширюється в просторі, відбивається від об'єкта і повертається назад до приймача радару. Вимірюючи час, за який сигнал повертається, та зміну частоти через ефект Доплера, можна визначити відстань до об'єкта, його швидкість та напрямок руху. Частотні зміни також можуть вказувати на деталі об'єкта, наприклад, обертання лопатей дрона, створює характерні мікро-Доплерові сигнатури, за якими можна ідентифікувати об'єкт як БПЛА. Радіолокаційний сигнал радару має наступні ключові характеристики:

- Частота: Визначає довжину хвилі сигналу. Радари можуть працювати в різних діапазонах частот, таких як X-діапазон (8-12 ГГц) або W-діапазон (75-110 ГГц), залежно від призначення.

- Інтенсивність (амплітуда): Відображає потужність сигналу, що повертається після відбиття від об'єкта.
- Фаза: Відображає зміщення сигналу в часі, що дозволяє вимірювати відстань до об'єкта.
- Поляризація: Характеризує орієнтацію електромагнітної хвилі, що впливає на відбиття від різних матеріалів.
- Час затримки: Допомогає визначити відстань до об'єкта, вимірюючи час між випромінюванням і поверненням сигналу.
- Допплерівський зсув: Зміна частоти сигналу через рух об'єкта, яка дозволяє виміряти його швидкість.

1.2 Аналіз існуючих публікацій щодо виявлення БПЛА

Оскільки використання БПЛА в різноманітних сферах людського життя стає все більш поширеним і ця тенденція існує вже довгий час [1], на даний момент існує значна кількість досліджень, що так чи інакше стосуються задачі виявлення дронів [2]. В загальному всі науково-дослідницькі роботи в напрямку ідентифікації БПЛА можна поділити на три категорії – роботи що стосуються покращення традиційних методів, які потребують наявності людини-оператора для їх застосування, автоматизовані програмні рішення з використанням машинного навчання для аналізу отримуваної акустичної та радіолокаційної інформації, використання засобів глибокого навчання для виявлення БПЛА [3]. Для робіт останніх років, особливо актуальним є тема інтеграції машинного навчання та нейронних мереж [4].

Акустичне виявлення дронів – це фундаментальний підхід, що використовує звукові сигнатури БПЛА для ідентифікації та класифікації їхньої активності. Цей метод особливо корисний у випадках, коли радары та візуальні системи можуть бути неефективними, наприклад, за поганих погодних умов або низької видимості [5]. Машинне навчання і глибоке навчання відіграють важливу роль у вдосконаленні методів акустичного виявлення, дозволяючи покращувати точність та підвищувати надійність систем в умовах зі складними фоновими шумами [6].

Частина досліджень зосередженні на вдосконаленні методів машинного навчання для виявлення цивільних або невеликих дронів, які часто працюють на нижчих висотах і задача виявлення яких є більше уразлива для акустичних перешкод. У дослідженні [7] запропоновано систему для виявлення цивільних дронів в умовах сильного фонового шуму, де досягнуто точності 83% завдяки змішуванню спектральних паттернів аудіо-сигналів дронів і шуму. Це дослідження підкреслює потенціал акустичного підходу для ідентифікації дронів у складних акустичних умовах. Інше дослідження [8] зосереджено на підвищенні надійності системи акустичного виявлення дронів в умовах високого рівня перешкод. Дослідники застосували різноманітні методи попередньої обробки сигналів, щоб зменшити кількість хибних спрацьовувань. Автори підкреслюють важливість адаптивності цього підходу для реальних додатків, де важлива точність. Також у роботі [9] представлено метод виявлення та класифікації дронів з використанням одного мікрофона та недорогих обчислювальних пристроїв. Для цього використовували метод опорних векторів (SVM) для класифікації спектральних і часових характеристик, отриманих з попередньо сегментованого аудіо-сигналу за допомогою ковзого вікна. Система була протестована в реальному часі за участю різних моделей дронів у реальному середовищі. Хоча результати показали задовільну ефективність у спокійній обстановці, система генерує надмірну кількість хибних спрацьовувань при наявності звуків садового обладнання.

У статті [10] порівнювали різні методи машинного навчання та нейромереж, таких як YAMNet в контексті виявлення дронів з акцентом на вплив відстані та поширення звуку на ефективність системи. База даних звуків дронів та шумових перешкод дозволила оцінити методи в реалістичних умовах. Результати показали, що при навчанні з неослабленими сигналами система ефективно виявляє дрони на відстані до 200 м, тоді як навчання з ослабленими сигналами збільшує діапазон до 300 м для більшості моделей і до 500 м для YAMNet. Дослідження також показало, що тренування з ослабленими сигналами може покращити загальну ефективність системи, що робить її придатною для реальних умов спостереження.

У [11] розроблено систему з використанням мікрофонів MEMS для виявлення дронів середнього та великого розміру на відстані до 500 метрів, що робить її підходящою для захисту приватних або обмежених зон, таких як військові чи урядові об'єкти. Також у [12] пропонується метод, що поєднує технологію формування діаграми спрямованості з нейронними мережами для виявлення акустичних ознак наявності дронів за допомогою систем масивів мікрофонів. Метод використовує алгоритм формування діаграми спрямованості для напрямленого захоплення звукових сигналів дронів. В якості класифікатора в дослідженні використовується згортоква нейронна мережа натренована Мел-спектрограмах та Мел-частотних кепстральних коефіцієнтах. Дослідження також містить експериментальний аналіз впливу різних алгоритмів попередньої обробки наборів даних на ефективність виявлення БПЛА. Результати показують, що цей метод перевершує інші реалізації з використанням єдиного мікрофона, досягаючи ефективного виявлення звуків дронів на відстані до 135 метрів. В свою чергу автори дослідження [13] порівняли використання різних методів вилучення ознак з звукових сигналів дронів з корисним навантаженням для класифікації алгоритмами машинного навчання. П'ять окремих ознак і їх комбінація використовувались для навчання алгоритмів SVM та методу К-найближчий сусідів (KNN). Результати показали, що комбінація ознак перевершує кожен з них окремо, з набагато вищими показниками точності.

Однією з проблем у дослідженнях даного напрямку є обмежена кількість наборів даних для тренування моделі. Автори робіт, пропонують різноманітні методи масштабування та збільшення варіативності наборів даних для вирішення проблеми обмеженої кількості акустичних даних. Автори роботи [14] дослідили техніки масштабування наборів даних, включаючи зміни висоти тону та гармонійні спотворення для створення більш різноманітних тренувальних даних на основі існуючих. Їх дослідження показало, що такі методи збагачення значно покращили стійкість класифікаторів до зміни акустичних умов, підвищуючи точність і адаптивність системи для роботи в реальних умовах. У [15] автори використовували генеративні змагальні мережі для розширення свого набору даних, що дозволило підвищити точність згорткових нейронних мереж для різних типів БПЛА. Стаття

демонструє, як збагачення даних може допомогти у вирішенні завдань виявлення дронів.

Ряд досліджень зосереджений на розробці спеціальних наборів даних для покращення продуктивності моделей у різних умовах експлуатації. Автори [16] застосували загальнодоступні набори даних для їх аналізу за допомогою алгоритмів машинного навчання. Досягнувши середнього F-бала 0,92 завдяки алгоритмам випадкового лісу та багат шарового перцепетрону, у статті підкреслюється економічність та ефективність рішень з використанням машинного навчання для задачі виявлення дронів за аналізом аудіо-даних у реальному часі. У роботі [17] виконали обчислення для виявлення дронів за допомогою імпульсних нейронних мереж, досягнувши точності виявлення 97.13% та ідентифікації 93.25% при обмежених ресурсах, що робить цей підхід придатним для ефективного використання у випадках економії обчислювальних потужностей.

У дослідженні [18] використали архітектури моделей-трансформерів для класифікації звуків дронів шляхом виявлення акустичних аномалій у їх роботі. Цей підхід продемонстрував високу чутливість до мінімальних змін звукових характеристик і можливість масштабування в мережах спостереження. Автори роботи [19] протестували підхід з використанням ансамблю з моделей CNN, RNN та CRNN і виявили, що такі методи ансамблів значно покращили точність класифікації за рахунок об'єднання виходів різних архітектур моделей. Найкраща отримувана точність у дослідженні становить 94.7% з використанням ансамблю декількох моделей. Застосування згортково-рекурентних мереж в контексті виявлення БПЛА є предметом дослідження ще декількох проаналізованих статей. Так в роботі [20] для виявлення та розпізнавання дронів у середовищах з високим електромагнітними перешкодами запропоновано новий підхід, який використовує згортково-рекурентну мережу для аналізу MFCC. Для демодуляції акустичних сигналів різних дронів із спектрів у дослідженні використовується швидкий алгоритм на основі білого світла, а сам набір даних акустичних сигналів дронів був зібраний за допомогою власного виготовленого акустичного датчика. Дослідження [21] пропонує простий акустичний метод для класифікації БПЛА на основі архітектури легкої згорткової мережі. В

якості вхідних даних, автори дослідження використовували власний набір даних із звуків 10 різноманітних типів БПЛА, поданих у вигляді спектрограм. Після навчання модель досягла середньої точності 93,33%, а також продемонструвала можливість використання на пристроях з обмеженими обчислювальними ресурсами. Схожа модель легкої згорткової мережі була використана в дослідженні [22] для виявлення дронів серед інших звуків, показуючи високу ефективність у середовищах із високою щільністю шуму. Натомість, у статті [23] досліджується ефективність рекурентних нейронних мереж для розпізнавання звуків дронів у реальному часі на основі Мел-спектрограм. Оцінюються моделі SimpleRNN, LSTM, BiLSTM і GRU, причому модель GRU показала найкращі результати: 98% точності для визначення станів завантаженості дронів і 99% для фонового шуму. Це підкреслює переваги GRU над іншими мережами для точного звукового моніторингу БПЛА.

Загалом, ці дослідження підкреслюють ефективність використання глибокого навчання у завданнях акустичного виявлення дронів. Різні архітектури, такі як CNN, RNN і трансформери, добре підходять для виділення характерних ознак звукових сигналів дронів і допомагають адаптуватися до різних акустичних умов. Ансамблеві підходи та збагачення даних за допомогою генеративних мереж також є перспективними напрямками, що дозволяють збільшити надійність і точність акустичних систем для виявлення БПЛА.

У сучасних умовах питання виявлення безпілотних літальних апаратів за допомогою радіолокаційних технологій набуло великого значення. Як зазначалось вище, широкий спектр досліджень у цій галузі зосереджений на застосуванні технологій машинного та глибокого навчання для підвищення точності та швидкості виявлення БПЛА. Багато досліджень останніх років використовували згорткові нейронні мережі, мережі довгої-короткочасної пам'яті та моделі трансформери.

Так у роботі [24], автори запропонували новітню модель DoreNet – це модель що реалізує архітектуру згорткової нейронної мережі, розроблена для аналізу даних радарів представлених у форматі матриць відношення дальність-Доплер. Використовуючи характерні патерни руху БПЛА, модель досягла точності 92,5% в умовах міста з високим рівнем перешкод. DoreNet демонструє ефективність у

середовищах з шумом у радіолокаційних даних, забезпечуючи більш високу точність у порівнянні з традиційними методами машинного навчання. Модель особливо корисна для виявлення БПЛА, які можуть залишатися непоміченими через малий розмір. Інше дослідження [25] зосереджується на використанні даних радіолокаційної сигнатури для класифікації БПЛА, зокрема, в статті проводиться порівняння традиційних методів машинного навчання та глибокого навчання. За результатами експериментів, моделі на основі глибокого навчання, зокрема згорткові нейронні мережі, показали вищу точність при класифікації малих БПЛА. Модель забезпечила точність 85-90% для різних наборів даних, що підкреслює потенціал глибокого навчання для точного виявлення в умовах, коли традиційні методи виявляються менш ефективними. Дослідження [26] демонструє, як об'єднання поляриметричних даних з Доплерівськими зсувами дозволяє краще розпізнавати дрони. Завдяки цьому підходу, дослідники досягли точності 88% у відокремленні дронів від інших об'єктів, таких як птахи. Такий підхід є перспективним для моніторингу повітряного простору, де звичайні радарні методи не завжди дозволяють чітко розрізнити об'єкти. У роботі [27] використовується попередньо натренована модель ResNet-18, адаптована для виявлення БПЛА за допомогою спектрограми радарного сигналу. Ця модель, оптимізована для швидкого навчання, досягла точності 83,39% за час навчання 242 секунди, що дозволяє зменшити час на навчання порівняно з базовою версією ResNet-18. Автори акцентують увагу на ефективності використання попередньо навчених моделей, таких як ResNet, для аналізу візуального представлення даних радару. В свою чергу у роботі [28] описано трьох-етапну систему для виявлення безпілотних літальних апаратів на основі радіолокаційних даних, яка дозволяє краще обробляти дані зі складним розподілом. Перший етап включає кластеризацію для відсіву аномальних даних і упорядкування складного розподілу сигналів, що допомагає у виявленні потенційних викидів. Другий етап здійснює аналіз надійності для подолання проблем з високою розмірністю і малим обсягом навчальних даних. Третій етап об'єднує інформацію з кластерів різної розмірності для точнішого розпізнавання об'єктів, що робить цей підхід більш ефективним, ніж багато сучасних методів, за результатами тестування на великому наборі даних.

Частина досліджень зосереджені на комбінованому використанні різних представлень радіолокаційного сигналу в якості вхідних даних. Так у статті [29] розглянуто підхід до класифікації БПЛА, заснований на глибокому навчанні з об'єднанням багатовимірних радіолокаційних даних, таких як мікро-Доплерівські сигнатури та інші параметри сигналу. Автори використовують модель глибокого навчання, що дозволяє поліпшити точність класифікації до 92%. Таке об'єднання даних сприяє підвищенню надійності системи в різних середовищах, дозволяючи відокремлювати дрони від інших аеродинамічних об'єктів з високою точністю. В свою чергу в статті [30] представлено використання комплексних даних для тренування CNN для підвищення точності виявлення БПЛА. Модель зберігає як амплітудну, так і фазову інформацію радарних сигналів, що дозволяє досягти більш точного відокремлення об'єктів з різними сигнатурами. Це особливо корисно для малих БПЛА, які мають слабку радіолокаційну відмітку. Використання фазової інформації дозволило підвищити точність на 7%.

Автори роботи [31] розробили модель DIAT-RadSATNet з цільовою задачею виявлення БПЛА на основі мікро-Доплерівських сигнатур. Дослідження показало, що ця архітектура є надзвичайно ефективною для розпізнавання різних типів дронів, зокрема завдяки чіткому захопленню мікро-Доплерівських зсувів. Модель досягла точності понад 90% для різних швидкостей та умов польоту, що дозволяє ефективно використовувати її для моніторингу в реальному часі. Завдяки оптимізації структури, DIAT-RadSATNet забезпечує швидкий аналіз та точність, що є важливим для безпеки повітряного простору. Результати дослідження демонструють перспективність моделі для класифікації різних типів БПЛА.

Автори іншого дослідження [32] пропонують використанням LSTM для класифікації БПЛА на основі мікро-Доплерівських сигнатур та досягли значних результатів. Використання LSTM дозволяє моделі аналізувати часові залежності, що є корисним для розпізнавання рухомих об'єктів, таких як дрони. Модель досягла точності 89% навіть у середовищах з великою кількістю перешкод, що показує її надійність у реальних умовах. LSTM вдало обробляє динамічні сигнатури, дозволяючи чітко розрізняти БПЛА від птахів та інших рухомих об'єктів. Такий

підхід є перспективним для моніторингу аеропортів та інших критичних об'єктів. Дослідження [33] фокусується на використанні мульти-шляхових мікро-Доплерівських сигнатур для підвищення точності класифікації БПЛА в урбанізованих середовищах. У містах, де сигнали часто відбиваються від будівель, цей ефект може значно змінювати сигнатуру дронів. Модель, розроблена у цьому дослідженні, досягла точності 87%, що робить її надійною для використання в міських умовах. У роботі [34] була представлена модель «Echoformer», що є однією з новітніх моделей, яка використовує архітектуру трансформерів для врахування слабо-залежних взаємодій у радарних даних, що робить її надзвичайно ефективною для виявлення малих БПЛА. Модель досягла точності 94% навіть у середовищах з низьким співвідношенням сигнал-шум, що підтверджує її ефективність у складних умовах. Echoformer може одночасно обробляти великі обсяги даних та виявляти малопомітні об'єкти. Завдяки своїм властивостям, модель підходить для моніторингу як у міських, так і у віддалених регіонах. Автори підкреслюють, що ця архітектура є перспективною для застосування у реальних сценаріях. Інша модель, представлені у статті [35], являє собою реалізацію архітектури, що об'єднує модулі Inception з залишковими з'єднаннями для покращення багаторазового вилучення ознак, що робить її надзвичайно ефективною для виявлення БПЛА. Використання архітектури Inception дозволяє обробляти дані на різних масштабах, що підвищує її здатність виявляти дрібні деталі. Модель досягла точності 91% і продемонструвала високу стабільність навіть за високого рівня шуму. Дослідження [36] адаптує модель YOLO для роботи з радарними даними, що дозволяє швидко виявляти БПЛА в режимі реального часу. Завдяки своїй архітектурі, модель працює на швидкості відеоряду у 25 кадрів на секунду при точності 92%, що робить її корисною для задач в умовах реального часу.

Автори роботи [37] використали комбінації R-PCA і SVM для класифікації малих БПЛА на основі Доплерівських сигнатур. Модель досягла точності 92%, знижуючи рівень шуму в радарних даних та підвищуючи точність в умовах інтенсивного повітряного трафіку. Поєднання R-PCA для обробки сигнатур і SVM для класифікації дозволило ефективно відокремити БПЛА від інших об'єктів, таких

як птахи та інші малі об'єкти. Цей підхід має потенціал для використання у зонах з підвищеним рухом. Результати дослідження підкреслюють ефективність моделі у складних сценаріях роботи.

Також були проаналізовані декілька досліджень, в основі яких лежать експерименти з радарними даними та їх вплив на точність роботи класифікаторів. У роботі [38] використовуються міліметрові хвилі CW радара для одночасного виявлення та класифікації кількох БПЛА. Модель досягла точності 85%, що дозволяє надійно відокремлювати дрони у зонах підвищеної безпеки, де часто одночасно перебуває кілька об'єктів. Аналіз Доплерівських зсувів дозволяє класифікувати кожен БПЛА індивідуально, що є особливо важливим для об'єктів з високим рівнем охорони. Використання CW радара з міліметровими хвилями підвищує точність та деталізацію сигнатур. Дослідження підтверджує, що цей підхід є ефективним для багатозадачного моніторингу. Автори іншого дослідження інше дослідження [39] використовують FMCW радар для одночасної локалізації та класифікації БПЛА, досягаючи точності в 96%. Завдяки інтеграції даних дальності та значень зсувів Доплера, модель забезпечує високу точність і здатність розпізнавати кілька об'єктів. Такий метод підходить для застосування в широкому спектрі середовищ, включаючи складні умови з високою щільністю об'єктів. У статті [40] описується застосування радара з частотно-модульованою безперервною хвилею (FMCW) для виявлення та класифікації безпілотних літальних апаратів. Автори акцентують увагу на перевагах FMCW радару в задачах класифікації дронів.

1.3. Аналіз існуючих моделей глибокого навчання для вирішення задачі виявлення БПЛА за аналізом акустичних та радіолокаційних даних

Вибір архітектури моделі глибокого навчання має критично-важливе значення для вирішення задачі з оптимальними показниками точності та часу роботи моделі. Кожна модель в проаналізованих науково-дослідних роботах характеризується власними сильними сторонами та обмеженнями, що робить її більш підходящою для вирішення конкретних задач на конкретних наборах даних. Під час ухвалення рішення важливо врахувати особливості цільової задачі, доступні обчислювальні ресурси, набори даних та вимоги щодо продуктивності й точності.

CRNN (Convolutional Recurrent Neural Network) [19, 20] у дослідженнях з детекції та ідентифікації дронів демонструє високу точність в обробці аудіосигналів, поєднуючи можливості CNN та RNN. На першому етапі архітектура виконує виділення ознак із вхідного аудіо-сигналу. Для цього сигнал перетворюється у спектрограму (візуальне представлення звуку як відношення амплітуди від часу), що дозволяє CNN знаходити шаблони, які можуть вказувати на наявність БПЛА. Після виділення ознак CNN ці дані передаються у рекурентні шари для обробки часових залежностей. Це особливо важливо для звукових сигналів, які згасають у часі й містять інформацію про зміну частоти. Переваги використання такої архітектури в тому, що вона враховує часові характеристики аудіо-сигналу та може виявляти стабільні паттерни звукових характеристик дрону в змінюваних фонових середовищах, що робить моделі стійкими до появи шумів.

GoogleNet [41]. Використання попередньо натренованої моделі GoogleNet є потужним інструментом для класифікації спектрограм аудіо-даних та сигналів радарів. Замість використання традиційних послідовних згорткових шарів, GoogleNet застосовує Inception-модулі. У кожному такому модулі паралельно використовуються кілька згорток різного розміру (1x1, 3x3, 5x5), що дозволяє мережі виявляти ознаки різної складності. У контексті задачі виявлення БПЛА, малі фільтри (1x1 або 3x3) можуть вилучати локальні особливості, такі як короткочасні, непостійні звуки пропелерів. В свою чергу великі фільтри (наприклад, 5x5) допомагають виявляти

макроструктури у відбитих радіохвилях від дронів. Також, однією з переваг використання цього підходу є реалізація мультимодального аналізу – створення двох потоків обробки для кожного типу даних із об'єднанням на певному шарі мережі для комплексної класифікації.

Yamnet [10]. Yamnet — це попередньо натренована модель від Google для класифікації аудіо-подій, яка особливо корисна для задач розпізнавання звуків, таких як шум пропелерів дронів. Модель використовує т. зв. "глибокі відокремлені згортки", які дозволяють суттєво зменшити кількість параметрів без втрати якості. Вхідний аудіо-сигнал перетворюється в мел-спектрограму, що дозволяє виділяти як короткочасні звукові патерни, так і більш довготривалі ознаки, пов'язані з характеристиками акустичних сигналів БПЛА. Yamnet ефективно справляється з шумом завдяки своїм глибинним згортковим шарам, які можуть фільтрувати фоновий шум і зосереджуватися на специфічних патернах, характерних для дронів. Завдяки простоті архітектури MobileNetV1, що лежить в основі моделі, Yamnet може бути інтегрована навіть у пристрої з обмеженими обчислювальними ресурсами, що робить її особливо корисною для розгортання на мобільних чи інших портативних платформах для реального часу. Також перевагою Yamnet є її гнучкість у використанні для різних типів аудіо-подій завдяки тренуванню на великому датасеті звуків, що дозволяє їй виділяти найбільш значущі ознаки навіть в умовах сильного шуму чи складного фону.

ResNet [27]. ResNet (Residual Network) — це глибока нейронна мережа, яка вирішує проблему згасаючих градієнтів за допомогою залишкових блоків. Основна ідея цих блоків полягає у використанні "пропускних зв'язків", що дозволяють передавати вихідні значення через кілька шарів, обминаючи деякі проміжні шари. Така структура допомагає зберігати важливу інформацію навіть у дуже глибоких мережах і забезпечує високу точність обробки даних, зокрема в умовах складних і шумних вхідних сигналів. Для задачі виявлення БПЛА ResNet використовується для аналізу спектрограм, отриманих з акустичних або радіолокаційних даних, що дозволяє виділяти багаторівневі патерни. Менші згорткові фільтри знаходять локальні ознаки, характерні для специфічних звуків, наприклад, шуму пропелерів

дронів, тоді як більші фільтри виявляють більш глобальні особливості, що корисно для аналізу радіолокаційних сигналів. Залишкові блоки в архітектурі ResNet підвищують її здатність адаптуватися до різних умов оточення та роблять модель стійкою до фонового шуму, що особливо важливо для роботи в реальному часі. ResNet також підтримує масштабування на глибші конфігурації або каскадні структури, що дозволяє інтегрувати різні типи даних, такі як акустичні та радіолокаційні, у вигляді мультимодальних потоків. Це дає можливість моделі ResNet краще ідентифікувати дрони, поєднуючи ключові характеристики з різних джерел сигналів у єдиній системі, що підвищує її загальну точність та надійність у складних акустичних середовищах.

