

# КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

магістр

(назва освітнього ступеня)

на тему: Метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі

Виконав(ла): студент(ка) 6 курсу, групи РРм-61  
спеціальності 172 Телекомунікації та радіотехніка

(шифр і назва спеціальності)

(підпис)

Атаманчук А.В.

(прізвище та ініціали)

Керівник

(підпис)

Дедів І.Ю.

(прізвище та ініціали)

Нормоконтроль

(підпис)

Хвостівська Л.В.

(прізвище та ініціали)

Завідувач кафедри

(підпис)

Дунець В.Л.

(прізвище та ініціали)

Рецензент

(підпис)

Тимків П.О.

(прізвище та ініціали)

Міністерство освіти і науки України  
Тернопільський національний технічний університет імені Івана Пулюя

Факультет прикладних інформаційних технологій та електроінженерії  
(повна назва факультету)  
Кафедра радіотехнічних систем  
(повна назва кафедри)

ЗАТВЕРДЖУЮ  
Завідувач кафедри  
Дунець В.Л.  
(підпис) (прізвище та ініціали)  
« » 2022 р.

### ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня магістр  
(назва освітнього ступеня)  
за спеціальністю 172 Телекомунікації та радіотехніка  
(шифр і назва спеціальності)  
студенту Атаманчуку Андрію Володимировичу  
(прізвище, ім'я, по батькові)

1. Тема роботи Метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі

Керівник роботи Дедів Ірина Юріївна, к.т.н., доц.  
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від « 6 » грудня 2022 року № 4/7-989

2. Термін подання студентом завершеної роботи \_\_\_\_\_

3. Вихідні дані до роботи Об'єкт дослідження: процес виявлення та ідентифікації БПЛА.  
предмет дослідження: метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

4. Зміст роботи (перелік питань, які потрібно розробити)

1. Аналітична частина

2. Основна частина

3. Науково-дослідна частина

4. Охорона праці та безпека в надзвичайних ситуаціях

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень, слайдів)  
Актуальність роботи

1. Порівняння методів виявлення БПЛА

2. Структура методу виявлення та ідентифікації БПЛА

3. Навчання CNN моделі

4. Результати методу виявлення та ідентифікації БПЛА

5. Дослідження акустичних спектрів звуків БПЛА та фону

6. Наукова новизна

7. Загальні висновки



## АНОТАЦІЯ

Тема кваліфікаційної роботи: «Метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі» // Кваліфікаційна робота // Атаманчук Андрій Володимирович // Тернопільський національний технічний університет імені Івана Пулюя, факультет прикладних інформаційних технологій та електроінженерії, група РРм-61 // Тернопіль, 2022 // с. – 89, рис. – 26, табл. – 7, додат. – 3, бібліогр. – 33.

Ключові слова: БПЛА, НЕЙРОННА МЕРЕЖА, МЕТОДИ ВИЯВЛЕННЯ, СПЕКТРОГРАМА, МЕТОДИ ІДЕНТИФІКАЦІЇ, АКУСТИЧНИЙ СПЕКТР.

У роботі розроблено метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

Проведено огляд сучасних методів виявлення безпілотних літальних апаратів. Зроблено порівняльну характеристику методів виявлення, проаналізовано переваги і недоліки кожного методу. Проаналізовано основні види акустичного виявлення.

Проаналізовано методи акустичного виділення акустичних ознак та розпізнавання БПЛА. Визначено ефективні методи для вирішення поставленого завдання: метод виділення - Mel спектрограма, та метод ідентифікації згортокова нейронна мережа(CNN). Розроблено та реалізовано код в програмному забезпеченні Python .

Досліджено акустичні спектри звуків: БПЛА та фонових звуків в програмному середовищі Matlab.

## ANNOTATION

Theme of qualification work: "Method of detection and identification UAV with using a neural network " // Qualification work // Atamanchuk Andrii // Ternopil Ivan Puluj National Technical University, Faculty of Applied Information Technologies and Electrical Engineering, group RRM-61 // Ternopil, 2022 // p. – 89, fig. – 26, tab. – 7, Add – 3, Ref. – 33.

Key words: UAV, NEURAL NETWORK, DETECTION METHODS, SPECTROGRAM, IDENTIFICATION METHODS, ACOUSTIC SPECTRUM.

In the work, a method of UAV detection and identification using a neural network was developed.

An overview of modern methods of detecting unmanned aerial vehicles was conducted. A comparative description of detection methods was made, the advantages and disadvantages of each method were analyzed. The main types of acoustic detection are analyzed.

The methods of acoustic identification of acoustic features and recognition of UAVs are analyzed. Effective methods for solving the task have been identified: the selection method - Mel spectrogram, and the convolutional neural network (CNN) identification method. Developed and implemented code in Python software.

Acoustic spectra of sounds: UAVs and background sounds were studied in the Matlab software environment.

## ЗМІСТ

ВСТУП.....	9
РОЗДІЛ 1. АНАЛІТИЧНА ЧАСТИНА .....	11
1.1. БПЛА. Типи БПЛА .....	11
1.1.1. Багатороторні дрони .....	11
1.1.2. Безпілотники з нерухомим крилом .....	12
1.1.3. Однороторні гелікоптерні дрони .....	13
1.1.4. Гібридні дрони VTOL з нерухомим крилом .....	14
1.2. Технічні характеристики досліджуваних БПЛА.....	15
1.2.1. Shahed-136.....	15
1.2.2. DJI Mavic Pro Platinum.....	17
1.3. Методи виявлення БПЛА .....	18
1.4. Акустичні методи виявлення .....	21
1.4.1. Пасивне акустичне виявлення БПЛА .....	22
1.4.2. Активне акустичне виявлення БПЛА .....	23
1.5. Висновок до розділу 1.....	24
РОЗДІЛ 2. ОСНОВНА ЧАСТИНА .....	26
2.1. Методи виділення акустичних ознак .....	26
2.1.1. Ознаки області часу .....	26
2.1.2. Ознаки частотної області.....	27
2.1.3. Кепстральні ознаки .....	28
2.1.4. Спектрограми.....	31
2.2. Методи ідентифікації.....	34
2.2.1. Dynamic Time Warping .....	34
2.2.2. Прихована модель Маркова .....	35