У результаті проведеного аналізу архітектур для виявлення та класифікації дронів, було обрано CRNN як оптимальне рішення завдяки її здатності поєднувати просторову та часову обробку даних. CNN-компонент дозволяє витягувати ключові ознаки з акустичних та радіолокаційних сигналів, тоді як RNN забезпечує аналіз часових залежностей, що критично важливо для динамічних сигналів. Це підвищує точність і стійкість системи навіть в умовах шуму та змінного середовища.

1.4 Постановка задачі.

Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання. Для досягнення поставленої мети потрібно виконати наступні завдання:

- 1) провести аналіз: предметної області для проблеми виявлення БПЛА; існуючих публікацій щодо виявлення БПЛА; існуючих моделей глибокого навчання для виявлення БПЛА;
- 2) вдосконалити метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання;
- 3) визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з іншими відомими підходами.

РОЗДІЛ 2. Вдосконалення методу виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів

Основна мета цього розділу – навести підходи, що були застосовані для вдосконалення існуючої архітектури згортково-рекурентної нейронної мережі, яка використовується для виявлення БПЛА на основі аналізу акустичних сигналів та адаптації даної архітектури для задачі аналізу радіолокаційних даних. Основна робота була зосереджена на покращеннях моделі, що спрямовані на підвищення її здатності до точного розпізнавання ключових особливостей сигналів, зменшення кількості помилкових класифікацій та підвищення загальної ефективності виявлення.

У процесі вдосконалення моделі основна увага приділялась змінам у згорткових і рекурентних шарах, що забезпечують кращу обробку просторових та часових ознак сигналів ознак БПЛА. Окрім того, описано як застосування додаткових повнозв'язних шарів та шарів виключення, сприяє підвищенню стійкості моделі до перенавчання, дозволяючи їй краще адаптуватися до різних умов вхідних даних. Особлива увага була приділена адаптації CRNN моделі для обробки не лише акустичних, а й радіолокаційних сигналів, що вимагає коригування підходів до навчання і налаштування архітектури.

У роботі запропоновані наступні вдосконалення моделі глибокого навчання для задачі, яка розглядається:

- збільшення точності розпізнавання – покращити здатність моделі виділяти характерні риси сигналів БПЛА за рахунок поглиблення архітектури згорткових шарів нейронної мережі;
- зниження кількості помилкових класифікацій - мінімізувати кількість помилкових спрацьовувань, що є критично важливим для роботи системи в реальних умовах за рахунок двонаправлених рекурентних блоків;
- підвищення якості роботи підходу для різнорідних даних – забезпечити точність роботи моделі при обробці варіативних сигналів для збільшення можливих сценаріїв застосування архітектур такого виду за рахунок масштабування повнозв'язних шарів мережі.

2.1 Модель глибокого навчання для виявлення БПЛА.

У цьому підрозділі розглядається початкова архітектура згортково-рекурентної нейронної мережі, яка використовувалася для виявлення БПЛА за акустичними сигналами у дослідженні [19]. Модель продемонструвала високі метрики ефективності, при тому що є реалізацією базової архітектури згортково-рекурентних мереж, таким чином вона є ідеальним прикладом використання підходу в задачі виявлення дронів.

2.1.1. Огляд архітектури згортково-рекурентних мереж.

Архітектура CRNN поєднує ключові компоненти згорткових і рекурентних нейронних мереж, що дозволяє ефективно працювати з послідовними даними, такими як електромагнітні та звукові хвилі. Ця структура добре підходить для задачі виявлення БПЛА, де необхідно враховувати як просторові, так і часові залежності в даних.

Згорткові шари служать для виділення ознак із зображень – візуальних представлень даних за допомогою фільтрів. Кожен згортковий шар складається з набору фільтрів, які виконують математичну операцію згортки – скалярний добуток між вхідними даними, які зазвичай подаються у форматі векторів або матриць, і фільтром заданої розмірності. Фільтр пересувається по вхідному вектору або матриці і за допомогою операції згортки формує карту ознак. Шляхом переміщення кожен фільтр створює власну карту ознак. У контексті обробки акустичних сигналів, звуковий сигнал можна перетворити у спектрограму, де кожна точка представляє інтенсивність певної частоти у певний момент часу. Застосування шару згортки дозволяє моделі знаходити локальні особливості (на кшталт частотних коливань), незалежно від їх розташування в просторі спектрограми, що сприяє ефективному виділенню ознак.

Рекурентні шари, такі як LSTM, спеціально розроблені для обробки послідовностей даних і враховують часові залежності між послідовними елементами. В обробці сигналів це дозволяє моделі пам'ятати послідовність змін частот та інтенсивності, таким чином модель може відстежувати характерні варіації в спектрі, що вказують на присутність БПЛА. LSTM складається з комірок, що зберігають та передають інформацію про попередні стани, що дозволяє обробляти довгі послідовності, зменшуючи вплив короткочасної пам'яті, яка характерна для звичайних рекурентних мереж.

2.1.2. Архітектура моделі для аналізу акустичних сигналів БПЛА.

Архітектура CRNN (Рис.2.1), запропонована для аналізу акустичних сигналів у дослідженні [19], є базовою моделлю, яка демонструє здатність CRNN виявляти БПЛА за допомогою обробки спектрограм аудіо-даних.

У даній архітектурі використовується кілька ключових компонентів, кожен з яких має свою роль у виділенні та класифікації акустичного сигналу БПЛА.




Рис.2.1. Архітектура базової моделі CRNN.

Першим основним компонентом моделі є згортковий шар з 16 фільтрами розміром 5x5. Цей шар відповідає за початкове виділення ознак у спектрограмі, таких як специфічні частотні піки або зміна інтенсивності на певних діапазонах частот. Після згорткового шару застосовується шар пулінгу, який виконує підвибірку розміром 5x5 з кроком 2x2. Цей шар зменшує розмірність вхідних даних, зберігаючи найбільш важливі ознаки. Підвибірка допомагає зменшити обчислювальну

складність моделі та підвищує її стійкість до змін масштабу, що є важливим для розпізнавання БПЛА незалежно від інтенсивності сигналу. Далі шар нормалізації стабілізує процес навчання, нормалізуючи вихідні дані попереднього шару. Це дозволяє прискорити збіжність моделі, зменшуючи чутливість до початкових параметрів та забезпечуючи стабільне навчання навіть при великій кількості епох. Нормалізація є корисною для підвищення точності моделі, особливо при роботі із зашумленими даними. Після блоку згортки модель переформатовує вихідні дані для подальшої обробки рекурентним шаром. Це необхідно, оскільки в даному випадку, згорткові шари створюють двовимірні карти ознак, а рекурентний шар потребує послідовних векторів значень. Переформатування забезпечує правильну подачу даних у рекурентний блок. Модель використовує один шар LSTM з 32 нейронами. Цей шар обробляє вхідні ознаки, зберігаючи інформацію про попередні значення. LSTM особливо важливий для врахування динамічних змін у спектрограмі, таких як коливання частоти, що можуть бути характерними для звуку БПЛА. Часова обробка дає змогу моделі краще розрізняти патерни та забезпечує кращу адаптацію до особливостей сигналу. Після рекурентного блоку модель використовує згладжувальний шар (flatten) для перетворення багатовимірних вихідних даних в одновимірний вектор, що дозволяє подати його на повнозв'язний шар. В даній архітектурі використаний шар з 32 нейронами для обробки ознак і формування остаточного прогнозу. Щоб запобігти перенавчанню, використовується шар вилучення із значенням ймовірністю 0.6, для відсіювання частки нейронів в процесі навчання, що призводить до зменшення розміру моделі. Це є одним із методів регуляризації, що допомагає запобігти перенавчанню моделі. Шар вилучення сприяє узагальненню моделі, що є важливим при роботі з даними, які можуть містити фонові шуми та варіації. Останнім компонентом моделі є один нейрон, що за допомогою функції активації softmax (2.1), перетворює вихід моделі у ймовірності для кожного класу — наявність або відсутність БПЛА.

$$f(z)_i = \frac{e^{z_i}}{\sum_i e^{z_i}} \quad (2.1)$$

Використана в дослідженні [19] модель, є простою, що надає можливість використовувати її на пристроях з невеликими обчислювальними ресурсами, але незважаючи на досить високі показники точності що були виявлені у дослідженні, можна висунути припущення про певні обмеження моделі у випадку аналізу більш комплексних аудіо-даних та роботи в реальних умовах.

2.2 Вдосконалення моделі для виявлення БПЛА

2.2.1 Огляд цілей та вимог до покращень.

Початкова архітектура CRNN моделі для виявлення безпілотних літальних апаратів за акустичними сигналами була розроблена для базової обробки послідовних даних із використанням згорткових і рекурентних шарів. Однак, ця проста архітектура, попри свою ефективність у базових задачах, має кілька обмежень, які заважають досягти високої точності та стійкості в умовах реальних акустичних сигналів. Ці обмеження обумовлюють потребу в покращеннях для забезпечення більш надійного та точного розпізнавання сигналів БПЛА, особливо в складних умовах, де можуть бути присутні значні шумові перешкоди.

Одним із можливих обмежень початкової архітектури є недостатня здатність виділяти складні ознаки сигналу. Використання всього 16 фільтрів у згорткових шарах значно обмежує можливості моделі щодо розпізнавання специфічних характеристик, які можуть відрізняти сигнали БПЛА від інших джерел шуму. При наявності таких низьких параметрів, модель ризикує втратити важливу інформацію про деталі звукових патернів, що ускладнює завдання класифікації. Збільшення кількості фільтрів та додавання нових згорткових блоків дозволить моделі краще аналізувати особливості сигналів на різних рівнях абстракції.

Ще одним критичним обмеженням є недостатня глибина рекурентної частини архітектури. Початкова модель використовує лише один шар LSTM із 32 нейронами, що є мінімальним для обробки часових залежностей, але недостатнім для захоплення складних патернів у послідовностях сигналів. Такий підхід може не дозволити моделі

ефективно розпізнавати закономірності у тривалих або взаємозалежних послідовностях, що характерно для акустичних сигналів дронів у реальних умовах експлуатації.

Крім того, модель має обмежену здатність до регуляризації, що робить її вразливою до перенавчання. Початкова архітектура містить лише один шар Dropout, який лише частково знижує ризик перенавчання. Проте для забезпечення стійкості при обробці великих більших обсягів даних або при використанні в умовах шуму необхідно додатково вдосконалити механізми регуляризації. Це дозволить моделі краще узагальнювати інформацію про сигнали, що є критичним для роботи з непередбачуваними даними або у випадках, коли вхідний сигнал значно відрізняється від даних, на яких модель була навчена.

Основними цілями покращень є підвищення точності, здатності моделі до узагальнення і забезпечення гнучкості для аналізу різних типів сигналів БПЛА. Ці вдосконалення дозволять покращеній моделі бути більш надійною у реальних умовах та забезпечать вищу точність і надійність виявлення БПЛА, навіть при наявності складних шумових перешкод.

2.2.2 Збільшення глибини згорткових шарів та зміна параметрів.

Як зазначалось, вище з метою покращення ефективності моделі для виявлення БПЛА за акустичними сигналами було обрано стратегію збільшення глибини згорткових шарів та зміни ключових параметрів, таких як кількість фільтрів і розмір ядра. Ці покращення сприяють більш якісному виділенню характеристик аудіо-сигналів і підвищують точність моделі при розпізнаванні специфічних ознак звуку дронів у складних акустичних умовах.

Однією з ключових змін у покращеній архітектурі є збільшення кількості фільтрів у згорткових шарах. У початковій архітектурі використовувалося лише 16 фільтрів у першому згортковому шарі, що є мінімальним значенням для обробки основних ознак сигналу, але недостатнім для виділення складніших патернів, які

можуть міститися у сигналах БПЛА. Таким чином, у вдосконаленнях архітектури вбуло прийнято рішення збільшити кількість фільтрів до 32, 64 і 128 (Рис.2.2) у послідовних згорткових шарах.

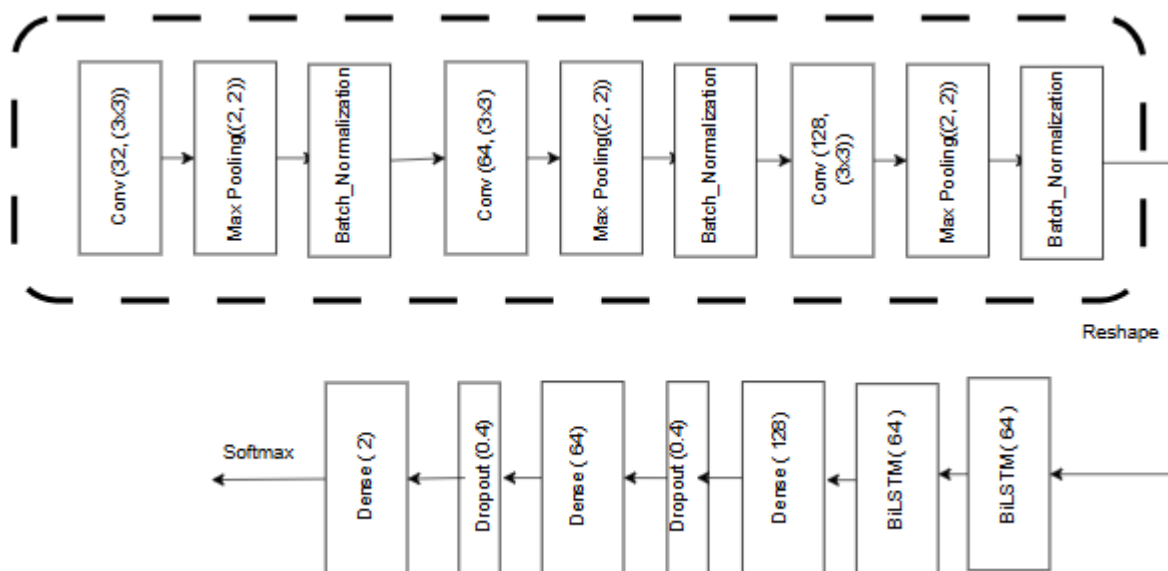


Рис.2.2. Вдосконалення архітектура CRNN (поглиблення шарів згортки).

Збільшення кількості фільтрів дозволяє моделі захоплювати ширший спектр ознак, оскільки кожен фільтр може виявляти різні аспекти сигналу. Наприклад, фільтри початкових шарів можуть фокусуватися на базових характеристиках, таких як низькочастотні варіації та ніші особливості спектру, тоді як глибші фільтри можуть аналізувати більш специфічні ознаки, такі як періодичні зміни, характерні для пропелерів. Збільшення кількості фільтрів також сприяє підвищенню гнучкості моделі, дозволяючи їй краще адаптуватися до сигналів із різними характеристиками, зокрема до шумних або зашумлених даних, що є типовим для реальних умов використання. Однак варто зауважити, що збільшення кількості фільтрів призводить до зростання обчислювальних витрат, оскільки кожен новий фільтр вимагає додаткових ресурсів для обробки. Тому збільшення кількості фільтрів має бути збалансованим із вимогами до обчислювальної ефективності. Вибір значень зроблено повинен забезпечує оптимальний баланс між точністю і швидкістю роботи моделі для задачі виявлення БПЛА.

Ще однією суттєвою зміною в архітектурі стало зменшення розміру ядра з 5×5 до 3×3 . У початковій моделі розмір ядра 5×5 забезпечував достатню можливість виділення основних особливостей, однак цей підхід може виявитися занадто грубим для виявлення дрібних деталей у сигналі. Використання ядра меншого розміру, такого як 3×3 , дозволяє моделі краще захоплювати локальні патерни та виявляти тонкі зміни у звукових хвилях, що можуть бути важливими для розпізнавання сигналів БПЛА. Малі ядра також мають додаткову перевагу, оскільки вони дозволяють проводити глибший аналіз за меншого обчислювального навантаження, ніж великі ядра. Розмір 3×3 є стандартним у багатьох сучасних згорткових нейронних мережах і дозволяє захоплювати більш детальні аспекти сигналу без значного збільшення кількості параметрів. Крім того, використання меншого ядра дозволяє моделі ефективно виявляти високочастотні компоненти у сигналі, знижувати вплив загальних амплітудних коливань на сусідні ділянки сигналу. Це дозволяє мережі краще ігнорувати навколишні шуми та незначні варіації, що не мають відношення до основного акустичного сигналу дронів. Загалом перевага менших ядер також полягає у здатності краще працювати з шумом. У випадку великого ядра, таке як 5×5 , модель може виявляти занадто великі області сигналу, що ускладнює виділення дрібних змін у звуковому спектрі, які можуть свідчити про наявність БПЛА. Натомість 3×3 ядра дозволяють моделі обробляти локальні ділянки сигналу більш детально, що позитивно позначається на точності класифікації.

2.2.3. Використання двонаправлених LSTM для покращення обробки послідовностей.

У задачах аналізу послідовних даних, таких як обробка акустичних сигналів для виявлення БПЛА, архітектура двонаправлених мереж довгої короткочасної пам'яті (BiLSTM) забезпечує низку переваг над класичними односпрямованими рекурентними мережами. BiLSTM, комбінуючи властивості стандартної довготривалої короткострокової пам'яті з можливістю обробки послідовності в обох

напрямок, дозволяє враховувати контекст як попередніх, так і наступних елементів у часових рядах. Це значно покращує здатність до виявлення шаблонів, які можуть проявлятися як на початку, так і наприкінці послідовності, що особливо важливо для задач, де віддалені елементи сигналу можуть мати взаємозв'язок.

BiLSTM складається з двох паралельних LSTM-шарів, які обробляють ту саму послідовність, але в різних напрямках:

- Прямий LSTM-шар — обробляє вхідні дані від початку до кінця послідовності, створюючи приховані стани, що ґрунтуються на інформації, отриманій до поточного кроку часу. Прямий шар дозволяє моделі мати контекст у напрямку від попередніх елементів до поточних.
- Зворотний LSTM-шар — обробляє ту ж саму послідовність, але в протилежному напрямку, від кінця до початку. Це дозволяє зворотному шару зберігати інформацію про майбутні значення у послідовності, що є корисним для більш точного розпізнавання патернів, які стають зрозумілими лише в контексті майбутніх елементів. Кожен із цих шарів працює незалежно, маючи свої параметри і внутрішню пам'ять.

На виході мережі об'єднуються результати обох шарів, зокрема приховані стани (наприклад, за допомогою конкатенації або усереднення), що формує повний прихований стан для кожного елемента послідовності. Таке об'єднання допомагає краще врахувати як попередній, так і наступний контексти для більш глибокого розуміння патернів і зв'язків у послідовності.

BiLSTM використовує базові елементи LSTM-комірки, кожна з яких складається з:

- Запам'ятовуюча комірка. Це головна ланка пам'яті в BiLSTM, яка зберігає інформацію протягом усієї послідовності. Вона являє собою вектор пам'яті і працює як потік, що переносить інформацію крізь мережу, дозволяючи моделі зберігати важливі особливості, не залежно від їхньої віддаленості у послідовності. Саме цей компонент дозволяє BiLSTM захоплювати як короткострокові, так і довгострокові залежності, що має важливе значення у

складних задачах обробки акустичних сигналів БПЛА, де важливо не втратити значущі патерни.

- Шлюз забуття – контролює, яку інформацію слід зберегти, а яку відкинути на кожному кроці послідовності. Шлюз функціонує на основі поєднання вхідного вектору значень та значень прихованого стану. Після цього за допомогою функції активації сигмоїд значення від 0 до 1, що визначає яку частину попереднього вектору значень потрібно зберегти, де 1 означає збереження інформації, а 0 — повне її відкидання. Це дозволяє BiLSTM оптимально управляти пам'яттю, зберігаючи важливі аспекти сигналу і зменшуючи ефект "забруднення" через непотрібні дані.
- Вхідний шлюз. Вхідний шлюз визначає, яку нову інформацію додати до запам'ятовуючої комірки. Спочатку, за допомогою функції активації сигмоїд, визначається, які значення слід додати, а гіперболічна тангенс-функція масштабує вхідні дані для покращення диференціації важливих аспектів. Це додає нову інформацію до комірки, оновлюючи довготривалу пам'ять.
- Вихідний шлюз. Вихідний шлюз обчислює значення, яке буде передано на наступний крок або на вихідний шар. Він працює подібно до інших шлюзів, використовуючи сигмоїд для обчислення відповідного значення. На цьому етапі об'єднаний контекст з обох напрямків зберігається, що дозволяє моделі приймати рішення на основі як минулої, так і майбутньої інформації.

Приклад архітектури блоку BiLSTM наведений на рисунку 2.3.

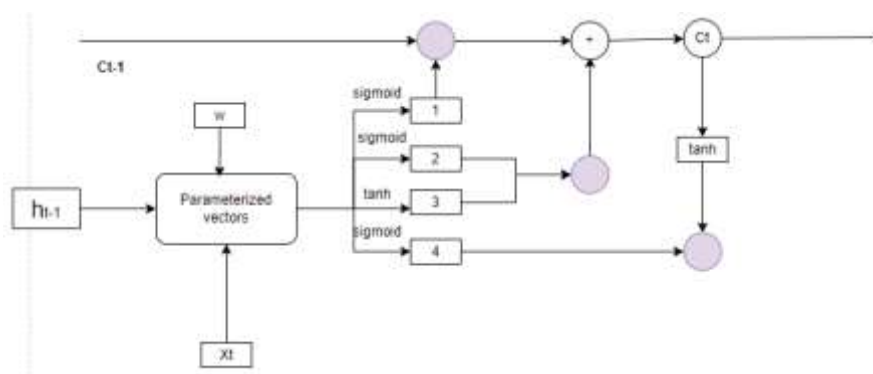


Рис.2.3 Архітектура блоку BiLSTM.

Загалом роботу мережі BiLSTM можна описати у декілька кроків. На вхід моделі подається вхідний вектор даних x^t для кожного елемента послідовності, а також приховані стани з попереднього кроку для прямого та зворотнього шарів LSTM. Кожен шар має власний прихований стан: h_{t-1} для прямого шару та h_{t+1} для зворотнього шару. Це дозволяє зберігати і передавати інформацію окремо для двох напрямків. На основі вхідного вектора даних x^t і прихованих станів h_{t-1} і h_{t+1} , обчислюються значення для кожного з LSTM-шарів окремо. Для цього проводиться множення вхідного вектора на відповідні матриці вагів для прямого та зворотнього шарів. Після цього обчислені вектори проходять через функції активації (сигмоїдальну і гіперболічну тангенс-функції), що дозволяє моделі навчитися виділяти найбільш значущі ознаки у двох напрямках. Після обчислення вхідних і вихідних векторів для кожного напрямку, знаходиться поточний вектор пам'яті для прямої та зворотної LSTM. Це відбувається шляхом комбінації поточного вхідного вектору з вектором пам'яті попереднього кроку (для прямого шару c_{t-1} та для зворотного шару c_{t+1}). Таким чином, кожен напрямок підтримує власну довготривалу пам'ять, що містить інформацію про попередні та наступні елементи відповідно. Після оновлення векторів пам'яті для обох напрямків, обчислюється остаточний прихований стан для поточного елемента послідовності. Це робиться шляхом об'єднання прихованих станів обох напрямків через конкатенацію або усереднення, що формує єдиний вихідний вектор. Цей комбінований прихований стан подається на наступний шар або використовується для подальшої обробки, наприклад, класифікації.