	7
2.2.3. Vector Quantization .....	35
2.2.4. Метод опорних векторів .....	36
2.2.5. Модель гаусових сумішей .....	38
2.2.6. Штучні нейронні мережі .....	39
2.3. Види нейронних мереж .....	41
2.3.1. Штучні нейронні мережі прямого зв'язку .....	42
2.3.2. Персептрон .....	45
2.3.3. Багатошаровий персептрон .....	46
2.3.4. Мережі з радіальною базовою функцією .....	47
2.3.5. CNN .....	50
2.3.6. RNN .....	51
2.4. Висновок до розділу 2 .....	53
РОЗДІЛ 3. НАУКОВО-ДОСЛІДНА ЧАСТИНА .....	54
3.1. Метод виявлення та ідентифікації БПЛА .....	54
3.1.1. База даних .....	55
3.1.2. Навчання нейронної мережі .....	57
3.1.3. Результати .....	58
3.2. Дослідження акустичного спектру БПЛА .....	61
3.3. Висновок до розділу 3 .....	64
РОЗДІЛ 4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ .....	65
4.1. Охорона праці .....	65
4.2. Безпека в надзвичайних ситуаціях .....	67
4.3. Висновки до розділу 4 .....	71
ЗАГАЛЬНІ ВИСНОВКИ .....	73
ПЕРЕЛІК ПОСИЛАНЬ .....	74

	8
ДОДАТКИ.....	77
ДОДАТОК А. Копія тези.....	78
ДОДАТОК Б. Код виявлення та ідентифікації БПЛА.....	82
ДОДАТОК В. Скрипт дослідження акустичного спектру.....	88



## ВСТУП

**Актуальність роботи.** На сьогоднішній день, в умовах коли на території України відбуваються жорстокі воєнні дії, дуже важливим є виявити та знешкодити ворожі безпілотні літальні апарати (БПЛА), які застосовують: для проведення повітряної розвідки: тактичної і стратегічної, для коригування вогневих ударів по наземних цілях, так і самі вогневі удари дронами-камікадзе.

Для виявлення БПЛА в теперішніх умовах використовують такі методи: оптичний, радіолокаційний, радіочастотний, інфрачервоний, лідар та акустичний. Кожен з методів має, як позитивні сторони, так і недоліки. Наприклад, при застосуванні оптичного методу, камери інколи можуть не ідентифікувати наявність БПЛА, оскільки, безпілотники бувають дуже малих розмірів та можуть маскуватись в навколишньому середовищі, радары також не можуть виявити БПЛА, через те що сигнали від малої цілі не відбиваються, а автономні дрони, які рухаються по GPS, обходять радіовиявлення. Також, більшість методів відрізняються високою вартістю обладнання, яке використовується для виявлення та ідентифікації БПЛА та умовою наявності прямої видимості безпілотника.

Традиційні види озброєння ППО розраховані на великі і віддалені цілі, в той час як сучасні безпілотники складаються з нано-, мікро- і міні-апаратів, що літають на малих висотах. Тому, розробка методів виявлення та ідентифікації БПЛА є актуальним завданням.

**Метою роботи** є метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

Завдання дослідження:

1. Провести огляд та аналіз існуючих на даний момент методів виявлення та ідентифікації БПЛА;
2. Проаналізувати методи виділення ознак і ідентифікації.
3. Розробити метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

4. Розробити засіб (програмний код) виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

5. Визначити ефективність розробленого методу.

6. Провести аналіз спектру звуків БПЛА.

**Об'єкт дослідження.** Процес виявлення та ідентифікації БПЛА.

**Предмет дослідження.** Метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

**Методи дослідження:** згорткові нейронні мережі, спектральні методи обробки звуку.

**Практичне значення.** Отримані результати можуть бути використані для розробки і проектування систем оповіщення, виявлення та знешкодження ворожих БПЛА.

**Наукова новизна отриманих результатів.** Обґрунтовано застосування нейронної мережі для виявлення та ідентифікації БПЛА що підвищує точність виявлення.

**Публікації.** Викладені в роботі результати доповідалися та обговорювалися на 11-ій міжнародній Науково-технічній конференції «Актуальні задачі сучасних технологій» (м. Тернопіль, 7-8 грудня 2022 р.)

## РОЗДІЛ 1

### АНАЛІТИЧНА ЧАСТИНА

#### 1.1. БПЛА. Характеристики БПЛА

Безпілотний літальний апарат (БПЛА) який керується автономно, або за допомогою дистанційного керування і має датчики, цілевказівники, наступальні боєприпаси або електронні передавальні пристрої, призначені для створення перешкод або знищення цілей противника. Не обтяжені екіпажем, системами життєзабезпечення та вимогами щодо безпеки пілотованих літальних апаратів, БПЛА можуть бути надзвичайно ефективними, пропонуючи значно більшу дальність і витривалість, ніж еквівалентні пілотовані системи [1].

Безпілотний літальний апарат (скор. UAV) — літальний апарат, який може виконувати політ, літати і приземлятися без фактичної наявності людини на борту. Політ і зліт БПЛА можливо виконувати віддаленим управлінням оператора, як дистанційний літальний апарат, або з різномоманітним рівнем автономності, як от поміч автопілоту аж до повного самостійного управління, яке не вимагає втручання людини. Залежності від типу управління, бувають такі типи безпілотних літальних систем:

- дистанційно-пілотовані БПЛА;
- некеровані БПЛА;
- автоматичні БПЛА.

Типи дронів за типом крил:

- багатороторні дрони;
- безпілотники з нерухомим крилом;
- однороторні гелікоптерні дрони;
- гібридні дрони VTOL з нерухомим крилом.

##### 1.1.1. Багатороторні дрони.

Багатороторні дрони, також відомі як гвинтокрилі, є найбільш широко використовуваним типом дронів для рекреаційного та професійного

використання. Їх невеликий розмір і чудове керування роблять багатороторні дрони найкращим вибором для аерофотозйомки. На рис. 1.1 зображено багатороторний дрон.



Рис. 1.1. Зовнішній вигляд багатороторного дрону.

Пропонуючи велику універсальність, вони дозволяють встановлювати всі типи камер для виконання різних завдань. Це безпілотники, які можуть легко зависати та злітати вертикально, що також додає більше гнучкості .

Однак найбільший недолік багатороторних дронів зазвичай пов'язаний з автономністю польоту, яку вони пропонують. Додавання додаткових роторів ускладнює керування дроном. Усі ці рухомі частини також споживають додаткову енергію, розряджаючи акумулятор швидше. Більшість багатороторних дронів мають час польоту менше години. Якщо ми хочемо виконувати певні завдання, які займають багато часу, нам потрібно мати кілька акумуляторів, щоб їх замінити. Це також означає додаткові витрати.