Бідирекційні LSTM мають значні переваги у задачах, де критичну роль відіграють шаблони в послідовності сигналу, наприклад, при класифікації та аналізі звуків. Завдяки здатності обробляти послідовність у двох напрямках, BiLSTM можуть захоплювати інформацію як із попередніх, так і з майбутніх точок послідовності. Це дозволяє моделі точніше розпізнавати важливі деталі та залежності у сигналі, які можуть проявлятися в різних частинах послідовності. Для сигналів БПЛА, які часто містять складні та нерегулярні варіації частоти та амплітуди, двобічна обробка дозволяє моделі ефективніше виділяти шаблони, навіть якщо вони є слабко

вираженими або перемішаними з іншими шумами. Наприклад, характерні коливання частоти або особливості звуку пропелерів БПЛА можуть проявлятися як на початку, так і наприкінці послідовності. Використання BiLSTM допомагає враховувати ці особливості, що підвищує точність класифікації, знижує чутливість моделі до шумів і забезпечує краще виділення специфічних залежностей.

Для підвищення точності виявлення акустичних сигналів БПЛА, у моделі було використано два послідовні BiLSTM-шари з 64 нейронами в кожному (Рис.2.4). Це дозволяє створити більш детальну модель даних, що враховує складні особливості сигналів у часових рядах. Перший

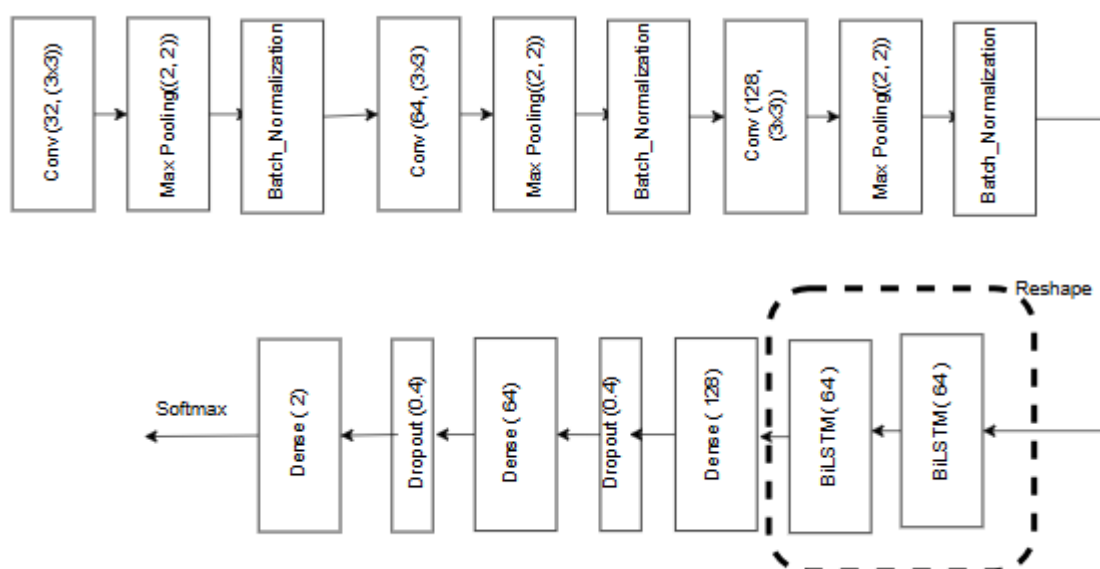


Рис.2.4. Вдосконалена архітектура CRNN (використання BiLSTM блоків).

BiLSTM-шар виділяє базові патерни сигналу, забезпечуючи фундаментальне представлення часової структури та частотних змін, тоді як другий шар деталізує і поглиблює цю інформацію, дозволяючи виявляти ще складніші взаємозв'язки у сигналі. Вибір 64 нейронів у кожному шарі є обґрунтованим компромісом між продуктивністю і обчислювальною складністю. Більша кількість нейронів могла б призвести до значного збільшення обчислювальних витрат, тоді як менша кількість могла б знизити здатність моделі до виявлення важливих особливостей. Використання двох шарів підвищує ефективність вилучення ознак, оскільки

додатковий BiLSTM-шар дозволяє моделі краще адаптуватися до різних акустичних патернів, пов'язаних з БПЛА, та покращує стійкість до зовнішніх шумів і перешкод.

2.2.4. Додаткові повнозв'язні та шари виключення для стабілізації та вдосконалення класифікації.

Використання додаткових шарів виключення у моделі (Рис.2.5) відіграє критичну роль у покращенні стабільності навчання та підвищенні ефективності класифікації. Кожен з цих шарів має своє значення в структурі моделі, особливо для роботи з великими наборами даних і зменшення ризику перенавчання.

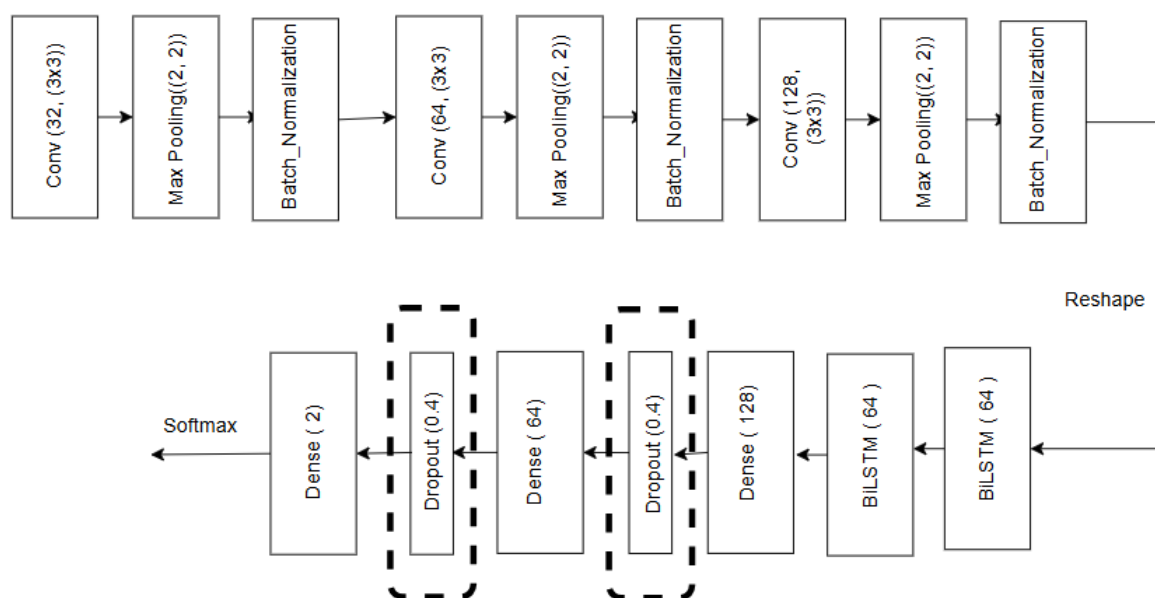


Рис.2.5. Вдосконалена архітектура CRNN (додаткові шари виключення).

Шар виключення (англ. Dropout) — це метод регуляризації, що використовується для зменшення можливості перенавчання нейронних мереж. Суть його роботи полягає у випадковому вимкненні певної частки нейронів під час навчання. Кожен шар виключення відключає випадковий набір нейронів на кожній ітерації, що змушує мережу адаптуватися до різноманітних комбінацій активних нейронів, підвищуючи її здатність до узагальнення. У задачах виявлення БПЛА, де акустичні сигнали можуть значно варіюватися в залежності від типу БПЛА та через

наявність різних шумів, стабільність і здатність до узагальнення є надзвичайно важливими характеристиками моделі. Також, у випадках, коли модель має доступ до великої кількості даних, з'являється ризик перенавчання, особливо в складних мережах з багатьма параметрами. Шари виключення зменшують цей ризик, примушуючи модель розвивати більш узагальнені властивості. Зокрема, кожен додатковий шар знижує залежність моделі від індивідуальних нейронів, що підвищує її здатність адаптуватися до нових даних. Також ці шари стабілізують процес навчання, оскільки зменшують ризик переобладнання до певних шаблонів у великих обсягах даних. Для виявлення БПЛА на основі акустичних сигналів, де характеристики сигналів можуть відрізнятися залежно від типу дрону, дистанції, фізичних перешкод на шляху сигналу, шар виключення допомагає моделі зосередитися на загальних, більш значущих ознаках, а не на випадкових варіаціях даних.

Повнозв'язні (або щільні, англ. Dense) шари є важливою частиною будь-якої нейронної мережі, оскільки вони дозволяють моделі перетворювати виділені ознаки у векторний простір для ефективної класифікації. Додавання двох додаткових Dense-шарів із 128 і 64 нейронами (Рис.2.6) на останніх етапах обробки класифікації сприяє створенню більш детального представлення вхідних даних. Такі шари забезпечують перетворення складних ознак на остаточний вектор для класифікації, покращуючи здатність моделі розпізнавати й класифікувати звукові патерни з високою точністю. Вихід моделі є аналогічним до початкової архітектури.

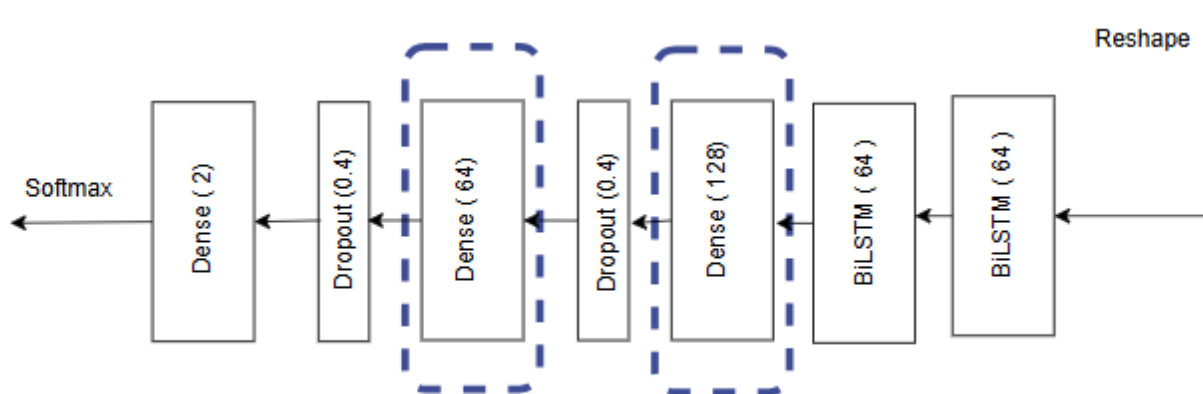


Рис.2.6. Вдосконалення архітектури CRNN (масштабування повнозв'язних шарів).

2.2.5. Модифікація моделі для роботи з радіолокаційними даними.

Для виявлення безпілотних літальних апаратів за допомогою радіолокаційних сигналів важливо розуміти специфіку даних, що надходять від радіолокаційної системи, яка визначає параметри рухомих об'єктів. Радіолокаційне виявлення БПЛА базується на відображенні сигналів, що генеруються їхньою поверхнею, з можливістю аналізу характеристик, таких як частотні зсуви, що виникають через ефект Доплера, а також відстань до об'єкта. Типовий радіолокаційний сигнал містить низку ключових параметрів: відстань до об'єкта, швидкість, відбиті сигнали з частотним зміщенням, які дозволяють створювати «портрет» рухомого об'єкта.

У дослідженні використовується публічно доступний датасет з радіолокаційними сигналами, де кожний елемент представлений у вигляді матриці розміром 11×61 , де ряди відповідають значенням відстані до об'єкта, колонки — доплерівським частотам, а значення — інтенсивності сигналу в децибелах. Ці матриці містять деталі про об'єкт, що перебуває у полі зору радару, та формуються після цифрової обробки сигналів. Після попередньої обробки, матриці перетворюють у зображення у форматі двовимірних доплерівських спектрів (Рис 2.7), які містять сигнали з різних класів об'єктів.




Рис.2.7. Візуальне подання матриці відстань-Доплер [42].

Адаптація CRNN-моделі для роботи з радіолокаційними даними потребує зміни архітектури згорткових шарів (Рис.2.8) для оптимізації виділення просторових особливостей у доплерівських спектрах.

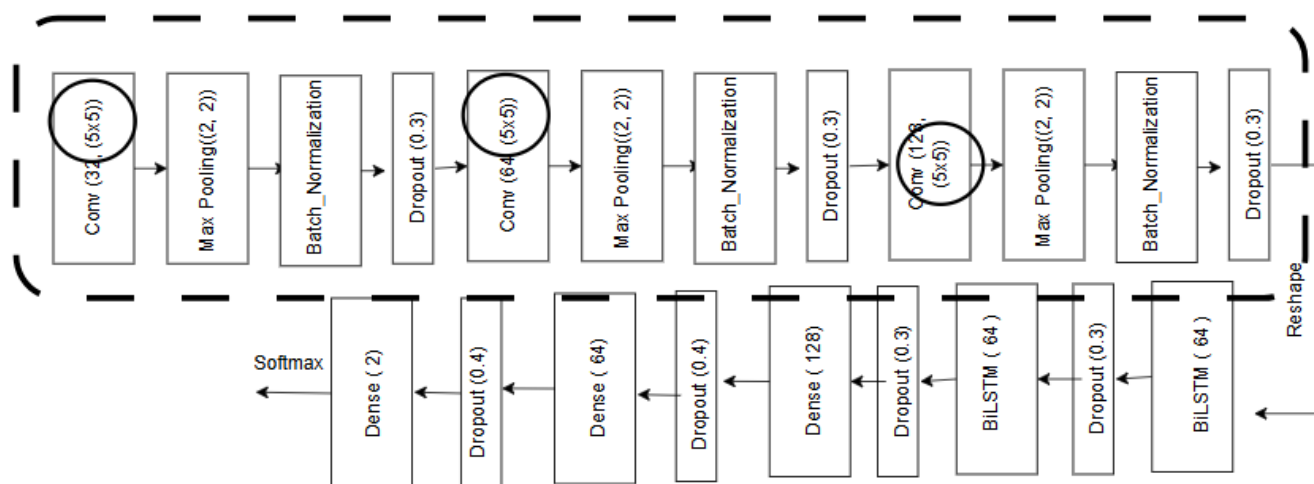


Рис.2.8. Модифікована архітектура CRNN для аналізу даних радару (зміна блоку згортки).

Основною задачею згорткових шарів є виявлення патернів, які зберігають просторову інформацію, зокрема структурні деталі доплерівських відбиттів, що можуть бути характерними для певного типу об'єктів, як-от БПЛА. Щоб краще адаптуватися до специфіки радіолокаційних сигналів, у CRNN-модель були додані згорткові шари з більшими розмірами фільтрів. Використання ширших фільтрів, таких як 5x5 (Рис.2.8), дозволяє виділити більш великі структури та виявити просторові патерни, що можуть бути непомітні при використанні менших фільтрів, як у випадку обробки акустичних сигналів. Більші розміри фільтрів допомагають уловити макропатерни у доплерівському спектрі, що містить просторові зміни, пов'язані з напрямком та швидкістю руху об'єкта. Для подальшої стабілізації обчислювального процесу у моделі використовуються шари нормалізації та шари виключення після кожного згорткового шару (Рис.2.9). Нормалізація знижує вплив варіацій інтенсивності сигналу, що дозволяє отримати більш стабільне навчання, тоді як Dropout сприяє узагальненню та допомагає знизити можливість перенавчання моделі.

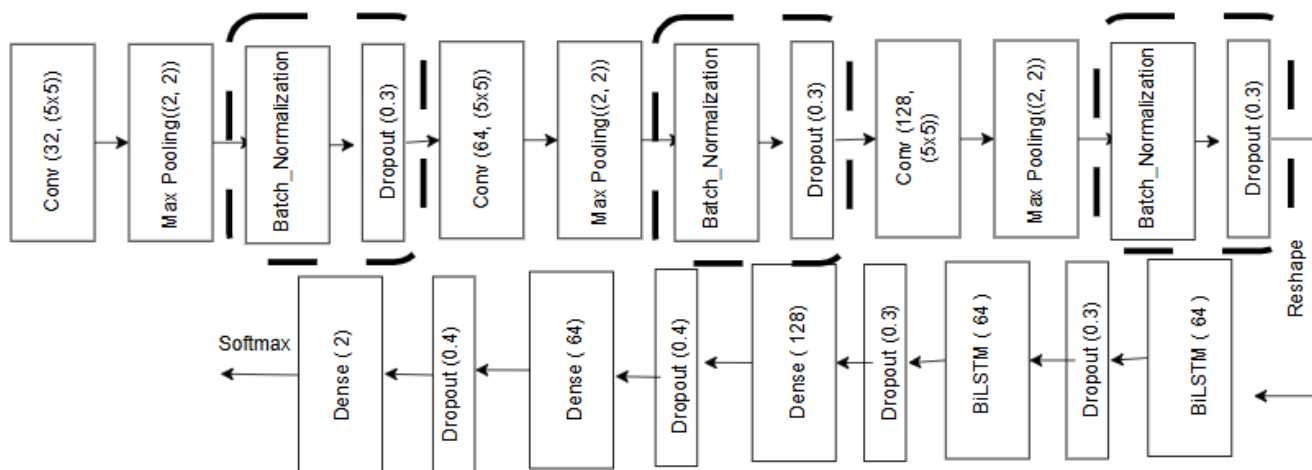


Рис.2.9. Модифікована архітектура CRNN для аналізу даних радару (додаткові шари нормалізації та виключення).

У випадку з радіолокаційними даними, використання бідирекційних LSTM дозволяє враховувати як минулі, так і майбутні стани послідовності, що може бути корисним при розпізнаванні зміни частоти, викликані змінами швидкості чи напрямку руху об'єкта. Розташування Dropout-шарів між рекурентними шарами забезпечує додатковий захист від перенавчання та сприяє узагальненню, що дозволяє моделі краще працювати з шумовими сигналами, характерними для радіолокаційного середовища. Це налаштування RNN-шарів сприяє стабільному вилученню патернів, які допомагають диференціювати цілі на основі їхніх доплерівських характеристик.

Обробка акустичних і радіолокаційних сигналів у CRNN-моделі має суттєві відмінності, обумовлені природою цих типів даних. Акустичні сигнали мають значну варіативність у часі та частоті, і їхній аналіз вимагає використання згорток з меншими фільтрами, що дозволяє виділяти локальні частотні особливості. Натомість для радіолокаційних даних, що містять більш стабільні доплерівські спектри, які відображають просторові характеристики руху об'єктів, важливо використовувати ширші фільтри для виділення глобальних структурних особливостей.

Щоб покращити кінцеві етапи класифікації, модель доповнена двома щільними шарами з 128 і 64 нейронами відповідно. Кожен з цих шарів відіграє особливу роль у процесі класифікації, забезпечуючи глибше навчання на вихідних

ознаках, отриманих після проходження через згорткові та рекурентні шари. Dense-шар з 128 нейронами виконує роль узагальнення попередніх ознак, допомагаючи моделі краще розпізнавати складні зв'язки між виділеними патернами у радіолокаційних даних. Dense-шар з 64 нейронами функціонує як підсумковий класифікаційний шар, що остаточно агрегує інформацію для прийняття рішення. Зменшення кількості нейронів на цьому етапі допомагає запобігти перенавчанню, оскільки модель на цьому етапі вже має достатню кількість узагальнених ознак для коректної класифікації. Вихід моделі формує останній шар із 3 нейронів – по 1 для кожного класу та функція активації softmax (2.1), яка повертає ймовірність приналежності елементу для кожного класу.

2.3 Налаштування процесу навчання моделей для виявлення БПЛА.

Одним з ключових етапів у тренуванні моделей глибокого навчання є підбір гіперпараметрів:

- Швидкість навчання (англ. learning rate) визначає, наскільки сильно оновлюються ваги нейронної мережі під час кожного кроку оптимізації, це коефіцієнт що регулює наскільки сильно будуть коригуватись ваги з врахуванням функції втрат в градієнтному спуску. Вона є ключовим параметром, який впливає на швидкість збіжності до оптимального розв'язку. Якщо швидкість навчання занадто велика, модель може стати нестабільною, пропускаючи оптимальні значення функції втрат. Занадто маленьке значення призводить до надто повільного навчання, коли модель може застрягти в локальних мінімумах.
- Розмір батчу (англ. batch size) визначає кількість зразків даних, які обробляються одночасно перед оновленням ваг моделі. Цей параметр має важливий вплив на швидкість навчання, використання пам'яті та стабільність градієнтів. Малий розмір батчу дозволяє моделям краще узагальнювати дані, але може додати шум у процес обчислення градієнтів. Натомість великий батч

знижує варіативність градієнтів і забезпечує більш точне оновлення, але потребує більше обчислювальних ресурсів.

- Кількість епох (англ. epoch number) це та кількість разів, яку вся навчальна вибірка буде використана для навчання моделі. Цей параметр контролює тривалість процесу навчання. Якщо кількість епох недостатня, модель не встигає вивчити закономірності в даних і може залишитися недонавченою. Якщо ж кількість епох надмірна, існує ризик перенавчання, коли модель запам'ятовує закономірності тренувальних даних, але погано працює на тестових.
- Оптимізатор (англ. optimizer) — це алгоритм, який визначає, як саме оновлюються ваги нейронної мережі з метою мінімізації функції втрат. Різні оптимізатори використовують різні стратегії для пошуку оптимального розв'язку, наприклад, метод градієнтного спуску або його варіації
- Функція втрат (англ. loss function) вимірює різницю між прогнозами моделі та реальними значеннями, відображаючи, наскільки добре модель виконує поставлене завдання. Вибір функції втрат залежить від типу задачі: для класифікації зазвичай використовують кросентропію, а для регресії — середньоквадратичну або середньоабсолютну помилку. Для задачі бінарної класифікації використовується функція бінарної кросентропії (2.2).

$$f(\alpha) = -\frac{1}{N} \sum_{i=1}^n [y_i * \log(p(y_i)) + 1(1 - y_i) * \log(1 - p(y_i))] \quad (2.2)$$

де f представляє функцію втрат, α - параметри моделі (коефіцієнти), y – реальні значення цільової функції (0 або 1), а p - передбачена ймовірність приналежності до класу. В випадку задачі багатокласової класифікації, використовується функція категоріальною перехресної ентропії.

$$CE = -\sum_{i=1} [y_i^{true} * \log(p(y_i^{pred}))] \quad (2.3)$$

, де y^{true} – реальні значення цільової функції (0 або 1), а p - передбачена ймовірність приналежності до класу.

2.4 Метрики для оцінювання якості виявлення БПЛА.

У завданні виявлення БПЛА (безпілотних літальних апаратів) на основі акустичних та радіолокаційних сигналів для оцінки якості класифікації використовуються кілька метрик, кожна з яких відображає різні аспекти продуктивності моделі. Обрання відповідних метрик є важливим кроком, оскільки саме вони дозволяють оцінити, наскільки ефективно модель розпізнає специфічні ознаки БПЛА серед різноманітних шумів та інших об'єктів.

Матриця помилок (Рис. 2.10) є основою для багатьох класифікаційних метрик.

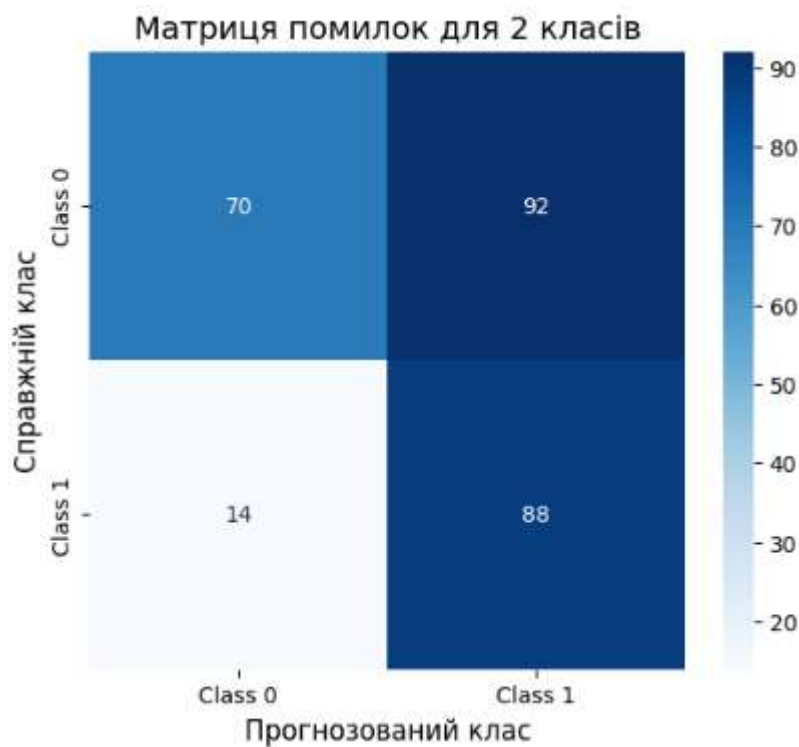


Рис. 2.10. Приклад матриці помилок.

Вона представляє результат класифікації у вигляді чотирьох елементів:

- True Positive (TP) – істинно позитивні, коли модель правильно прогнозує клас елемента як позитивний (в контексті задачі, це наявність БПЛА).
- False Positive (FP) – хибно позитивні, коли модель помилково прогнозує клас елемента як позитивний.

- True Negative (TN) – істинно негативний, коли модель правильно класифікує сигнал як відсутність БПЛА.
- False Negative (FN) – хибно негативи, коли модель помилково не розпізнає БПЛА у сигналі.

На основі цих значень обчислюються більшість інших метрик. Матриця помилок є особливо корисною для аналізу продуктивності в умовах дисбалансу класів, коли позитивних прикладів (сигналів БПЛА) значно менше, ніж негативних (фонових шумів чи інших об'єктів). Наприклад, велика кількість FP може свідчити про надмірне реагування на шумові сигнали, тоді як висока FN вказує на пропуски, що є критичним для питань безпеки.

Точність (accuracy) — це базова метрика, що визначає частку правильно класифікованих зразків серед загальної кількості. Вона визначається за як відношення всіх істинно виявлених елементів до всієї вибірки (2.1). Це базова метрика, яка показує, наскільки часто модель правильно класифікує вхідні сигнали. Однак точність може бути ненадійною у випадках, коли класи дисбалансовані. Наприклад, якщо більшість сигналів не містять БПЛА (тобто є негативними прикладами), модель може досягти високої точності, прогнозуючи більшість випадків як "без БПЛА". У такій ситуації метрики, які враховують і позитивні, і негативні передбачення, такі як F1-бал, стають більш значущими.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2.4)$$

Точність позитивних передбачень (precision) є важливою метрикою для виявлення БПЛА, оскільки вона показує, яка частка передбачених позитивних результатів є дійсно правильними. Обчислюється як відношення істинно позитивних елементів до всіх позитивних елементів, класифікованих мережею (2.5). Ця метрика є корисною для виявлення дронів, оскільки висока точність позитивних передбачень вказує на те, що модель рідко помиляється, сигналізуючи про їх наявність. В умовах реального застосування це дозволяє зменшити кількість помилкових тривог, що може бути критично важливим для оперативного реагування.

$$precision = \frac{TP}{TP + FP}, \quad (2.5)$$

Повнота (Recall) — це здатність моделі коректно виявляти всі позитивні приклади, визначається як співвідношення кількості правильно прогнозованих позитивних даних до суми кількості правильно прогнозованих позитивних та хибно прогнозованих негативних (2.5). Високий рівень recall важливий, коли пріоритетом є зменшення кількості пропущених випадків. У ситуаціях, коли модель має високе значення recall, ймовірність пропуску сигналів БПЛА мінімізується, що важливо для задач, де пропуск може мати серйозні наслідки.

$$recall = \frac{TP}{TP + FN}, \quad (2.6)$$

F1-бал або F1-міра (F1-score) є гармонійним середнім між precision і recall, забезпечуючи баланс між цими двома показниками. Визначається за формулою 2.7.

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall}, \quad (2.7)$$

У випадку з виявленням БПЛА F1-міра є більш надійною метрикою, ніж точність, оскільки вона враховує як precision, так і recall. Це особливо важливо для задачі класифікації, де модель повинна добре розпізнавати всі сигнали БПЛА і при цьому уникати надмірних помилкових тривог.

Крива ROC (Receiver Operating Characteristic) - використовується для оцінки продуктивності моделей класифікації. Вона демонструє співвідношення між істинно позитивною частотою (True Positive Rate, TPR (2.6)) і хибно позитивною частотою (False Positive Rate, FPR (2.8)) при різних порогах класифікації.

$$FPR = \frac{FP}{FP + TN}, \quad (2.8)$$

В контексті теми кваліфікаційної роботи, TPR показує, яку частку сигналів БПЛА модель правильно розпізнає, тоді як FPR вказує, яку частку фонових сигналів вона помилково класифікує як БПЛА. ROC-крива будується на графіку, де вісь X представляє FPR, а вісь Y – TPR (Рис.2.11).

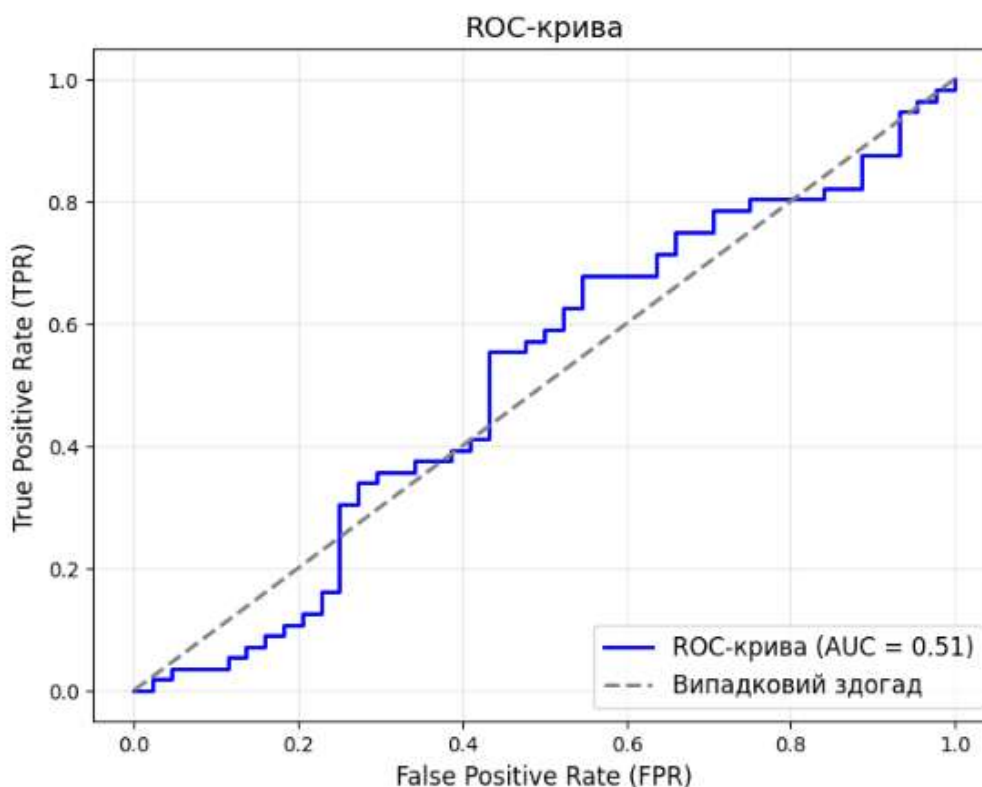


Рис. 2.11. Приклад ROC-кривої.

Оптимальною вважається модель, ROC-крива якої максимально наближена до верхнього лівого кута ($TPR = 1$, $FPR = 0$). Для кількісної оцінки використовується площа під кривою (AUC, Area Under Curve): $AUC = 1$ означає ідеальну модель, $AUC = 0.5$ відповідає випадковій класифікації. У задачах виявлення БПЛА ROC-крива допомагає вибрати оптимальний поріг класифікації, що балансує між зменшенням пропусків сигналів (низький FN) і зменшенням помилкових тривог (низький FP). Вона також дозволяє порівнювати різні моделі, де вищий AUC свідчить про кращу продуктивність.

У випадку задачі багатокласової класифікації, матриця помилок має дещо інший вигляд (Рис. 2.12) – кількість рядків та стовпців відповідають кількості класів, кожний елемент (a, b) матриці показує кількість виходів моделі коли вона класифікувала елемент a як клас b. Діагональні елементи в матриці демонструють кількість разів коли модель правильно класифікувала елемент.




Рис.2.12. Приклад матриці помилок для мультикласової класифікації (3 класів).

Для задачі багатокласової класифікації, точність повнота як відношення діагонального елемента (вірно класифікованого зразка) до суми всіх інших елементів в рядку (2.5). В свою чергу точність позитивних передбачень визначається як відношення діагонального елемента матриці до суми всіх елементів в стовбці для конкретного класу (2.6).

$$recall = \frac{A_{c,c}}{\sum_{i=1}^n A_{c,i}}, \quad (2.9)$$

$$precision = \frac{A_{c,c}}{\sum_{i=1}^n A_{i,c}}, \quad (2.10)$$

, де c – номер певного класу, n – кількість класів, A – значення елемента матриці помилок.

У контексті виявлення дронів точність може виявитися недостатньо інформативною метрикою, особливо при дисбалансі класів. Метрики *precision* і *recall* дають більш детальну інформацію про якість класифікації, дозволяючи оцінити,

наскільки модель правильно визначає БПЛА (без зайвих тривог) та наскільки вона чутлива до сигналів. У випадках, коли точність недостатньо інформативна, F1-міра дозволяє досягти балансу між precision і recall, що є критичним для завдань виявлення. Матриця помилок і також є важливим інструментом для аналізу конкретних помилок моделі, особливо в умовах високого дисбалансу класів, вона надає більше розуміння щодо продуктивності моделі на різних рівнях порогу.

Висновки до розділу 2

У другому розділі було запропоновано та детально розглянуто вдосконалений метод для виявлення безпілотних літальних апаратів за допомогою аналізу акустичних і радіолокаційних сигналів з використанням глибокого навчання. Головною метою роботи було підвищення точності, стійкості до шуму та здатності моделі до узагальнення, щоб забезпечити її ефективну роботу в реальних умовах, де можуть виникати різні перешкоди й варіативні сигнали. Для досягнення цих цілей було розроблено оновлену архітектуру згортково-рекурентної нейронної мережі, яка адаптована до особливостей як акустичних, так і радіолокаційних даних.

Основні вдосконалення моделі включають збільшення кількості фільтрів і глибини згорткових шарів. Це дозволить моделі краще аналізувати різні рівні абстракції у вхідних даних, виділяти ключові ознаки сигналів і розрізняти їхні унікальні характеристики. Зокрема, збільшення глибини згорткових шарів сприяє кращому розпізнаванню важливих особливостей доплерівських спектрів, характерних для радіолокаційних сигналів БПЛА. Застосування двонаправлених рекурентних шарів LSTM дозволяє моделі враховувати як попередні, так і наступні стани у послідовностях, що мусить підвищити ефективність виділення ознак сигналів. Це забезпечує здатність моделі з більшою точністю виявляти БПЛА навіть у складних шумових умовах, де типові підходи можуть давати значні похибки.

Регуляризацію моделі та зменшення ризику перенавчання реалізовано через додаткові шари вилучення, ці компоненти є необхідними для її стабільної роботи з різними типами сигналів у реальних умовах.

Особливу увагу було приділено адаптації CRNN для роботи з радіолокаційними сигналами. Радіолокаційні дані, на відміну від акустичних, мають унікальні просторово-часові особливості, такі як частотні зміни, викликані ефектом Доплера. Для забезпечення ефективного розпізнавання цих ознак CRNN-модель була розширена на рівні згорткових шарів та адаптована до обробки двовимірних доплерівських спектрів. Ці вдосконалення розширюють сферу застосування моделі для моніторингу БПЛА в реальних умовах, що є важливим кроком до забезпечення надійного і ефективного аналізу радіолокаційних сигналів.

Таким чином, запропоновані вдосконалення покращують архітектуру CRNN, роблячи її потенційно ефективнішою для задач виявлення БПЛА.

РОЗДІЛ 3 Основні кроки методу по вдосконаленню та використанню згортково-рекурентної мережі

У розділі розглянуто кроки методу по вдосконаленню CRNN моделі для виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів та кроки методу для виявлення БПЛА.

3.1 Основні кроки методу по вдосконаленню архітектури глибокого навчання

На рис. 3.1 наведено основні кроки методу по вдосконаленню архітектури глибокого навчання.

На вхід подається набір даних аудіо-файлів розмічених як БПЛА/не БПЛА та початкова архітектура згортково-рекурентної мережі.

Далі відбувається попередня обробка даних з датасету. Аудіо-файли розбиваються на проміжки тривалістю 1 секунда для нормалізації розмірності записів та розширення датасету для кращого навчання мережі. На основі отриманих сегментів створюються спектрограми. Потужність сигналу конвертується в децибели задля нормалізації значень. Набір даних поділяється на тренувальну, навчальну та валідаційну вибірки.

Початкова архітектура розширюється за рахунок збільшення кількості згорткових шарів та зменшення ядра згортки. Використовуються двонаправлені LSTM блоки для аналізу вхідних даних та додаткові повнозв'язні шари для узагальнення мережі. Для додаткової регуляризації додаються шари виключення.

Наступним кроком є оцінка якості класифікації вдосконаленої мережі за допомогою статистичних показників. На вхід моделі подається навчальна та валідаційна вибірки. Відбувається підбір гіперпараметрів для налаштування процесу навчання нейронної мережі. Модель тренується на навчальній вибірці та звіряє точність класифікації за рахунок валідаційної вибірки. Проводиться оцінка роботи моделі на тестових та нових даних.

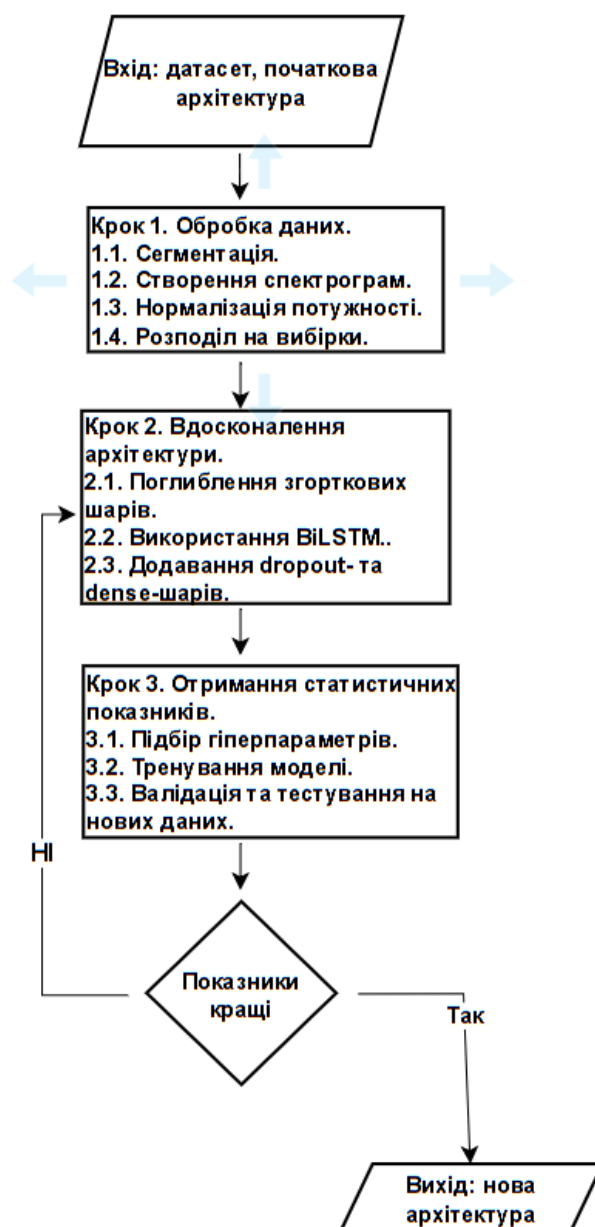


Рис. 3.1. Схема методу вдосконалення архітектури згортково-рекурентної мережі для виявлення БПЛА за акустичними сигналами.

Якщо результат роботи моделі вдосконаленої згортково-рекурентної мережі за метриками перевершує результати оригінальної моделі, то архітектура подається на вихід. В іншому випадку, відбувається перегляд та відповідні модифікації у вдосконаленнях мережі.

Виходом методу є нова архітектура згортково-рекурентної мережі для класифікації БПЛА за їх акустичним сигналом.

3.2. Модифікація вдосконаленої архітектури для задачі класифікації радіолокаційного сигналу БПЛА

Далі розглянемо кроки модифікації отриманої вдосконаленої архітектури CRNN для класифікації радіолокаційних даних (Рис.3.2).

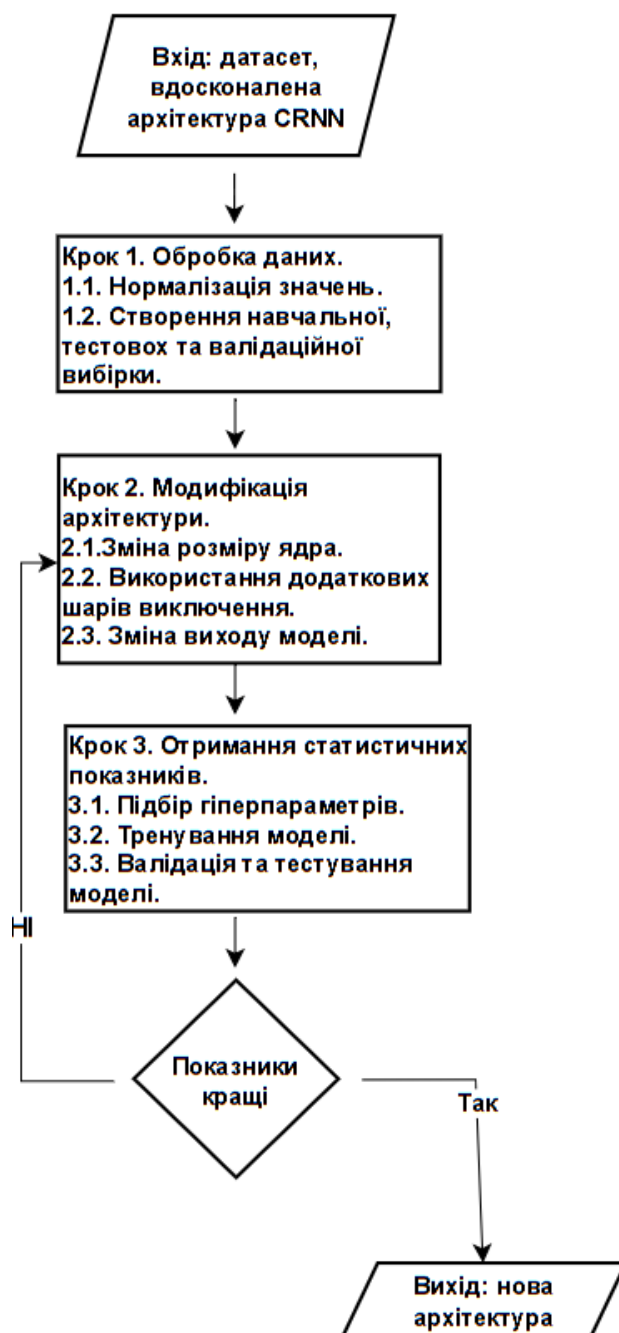


Рис. 3.2. Схема методу модифікації архітектури згортково-рекурентної мережі для виявлення БПЛА для роботи з радіолокаційними даними.

На вхід подається набір радіолокаційних даних в форматі матриць відстань-Доплер та вдосконалена архітектура CRNN отримана на попередньому етапі.

На кроці попередньої обробки даних, значення інтенсивності нормалізуються у масштаб $[0,1]$. Далі набір даних ділиться на тренувальну, валідаційну та тестову вибірку.

Отримана архітектура CRNN модифікується для задачі класифікації радіолокаційних даних. Розмір ядра в згорткових шарах збільшується для вилучення ознак з матриць вхідних даних, для додаткового узагальнення роботи мережі після кожного згорткового шару використовується шар виключення. Вихід моделі змінюється для задачі багатокласової класифікації для отриманого вхідний набір даних.

Наступним кроком є оцінка якості модифікованої мережі за допомогою статистичних показників. На вхід моделі подається навчальна та валідаційна вибірки. Відбувається підбір гіперпараметрів для налаштування процесу навчання нейронної мережі. Модель тренується на навчальній вибірці та звіряє точність класифікації за рахунок валідаційної вибірки. Проводиться оцінка роботи моделі на тестових даних.

Якщо результат роботи моделі модифікованої згортково-рекурентної мережі за метриками є достатнім та перевершує результати інших проаналізованих підходів до виявлення БПЛА за аналізом радіолокаційних даних то архітектура подається на вихід. В іншому випадку, відбувається перегляд та відповідні модифікації у мережі.

3.3. Використання отриманих моделей для виявлення БПЛА.

Метод використання навчених вдосконалених моделей CRNN для виявлення БПЛА зображений на рисунку 3.3.

На вхід подається сигнал БПЛА, після чого визначається його тип – радіолокаційний або акустичний.

Наступним кроком сигнал форматується для обробки певною моделлю:

- В випадку акустичного сигналу – аудіозапис сегментується та перетворюється в формат спектрограм.

- В випадку сигналу радара – значення інтенсивностей матриці відсань-Доплер нормалізується в маштаб [0,1]

Оброблений сигнал подається на вхід моделі глибокого навчання.

Виходом є значення класу сигналу: БПЛА/НЕ БПЛА.