#### 1.1.2. Безпілотники з нерухомим крилом

Безпілотники з нерухомим крилом здатні використовувати повітря та генерувати сили, які дозволяють їм залишатися в повітрі, використовуючи переваги своєї аеродинаміки. Вони подібні за дизайном або естетикою до радіокерованих літальних апаратів і часто використовуються для картографування великих територій завдяки своїй великій автономності. Вони використовують переваги своєї аеродинаміки та дизайну, щоб утримувати їх на

плаву, а це означає, що вони мають більшу витривалість і швидкість польоту. На рис. 1.2 зображено безпілотник з нерухомим крилом.



Рис. 1.2. Зовнішній вигляд безпілотника з нерухомим крилом.

Недоліком безпілотників з нерухомим крилом є те, що вони, як правило, дорожчі порівняно з багатороторними дронами. Їм потрібен великий вільний простір для зльоту та посадки, як і літакам. Деякі більші моделі також вимагають спеціалізованого наземного обладнання, щоб допомогти їм злетіти та приземлитися. Крім того, дрони з нерухомим крилом можуть літати лише вперед, тому вони не пропонують такої ж маневреності, як багатороторні дрони.

### 1.1.3. Однороторні гелікоптерні дрони

Потужні та довговічні однороторні безпілотні літальні апарати за своєю конструкцією та дизайном схожі на справжні вертольоти, лише з одним ротором, який забезпечує потужність, а також хвостом для контролю напрямку та стабільності. Поєднуючи в собі переваги крихитних багатороторних дронів і однороторних дронів, вони краще підходять для перевезення більшого корисного навантаження та літають ефективніше, ніж багатороторні. У однороторних апаратах зазвичай використовуються газові двигуни, а не батареї, що значно збільшує час їх польоту. На рис. 1.3 зображено гелікоптерний дрон.



Рис. 1.3. Зовнішній вигляд гелікоптерного дрону.

Однак ці дрони, як правило, більші та складніші за інші типи БПЛА. Це означає, що вони дорожчі та важчі в експлуатації, а їхні великі леза можуть зробити їх більш небезпечними.

#### 1.1.4. Гібридні дрони VTOL з нерухомим крилом

Гібридні безпілотні літальні апарати VTOL з нерухомим крилом, як остання технологія безпілотних літальних апаратів, відносяться до літальних апаратів з нерухомим крилом, які були модифіковані для вертикального зльоту та посадки. Вони поєднують дальність і час польоту БПЛА з нерухомим крилом із можливістю вертикального зльоту гвинтокрилих пристроїв, усуваючи недоліки БПЛА з нерухомим крилом, які потребують великого простору для зльоту та посадки. Вони призначені для картографування, спостереження, сільського господарства та рятувальних операцій. На рис 1.4 зображено гібридний безпілотник.



Рис. 1.4. Зовнішній вигляд гібридного безпілотника.

## 1.2. Технічні характеристики досліджуваних БПЛА

### 1.2.1. Дрон-камікадзе Shahed 136

Shahed 136 — це іранський безпілотний літальний апарат (безпілотник-смертник). Цей безпілотник був розроблений Shahed Aviation Industries і виготовлений HESA. У 2019 році цей дрон був запущений з Ірану проти саудівського нафтового заводу. Офіційно Shahed 136 перебуває на озброєнні Ірану з 2021 року. У 2022 році велика кількість цих безпілотників була експортована до росії, де Shahed 136 відомий як Geran 2. У 2022 році росіяни широко використовували ці безпілотники-смертники проти цілей в Україні.[2]

Основне призначення цього безпілотника - атакувати нерухомі наземні цілі, координати яких відомі. Він вдаряє по заданих координатах. Цей дрон неефективний проти рухомих цілей.

Цей дрон має дельтоподібну форму крила. Він нагадує менший Shahed 131 і відрізняється головним чином стабілізаторами кінцівок крила. Використовує поршневий двигун MADO MD-550, що розвиває 50 к.с. Це іранська копія німецького Limbach L550E. Двигун знаходиться ззаду і штовхає дрон вперед. Максимальна швидкість становить близько 185 км/год. Точна дальність польоту цього безпілотника невідома, хоча різні оцінки коливаються від 1000 км до 2500 км. Стеля польоту до 4 км. Shahed 136 має осколково-фугасну боєголовку. Його вага становить від 36 до 50 кг. Тож за фугасною силою він перевершує 155-мм артилерійський снаряд.

Дрон запускається зі стійки, яка вміщує 5 таких дронів. Сійка може бути встановлена на вантажний автомобіль. У дорожньому стані він виглядає як стандартна логістична вантажівка з брезентовим покриттям. Shahed 136 запускається майже горизонтально та використовує ракетний зліт.

Експертиза розбитих і збитих в Україні безпілотників показала, що у своїй конструкції використовується ряд західних і китайських комплектуючих. Українці повідомляють, що в ньому використовується комп'ютерний процесор

американської корпорації "Альтера", але без жодних позначень. Так Ірану вдалося подолати санкції та отримати життєво важливі компоненти для своїх безпілотників, які не продаються широкому загалу.

Дрон не має дистанційного керування. Натомість він має просту інерціальну навігаційну систему з системою GPS споживчого класу, щоб вразити ціль. В ході оперативного використання встановлено, що Shahed 136 стійкий до протидронних гвинтівок і систем радіоелектронної боротьби.

Shahed 136 не настільки ефективний проти військових цілей, оскільки він великий, повільний і шумний. Його поршневий двигун видає характерний звук газонокосарки чи мопеда. Українці прозвали ці дрони «літаючими мопедами». Його можна почути на значних відстанях. Деякі джерела припускають, що цей дрон був спеціально розроблений для знищення цивільної інфраструктури, а не військових цілей.

Shahed 136 досить недорогий. Ціна одиниці невідома, але оцінки варіюються від \$20 000 до \$50 000. Насправді це невелика сума, враховуючи, яку шкоду такий дрон може завдати цивільній інфраструктурі. Крім того, ракета «земля-повітря», щоб збити цей дрон, коштуватиме дорожче, ніж ціна цього дрона. Рій цих безпілотників може просто витратити ракети систем ППО. Це вигідно для ворогів, оскільки захисник витратить значно більше на захист від цих безпілотників традиційними методами. На рис. 1.5 зображено Shahed-136.



Рис. 1.5. Зовнішній вигляд дрона-камікадзе Shahed-136.



Технічні характеристики Shahed-136 приведені у табл. 1.1.

Таблиця 1.1

### Shahed-136

Довжина корпусу	3,5м
Довжина розмаху крил	2,5 м
Вага апарату	200 кг
Вага бойової частини	30-50 кг
Радіус ураження осколками	понад 100м
Тип двигуна	двотактний
Об'єм двигуна	550 куб. см
Швидкість	до 185 км/год
Дальність	до 2000 км.
Висота	до 5 км.
Період баражування	10-12 годин
Тип навігації	супутникова + інерційна
Вартість	від 20 до 50 тисяч доларів.