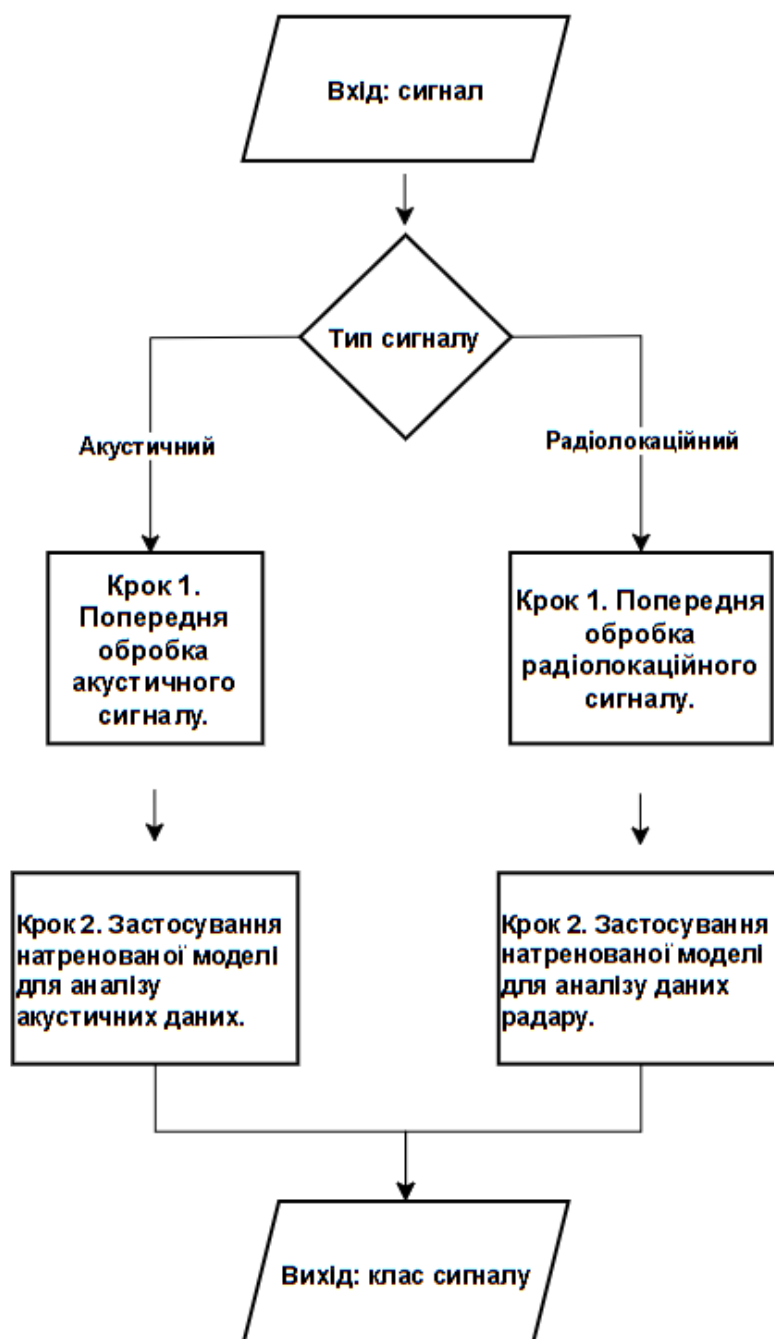


Рис.3.3. Схема методу використання отриманих моделей CRNN для аналізу сигналів БПЛА.

РОЗДІЛ 4 Експериментальна валідація запропонованого вдосконалення методу виявлення БПЛА.

Для дослідження запропонованого вдосконалення методу виявлення БПЛА за аналізом акустичних та радіолокаційних даних було створено застосунок для проведення експериментів та оцінки точності та якості роботи створених моделей глибокого навчання. У цьому розділі детально описано процес підготовки даних, архітектури моделей, застосованих для вирішення поставленої задачі, та результати експериментів, що підтверджують ефективність підходу.

У межах розділу наведено:

- опис програмного застосунку, що використовувався для проведення експериментів;
- аналіз використаних в рамках дослідження наборів даних та алгоритми їх попередньої обробки;
- проведення експериментів з вдосконалення архітектури згортково-рекурентної нейронної мережі, в ході яких було проведено тренування моделей глибокого навчання та оцінки їх роботи.

4.1 Опис застосунку для проведення експериментів.

В якості засобів розробки для реалізації застосунку та проведення експериментів було обрано середовище «Jupyter Notebook» та мову програмування Python. «Jupyter Notebook» це інтерактивний веб інтерфейс для виконання задач аналізу та візуалізації даних. Основною перевагою цього інструменту є можливість розбивати програмний код на окремі частини за допомогою комірок та запускати їх незалежно один від одного. Також «Jupyter Notebook» візуалізовує процес виконання коду в реальному часі і дає можливість одразу побачити результат виконання потрібної частини програми, що значно спрощує процес відстеження та виправлення

помилки. Середовище підтримує більшість бібліотек для аналізу даних та програмування неймереж, тому є підходящим програмним забезпеченням для реалізації експериментів в рамках даного дослідження.

Загалом застосування програмної реалізації можна поділити на декілька етапів:

- підключення необхідних бібліотек та фреймворків для аналізу даних та роботи з нейронними мережами
- завантаження необхідних наборів даних, що будуть використовуватись в дослідженні з онлайн ресурсів
- визначення структурних компонентів програми: класів та функцій, що забезпечують попередню обробку даних, тренування та тестування нейронних мереж, використання навчених моделей тощо
- ітерації з вдосконалення архітектури базової згортково-рекурентної нейронної мережі – тестування різних версій архітектури, навчання на датасеті використаному в дослідженні [19], валідація роботи навчених моделей на «небаченому» наборі даних
- навчання та тестування вхідної та кінцевої вдосконаленої моделі на новому великому наборі акустичних-сигналів БПЛА
- модифікація отриманої архітектури для задачі класифікації візуального представлення радіолокаційних сигналів БПЛА
- тестування роботи навчених моделей в умовах зашумлених даних
- аналіз результатів експериментів

4.2 Опис датасету.

4.2.1 Опис наборів радіолокаційних та акустичних сигналів БПЛА.

Для проведення дослідження будуть використані декілька публічно доступних наборів акустичних та радіолокаційних сигналів БПЛА. Для тренування згортково-рекурентної мережі для задачі класифікації звуків дронів будемо використовувати датасет створений в рамках дослідження [43]. Цей набір даних був створений для

задачі виявлення БПЛА в складних акустичних умовах. Аудіо-записи у датасеті розмічені за двома класами – записи звуку роботи дронів та фонових шумів, звуків середовища. Дані для класу «дрон» охоплюють записи звуків кількох моделей дронів, таких як "Parrot Bebop 2" та "Parrot Mambo". Записи проводилися в контрольованих умовах із використанням простих та доступних мікрофонів. Особливу увагу приділяли змінам режимів роботи двигунів, зокрема різним швидкостям обертання пропелерів, щоб отримати більше варіацій звуків. Дрони записувалися на різних відстанях від мікрофона, що дозволяло моделювати ситуації з різними рівнями інтенсивності сигналу. Фонові звуки включали природні та техногенні шуми, такі як шум транспорту, вітер, спів птахів, гелікоптери та звуки міста. Для записів використовувалися різноманітні умови, включаючи міські райони, відкриті простори та тихі приміщення. Всі аудіо-записи були нормалізовані за заданою частотою дискретизації – 16кГц та сегментовані на аудіо-кліпи по 1 секунді для кращого навчання нейронних мереж. В наборі даних є значний дисбаланс класів (Рис.4.1). Елементів розмічених як «дрон» 1332 файли, в той же час елементів розмічених як фонові шуми та звук середовища 10372 файли.

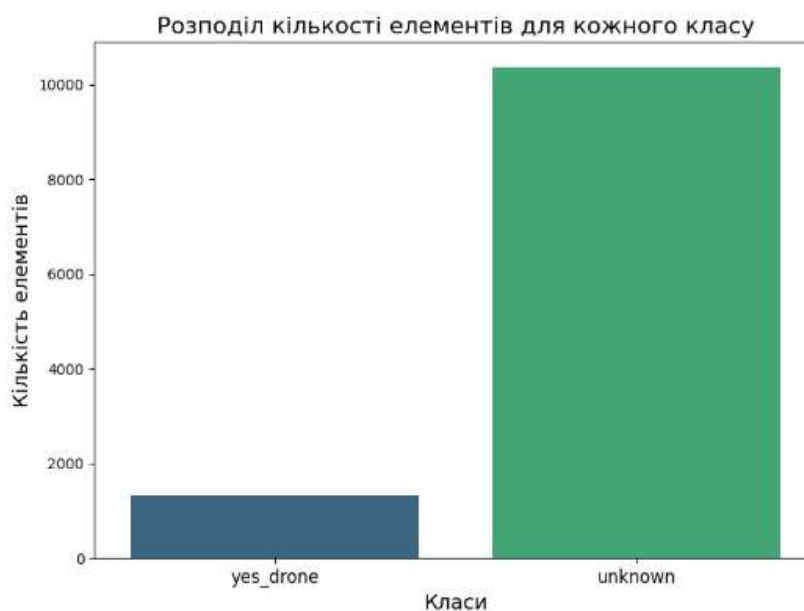


Рис.4.1. Розподіл елементів у наборі даних [42] по класам за кількістю елементів.

У задачах із класом-ціллю (ціль – акустичний сигнал дронів) є стандартною ситуацією, коли кількість елементів цільового класу значно менше елементів класу, що узагальнює усі інші випадки (для нашої задачі це усі фонові звуки, звуки навколишнього середовища, шум роботи інших пристроїв). Подібний дисбаланс класів може впливати на процес навчання моделі і викривляти її роботу в сторону класифікації класу більшості. В таких ситуаціях, модель не визначає потрібну кількість позитивних зразків (аудіо-сигналів БПЛА) і збільшує кількість хибно негативних результатів класифікації.

Також, для задачі класифікації дронів за звуком, використовуватимемо валідаційний датасет із дослідження [19] для того, щоб протестувати роботу моделі вдосконаленої мережі на раніше небачених даних, що не входили в датасет [43] та порівняти якість класифікації з початковою архітектурою згортково-рекурентної мережі відповідного дослідження. Даний датасет це збалансований набір аудіо-даних розмічених як дрон/не дрон по 273 елементи для кожного класу (Рис.4.2). Дані являють собою аудіо-записи тривалістю в 1 секунду роботи дрона DJI Mini 2 в умовах реального середовища – звук був записаний біля доріг, на фоні шуму садового обладнання, роботи гелікоптера тощо. Для класу розмічених як не дрон, були зроблені аудіо-записи в тих же умовах, але без використання БПЛА.

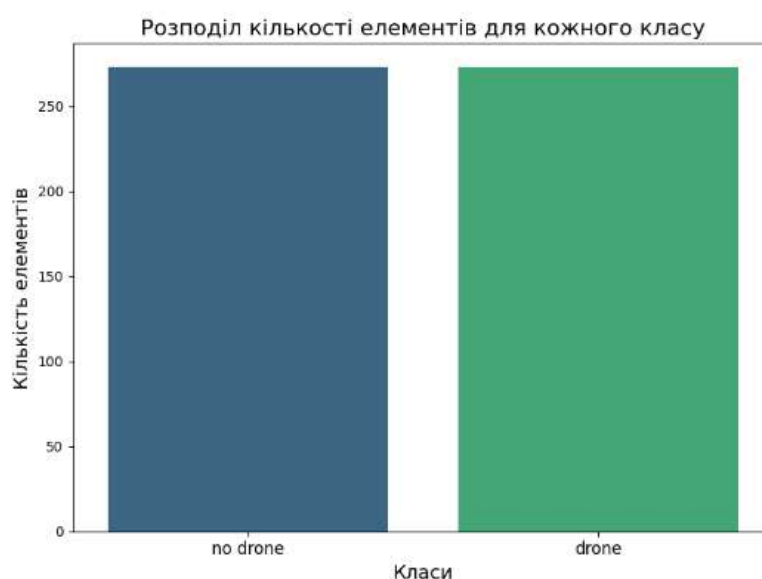


Рис.4.2. Розподіл елементів у валідаційному наборі даних по класам за кількістю елементів.

Датасетом для тренування класифікатора радіолокаційних сигналів БПЛА буде набір даних представлений у дослідженні [42], який є першим публічним набором даних для класифікації об'єктів на основі інформації з радіолокаційних систем. Він створений для виявлення та класифікації об'єктів трьох класів: дрони, люди та автомобілі, у реальних умовах, використовуючи сигнатури з доплерівських спектрів. Цей датасет містить 17 485 зразків, організованих у CSV-файли з матрицями розміром 11×61 (Рис. 4.3), які представляють силу сигналу в дБм для кожної комірки. Кожна матриця відображає дальність та швидкість об'єкта.

```

Числова матриця:
  0      1      2      3      4      5      6      7      8  \
0 -113.90 -109.06 -109.85 -117.79 -120.07 -114.35 -123.82 -130.00 -120.38
1 -109.71 -110.72 -114.25 -115.19 -116.60 -118.53 -124.54 -119.57 -115.67
2 -110.34 -110.46 -111.31 -114.42 -111.03 -113.81 -117.53 -118.90 -113.34
3 -120.28 -116.06 -111.29 -111.83 -110.46 -116.59 -110.13 -113.21 -130.39
4 -116.40 -131.78 -112.56 -114.52 -113.98 -130.68 -110.70 -110.03 -116.46
5 -120.16 -133.71 -112.20 -115.07 -122.19 -119.47 -115.16 -115.96 -111.11
6 -122.50 -119.73 -111.81 -111.47 -116.14 -115.02 -116.13 -114.60 -108.42
7 -123.34 -122.18 -116.10 -110.86 -113.75 -118.00 -111.32 -116.08 -116.82
8 -113.94 -112.63 -124.39 -114.48 -115.50 -122.14 -111.73 -115.80 -123.77
9 -117.37 -114.00 -113.73 -112.78 -119.14 -122.06 -119.05 -123.35 -116.08
10 -113.35 -112.29 -111.82 -110.47 -120.26 -114.90 -121.76 -115.36 -112.40

      9      ...      51      52      53      54      55      56      57  \
0 -117.46 ... -113.45 -125.10 -114.54 -123.59 -123.90 -121.01 -118.71
1 -122.10 ... -118.56 -116.47 -112.64 -118.68 -121.73 -121.67 -117.67
2 -111.41 ... -118.75 -114.66 -119.37 -130.47 -116.56 -117.20 -124.49
3 -115.02 ... -130.97 -124.47 -119.20 -115.68 -120.83 -123.46 -119.16
4 -114.28 ... -119.66 -118.40 -116.31 -115.94 -126.68 -123.28 -121.56
5 -110.96 ... -120.25 -122.88 -114.24 -111.14 -115.72 -130.04 -115.68
6 -109.11 ... -119.16 -118.17 -111.56 -110.36 -115.00 -122.52 -114.61
7 -116.32 ... -115.41 -119.01 -112.22 -113.42 -133.91 -114.89 -113.36
8 -116.50 ... -115.89 -120.25 -116.12 -113.92 -122.00 -113.97 -113.64
9 -120.62 ... -117.45 -125.08 -120.86 -121.38 -122.69 -118.07 -116.35
10 -112.53 ... -118.91 -123.57 -118.00 -125.19 -117.47 -119.19 -116.81

      58      59      60
0 -120.11 -118.88 -114.00
1 -122.61 -123.44 -124.18
2 -114.84 -119.98 -120.21
3 -113.90 -120.79 -123.61
4 -131.13 -121.23 -114.49
5 -112.98 -115.91 -110.20
6 -113.51 -114.26 -114.08
7 -120.55 -114.91 -116.96
8 -131.29 -117.49 -122.12
9 -112.74 -112.31 -118.13
10 -114.15 -114.07 -118.61

[11 rows x 61 columns]

```

Рис.4.3. Приклад матриці відстань-Доплер.

Зразки розподілені між класами наступним чином: 5 065 зразків помічених як дрони, 6 700 як люди і 5 720 як автомобілі, забезпечуючи баланс між категоріями (Рис.3.4). Дані були зібрані за допомогою FMCW-радару на відкритій території в

Іспанії. Для різноманітності враховувалися різні швидкості руху, орієнтації та відстані об'єктів (до 3 км).

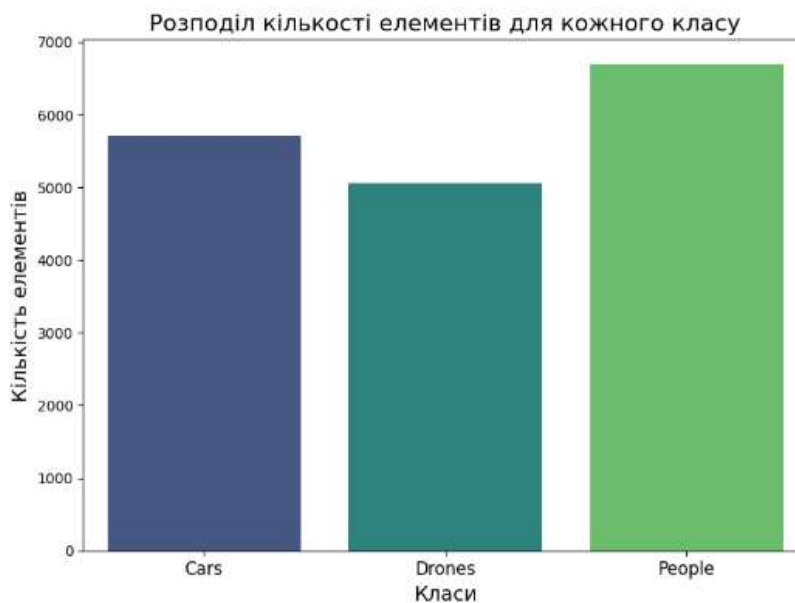


Рис.4.4. Розподіл елементів у наборі радіолокаційних сигналів БПЛА по класам за кількістю елементів.

4.2.2. Попередня обробка вхідних даних.

Попередня обробка вхідних даних є одним з ключових етапом у підготовці інформації для тренування моделей глибокого навчання. Аудіо-файл містить в собі інформацію про звукові дані в визначеній часовій області, оскільки згорткові нейронні мережі не можуть напряму працювати із аудіо-даними, потрібно їх представити в чисельному форматі. Це досягається шляхом створення спектрограм, що показують залежність амплітуди сигналу від частоти і часу. Процес обробки аудіо-сигналів включає в себе:

- Нормалізацію та фільтрацію сигналу: Завантажений аудіосигнал фільтрується для усунення зайвого шуму та нормалізується для забезпечення однакового масштабу даних.
- Розбиття на сегменти: Сигнал розбивається на короткі часові вікна, що дозволяє аналізувати частотні характеристики в кожному сегменті.

- Перетворення Фур'є: Для кожного сегмента обчислюється швидке перетворення Фур'є, яке переводить сигнал із часової області в частотну.
- Генерація спектрограм: Результати швидкого перетворення Фур'є, комбінуються у вигляді двовимірної матриці, яка представляє частотний спектр сигналу у часі. Для покращення аналізу можуть використовуватися мел-частотні кепстральні коефіцієнти.

На рисунку 4.5 зображений приклад спектрограм для наборів акустичних сигналів дронів, що використовуються у дослідженні.




Рис.4.5. Приклад спектрограм з наборів даних (зліва – звук середовища, справа звук БПЛА).

Також, як зазначено вище, датасет акустичних сигналів, що використовується для навчання мережі має дисбаланс класів (Рис.3.1). Для уникнення похибок в класифікації, що можуть бути спричинені кількісною перевагою класу більшості, був створений нова навчальна набірка даних шляхом зменшення вибірки класу більшості до кількості екземплярів класу меншості (Рис.3.6). Зменшення вибірки відбувалось за рахунок випадкового видалення елементів розмічених як не сигнал БПЛА. Оскільки цей клас є не цільовим і містить в собі звуки різноманітних середовищ та фонових шумів то ймовірність втратити важливу інформацію про ключові паттерни сигналу є мінімальною.

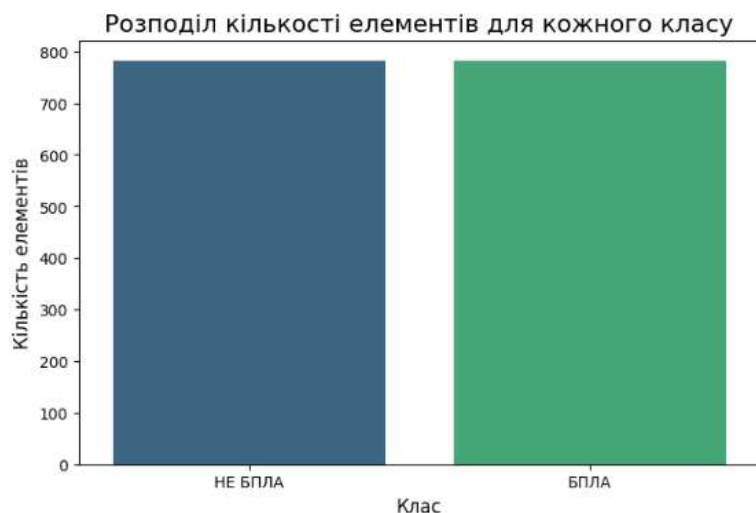


Рис.4.6. Розподіл класів тренувальної вибірки після процесу балансування класів.

У наборі радіолокаційних сигналів БПЛА – кожний елемент матриці відображає інтенсивність сигналу (Рис.4.7) .

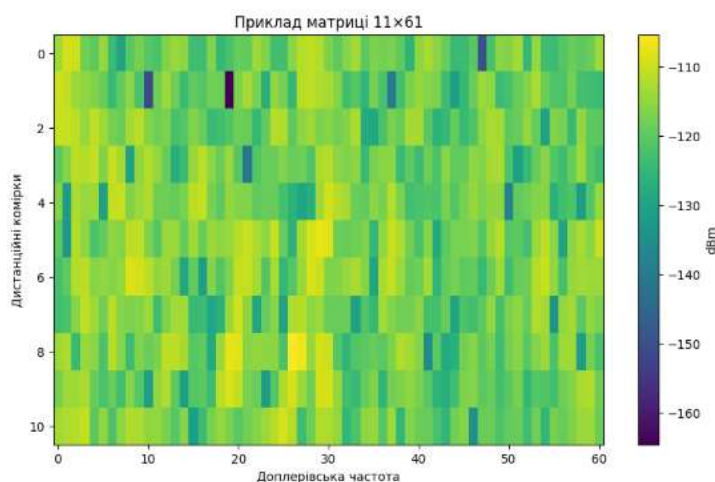


Рис. 4.7. Приклад візуального зображення матриці відстань-Доплер з набору даних.

Після нормалізації значень інтенсивності у заданий діапазон $[0, 1]$ формується візуальне представлення матриці у вигляді теплової карти, де кольори відповідають значенням інтенсивності сигналу.

Для тренування та тестування моделей відповідних архітектур, набори даних, що використовуються для тренування моделей були розділені на навчальну, валідаційну та тестову вибірку в співвідношенні 70:15:15.

4.3 Експерименти.

4.3.1. Результати вдосконалення архітектури згортково-рекурентної мережі для аналізу акустичних сигналів БПЛА.

Під час проведення дослідження було створено та протестовано різноманітні версії вдосконалення базової архітектури згортково-рекурентної мережі представленої в дослідженні [19]. Всі версії реалізують в собі основну ідею поглиблення архітектури за рахунок додавання додаткових згорткових шарів для захоплення більш складних та комплексних ознак із спектрограм та використання двонаправлених LSTM блоків для аналізу часових взаємозалежностей у аудіо-даних. Окрім вихідної архітектури згортково-рекурентної мережі, зображеної на рисунках 2.2, 2.4, 2.5, 2.6, в розділі будуть представлені ще дві перехідні версії. Кожна представлена мережа є фінальним варіантом вдосконалення попередньої, що продемонструвала найкращі результати класифікації.

Вдосконаленню CRNN_1 відповідає модель, що розширює базову архітектуру, з використанням додаткового шару згортки. Короткий опис архітектури:

- Згорткові шари: Перший згортковий шар має 32 фільтри розміром 3×3 , що дозволяє моделі виділяти базові просторові патерни. Другий згортковий шар має 64 фільтри розміром 3×3 , які слугують для виділення складніших ознак. Після кожного згорткового шару, іде шар пулінгу MaxPooling (2×2) для зменшення розмірності ознак і прискорення обчислень, а також використовується Batch Normalization для стабілізації навчання.
- Рекурентний шар: Вихід згорткових шарів реорганізується за допомогою шару Reshape у формат, сумісний із рекурентними мережами. Модель містить один шар LSTM із 64 нейронами.
- Повнозв'язні шари і Dropout: Один повнозв'язний (щільний) шар із 64 нейронами дозволяє моделі комбінувати витягнуті ознаки. Dropout із коефіцієнтом 0.6 зменшує ризик перенавчання, випадково відключаючи 60% нейронів під час навчання.

- Вихідний шар: аналогічний до базової моделі - шар із 2 нейронами, який відповідає кількості класів та функція активації softmax(2.1).

Наступна архітектура CRNN_2 окрім поглиблення згорткових шарів, також використовує мережу двонаправленої довгої короткочасної пам'яті. Короткий опис архітектури мережі:

- Згорткові шари: Мережа містить три згорткові шари для кращого виділення ознак: перший із 32 фільтрами (3×3), другий із 64 фільтрами (3×3), і третій із 128 фільтрами (3×3). Після кожного згорткового шару додаються шари MaxPooling (2×2) і Batch Normalization для зменшення розмірності ознак і стабілізації навчання, а після третього згорткового шару використовується Dropout із коефіцієнтом 0.3 для запобігання перенавчанню.
- Рекурентний шар: Для обробки часових залежностей застосовується двонаправлений LSTM із 64 нейронами, що дозволяє враховувати залежності в обох напрямках.
- Повнозв'язні шари і Dropout: Перший щільний шар із 128 нейронами дозволяє моделі формувати складні комбінації ознак, а Dropout із коефіцієнтом 0.4 зменшує ризик перенавчання; другий щільний шар із 64 нейронами додає гнучкості до фінальної класифікації, а Dropout із коефіцієнтом 0.3 забезпечує додаткову регуляризацию.
- Вихідний шар: щільний шар із 2 нейронами та функцією активації softmax використовується для ймовірнісної класифікації, забезпечуючи прогноз належності даних до одного з двох класів.

Вихідна версія розширеної архітектури (Рис.2.4) відрізняється від версії 2 наявністю додаткового BiLSTM шару та зміненими параметрами шарів виключення.

На основі проаналізованої літератури, схожих досліджень та проведених додаткових експериментів були визначені значення (Табл. 4.1) для гіперпараметрів навчання.

Таблиця 4.1.

Параметр	Значення
Швидкість навчання	0.0001
Розмір батчу	16
Кількість епох	10
Оптимізатор	Adam
Функція втрат	Бінарна перехресна ентропія

Всі версії згортково-рекурентної мережі (включно з початковою) були натреновані та протестовані на відповідному наборі акустичних даних БПЛА, після чого були сформовані матриці помилок та ROC-крива (Рис.4.8 – 4.15).

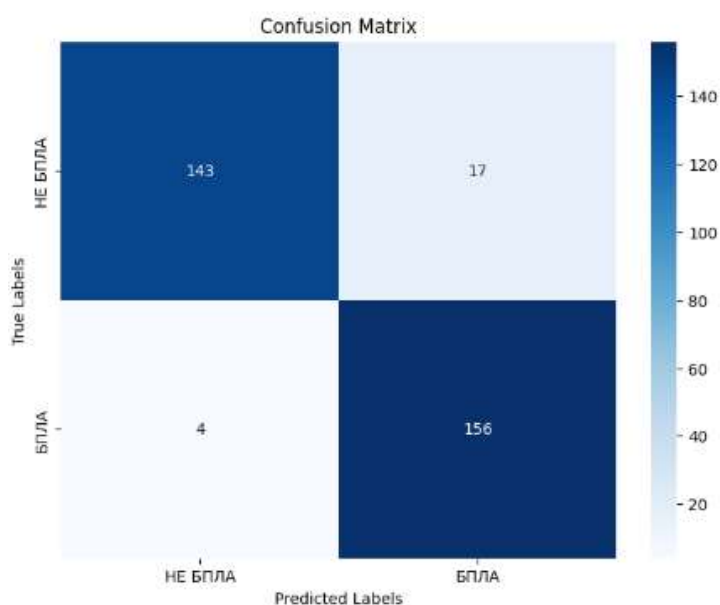


Рис. 4.8. Матриця помилок для початкової CRNN

Матриця помилок свідчить про точність у класифікації, адже більшість зразків класифіковано правильно, хоча є 17 хибно-позитивних спрацьовувань і 4 пропущені сигнали БПЛА. Це означає, що модель має тенденцію до незначної переваги до невірної класифікації даних як сигналу дрона. Також можемо сказати, що початкова модель демонструє високу ефективність, що підтверджується значенням площі під

ROC-кривою (Рис.4.9), яка вказує на чудову здатність розрізняти класи "БПЛА" та "НЕ БПЛА".




Рис.4.9. ROC-крива для початкової моделі CRNN.

Аналіз матриці помилок та ROC-кривої для моделі архітектури CRNN_1 (Рис.4.10, 4.11) акустичних сигналів БПЛА свідчить про їх високу ефективність.




Рис. 4.10. Матриця помилок для вдосконаленої CRNN_1.

Модель правильно класифікувала 150 із 160 випадків класу "НЕ БПЛА" та всі 160 випадків класу "БПЛА", демонструючи мінімальну кількість помилкових передбачень. ROC-крива (Рис.4.11) підтверджує ідеальну якість класифікації, що свідчить про високу здатність моделі розрізняти класи на всіх порогах.

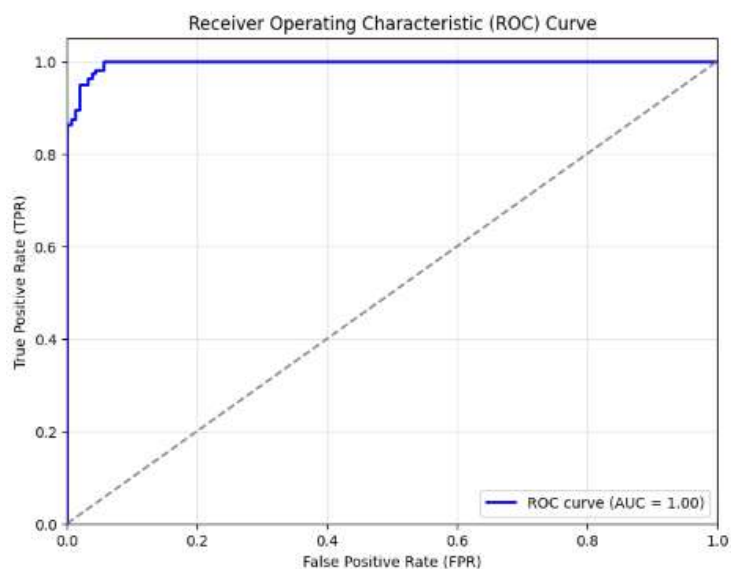


Рис.4.11. ROC-крива для вдосконаленої моделі CRNN_1.

Результати роботи моделі CRNN_2 на тестовій вибірці зображенні на рисунках 4.12 та 4.13.




Рис. 4.12. Матриця помилок для вдосконаленої CRNN_2.




Рис.4.13. ROC-крива для вдосконаленої моделі CRNN_2.

Аналізуючи їх, можна побачити, що архітектура CRNN_2 краще вирізняє фоніві шуми від звуків дрону, але в той же час, не розпізнає всі справжні звуки БПЛА, класифікуючи їх як звуки середовища.

Архітектура CRNN_3 аналогічно до інших вдосконалених версій має високі показники точності, але є більш збалансованою з точки зору хибно-негативних та хибно-позитивних класифікацій.




Рис. 4.14. Матриця помилок для вдосконаленої CRNN 3.

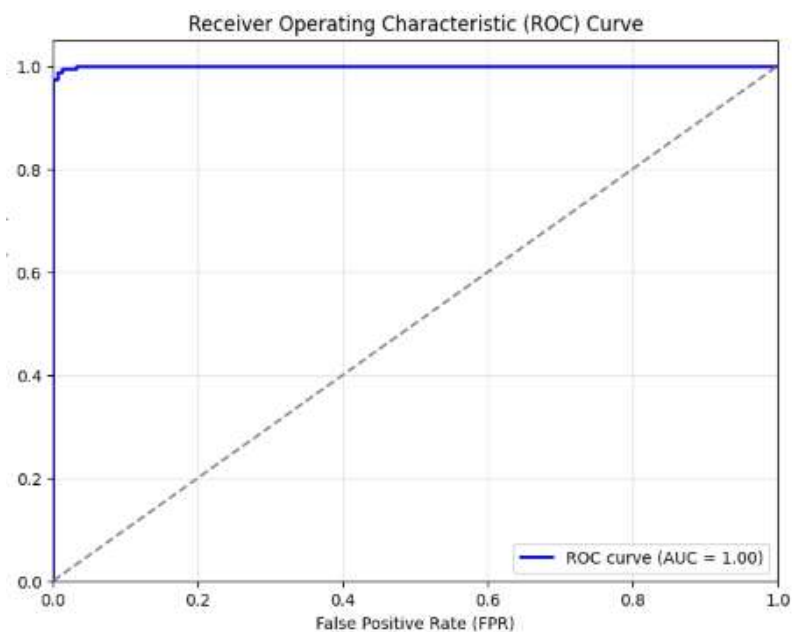


Рис.4.15. ROC-крива для вдосконаленої моделі CRNN 3.

Для більш повної картини ефективності роботи моделей обчислимо основні метрики: accuracy, precision, recall, F1-score (Табл. 4.2).

Таблиця 4.2.

	Початкова CRNN	CRNN 1	CRNN 2	CRNN 3
Метрики				
accuracy	0.93	0.97	0.97	0.98
precision	0.94	0.97	0.97	0.97
recall	0.93	0.97	0.97	0.99
F1-score	0.93	0.97	0.97	0.98

Найкращі результати класифікації були отримані останньою модифікацією згортково-рекурентної мережі – CRNN_3, але загалом всі вдосконалення початкової архітектури перевершили її. Такі високі показники можуть свідчити про часткове або значне перенавчання моделей для конкретного набору даних. Щоб переконатись в якості класифікації, протестуємо моделі на раніше не бачених даних із дослідження [19]. Це також потрібно для більш конструктивного порівняння з вхідною

архітектурою, адже тренувальні датасети використані в дослідженні не доступні, тому точність моделі CRNN порівнювати на валідаційному датасеті. Результати класифікації валідаційного набору даних зображені на рисунках 4.16, 4.17 та таблиці 4.3.

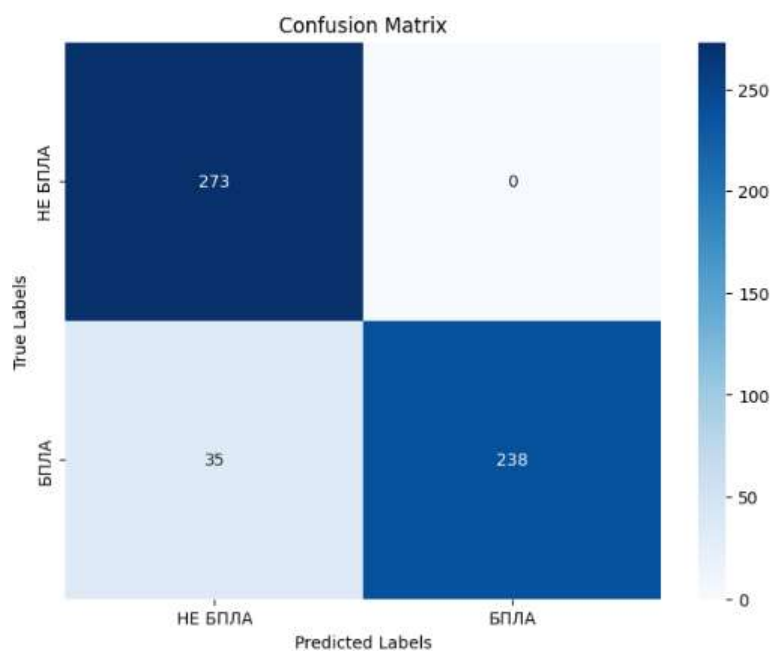


Рис.4.16. Матриці помилок для валідаційного датасету, початкова CRNN.




Рис.4.17. Матриці помилок для CRNN_3 для валідаційного датасету.

З отриманих результатів, можна підсумувати, що моделі зберегли високу точність при класифікації даних, що були новими – не входили в тренувальну і тестову вибірки. В матрицях помилок можна помітити закономірність, що моделі мають певну кількість хибно негативних результатів в той же час, як кількість хибно позитивних екземплярів близько 0. Можна зробити висновок, що моделі добре вирізняють звуки БПЛА, але в той же час існує категорія фонових шумів середовища, в якому акустичний сигнал дрона важче відділити від інших звуків.

Таблиця 4.3.

	Accuracy	Precision	Recall	F1-score
Модель				
Початкова CRNN	0.9359	1	0.8718	0.9315
Вдосконалена CRNN	0.9743	0.9961	0.9523	0.9737

Загалом вдосконалена модель CRNN_3 перевершала значення початкової моделі за всіма метриками окрім precision (Табл.4.3), оскільки вдосконалена модель має 1 хибно негативний прогноз. З точки зору реальної задачі, найважливішою метрикою є повнота, за якою вдосконалена модель перевершила початкову на 8%. В порівнянні з метриками, що були отримані в дослідженні [19] для CRNN – 0.9412 для accuracy та 0.9427 для F1-score, вдосконалена модель працює краще. Окрім того, всі моделі представлені в відповідному дослідженні продемонстрували гірші результати на валідаційному датасеті.

4.3.2. Результати модифікації вдосконаленої згортково-рекурентної мережі для задачі виявлення БПЛА за радіолокаційним сигналом.

Представлення даних із датасету радіолокаційних сигналів БПЛА за своїм змістом є дуже схожими з Мел-спектрограмами аудіо-сигналів. Рядки з матриць

відстань-Доплер представляють відстань до об'єкта, стовпці — доплерівські частоти, а значення — потужність сигналу в дБм. Подібно до спектрограм, ці дані є двовимірними представленнями, де кожна координата (рядок і стовпець) відповідає фізичному параметру сигналу (відстань або час), а числові значення відображають енергетичні характеристики (інтенсивність сигналу). Таким чином, для вирішення задачі класифікації радіолокаційних сигналів БПЛА, можна використати підхід з застосуванням згортково-рекурентних нейронних мереж. В якості вхідної архітектури, візьмемо CRNN 3 отриману при експериментах з акустичними даними БПЛА, оскільки вона продемонструвала найкращі метрики. Для навчання мережі CRNN 3 варто визначити гіперпараметри навчання (Табл. 4.4).

Таблиця 4.4.

Параметр	Значення
Швидкість навчання	0.001
Розмір батчу	16
Кількість епох	20
Оптимізатор	Adam
Функція втрат	Категоріальна перехресна ентропія

Оскільки для цього набору даних виконується задача багатокласової класифікації, необхідно використовувати категоріальну перехресну ентропію (2.3) для обчислення втрат. Також, для запобігання можливого перенавчання моделі за рахунок великої кількості епох, застосовано механізм ранньої зупинки – модель припиняла навчання, якщо значення помилки для валідаційного набору даних не зменшувалось протягом 5 епох на більше чим 0.001. Також, вихід моделі був модифікований, оскільки для радіолокаційних даних є три класи, то в останньому шарі має бути три нейронни – для визначення ймовірності приналежності до кожного з трьох класів.

Після тренування модель була оцінена на тестовій вибірці – створена матриця помилок (Рис.4.18) та обчислені метрики (Табл. 4.5).



Рис.4.18. Матриця помилок для моделі CRNN_3 натренованої на наборі радіолокаційних даних.

Таблиця 4.5.

	precision	recall	F1-score
Клас			
Авто	0.94	0.91	0.93
БПЛА	0.88	0.96	0.92
Люди	1	0.96	0.98

З отриманих результатів класифікації на тестовій вибірці, можна сказати що архітектура CRNN_3 підходить для класифікації радіолокаційних сигналів БПЛА, адже для усіх трьох класів вона продемонструвала високі значення метрик. Найкраще модель розпізнає доплерівські сигнатури людей. Для класу БПЛА модель продемонструвала гарне значення повноти, що означає що модель здатна розпізнавати сигнали БПЛА, в той же час модель досить часто помилково класифікувала сигнали інших класів (особливо авто) як сигнали БПЛА.

В якості модифікацій вдосконаленої моделі CRNN в рамках задачі виявлення дронів за радіолокаційним сигналом було створено дві моделі. Перша модель є спрощеною версією архітектури CRNN_3. В моделі зменшено кількість фільтрів та згорткових блоків за для меншої обчислювальної складності, також були видаленні шари виключення, таким чином модель мала менш глибоку структуру, не потрібну для менш комплексних даних, але в той же час зберігала здатність виділяти значущі ознаки з радіолокаційних даних. Короткий опис архітектури моделі:

- Згорткові шари: модель має два блоки згорткових шарів. У першому блоці використовується шар з 16 фільтрами розміром 3×3 та "same" padding, що дозволяє зберігати початкові розміри даних. Після цього йде шар пулінгу MaxPooling із фільтром 2×2 , який зменшує розміри тензора вдвічі, дозволяючи виділити ключові ознаки. Для стабілізації процесу навчання використовується нормалізація через BatchNormalization. Другий блок має аналогічну структуру, але кількість фільтрів збільшується до 32.
- Рекурентний блок: Після проходження згорткових шарів дані мають тривимірну структуру (висота, ширина, канали), що непридатна для роботи рекурентних шарів. Тому використовується шар Reshape, який перетворює тензор у формат послідовності. Модель включає два двонаправлені LSTM-шари. Перший шар має 32 нейрони та повертає всю послідовність для наступного шару, що дозволяє зберігати часовий контекст на кожному етапі. Другий шар також містить 32 нейрони, але повертає лише фінальний вектор ознак.
- Вихід: Фінальний шар моделі, складається з трьох нейронів із активацією softmax. Він перетворює вихідний вектор ознак у ймовірності належності до кожного з трьох класів.

Спрощена модель була натренована та оцінена на тестовій вибірці (Рис.4.19, Табл.4.6).




Рис. 4.19. Матриці помилок для спрощеної моделі CRNN_3.

Таблиця 4.6.

	precision	recall	F1-score
Клас			
Авто	0.95	0.93	0.94
БПЛА	0.92	0.95	0.93
Люди	0.99	0.98	0.99

За метриками та матрицею помилок можна сказати, що спрощена модель не втратила якості класифікації, а й навпаки краще розрізняє класи авто та БПЛА, крім того має кращий показник precision.

Друга модифікація CRNN_3 (Рис.2.8) була створена з врахуванням особливостей радіолокаційних даних та є вихідною для задачі класифікації радіолокаційних сигналів БПЛА. Розмір фільтрів в згорткових шарах збільшений до (5x5) для кращого виявлення макроструктурних особливостей даних, що є критичним для роботи з радіолокаційними сигналами, де доплерівські спектри відображають масштабні просторові патерни. Аналогічно до попередньої модифікації, модель була

натренована з тими ж гіперпараметрами. Матриця помилок та метрики модифікованої моделі зображені на рисунку 3.20 та таблиці 3.7. 2514 2623




Рис.4.20. Матриця помилок для другої модифікації CRNN_3.

Таблиця 4.7.

	precision	recall	F1-score
Клас			
Авто	0.97	0.91	0.94
БПЛА	0.90	0.97	0.935
Люди	0.99	0.99	0.99

З точки зору виявлення БПЛА дана модель показує найкращий результат, адже має найвище значення recall. Аналогічно до інших версій CRNN_3 модель допускає помилки в диференціації екземплярів класу Авто та БПЛА. Це пов'язано з тим, що Доплерівські сигнатури БПЛА та авто схожі, за рахунок наявності конструкцій, що обертаються та характеру рухів об'єкта.

Висновки до розділу 4

У четвертому розділі було описано серію експериментів проведених для створення та оцінки ефективності методів виявлення безпілотних літальних апаратів (БПЛА) за допомогою глибоких нейронних мереж. Основна увага приділялася вдосконаленню базової архітектури згортково-рекурентної нейронної мережі та її адаптації до різних типів даних.

Результати дослідження підтвердили, що модифікації базової архітектури забезпечують значне покращення точності та надійності моделей. Зокрема для акустичних сигналів найкращі показники продемонструвала модель CRNN_3, що досягла значень accuracy = 98,44%, precision = 97,55%, recall = 99,38% і F1-score = 98,46% на тестовій вибірці. Ця модель була доповнена додатковими згортковими шарами, двонаправленими LSTM-блоками та оптимізованими параметрами регуляризації, що дозволило значно знизити хибно-позитивні спрацьовування та підвищити точність розпізнавання звуків дронів навіть у зашумленому середовищі.

Для радіолокаційних сигналів адаптація архітектури CRNN_3 також показала високі результати. На тестовій вибірці було отримано наступні значення метрик: для класу "БПЛА" precision = 90%, recall = 97%, F1-score = 94%. Модифікована архітектура ефективно працювала з даними формату відстань-Доплер, зберігаючи високу здатність до класифікації трьох класів об'єктів (БПЛА, автомобілі, люди). Експерименти також показали, що вдосконалені моделі CRNN не лише перевершують базову архітектуру на тестовій вибірці, але й демонструють здатність до генералізації, забезпечуючи високу якість класифікації на нових даних. Наприклад, на валідаційних вибірках, що не входили у тренувальний процес, CRNN_3 досягла accuracy = 97,43%, F1-score = 97,37%, precision = 99,61%, recall = 95,23% для акустичних сигналів, що перевищує показники початкової моделі отримані в рамках проведених експериментів та зазначені у статті [19].

Водночас експерименти виявили певні виклики. Наприклад, складність у розпізнаванні БПЛА у випадках схожості з шумами середовища або сигнатурами інших об'єктів, таких як автомобілі, залишається актуальною. Це проявлялося у

незначному збільшенні хибно-негативних результатів. Загалом експерименти підтверджують, що підхід з використанням CRNN є ефективним інструментом для виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів.

Загальні висновки

Кваліфікаційна робота магістра була спрямована на вдосконалення методу виявлення безпілотних літальних апаратів шляхом аналізу акустичних та радіолокаційних сигналів із використанням методів глибокого навчання.

У процесі виконання роботи виконано такі задачі:

- проведено аналіз предметної області, що охоплює особливості акустичних і радіолокаційних сигналів БПЛА, сучасні підходи до їх виявлення, а також існуючі архітектури глибокого навчання що використовуються для цього;
- вдосконалено архітектуру згортково-рекурентної нейронної мережі для аналізу акустичних сигналів БПЛА. Покращення включають додавання двонаправлених LSTM, збільшення глибини згорткових шарів, а також додавання шарів Dropout і Dense, що забезпечило підвищення точності класифікації.
- модифіковано запропоновану архітектуру нейронної мережі для роботи з радіолокаційними сигналами, що дозволяє ідентифікувати БПЛА за допомогою аналізу мікро-Доплерівських сигнатур.

В рамках виконання кваліфікаційної роботи була створена програмна реалізація та проведено експериментальне дослідження запропонованих вдосконалень архітектури згортково-рекурентної мережі. В результаті дослідження було досягнуто покращення точності виявлення сигналів БПЛА. Для задачі класифікації акустичних даних вихідна модель перевершує якість роботи початкової архітектури на тестовій вибірці (Табл. 3.2). На валідаційному наборі акустичних сигналів записаних в умовах реального середовища, модель дає краще результати за метриками: Accuracy на 3,84%, Recall 8,05% та F1-score 4,22%. А також на перевершує на 3,31% та 3,09% Accuracy та 3,09% заявлені в дослідженні. В рамках дослідження модифікації вдосконаленої архітектури для задачі класифікації радіолокаційних даних була досягнуті значення Precision = 90,15%, Recall = 97,27% та F1-score = 93,57% для класу БПЛА та середньою точністю 95,84%.

Результати експериментів демонструють, що запропоновані вдосконалення забезпечують високу якість класифікації акустичних та радіолокаційних сигналів БПЛА та демонструють значні покращення точності у виявленні дронів, про яке можна зробити висновок через зростання метрик Recall та F1-score.

Отримані результати дослідження підтверджують якість вдосконаленого методу виявлення БПЛА. Запропоновані моделі можуть бути покращені та інтегровані в сучасні системи виявлення БПЛА, що відкриває перспективи їх подальшого розвитку.