#### 1.2.2. DJI Mavic Pro Platinum

DJI Mavic Pro Platinum – це компактний високотехнологічний квадрокоптер, з дистанційним керуванням для особистого та комерційного використання аерофотозйомки та відеозйомки, випущених китайською технологічною компанією DJI. В своєму складі він має 24 високопродуктивних процесорних ядер, високошвидкісний бездротовий зв'язок, який може передавати дані до 7000 м, оптична камера розташована на трьох осьовому стабілізаторі, може знімати відео в якості 4К. Тривалість польоту до 27 хвилин, при цьому зменшено шум на 4дБ (60%) при зльоті та посадці [3]. На рис. 1.6 зображено DJI Mavic Pro Platinum.



Рис. 1.6. Зовнішній вигляд квадрокоптера DJI Mavic Pro Platinum.

Технічні характеристики DJI Mavic Pro Platinum приведені у табл. 1.2.

Таблиця 1.2

### DJI Mavic Pro Platinum

Максимальна швидкість польоту	65 км / год
Максимальна швидкість піднімання	5 м/с
Практична стеля літального апарату	5 км
Час польоту	до 30 хв.
Дальність польоту	до 15 км (без вітру)
Система навігації	GPS / Глонасс
Частота керування	2.4 - 2.483 ГГц
Дальність передачі сигналу	до 7 км (FCC), 4 км (CE)
Вага апарату	0.743 кг
Робоча температура	0 - 40С
Ємність акумулятора	2970 mAh
Сенсор	1 / 2.3 "(CMOS), 12.35 MPx
Режими знімання відео	4K / 30р, HD / 120р
Стабілізація	3-осьова (pitch, roll, yaw)

### 1.3. Методи виявлення БПЛА

Кожному безпілотнику, властиві ознаки, які роблять його видимим для спостереження. Рівень помітності літального апарату визначають значенням його сигналів в інфрачервоному (ІЧ), радіочастотному, і видимому діапазонах спектру, а також звуковою сигнатурою. Сучасні не важкі БПЛА виготовляють з використанням епоксидних матеріалів та пластику зі спеціальним забарвленням

і особливою поєднанням шарів; малі бензинові двигуни або електродвигуни випромінюють небагато тепла [4].

Велика кількість можливих варіантів побудови і використання засобів спостереження в кожному з можливих каналів виявлення обумовлює труднощі оцінювання їх ефективності.

Акустичний канал. Узагальнений спектр звукового випромінювання тактичного безпілотного літального апарату обумовлений гармонійними і широкосмуговими складовими. В звуковий спектр входять гармонійні складові шуму: двигуна, обертів лопаті, механізмів БПЛА, а також низькочастотну і високочастотну складові випромінювання двигуна з безперервними по частоті спектрами [5].

Оптичний канал [6]. Оптичне виявлення безпілотників дуже залежить від факторів зовнішнього середовища. Завдяки зуженню поля зору, зменшення зони огляду і збільшення часу пошуку відбувається збільшення дальності виявлення. Тому візуальні сенсори є недієвими приладами для проведення пошуку. При надходженні зовнішніх цілевказівок від більш дієвого пошукового засобу оптичні сенсори можуть бути ефективно використані для супроводу безпілотного літального апарату. Через те що БПЛА є набагато меншими за розмірами ніж пілотовані літальні апарати, то це ускладнює їх виявлення оптичними засобами. Порівняно з контрастністю зображення літака контрастність БПЛА щодо фону навколишнього середовища є меншою через відсутність світлових маяків і меншу поверхню відображення.

ІЧ канал. Тепло від безпілотного апарату випромінюється найбільше силовою установкою і меншою мірою електронними пристроями, а також компонентами гальмування на несучих краях крил, пропелерів і гвинтів. Творці БПЛА намагаються направити теплове випромінювання в бік неба щоб ускладнити роботу приймачів ІЧ випромінювання розміщених на землі. Крім того, використовують матеріали з малою випромінювальною здатністю, такі як срібло і алюміній. Контраст, випромінювальна здатність, площа випромінювання відповідають за можливість виявити БПЛА.

Радіоканал. Пошук безпілотників з використанням активних станцій радіолокації є досить ефективним, тому що станції мають великий імпульсний обсяг пошуку і відносно велику дальність виявлення. Але РЛС можуть бути виявлені ворогом за власним випромінюванням. Радіолокаційний пошук БПЛА може бути сприятливим тільки тоді, коли не вимагається скритність роботи або високої швидкості переміщення. Як уже згадувалося, більшість БПЛА виробляють з спеціальних матеріалів, які погано відображають електромагнітні хвилі. Електромагнітні хвилі проникають через поверхню літака і лише мала кількість відбивається від неї [7].

Канал радіорозвідки. Засобами радіотехнічної розвідки безпілотні літальні апарати можуть бути виявлені шляхом приймання і дослідження радіосигналів ліній зв'язку та керування, радіолокаційних вимірювачів висоти, джерел активних завад і радіолокаційних станцій. Проте цей методом лише встановлює напрямок літального апарату, притому що точність виявлення зростає при збільшенні часу спостереження. Окремі низькочастотні лінії зв'язку можливо виявити на більших відстанях. Проте радіохвилі бортових РЛС і постановка активних завад БПЛА виявляються на ще більших відстанях. Цьому методу потрібно мінімальне устаткування та дає змогу швидко визначити розташування цілі при подальшій передачі цілевказівок на засоби візуального або теплового спостереження.

Найбільш дієвим напрямком ефективного виявлення БПЛА є сумарна інформація, яка надходить з різних типів давачів, але для експлуатації комплексних методів потрібно використати більшу кількість устаткування, що збільшує розміри та ціну таких систем, що в свою чергу зменшує їх мобільність. Порівняння методів виявлення БПЛА представлено у табл. 1.3.