Перелік посилань

1. A review on Unmanned Aerial Vehicle (UAV) threats assessments / M. S. Ismail et al. *Viii international annual conference “industrial technologies and engineering” (icite 2021)*, Shymkent, Kazakhstan. 2022. URL: <https://doi.org/10.1063/5.0119703> .
2. On the localization of wireless targets: a drone surveillance perspective / I. Bisio et al. *IEEE network*. 2021. P. 1–7. URL: <https://doi.org/10.1109/mnet.011.2000648> .
3. A comprehensive survey of unmanned aerial vehicles detection and classification using machine learning approach: challenges, solutions, and future directions / M. H. Rahman et al. *Remote sensing*. 2024. Vol. 16, no. 5. P. 879. URL: <https://doi.org/10.3390/rs16050879> .
4. Alaparthi V., Mandal S., Cummings M. Machine learning vs. human performance in the realtime acoustic detection of drones. *2021 IEEE aerospace conference*, Big Sky, MT, USA, 6–13 March 2021. 2021. URL: <https://doi.org/10.1109/aero50100.2021.9438533> .
5. Advances and challenges in drone detection and classification techniques: a state-of-the-art review / U. Seidaliyeva et al. *Sensors*. 2023. Vol. 24, no. 1. P. 125. URL: <https://doi.org/10.3390/s24010125> .
6. Amateur Drones Detection: a machine learning approach utilizing the acoustic signals in the presence of strong interference / Z. Uddin et al. *Computer communications*. 2020. Vol. 154. P. 236–245. URL: <https://doi.org/10.1016/j.comcom.2020.02.065> .
7. Robust drone detection for acoustic monitoring applications / M. Ohlenbusch et al. *2020 28th european signal processing conference (EUSIPCO)*, Amsterdam, 18–21 January 2021. 2021. URL: <https://doi.org/10.23919/eusipco47968.2020.9287433> .
8. Acoustic detection of drones through real-time audio attribute prediction / S. Mandal et al. *AIAA scitech 2020 forum*, Orlando, FL. Reston, Virginia, 2020. URL: <https://doi.org/10.2514/6.2020-0491> .
9. Acoustic-Based detection of uavs using machine learning: analysis of distance and environmental effects / D. Tejera-Berengue et al. *2023 IEEE sensors applications symposium (SAS)*, Ottawa, ON, Canada, 18–20 July 2023. 2023. URL: <https://doi.org/10.1109/sas58821.2023.10254127> .
10. Development of an acoustic system for UAV detection / C. Dumitrescu et al. *Sensors*. 2020. Vol. 20, no. 17. P. 4870. URL: <https://doi.org/10.3390/s20174870> .
11. Deep Learning-based drone acoustic event detection system for microphone arrays / Y. Sun et al. *Multimedia tools and applications*. 2023. URL: <https://doi.org/10.1007/s11042-023-17477-1> .

12. A feature engineering focused system for acoustic UAV detection / Y. Wang et al. 2021 *fifth IEEE international conference on robotic computing (IRC)*, Taichung, Taiwan, 15–17 November 2021. 2021. URL: <https://doi.org/10.1109/irc52146.2021.00031> .
13. Kümmritz S. The sound of surveillance: enhancing machine learning-driven drone detection with advanced acoustic augmentation. *Drones*. 2024. Vol. 8, no. 3. P. 105. URL: <https://doi.org/10.3390/drones8030105> .
14. Al-Emadi S., Al-Ali A., Al-Ali A. Audio-Based drone detection and identification using deep learning techniques with dataset enhancement through generative adversarial networks. *Sensors*. 2021. Vol. 21, no. 15. P. 4953. URL: <https://doi.org/10.3390/s21154953> .
15. Acoustic based drone detection via machine learning / C. A. Ahmed et al. 2022 *international conference on IT and industrial technologies (ICIT)*, Chiniot, Pakistan, 3–4 October 2022. 2022. URL: <https://doi.org/10.1109/icit56493.2022.9989229> .
16. Detection and classification of drones through acoustic features using a spike-based reservoir computer for low power applications / A. Henderson et al. 2022 *IEEE/AIAA 41st digital avionics systems conference (DASC)*, Portsmouth, VA, USA, 18–22 September 2022. 2022. URL: <https://doi.org/10.1109/dasc55683.2022.9925735> .
17. A stethoscope for drones: transformers based methods for uavs acoustic anomaly detection / O. H. Anidjar et al. *IEEE access*. 2023. P. 1. URL: <https://doi.org/10.1109/access.2023.3262702> .
18. Casabianca P., Zhang Y. Acoustic-Based UAV detection using late fusion of deep neural networks. *Drones*. 2021. Vol. 5, no. 3. P. 54. URL: <https://doi.org/10.3390/drones5030054> .
19. Drone detection and recognition based on fiber-optic EFPI acoustic sensor and CNN-LSTM network model / R. Ding et al. *IEEE sensors journal*. 2024. P. 1. URL: <https://doi.org/10.1109/jsen.2024.3432622> .
20. Drone detection and recognition based on fiber-optic EFPI acoustic sensor and CNN-LSTM network model / R. Ding et al. *IEEE sensors journal*. 2024. P. 1. URL: <https://doi.org/10.1109/jsen.2024.3432622> .
21. Estimation of number of unmanned aerial vehicles in a scene utilizing acoustic signatures and machine learning / W. A. N. et al. *The journal of the acoustical society of america*. 2023. Vol. 154, no. 1. P. 533–546. URL: <https://doi.org/10.1121/10.0020292> .
22. Aydın İ., Kızılay E. Development of a new Light-Weight Convolutional Neural Network for acoustic-based amateur drone detection. *Applied acoustics*. 2022. Vol. 193. P. 108773. URL: <https://doi.org/10.1016/j.apacoust.2022.108773> .

23. Utebayeva D., Ilipbayeva L., Matson E. T. Practical study of recurrent neural networks for efficient real-time drone sound detection: a review. *Drones*. 2022. Vol. 7, no. 1. P. 26. URL: <https://doi.org/10.3390/drones7010026> .
24. DopeNet: range–doppler radar-based UAV detection using convolutional neural network / A. Aouto et al. *2023 fourteenth international conference on ubiquitous and future networks (ICUFN)*, Paris, France, 4–7 July 2023. 2023. URL: <https://doi.org/10.1109/icufn57995.2023.10200675> .
25. Comparative analysis of radar cross section based UAV recognition techniques / M. Ezuma et al. *IEEE sensors journal*. 2022. P. 1. URL: <https://doi.org/10.1109/jsen.2022.3194527> .
26. Improved drone classification using polarimetric merged-doppler images / B. K. Kim et al. *IEEE geoscience and remote sensing letters*. 2021. P. 1–5. URL: <https://doi.org/10.1109/lgrs.2020.3011114> .
27. Radar-Spectrogram-Based UAV classification using convolutional neural networks / D. Park et al. *Sensors*. 2020. Vol. 21, no. 1. P. 210. URL: <https://doi.org/10.3390/s21010210> .
28. Ren J., Jiang X. A three-step classification framework to handle complex data distribution for radar UAV detection. *Pattern recognition*. 2021. Vol. 111. P. 107709. URL: <https://doi.org/10.1016/j.patcog.2020.107709> .
29. UAV classification based on deep learning fusion of multi-dimensional UAV micro-doppler image features / X. Chen et al. *IEEE geoscience and remote sensing letters*. 2024. P. 1. URL: <https://doi.org/10.1109/lgrs.2024.3371171> .
30. Radar-Based drone detection using complex-valued convolutional neural network / A. Dey et al. *2023 IEEE sensors applications symposium (SAS)*, Ottawa, ON, Canada, 18–20 July 2023. 2023. URL: <https://doi.org/10.1109/sas58821.2023.10254135> .
31. Kumawat H. C., Chakraborty M., Raj A. A. B. DIAT-RadSATNet-A novel lightweight DCNN architecture for micro-doppler based small unmanned aerial vehicle (SUAV) targets' detection & classification. *IEEE transactions on instrumentation and measurement*. 2022. P. 1. URL: <https://doi.org/10.1109/tim.2022.3188050> .
32. Micro-Doppler signature-based detection, classification, and localization of small UAV with long short-term memory neural network / Y. Sun et al. *IEEE transactions on geoscience and remote sensing*. 2020. P. 1–16. URL: <https://doi.org/10.1109/tgrs.2020.3028654> .
33. Exploitation of multipath micro-Doppler signatures for drone classification / P. Zhang et al. *IET radar, sonar & navigation*. 2020. Vol. 14, no. 4. P. 586–592. URL: <https://doi.org/10.1049/iet-rsn.2019.0105> .

34. Echoformer: Transformer architecture based on radar echo characteristics for UAV detection / Y. Yang et al. *IEEE sensors journal*. 2023. P. 1. URL: <https://doi.org/10.1109/jsen.2023.3254525> .
35. Micro-Doppler-Radar-Based UAV detection using inception-residual neural network / H. Le et al. *2020 international conference on advanced technologies for communications (ATC)*, Nha Trang, Vietnam, 8–10 October 2020. 2020. URL: <https://doi.org/10.1109/atc50776.2020.9255454> .
36. Drone detection & classification with surveillance ‘radar on-the-move’ and YOLO / H. Haifawi et al. *2023 IEEE Radar Conference (RadarConf23)*, San Antonio, TX, USA, 1–5 May 2023. 2023. URL: <https://doi.org/10.1109/radarconf2351548.2023.10149588> .
37. Hasan M. M., Chakraborty M., Raj A. A. B. A hyper-parameters-tuned R-PCA+SVM technique for suav targets classification using the range-/micro-doppler signatures. *IEEE transactions on radar systems*. 2023. P. 1. URL: <https://doi.org/10.1109/trs.2023.3322607> .
38. Rahman S., Robertson D. A. Multiple drone classification using millimeter-wave CW radar micro-Doppler data. *Radar sensor technology XXIV*, Online Only, United States, 27 April – 1 May 2020 / ed. by A. M. Raynal, K. I. Ranney. 2020. URL: <https://doi.org/10.1117/12.2558435> .
39. Localization and activity classification of unmanned aerial vehicle using mmwave FMCW radars / P. K. Rai et al. *IEEE sensors journal*. 2021. Vol. 21, no. 14. P. 16043–16053. URL: <https://doi.org/10.1109/jsen.2021.3075909> .
40. Sayed A. N., Ramahi O. M., Shaker G. Frequency-Modulated continuous-wave radar perspectives on unmanned aerial vehicle detection and classification: a primer for researchers with comprehensive machine learning review and emphasis on full-wave electromagnetic computer-aided design tools. *Drones*. 2024. Vol. 8, no. 8. P. 370. URL: <https://doi.org/10.3390/drones8080370> .
41. Comparison of drone classification accuracy for CNN models using UWB radar / M. Kurosaki et al. *2022 Asia-Pacific Microwave Conference (APMC)*, Yokohama, Japan, 29 November – 2 December 2022. 2022. URL: <https://doi.org/10.23919/apmc55665.2022.10000022>.
42. DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range–Doppler radar / I. Roldan et al. *IET radar, sonar & navigation*. 2020. Vol. 14, no. 4. P. 593–600. URL: <https://doi.org/10.1049/iet-rsn.2019.0307> .
43. Audio based drone detection and identification using deep learning / S. Al-Emadi et al. *2019 15th international wireless communications and mobile computing conference (IWCMC)*, Tangier, Morocco, 24–28 June 2019. 2019. URL: <https://doi.org/10.1109/iwcmc.2019.8766732> .

ДОДАТКИ

Додаток А

Світлини наукових публікацій, виконаних при роботі над кваліфікаційною роботою магістра

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

Перелік наукових публікацій:

Байдич В.В. МЕТОД ВИЯВЛЕННЯ БПЛА ЗА АНАЛІЗОМ АКУСТИЧНИХ ТА РАДІОЛОКАЦІЙНИХ СИГНАЛІВ ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ.

Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2024». - Хмельницький, 2024. - С. 26-28

УДК 004.8

Байдич В.В.

*Хмельницький національний університет***МЕТОД ВИЯВЛЕННЯ БПЛА ЗА АНАЛІЗОМ АКУСТИЧНИХ ТА РАДІОЛОКАЦІЙНИХ СИГНАЛІВ ЗАСОБАМИ ГЛИБОКОГО НАВЧАННЯ**

Запропоновано вдосконалення моделі глибокого навчання та метод виявлення БПЛА за аналізом його акустичних та радіолокаційних сигналів. Запропонований метод забезпечує швидке та точне виявлення безпілотних літальних апаратів за допомогою CRNN (згортково-рекурентної нейронної мережі). Це дозволяє ефективно аналізувати аудіо- та радіолокаційні дані за для виявлення БПЛА навіть при складних фонових шумах.

An improvement of the deep learning model and a method for detecting UAVs by analyzing their acoustic and radar signals are proposed. The proposed method provides fast and accurate detection of unmanned aerial vehicles using a convolutional recurrent neural network (CRNN). This allows for effective analysis of audio and radar data for UAV detection even in the presence of complex background noise.

З розвитком безпілотних літальних апаратів та їхньою дедалі більшою інтеграцією в цивільну та військову сфери, проблема виявлення дронів стає все більш актуальною [1, 2]. Можливість застосування БПЛА для різних задач, включно з протиправними діями такими як шпигунство, нелегальна доставка вантажів, терористичні атаки, потребує ефективних методів їх виявлення для організації безпеки та контролю повітряного простору. Використання традиційних систем виявлення дронів часто виявляється недостатнім [3], особливо в умовах реального світу через особливості навколишнього середовища та типи літальних апаратів. Ці фактори можуть спотворювати отримувані сигнали додатковими шумами, що впливає на точність розпізнавання[4]. Методи глибокого навчання, зокрема згортково-рекурентні нейронні мережі (CRNN), пропонують ефективні рішення для аналізу акустичних і радіолокаційних сигналів БПЛА [5, 6]. Моделі цієї архітектури забезпечують швидке та точне виявлення БПЛА, дозволяючи ефективно обробляти візуальне представлення аудіо-сигналів та сигналів радару (спектрограми) [7]. Використання CRNN у цій сфері дозволяє не лише підвищити точність виявлення, а й адаптуватися до різних умов роботи. У міру розвитку цих технологій важливо продовжувати вдосконалювати моделі та пропонувати нові підходи, щоб забезпечити ефективне розпізнавання дронів у реальних умовах та зменшити ймовірність помилок.

Метою роботи є вдосконалення точності існуючих підходів до виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів з використанням засобів

глибокого навчання. Впровадження запропонованого вдосконалення моделі глибокого навчання дозволить значно покращити можливості виявлення дронів у реальному часі, що сприятиме своєчасному реагуванню на потенційні загрози.

В основі запропонованого методу лежить використання згортково-рекурентної нейронної мережі натренованої для задачі виявлення дронів за їх акустичним та радіолокаційним сигналом. Для цього спочатку виконується підготовка набору даних аудіо-записів роботи БПЛА та сигналів радарів [8, 9]. Вибір архітектури CRNN обумовлений її здатністю аналізувати просторово-часові характеристики сигналів та стійкістю до фонових шумів. Вхідними даними для моделі є набори аудіо-записів та цифрове подання сигналів радару розмічених за критерієм наявності на них БПЛА. Перед поданням даних до моделі, виконується попередня обробка даних – створення спектрограм (для акустичних даних) та візуального зображення матриці відстані за ефектом Доплера.

Була виконана модифікація архітектури моделі та її тонке налаштування для покращення результатів, в тому числі з врахуванням конкретного набору та типу даних. Це включало підбір гіперпараметрів, розробку індивідуального навчального плану для підвищення точності класифікації сигналів. Зокрема, було визначено кількість епох навчання, навчальну швидкість (learning rate), та розмір батчів (batch size), щоб уникнути перенавчання моделі на навчальній вибірці.

Після тренування моделей, були обчислені основні метрики для кожного з наборів даних.

Таблиця 1. Значення метрик для оцінки роботи моделей.

	Accuracy	Precision	Recall	F1-scope
Акустичні данні	0,95	1,0	0,89	0,938
Радіо-локаційні	0,94	0,94	0,95	0,947

На основі проведених експериментів, модель для аналізу акустичних сигналів досягла показника ассюрасу 0.95, що демонструє високий рівень точності виявлення БПЛА у порівнянні з іншими дослідженнями, де використовувались моделі на основі архітектури легкої згорткової мережі – 0.93 [10] та моделі трансформер – 0.91 [11].

Для валідації моделі на нових даних було використано додатковий набір аудіо записів роботи БПЛА, що не входили до початкового навчального набору. Модель змогла зберегти високий рівень точності ассюрасу = 0.89, що свідчить про її здатність узагальнювати результати на нових даних. Це підтверджує ефективність моделі для використання в різних середовищах ідентифікації БПЛА.

Також модель для виявлення дронів за аналізом радіолокаційних даних показала високі показники точності. Вони перевершують показники моделей у багатьох попередніх дослідженнях, зокрема моделей на основі попередньо навчених версій Resnet [12].

Таким чином, запропоновані моделі продемонстрували вищу якість класифікації порівняно з іншими дослідженнями, досягнувши показника асигасу 0.95 та 0.94. Вони також забезпечили хорошу продуктивність на нових даних, зберігши високий показник точності. Це свідчить про ефективність даного підходу для ідентифікації безпілотних літальних апаратів у різних умовах, що робить цю модель кращим вибором для вирішення задач виявлення дронів у реальному часі.

Перелік посилань

1. Ahmed F. Recent advances in unmanned aerial vehicles: a review / F. Ahmed, J. C. Mohanta, A. Keshari, P. S. Yadav // *Arabian Journal for Science and Engineering*. — 2022. — Vol. 47, No. 7. — P. 7963–7984.
2. Telli K. A comprehensive review of recent research trends on unmanned aerial vehicles (uavs) / K. Telli, O. Kraa, Y. Himeur, [et al.] // *Systems*. — 2023. — Vol. 11, No. 8. — P. 400.
3. Seidaliyeva U. Advances and challenges in drone detection and classification techniques: a state-of-the-art review / U. Seidaliyeva, L. Pipbayeva, K. Taissariyeva, [et al.] // *Sensors*. — 2023. — Vol. 24, No. 1. — P. 125.
4. Park S. Survey on anti-drone systems: components, designs, and challenges / S. Park, H. T. Kim, S. Lee, [et al.] // *IEEE Access*. — 2021. — Vol. 9. — P. 42635–42659.
5. Al-Emadi S. Audio-based drone detection and identification using deep learning techniques with dataset enhancement through generative adversarial networks / S. Al-Emadi, A. Al-Ali, A. Al-Ali // *Sensors*. — 2021. — Vol. 21, No. 15. — P. 4953.
6. Casabianca P. Acoustic-based uav detection using late fusion of deep neural networks / P. Casabianca, Y. Zhang // *Drones*. — 2021. — Vol. 5, No. 3. — P. 54.
7. Kumawat H. C. DIAT- μ sat: small aerial targets' micro-doppler signatures and their classification using cnn / H. C. Kumawat, M. Chakraborty, A. A. Bazil Raj, S. V. Dhavale // *IEEE Geoscience and Remote Sensing Letters*. — 2022. — Vol. 19. — P. 1–5.
8. Roldan I. DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range-doppler radar / I. Roldan, C. R. del-Blanco, A. Duque De Quevedo, [et al.] // *IET Radar, Sonar & Navigation*. — 2020. — Vol. 14, No. 4. — P. 593–600.
9. GitHub - saraalcmadi/droncaudiodataset / .
10. Aydın İ. Development of a new light-weight convolutional neural network for acoustic-based amateur drone detection / İ. Aydın, E. Kızılay // *Applied Acoustics*. — 2022. — Vol. 193. — P. 108773.
11. Bilal M. Roman urdu hate speech detection using transformer-based model for cyber security applications / M. Bilal, A. Khan, S. Jan, [et al.] // *Sensors*. — 2023. — Vol. 23, No. 8. — P. 3909.
12. Park D. Radar-spectrogram-based uav classification using convolutional neural networks / D. Park, S. Lee, S. Park, N. Kwak // *Sensors*. — 2020. — Vol. 21, No. 1. — P. 210.

Додаток Б

Програмні коди

```

import librosa
import math
import json
import os
from sklearn.model_selection import train_test_split
import tensorflow.keras as keras
import pandas as pd
from datetime import datetime
from termcolor import colored
import numpy as np
import seaborn as sns
from sklearn.metrics import confusion_matrix, classification_report, roc_curve, auc
from sklearn.utils import shuffle
import matplotlib.pyplot as plt
from keras import layers

SAMPLE_RATE = 16000 # Sample rate of 16 kHz
DURATION = 1 # Audio duration in seconds
SAMPLES_PER_TRACK = SAMPLE_RATE * DURATION

def save_mfcc(dataset_path, json_path, n_mels=90, n_fft=2048, hop_length=512, num_segments=1):
    """
    Function to save mel spectrograms from audio files into JSON format.
    """
    data = {
        "mapping": [],
        "mel": [],
        "labels": []
    }

    num_samples_per_segment = SAMPLES_PER_TRACK // num_segments
    expected_num_mel_vectors_per_segment = math.ceil(num_samples_per_segment / hop_length)

    for i, (dirpath, dirnames, filenames) in enumerate(os.walk(dataset_path)):
        if dirpath != dataset_path:
            dirpath_components = dirpath.split("/")
            semantic_label = dirpath_components[-1]
            label = 1 if semantic_label.lower() == "drone" else 0

            data["mapping"].append(semantic_label)

            for f in filenames:
                file_path = os.path.join(dirpath, f)
                signal, sr = librosa.load(file_path, sr=None)
                if sr != SAMPLE_RATE:
                    signal = librosa.resample(signal, orig_sr=sr, target_sr=SAMPLE_RATE)

                for s in range(num_segments):
                    start_sample = num_samples_per_segment * s
                    finish_sample = start_sample + num_samples_per_segment

                    mel = librosa.feature.melspectrogram(
                        y=signal[start_sample:finish_sample],
                        sr=SAMPLE_RATE,
                        n_fft=n_fft,
                        n_mels=n_mels,
                        hop_length=hop_length
                    )
                    db_mel = librosa.power_to_db(mel).T

                    if len(db_mel) == expected_num_mel_vectors_per_segment:
                        data["mel"].append(db_mel.tolist())
                        data["labels"].append(label)

            with open(json_path, "w") as fp:
                json.dump(data, fp, indent=4)

    def load_data(data_path):
        with open(data_path, "r") as fp:
            data = json.load(fp)
            X = np.array(data["mel"])
            y = np.array(data["labels"])
            return shuffle(X, y, random_state=42)

    def prepare_datasets(data_path, test_size, validation_size):
        X, y = load_data(data_path)
        X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=test_size, random_state=42)
        X_train, X_validation, y_train, y_validation = train_test_split(X_train,

```

```

y_train,          test_size=validation_size,
random_state=42)
    return (
        X_train[...],          np.newaxis],
X_validation[...], np.newaxis], X_test[...],
np.newaxis],
        y_train, y_validation, y_test
    )

def undersample_data(X, y):
    class_0_indices = np.where(y == 0)[0]
    class_1_indices = np.where(y == 1)[0]
    minority_class_size =
min(len(class_0_indices),
len(class_1_indices))

    class_0_indices_downsampled =
np.random.choice(class_0_indices,
size=minority_class_size, replace=False)
    class_1_indices_downsampled =
np.random.choice(class_1_indices,
size=minority_class_size, replace=False)

    undersampled_indices =
np.concatenate([class_0_indices_downsampled
, class_1_indices_downsampled])
    return shuffle(X[undersampled_indices],
y[undersampled_indices], random_state=42)

def build_crnn_model(input_shape):
    model = keras.Sequential([
        layers.Conv2D(16, (5, 5),
activation='relu', input_shape=input_shape),
        layers.MaxPooling2D((5, 5),
strides=(2, 2), padding='same'),
        layers.BatchNormalization(),

        layers.Reshape((input_shape[0], -
1)),
        layers.LSTM(32,
return_sequences=True),

        layers.Flatten(),
        layers.Dense(32, activation='relu'),
        layers.Dropout(0.3),

        layers.Dense(2,
activation='softmax')
    ])
    return model

def build_optimized_model(input_shape):
    model = keras.Sequential([
        layers.Conv2D(32, (3, 3),
activation='relu', input_shape=input_shape),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),

        layers.Conv2D(64, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),

        layers.BatchNormalization(),
        layers.Conv2D(128, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),
        layers.Dropout(0.3),

        layers.Reshape((input_shape[0] // 4,
-1)),
        layers.Bidirectional(layers.LSTM(64,
return_sequences=True)),
        layers.Bidirectional(layers.LSTM(64)),

        layers.Dense(128,
activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(64, activation='relu'),
        layers.Dropout(0.5),

        layers.Dense(2,
activation='softmax')
    ])
    return model

def build_model_v2(input_shape):
    model = keras.Sequential([
        layers.Conv2D(32, (3, 3),
activation='relu', input_shape=input_shape),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),

        layers.Conv2D(64, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),

        layers.Reshape((input_shape[0] // 2,
-1)),
        layers.LSTM(64,
return_sequences=False),

        layers.Dense(64, activation='relu'),
        layers.Dropout(0.4),

        layers.Dense(2,
activation='softmax')
    ])
    return model

def build_model_v3(input_shape):
    model = keras.Sequential([
        layers.Conv2D(32, (3, 3),
activation='relu', input_shape=input_shape),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),

        layers.Conv2D(64, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),
        layers.Conv2D(128, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),
        layers.Dropout(0.3),

        layers.Reshape((input_shape[0] // 4,
-1)),
        layers.Bidirectional(layers.LSTM(64,
return_sequences=True)),
        layers.Bidirectional(layers.LSTM(64)),

        layers.Dense(128,
activation='relu'),
        layers.Dropout(0.5),
        layers.Dense(64, activation='relu'),
        layers.Dropout(0.5),

        layers.Dense(2,
activation='softmax')
    ])
    return model

```

```

        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),

        layers.Conv2D(128, (3, 3),
activation='relu'),
        layers.MaxPooling2D((2, 2)),
        layers.BatchNormalization(),
        layers.Dropout(0.3),

        layers.Reshape((input_shape[0] // 4,
-1)),

layers.Bidirectional(layers.LSTM(64,
return_sequences=False)),

        layers.Dense(128,
activation='relu'),
        layers.Dropout(0.4),
        layers.Dense(64, activation='relu'),
        layers.Dropout(0.6),

        layers.Dense(2,
activation='softmax')
    ])
    return model

def compile_and_train(model, X_train,
y_train, X_validation, y_validation,
save_path, epochs=10, batch_size=64):

model.compile(optimizer=keras.optimizers.Ad
am(learning_rate=0.00005),

loss="sparse_categorical_crossentropy",
metrics=['accuracy'])

    callbacks = [

keras.callbacks.EarlyStopping(monitor='val_
loss', patience=5,
restore_best_weights=True),

keras.callbacks.ModelCheckpoint(save_path,
monitor='val_loss', save_best_only=True)
    ]

    history = model.fit(X_train, y_train,
validation_data=(X_validation,
y_validation),

epochs=epochs,
batch_size=batch_size, callbacks=callbacks)
    return history

def plot_training_history(history):
    fig, (ax1, ax2) = plt.subplots(1, 2,
figsize=(12, 5))
    ax1.plot(history.history['loss'],
label='Training Loss')
    ax1.plot(history.history['val_loss'],
label='Validation Loss')
    ax1.set_title('Loss Over Epochs')

    ax1.legend()

    ax2.plot(history.history['accuracy'],
label='Training Accuracy')

ax2.plot(history.history['val_accuracy'],
label='Validation Accuracy')
    ax2.set_title('Accuracy Over Epochs')
    ax2.legend()
    plt.show()

def plot_confusion_matrix(y_true, y_pred,
class_names):
    cm = confusion_matrix(y_true, y_pred)
    sns.heatmap(cm, annot=True, fmt='d',
cmap='Blues', xticklabels=class_names,
yticklabels=class_names)
    plt.xlabel('Predicted')
    plt.ylabel('True')
    plt.title('Confusion Matrix')
    plt.show()

def calculate_metrics(y_true, y_pred):
    accuracy = accuracy_score(y_true,
y_pred)
    precision = precision_score(y_true,
y_pred, average="weighted")
    recall = recall_score(y_true, y_pred,
average="weighted")
    f1 = f1_score(y_true, y_pred,
average="weighted")
    print(f'Accuracy: {accuracy:.2f}')
    print(f'Precision: {precision:.2f}')
    print(f'Recall: {recall:.2f}')
    print(f'F1 Score: {f1:.2f}')

DATA_PATH = "path_to_your_data.json" #
Path to JSON file created from `save_mfcc`
MODEL_SAVE_PATH = "saved_model.h5" # Path
to save the trained model

X_train, X_validation, X_test, y_train,
y_validation, y_test =
prepare_datasets(DATA_PATH, test_size=0.15,
validation_size=0.15)

X_train, y_train =
undersample_data(X_train, y_train)
X_test, y_test = undersample_data(X_test,
y_test)
X_validation, y_validation =
undersample_data(X_validation,
y_validation)

input_shape = X_train.shape[1:] # Shape
for input data
model = build_optimized_model(input_shape)
history = compile_and_train(model, X_train,
y_train, X_validation, y_validation,
save_path=MODEL_SAVE_PATH)

```

```

plot_training_history(history)

y_pred = np.argmax(model.predict(X_test),
axis=1)
plot_confusion_matrix(y_test, y_pred,
class_names=["NO UAV", "UAV"])
calculate_metrics(y_test, y_pred)

=====
=====

def load_data_from_folders(data_path):
    X, y = [], []
    for class_folder in
os.listdir(data_path):
        class_path =
os.path.join(data_path, class_folder)
        if os.path.isdir(class_path):
            for csv_folder in
os.listdir(class_path):
                csv_folder_path =
os.path.join(class_path, csv_folder)
                if
os.path.isdir(csv_folder_path):
                    for file in
os.listdir(csv_folder_path):
                        if
file.endswith('.csv'):
                            file_path =
os.path.join(csv_folder_path, file)
                            data =
pd.read_csv(file_path).values

                                # Ensure the
data shape matches expectations
                                if data.shape
== (10, 61):

X.append(data)

y.append(class_folder)

                                else:

print(f"File {file_path} skipped due to
mismatched shape.")
                                return np.array(X), np.array(y)

def shuffle_dataset(X, y):
    indices = np.arange(X.shape[0])
    np.random.shuffle(indices)
    return X[indices], y[indices]

def build_optimized_model(input_shape):
    model = models.Sequential([
        layers.Conv2D(32, (3, 3),
activation='relu', padding='same',
input_shape=input_shape),
        layers.MaxPooling2D((2, 2),
padding='same'),
        layers.BatchNormalization(),

                                layers.Conv2D(64, (3, 3),
activation='relu', padding='same'),
                                layers.MaxPooling2D((2, 2),
padding='same'),
                                layers.BatchNormalization(),
                                layers.Dropout(0.3),

                                layers.Reshape((input_shape[0] //
4, -1)),

                                layers.Bidirectional(layers.LSTM(64,
return_sequences=True)),
                                layers.Bidirectional(layers.LSTM(64)),

                                layers.Dense(128,
activation='relu'),
                                layers.Dropout(0.5),
                                layers.Dense(64,
activation='relu'),
                                layers.Dropout(0.5),
                                layers.Dense(3,
activation='softmax')
                                ])
    return model

def build_small_crnn(input_shape):
    model = models.Sequential([
        layers.Conv2D(16, (3, 3),
activation='relu', padding='same',
input_shape=input_shape),
        layers.MaxPooling2D((2, 2),
padding='same'),
        layers.BatchNormalization(),

                                layers.Conv2D(32, (3, 3),
activation='relu', padding='same'),
                                layers.MaxPooling2D((2, 2),
padding='same'),
                                layers.BatchNormalization(),

                                layers.Reshape((input_shape[0] //
2, -1)),

                                layers.Bidirectional(layers.LSTM(32,
return_sequences=True)),
                                layers.Bidirectional(layers.LSTM(32)),

                                layers.Dense(3,
activation='softmax')
                                ])
    return model

```

```

def build_improved_crnn(input_shape,
num_classes):
    model = models.Sequential([
        layers.Conv2D(32, (5, 5),
activation='relu', padding='same',
input_shape=input_shape),
        layers.MaxPooling2D((2, 2),
padding='same'),
        layers.BatchNormalization(),

        layers.Conv2D(64, (5, 5),
activation='relu', padding='same'),
        layers.MaxPooling2D((2, 2),
padding='same'),
        layers.BatchNormalization(),
        layers.Dropout(0.3),

        layers.Conv2D(128, (3, 3),
activation='relu', padding='same'),
        layers.MaxPooling2D((2, 2),
padding='same'),
        layers.BatchNormalization(),
        layers.Dropout(0.3),

        layers.Reshape((input_shape[0] //
4, -1)),

layers.Bidirectional(layers.LSTM(64,
return_sequences=True)),
        layers.Dropout(0.3),

layers.Bidirectional(layers.LSTM(32)),
        layers.Dropout(0.3),

        layers.Dense(128,
activation='relu'),
        layers.Dropout(0.4),
        layers.Dense(64,
activation='relu'),
        layers.Dropout(0.4),
        layers.Dense(num_classes,
activation='softmax')
    ])
    return model

data_path = "path_to_radar_data"
X, y = load_data_from_folders(data_path)
X = (X - np.min(X)) / (np.max(X) -
np.min(X)) # Normalize
X = X[... , np.newaxis]

encoder = LabelEncoder()
y = encoder.fit_transform(y)
y = to_categorical(y)

X, y = shuffle_dataset(X, y)
X_train, X_temp, y_train, y_temp =
train_test_split(X, y, test_size=0.3,
random_state=42)
X_val, X_test, y_val, y_test =
train_test_split(X_temp, y_temp,
test_size=0.5, random_state=42)

input_shape = (10, 61, 1)
num_classes = y_train.shape[1]

improved_crnn =
build_improved_crnn(input_shape,
num_classes)
improved_crnn.compile(optimizer=Adam(learnin
g_rate=0.001),
loss='categorical_crossentropy',
metrics=['accuracy'])

history = improved_crnn.fit(
    X_train, y_train,
    epochs=20,
    batch_size=16,
    validation_data=(X_val, y_val),
    callbacks=[
        EarlyStopping(monitor='val_loss',
patience=5, restore_best_weights=True),

ModelCheckpoint('improved_crnn_model.keras'
, save_best_only=True, monitor='val_loss')
    ]
)

test_loss, test_accuracy =
improved_crnn.evaluate(X_test, y_test)
print(f"Test Loss: {test_loss}, Test
Accuracy: {test_accuracy}")

y_pred =
np.argmax(improved_crnn.predict(X_test),
axis=1)
y_true = np.argmax(y_test, axis=1)

print("Classification Report:")
print(classification_report(y_true, y_pred,
target_names=['Car', 'UAV', 'Human']))

plot_confusion_matrix(y_true, y_pred,
class_names=['Car', 'UAV', 'Human'])

improved_crnn.save("improved_crnn_model.ker
as")

```

Додаток В

Презентаційний матеріал

Кваліфікаційна робота магістра

Метод виявлення БПЛА за
аналізом акустичних та
радіолокаційних сигналів
засобами глибокого
навчання

Виконав: студент 2 курсу ОР
«Магістр», група КНм-23-2, Байдич
В.В.

Керівник: Зав. кафедри КН, д.т.н.,
професор, Бармак О. В.

Актуальність теми

Виявлення безпілотних літальних апаратів є важливим напрямком у сучасному світі через зростання використання дронів як у цивільній, так і у військовій сферах. Широка доступність БПЛА сприяють їх застосуванню в різноманітних цілях, зокрема для незаконної діяльності, такої як несанкціоноване спостереження, порушення конфіденційності, контрабанда або нанесення шкоди об'єктам критичної інфраструктури.

Варіативність БПЛА, їхнього функціоналу, методів та середовищ їх використання робить завдання розпізнавання складним та багаторівневим. Сучасні дрони можуть досягати найменших розмірів, використовувати різноманітні стелс-технології для зменшення видимості на багатьох спектрах спостереження, таким чином обробка різних типів сигналів дронів є одним з ключових факторів точного виявлення БПЛА.

Мета роботи

Метою кваліфікаційної роботи магістра є підвищення якості виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання.

Для досягнення мети, були визначені наступні задачі:

- Провести аналіз предметної області для проблеми виявлення БПЛА;
- Провести аналіз існуючих моделей глибокого навчання для виявлення БПЛА;
- Вдосконалити метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання;
- визначити якість запропонованого методу за відомими статистичними показниками та навести порівняння з іншими відомими підходами

Об'єкт та предмет дослідження

Об'єкт дослідження.
процес виявлення БПЛА
за аналізом акустичних та
радіолокаційних сигналів
за моделлю глибокого
навчання

Предмет дослідження.
Моделі глибокого
навчання для аналізу
акустичних та
радіолокаційних даних.


Наукова новизна

В результаті проведеної роботи було отримано наступний результат:


Удосконалено метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання, який відрізняється від існуючих вдосконаленням архітектури шляхом збільшення кількості згорткових шарів, використанням послідовних шарів двонаправлених LSTM, доповненням додатковими шарами Dropout та Dense, що дозволило забезпечити високу якість класифікації для різних типів сигналу.

Найкращі показники точності та повноти отримані в ході роботи: для аудіо-сигналу - **97,43%**, та **95,23%**, для сигналу радару - **95,84%** та **97,27%**.


Аналіз наборів даних акустичних та радіолокаційних сигналів. Розподіл даних по класам.



Тренувальний набір,
акустичних даних




Валідаційний набір
акустичних даних




Набір
радіолокаційних
даних

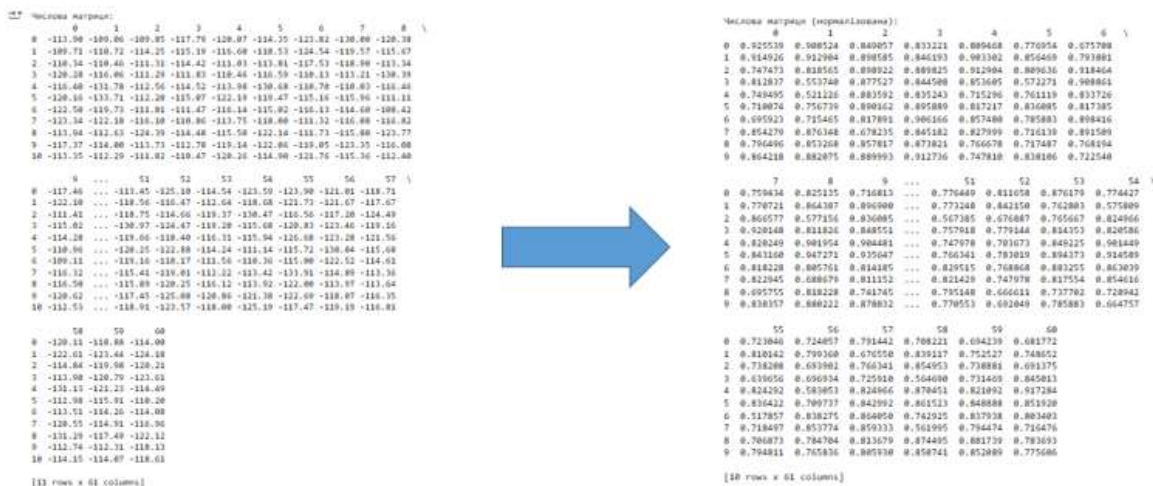
Попередня обробка акустичних даних




Збалансування набору даних




Попередня обробка радіолокаційних даних




Початкова CRNN для аналізу акустичних даних




Вдосконалена версія згортково-рекурентної нейронної мережі CRNN_1



Вдосконалена версія згортково-рекурентної нейронної мережі CRNN_2



Вдосконалена версія згортово-рекурентної нейронної мережі CRNN_3




Результати роботи початкової та вдосконалених архітектур CRNN на тестовій вибірці


	Початкова CRNN	CRNN 1	CRNN 2	CRNN 3
Метрики				
Accuracy	0.93	0.97	0.97	0.98
Precision	0.94	0.97	0.97	0.97
Recall	0.93	0.97	0.97	0.99
F1-score	0.93	0.97	0.97	0.98

Результати роботи початкової та вдосконаленої архітектури CRNN_3 на валідаційному датасеті

Матриця помилок для початкової CRNN




Матриця помилок для вдосконаленої CRNN_3




Модель	Accuracy	Precision	Recall	F1-score
Початкова CRNN	0.9359	1	0.8718	0.9315
Вдосконалена CRNN_3	0.9743	0.9961	0.9523	0.9737

Модифікації архітектури CRNN_3 для задачі виявлення БПЛА за аналізом радіолокаційних сигналів




CRNN_4



CRNN_5


Результати роботи CRNN_3 та модифікацій на тестовій вибірці

CRNN_3




	precision	recall	F1-score
Клас			
Авто	0.94	0.91	0.93
БПЛА	0.88	0.96	0.92
Люди	1	0.96	0.98

CRNN_4



	precision	recall	F1-score
Клас			
Авто	0.95	0.93	0.94
БПЛА	0.92	0.95	0.93
Люди	0.99	0.98	0.99

CRNN_5



	precision	recall	F1-score
Клас			
Авто	0.97	0.91	0.94
БПЛА	0.90	0.97	0.935
Люди	0.99	0.99	0.99

Дякую за увагу!

Thu Dec 05 15:02:11 EET 2024, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

Anti-Plagiarism v-15.258 Educational

Максимальне співпадіння з одним документом 1.0%

Словники перевірки: en_US, ru_RU, ua_UA. Помилки в документах: 14%

ID: 154803 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання Додано в БД: 2024-12-05 Автора: Володимир БАЙДІЧ Керівники: Олександр БАРМАК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	104160	1534	2295 (2%)	34 (2%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

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

Автор: Володимир БАЙДИЧ

Співавтор:

Назва: Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання

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

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 1.1%

Коефіцієнт подібності 2: 0.7%

Мікропробіли: 0

Заміна букв: 1

Інтервали: 0

Білі знаки: 1

Дата створення звіту: 2024-12-05 14:13:58.0

Після аналізу Звіту подібності констатую наступне:

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

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

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

Обґрунтування:

Дата 5.12.2024

експерт

Л.А. Петровський Р.Р.

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ
КАФЕДРИ КОМП'ЮТЕРНИХ НАУК
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ МАГІСТРА ДО ЗАХИСТУ ЗА
РЕЗУЛЬТАТАМИ АНАЛІЗУ ЗВІТУ ПОДІБНОСТІ

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

Назва: Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання

Автор: Володимир БАЙДИЧ

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

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

Після аналізу звіту подібності зроблено такий висновок:

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

Підтвердження:

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




- 1) за програмою Anti-Plagiarism виявлені 1% запозичень вказують на відомі терміни.
- 2) За програмою StrikePlagiarism виявлені запозичення (КП1=1.1% та КП2=0.7%) є фрагментарними – містять поширені конструкції та схеми (у роботі вказані посилання на ці джерела), загальновідомі терміни, скорочення та визначення.

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

Керівник роботи

Гарант ОП

Завідувач кафедри КН

О. В. Бармак

Р. В. Багрій

О. В. Бармак



ВІДГУК НАУКОВОГО КЕРІВНИКА

на кваліфікаційну роботу магістра

гр. КНм-23-2 Володимира БАЙДИЧА за темою: Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання

1. Актуальність теми

Виявлення БПЛА є важливим напрямком дослідження через зростання їхнього використання як у цивільній, так і у військовій сферах. Широка доступність та функціональність БПЛА сприяють їх застосуванню з різноманітною метою, зокрема для незаконної діяльності, такої як несанкціоноване спостереження, порушення конфіденційності, контрабанда або нанесення шкоди об'єктам критичної інфраструктури. У зв'язку з цим, задача розпізнавання БПЛА є надзвичайно важливою з точки зору мінімізації потенційної шкоди, що може бути нанесена живим та неживим об'єктам з використанням дронів. Особливої актуальності ця проблема набуває в сучасних реаліях держави, що знаходиться в стані війни.

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

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

3. Професійні та особистісні якості магістранта

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

4. Ступінь самостійності під час виконання кваліфікаційної роботи

У ході роботи магістрант проявив достатній ступінь самостійності. Зокрема, ним особисто було: проведено аналіз існуючих підходів до виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання; вдосконалено метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів за моделлю глибокого навчання; визначено якість запропонованого методу за відомими статистичними показниками та проведено порівняння з іншими відомими підходами.

5. Наукова новизна та оригінальність запропонованих підходів

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

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

6. Ступінь оволодіння методами дослідження

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

7. Повнота та якість розкриття теми роботи

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

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

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

9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Робота має теоретико-прикладний характер. Результати роботи можна застосовувати у системах для виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів.

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

Рекомендую допустити роботу до захисту.

Кваліфікаційна робота заслуговує на оцінку «Добре».

Науковий керівник _____ д.т.н., проф. Олександр Бармак



ВІДГУК ОПОНЕНТА

на кваліфікаційну роботу магістра

гр. КНм-23-2 Володимира БАЙДИЧА за темою: Метод виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів засобами глибокого навчання

1. Актуальність обраної теми

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

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

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

3. Повнота розкриття мети та завдань дослідження

Часткові завдання дослідження сформульовані коректно та повністю відповідають меті роботи.

4. Наявність наукової новизни

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

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

5. Зміст кожного розділу роботи

Робота складається з чотирьох розділів.

У першому розділі – «Аналіз сучасного стану у використанні методів глибокого навчання для виявлення БПЛА» автором проведено аналіз предметної області, існуючих публікацій, щодо виявлення БПЛА та моделей глибокого навчання, що використовуються для виявлення дронів.

У другому розділі – «Вдосконалення методу виявлення БПЛА за аналізом акустичних та радіолокаційних сигналів» магістрантом удосконалено метод виявлення БПЛА за аналізом

акустичних сигналів за моделлю глибокого навчання та модифіковано даний метод для задачі аналізу радіолокаційних сигналів.

У третьому розділі – «Основні кроки методу по вдосконаленню та використанню згортково-рекурентної мережі» автором описана послідовність дій виконаних для вдосконалення та модифікації згортково-рекурентної мережі для виявлення БПЛА, а також кроки використання вдосконаленої мережі для аналізу акустичних та радіолокаційних сигналів.

У четвертому розділі – «Експериментальна валідація запропонованого вдосконалення методу виявлення БПЛА» магістрантом проведено оцінку ефективності вдосконаленого авторського методу. В якості результатів, що порівнювались із запропонованим методом з удосконаленою архітектурою, ним вдало обрано існуючі моделі згортково-рекурентних мереж, натреновані на наборах даних, що були використані для навчання вдосконаленої мережі.

6. Ступінь розкриття теми роботи

Тема роботи розкрита достатньою мірою та мета досягнута.

7. Якість оформлення кваліфікаційної роботи

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

8. Недоліки кваліфікаційної роботи

Разом з тим, у роботі є і певні недоліки. Так, у роботі відсутні відповіді на питання щодо ефективності авторського удосконалення на інших наборах даних, крім тих, що досліджені в магістерській роботі.

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

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

Рекомендую допустити роботу до захисту.

Кваліфікаційна робота заслуговує на оцінку «Добре».

Опонент (прізвище, імя, по батькові, посада, місце роботи)

Мартишов Валерій Володимирович,
Зав. кафедр. АКІТя Р

«09» грудня 2024 р.


Підпис