*Таблиця 1.3.*

### **Порівняння методів виявлення БПЛА**

Принцип роботи датчика	Гранична дальність, м	Фактори впливають на якість роботи	Особливості функціонування	Робота в режимі радіомовчання

Акустичний	100-1000	Шум зовнішнього середовища	-	Так
Оптичний	500-600	Освітлення, погодні умови (туман, опади)	Потрібна наявність прямої видимості	Так
Інфрачервоний	500-600	Погодні умови (туман, опади)	Потрібна наявність прямої видимості	Так
Лідар	1000	Погодні умови (туман, опади)	Потрібна наявність прямої видимості	Ні
Радіолокаційний	>2000	Розмір БПЛА (ефективна площа розсіювання)	Потрібна наявність прямої видимості	Ні
Радіочастотний	2000	Потужність випромінювання передавача на БПЛА	БПЛА який керується дистанційно, можливо виявити оператора до зльоту дрона	Так

Таким чином, підсумувавши переваги і недоліки досліджених фізичних каналів виявлення БПЛА, можна дійти висновку, що для виявлення малих БПЛА та БПЛА з бензиновим двигуном, які є найбільш часто використовують у вирішенні цивільних і військових завданнях значну увагу потрібно приділити дослідженню звукових методів виявлення БПЛА.

#### 1.4. Акустичні методи виявлення БПЛА

Акустична локація – це галузь використання звуку для виміру відстані і напрямку об'єктів. Акустичне виявлення може відбуватися активно або пасивно, а також в різних середовищах: в газах (наприклад в атмосфері), рідинах (таких як вода) і твердих тілах (наприклад, у землі)[8].

Активна звукова локація передбачає відтворення звуку для створення відлуння, проводиться аналіз звуку для визначення координат відповідного об'єкта.

Пасивна звукова локація працює за такими принципами, звук або вібрація яке випромінює об'єкт, приймається мікрофоном або масивом мікрофонів які підключені до ЕОМ, далі проводиться аналіз для визначення місцезнаходження об'єкта.

#### 1.4.1. Пасивне акустичне виявлення

Історично пасивні акустичні локатори були першими технічними засобами виявлення літаків. Основна проблема їх застосування - високий рівень природних та штучних перешкод. Зараз цю проблему можна вирішити за допомогою сучасних засобів цифрової обробки сигналу. Особливо ефективним методом може бути виявлення БПЛА з двигунами внутрішнього згоряння. На рис. 1.7 зображено систему пасивного акустичного виявлення.



Рис. 1.7. Система пасивного акустичного виявлення безпілотного апарату.

Апаратні засоби для пасивної акустичної локації – гостронаправлені акустичні антени, мікрофони, підсилювачі, засоби аналого-цифрового перетворення (АЦП) та цифрової обробки сигналів (ЦОС). Усі компоненти, крім антен, широко представлені ринком. В умовах відносно широкої діаграми спрямованості акустичних антен доцільно використовувати двоканальний варіант з розміщенням антен у горизонтальній площині. Це дозволить використовувати методи зворотного синтезу апертури для підвищення роздільної здатності по азимуту та метод триангуляції для вимірювання дальності.

У разі хвилеводного поширення звуку (водна поверхню, гори, не покриті рослинністю) дальність акустичного виявлення може зростати до 2...5 км. У тумані дальність падає у 1,5...2 рази (табл. 1.4).

Таблиця 1.4.

### Основні параметри пасивного акустичного виявлення

Параметр	Значення
Орієнтовний радіус дії для малих БПЛА	До 2-5 км в умовах низького рівня зовнішніх перешкод. До 1...2 км за умов високого рівня зовнішніх перешкод.
Використані області спектра	Інфразвук та низькі частоти звукового спектру: звуки вихлопу двигуна внутрішнього згоряння, низькочастотні шуми вертолітних та літакових гвинтів.. Низькочастотна частина звукового спектру: шуми двигуна та гвинтів.
Визначаються параметри для вказівки	Азимут і кут місця в межах 0,5 радіуса дії, з роздільною здатністю, що визначається апертурою антени. Для визначення дальності та радіальної швидкості методом триангуляції необхідний інший канал
Кут огляду	Визначається шириною діаграми спрямованості мікрофона

#### 1.4.2. Активне акустичне виявлення

Активна акустична локація (ультразвукова) теоретично має право на існування. Вона дозволяє виявити безшумні об'єкти, що не відображають радіохвилі (кулі-зонди, повітряні змії, мікро-планери) в умовах «нульової» оптичної видимості. Але для отримання прийняттого радіусу дії в умовах високих втрат ультразвуку в повітрі знадобиться ультразвуковий випромінювач високої потужності (сотні ват – десятки кіловат акустичної потужності в імпульсі). Дія подібних сигналів на живий організм поки що досконало не вивчена (табл. 1.5). Тому технологію доводиться вважати потенційно небезпечною. Використовувати її доцільно лише для особливих об'єктів та при непрацездатності інших засобів виявлення. На рис. 1.8 зображено структуру активного акустичного виявлення.




Рис. 1.8. Активне акустичне виявлення безпілотного апарату.

Таблиця 1.5.

### Основні параметри активного акустичного виявлення

Параметр	Значення
Орієнтовний радіус дії для малих БПЛА	До 1...2 км.
Використані області спектра	Низькочастотна частина ультразвукового спектру (22...30 кГц)
Визначаються параметри для вказівки	Азимут і кут місця в межах радіусу дії, з роздільною здатністю, що визначається апертурою антени. Для визначення дальності та радіальної швидкості методом триангуляції необхідний інший канал. Оцінка зовнішнього вигляду мети – не більше 1/4 радіусу дії
Кут огляду	Визначається шириною діаграми спрямованості антени. Для ультразвуку реалізовані антени із шириною діаграми до 1...2°.

#### 1.5. Висновки до розділу 1

Основними випромінювачами шуму безпілотного апарату малого розміру є мотор та лопать. Для безпілотного літального апарату з електродвигуном дальність виявлення приблизно в 5 разів менше ніж у БПЛА з двигунами внутрішнього згорання [9]. Електричним моторам властиві більш низькі шумові характеристики, проте їх використання сильно залежить від акумулятора тобто квадрокоптери мають обмежений радіус польоту. Для пошуку БПЛА найдоцільніше використовувати пасивні акустичні сенсори, що дозволяють залишатися непоміченими з боку супротивника.



Сумарний спектр акустичного випромінювання безпілотного апарату зумовлений гармонічними та широкосмуговими складовими. Акустичний сигнал безпілотника складається з шуму: двигуна, обертання лопаті, механічних деталей. Спектри акустичного сигналу БПЛА мають точно виражені гармоніки, що кратні частоті руху лопаті. При значній різниці в режимах роботи моторів безпілотного апарату спектральні максимуми поділяються на декілька гармонік, цей чинник можна використати як звукову ознаку для виявлення БПЛА .

Геометрична дальність виявлення БПЛА акустичним методом залежить від таких факторів: від погоди навколишнього середовища, рельєфу земної поверхні, висоти джерела звуку та характеристик його спрямованості, яку ще називають зоною акустичного освітлення.

У випадках, коли БПЛА малорозмірні, мають не потужні електричні мотори, якщо відсутній зв'язок за радіоканалом використання інших методів стає неідеальним. Аналіз спектру лімітований низьким за частотою пропелерним шумом [10]. Тому можна вважати акустичні спостереження одні з важливих напрямків у виявленні та ідентифікації БПЛА. Обертання лопаті і механізми БПЛА створюють шум, який є значною демаскуючою ознакою. Розробка і удосконалення методів виявлення та ідентифікації малих БПЛА або БПЛА з бензиновим двигуном шляхом приймання і аналізу акустичних сигналів є актуальним завданням яке вимагає більше досліджень зі спектром [11].

## РОЗДІЛ 2

### ОСНОВНА ЧАСТИНА

#### 2.1. Методи виділення акустичних ознак

Виділення ознак є дуже важливою частиною в аналізі та пошуку зв'язків між різними об'єктами. Необроблені аудіодані не можуть бути зрозумілі моделями безпосередньо, щоб перетворити їх у зрозумілий формат, використовується виділення функцій. Це процес, який пояснює більшість даних, але в зрозумілий спосіб. Виділення ознак необхідне для алгоритмів класифікації, прогнозування та рекомендацій.

Існує кілька способів перетворення сигналу, о самих поширених з них буде описано нижче.

##### 2.1.1. Ознаки області часу

Функції часової області працюють безпосередньо з необробленим аудіосигналом у часовій області, без прямого використання будь-яких спектральних характеристик.

##### Швидкість переходу через нуль (ZCR)

Швидкість переходу через нуль (ZCR) — це швидкість, з якою сигнал змінюється з позитивного на нульовий і на негативний, або з негативного на нульовий і на позитивний. Його значення широко використовувалося як для розпізнавання мови, так і для пошуку музичної інформації, будучи ключовою характеристикою для класифікації ударних звуків [12].

ZCR формально визначається як:

$$zcr = \frac{1}{T-1} \sum_{t=1}^{T-1} 1_{R<0}(s_t s_{t+1} - 1), \quad (2.1)$$

де  $S$  є сигналом довжини  $T$ ,  $1_{R<0}$  є індикаторною функцією.

У деяких випадках враховуються лише «позитивні» або «негативні» переходи, а не всі переходи, оскільки між парою суміжних позитивних переходів нуля має бути один негативний перетин нуля.

Для монофонічних тональних сигналів швидкість переходу через нуль може бути використана як примітивний алгоритм виявлення висоти. Швидкість перетину нуля також використовується для виявлення голосової активності, яке визначає, чи є людська мова в аудіосегменті чи ні.

Енергія сигналу

Енергія сигналу відповідає загальній величині сигналу. Для аудіосигналів це приблизно відповідає гучності сигналу. Енергія в сигналі визначається як:

$$Energy = \sum_n [x(n)]^2 \quad (2.2)$$

Середньоквадратична енергія (RMSE) у сигналі визначається як:

$$RMSE = \sqrt{\frac{1}{N} \sum_n [x(n)]^2} \quad (2.3)$$

### 2.1.2. Ознаки частотної області

Частотні характеристики, витягуються з кадрів, отриманих шляхом перетворення часового сигналу віконним перетворенням Фур'є. Також можуть використовувати масштабування частоти Mel або постійної частоти Q або масштабування логарифмічної амплітуди замість лінійного масштабування.

Енергія смуги

Енергія смуги – це загальна енергія, що міститься в даній смузі частот  $k$  кадру  $m$  представлення сигналу  $X[k,m]$  у частотно-часовому діапазоні, визначеного як квадрат його величини:

$$E[k, m] = [X[k, m]]^2 \quad (2.4)$$

Потужною функцією, пов'язаною з енергією діапазону, є логарифм енергії діапазону Mel, який використовує масштабування частоти Mel і логарифмічне масштабування амплітуди. Це одна з небагатьох спектральних характеристик, придатних для більш складних таких завдань, як поліфонічна і багатоканальна SED [13].

### Спектральний потік

Спектральний потік вимірює спектральну зміну між послідовними кадрами. Він визначається як квадрат різниці між нормованою величиною  $\hat{X}$  двох кадрів:

$$F[m] = \sum_{k=1}^N (\hat{X}[k, m] - \hat{X}[k, m - 1])^2 \quad (2.5)$$

Як окрему функцію використовуйте спектральний потік Mel сигналу для виявлення мовної активності.

### Спектральний спад

Спектральний спад кадру вказує на асиметрію його спектральної форми та визначається як частота нижче якої міститься заздалегідь визначена кількість (зазвичай від 85% до 99% загальної енергії) спектральної енергії .

Оскільки більшість із цих індивідуальних спектральних характеристик є спрощеними, їх зазвичай об'єднують в одну вектор-функцію, який надає більше інформації [14]. Цю комбінацію характеристик часової та частотної області часто називають вектором ознак низького рівня сигналу.

Спектральний центроїд — це міра, яка використовується в цифровій обробці сигналу для характеристики спектру . Він вказує, де розташований центр мас спектру. З точки зору сприйняття, він має міцний зв'язок із враженням яскравості звуку . Його іноді називають центром спектральних мас.

Він обчислюється як середнє зважене частот, присутніх у сигналі, визначених за допомогою перетворення Фур'є , з їх величинами як вагами:

$$Centroid = \frac{\sum_{n=0}^{N-1} f(n)x(n)}{\sum_{n=0}^{N-1} x(n)} \quad (2.6)$$

де  $x(n)$  представляє значення зваженої частоти або величину секції з номером  $n$  , а  $f(n)$  представляє центральну частоту цієї секції.

### 2.1.3. Кепстральні ознаки

Кепстральні ознаки – це ознаки звукового сигналу, які діють у кепстральній області, пов'язаній із частотним спектром сигналу. Кепстр  $X_c[n]$

спектра  $X[k]$  отримується шляхом застосування зворотного ДПФ до логарифму його спектру потужності:

$$X_c[n] = I - DFT(\log(|X[k]|^2)) \quad (2.7)$$

Перевага кепстральної області полягає в тому, що вона дозволяє відокремити джерело та фільтр(и), оскільки згортка над часом представлено як додавання в кепстральній області (через логарифмічну операцію над спектром).

Такі кепстральні функції широко використовуються в автоматичному розпізнаванні мови (ASR) і в завдання синтезі мови [15].

### MFCC

Коефіцієнти мел-частотного кепструму (MFCC) — це представлення, визначене як реальний кепстр віконного короткочасного сигналу, отриманого з ШПФ цього сигналу. Відмінність від справжнього кепстра полягає в тому, що використовується нелінійна частотна шкала, яка апроксимує поведінку слухової системи. Девіс і Мермельштейн [16] показали, що подання MFCC є корисним для розпізнавання мови. Враховуючи DFT вхідного сигналу (2.8).

$$X_a[k] = \sum_{n=0}^{N-1} x[n]e^{-j2\pi nk/N} \quad (2.8)$$

Визначено набір фільтрів із  $M$  фільтрів ( $m = 1, 2, \dots, M$ ), де фільтр  $m$  є трикутним фільтром, заданим як:

$$H_m[k] = \begin{cases} 0 \\ \frac{2(k-f[m-1])}{(f[m+1]-f[m-1])(f[m]-f[m-1])} \end{cases} \quad (2.9)$$

Такі фільтри обчислюють середній спектр навколо кожної центральної частоти зі збільшенням смуги пропускання, і вони показані на рисунку 2.1.




Рис. 2.1. Трикутні фільтри, що використовуються при обчисленні мел-кепстра

Крім того, фільтри можна вибрати як:

$$H_m[k] = \begin{cases} 0 \\ \frac{(k-f[m-1])}{(f[m]-f[m-1])} \end{cases} \quad (2.10)$$

що задовольняє  $\sum_{m=0}^{M-1} H_m[k] = 1$ . Мел-кепстр, обчислений за допомогою  $H_m[k]$ , відрізнятиметься постійним вектором для всіх вхідних даних, тому вибір стає неважливим при використанні в системі розпізнавання мовлення, яка навчена з тими самими фільтрами.

Давайте визначимо  $f_1$  та  $f_h$  як найнижчу та найвищу частоти групи фільтрів у Гц,  $F_s$  — частоту дискретизації в Гц,  $M$  — кількість фільтрів, а  $N$  — розмір ШПФ. Граничні точки  $f[m]$  рівномірно розташовані на шкалі mel:

$$f[m] = \left(\frac{N}{F_s}\right) B^{-1}\left(B(f_1) + m \frac{B(f_h) - B(f_1)}{M+1}\right) \quad (2.11)$$

де мел-шкала  $B$  задана рівнянням (2.11), а  $B^{-1}$  є його оберненим значенням. Потім ми обчислюємо логарифм енергії на виході кожного фільтра як:

$$B^{-1}(b) = 700\left(\exp\left(\frac{b}{1125}\right) - 1\right) \quad (2.12)$$

Тоді кепстр частоти мел є дискретним косинусним перетворенням виходів фільтра  $M$ :

$$S[m] = \ln[\sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k]], 0 \leq m < M, \quad (2.13)$$

де  $M$  змінюється для різних реалізацій від 24 до 40. Для розпізнавання мови зазвичай використовуються тільки перші 13 коефіцієнтів кепстра. Важливо зазначити, що представлення MFCC більше не є гомоморфним перетворенням. Це було б, якби порядок підсумовування та логарифмів у рівнянні (2.13) були змінені:

$$c[n] = \sum_{m=0}^{M-1} S[m] \cos\left(\frac{\pi n(m+\frac{1}{2})}{M}\right) 0 \leq n < M \quad (2.14)$$

На практиці, однак, представлення MFCC є приблизно гомоморфним для фільтрів, які мають точну передаточну функцію. Перевага використання представлення MFCC.

$$S[m] = \sum_{k=0}^{N-1} \ln(|X_a[k]|^2 H_m[k]) 0 \leq m < M \quad (2.15)$$

Використання (2.13) замість (2.15) полягає в тому, що енергії фільтра більш стійкі до шуму та помилок спектральної оцінки. Цей алгоритм широко використовувався як вектор функцій для систем розпізнавання мовлення.

#### 2.1.4. Спектрограми

Спектрограма — це візуальний спосіб представлення сили сигналу або гучності сигналу в часі на різних частотах, присутніх у певній формі сигналу. Можна не тільки побачити, чи більше або менше енергії, наприклад 2 Гц проти 10 Гц, але також можна побачити, як рівні енергії змінюються з часом [17]. В інших науках спектрограми зазвичай використовуються для відображення частот звукових хвиль, створюваних людьми, машинами, тваринами, китами, реактивними літаками тощо, записаних мікрофонами. У сейсмології спектрограми все частіше використовуються для перегляду частотного вмісту

безперервних сигналів, записаних окремими або групами сейсмометрів, щоб допомогти розрізнити та охарактеризувати різні типи землетрусів або інших коливань землі. На рис 2.2 зображено спектрограма гри на скрипці.




Рис. 2.2. Спектрограма запису гри на скрипці

#### Mel - спектрограма

Функції аудіовходу менш очевидні, ніж зображення, а необроблений аудіосигнал без втрати містить довгий потік цифр. Історично склалося так, що створені вручну функції спеціально розроблялися та обчислювалися для відповідних додатків. Методи побудови ознак в основному ґрунтуються на різних формах спектральних форм, що включають швидке перетворення Фур'є необробленої форми звукового сигналу. Останнім часом стало можливим використання необробленої форми аудіосигналу як пряме введення для нейронних мереж, і це може дати відповідні хороші результати. Тим не менш, використання необробленої форми аудіосигналу ще не повністю розроблено, багато програм все ще використовують традиційні функції спектральних форм.

MFCC, які містять спектральні форми із втратами для аудіосегментів, показали свою ефективність для розпізнавання фонем. Однак MFCC є компактними і стислими функціями, які дуже обмежені для загальної аудіо класифікації. Отже, різні типи звукових подій потребують більш детального спектрального представлення.



Спектрограма є найкращою альтернативою, яка має серію спектрів, що становлять тимчасову еволюцію частотних компонентів. Логарифмічна спектрограма дуже схожа на робочий механізм наших равликів. Равлики – органи слуху людини, службовці сприйняття звуку. Спектр містить масив значень, що представляють силу відповідних частот, тоді як равлики також сприймають звук відповідно до різних частот. Частота дискретизації може вплинути ефективний частотний діапазон спектра. Відповідно до теореми Найквіста, втрати відсутні для частотних складових, частота яких менша за половину частоти дискретизації. Діапазон частот людського слуху становить приблизно від 20 до 20 000 Гц, що є хорошим орієнтиром при виборі частоти дискретизації. Проте сприйняття частот равликами перестав бути постійним і лінійно пропорційним частоті. Стівенс та ін. запропонував перцептивну мел-шкалу висоти тону, засновану на експериментальних та усереднених результатах набору випробуваних [18]. Ця шкала є найбільш підходящою моделлю для звукового сприйняття людини. Отже, звичайні спектрограми необхідно перетворити на спектрограми Mel за допомогою формули (2.16).

$$m = 1127 \ln\left(1 + \frac{f}{700}\right) \quad (2.16)$$

де  $f$  відноситься до фактичної частоти, а  $m$  - Mel частота. Оскільки людина сприймає гучність звуку логарифмічно, значень Mel-спектрограм виконується логарифмічна операція. Перетворені спектрограми називаються логарифмічними спектрограмами та використовуються для завдань даної дисертації.

Розрахунок логарифмічної спектрограми описується в такий спосіб. Необроблена форма аудіосигналу спочатку розбивається на кадри, що перекриваються. Довжина кадру зазвичай становить 15-25 мс, причому звук може сприйматися як приблизно стаціонарний. Розмір переходу, зазвичай близько 10 мс, є тимчасовим зсувом між кадрами. Цей зсув може зменшити втрату інформації, спричинену поділом.

## 2.2 Методи класифікації мовного сигналу

У даному підрозділі розглядаються основні існуючі рішення завдання ідентифікації БПЛА. Незважаючи на те, що методи во багато в чому відрізняються, в цілому можна можливо виділити наступні основні етапи, властиві кожному з аналізованих методів:

1. Виділення ознак з вхідного сигналу.
2. Побудова моделі (шаблону) БПЛА на основі отриманих на попередньому крок векторів ознак.

Процес ідентифікації БПЛА, який є в базі даних, по вхідному аудіосигналу у всіх досліджуваних методах складається з пошуку найбільш підходящою збереженою моделі на основі деяких критеріїв [19].

### 2.2.1 Dynamic Time Warping

Dynamic Time Warping (DTW) – метод динамічного програмування, що дозволяє знайти близькість між двома послідовностями вимірювань за деякий проміжок часу. У загалом випадку ці послідовності можуть бути різний довжини, і вимірювання можуть проводитися з різною швидкістю.

У якості зберігається моделі в даному методі виступає послідовність векторів ознак вхідного сигналу з навчальною вибірки  $Q = \{q_1, \dots, q_n\}$ . Нехай  $C = \{c_1, \dots, c_n\}$  – послідовність векторів ознак вхідного мовного сигналу з тестової вибірки. Також вводяться поняття матриці вирівнювання двох послідовностей  $M_{m \times n}$  у позиції  $(i, j)$  якої міститься значення вирівнювання між елементами  $c_i$  і  $q_j$  послідовностей  $C$  і  $Q$  відповідно, і набору індексів суміжних елементів цією матриці  $W = \{w_1, \dots, w_n\}$  – визначального відповідності між елементами зіставних послідовностей. При цьому елементи набору  $W$  повинні задовольняти наступним умовам:

1.  $w_1 = (1,1), w_T = (m, n)$ ,
2. Якщо  $w_{t-1} = (a', b')$ , то  $w_t = (a, b)$ , де  $a - a' \leq 1$ , де  $b - b' \leq 1$

Метою алгоритму DTW є перебування такого набору  $W$ , задовольняє

умовам 1 і 2, при якому сумарне спотворення послідовності  $C$  щодо послідовності  $Q$  було б мінімальним, то є:

$$DTW(Q, C) = \min \left\{ \frac{1}{T} \sqrt{\sum_{t=1}^T M(w_t)} \right\} \quad (2.17)$$

Значення цього виразу і визначатиме міру близькості послідовностей  $Q$  та  $C$ . Для знаходження значення  $DTW(Q, C)$  застосовується метод динамічного програмування, де на кожному кроці обчислюється значення  $M(i, j)$  за формулою:

$$M(i, j) = d(i, j) + \min\{M(i-1, j-1), M(i-1, j), M(i, j-1)\} \quad (2.18)$$

При цьому  $M(0, 0)=0$ , а всі інші елементи стовпця та рядки з індексом 0 ініціалізуються значенням  $\infty$ ,  $d(i, j)$  визначає евклідове відстань між елементами  $c_i$  і  $q_j$ . Результатом роботи алгоритму є значення  $DTW(Q, C) = M(m, n)$ .

Для визначення БПЛА обчислюється значення  $DTW(Q_i, C)$ , для кожного збереженого шаблону. Значення  $i$  при якому досягається мінімум, визначає модель БПЛА, зразок звуку якого найбільше близький до зразка вхідного сигналу [20].

Основною перевагою алгоритму  $DTW$  є простота реалізації.

### 2.2.2. Hidden Markov Model

Приховані Марковські Моделі (НММ) утворюють клас статистичних моделей, у яких система що моделюється вважається марковським процесом із прихованими станами. Зі спостережуваних вихідних послідовностей, згенерованих марковським процесом, і ймовірності вихідного випромінювання з прихованих станів, та переходу між прихованими станами можна оцінити за допомогою методів динамічного програмування. Розраховані параметри моделі потім можна використовувати для різних цілей аналізу послідовності. [20].

### 2.2.3. Vector Quantization

Завдання векторних квантувань з векторним кодом  $W = \{w_1, w_2, \dots, w_n\}$

для черговості векторів входу  $C = \{c_1, c_2, \dots, c_m\}$  поставлено як задача зменшити спотворення при заміні кожного вектора з  $Q$  даним кодовим вектором.

Моделю БПЛА в цьому методі є безліч векторних кодів, одержуваних із початкової послідовності векторів ознак вхідного сигналу. Для створення цього масиву даних, послідовність на виході векторів ознак розділяється на  $L$  кластерів, і тому як коди векторів беруться їх центри.

Процес навчання моделі по вхідному аудіо сигналу здійснюється в такий спосіб. Для кожного тестового вектора  $C_j$  визначаються найближчі кодові вектори. Нехай  $k_{ij}$  кількість векторів, що належать моделі  $S_j$ , серед знайдених найближчих. Тоді ймовірність того, що вектор  $C_j$  належить моделі  $S_j$ , визначається формулою:

$$P(S_j|c_i) = \frac{k_{ij}}{k} \quad (2.19)$$

Отже, послідовність тестових векторів класифіковано по правилу:

$$S = \operatorname{argmax} \prod_{i=1}^L P(S_j|c_i) \quad (2.20)$$

Для згладжування похибки вимірювання, пов'язаної з близькими до нуля ймовірностями, з урахуванням постійності числа частіше використовують правило:

$$S = \operatorname{argmax} \prod_{i=1}^L P(S_j|c_i) = \operatorname{argmax} \sum_{i=1}^L k_{ij} \quad (2.21)$$

Метод векторного квантування простий у відтворенні, проте не завжди дає високу точність розпізнавання [21].

#### 2.2.4 Support Vector Machine

Support vectors machine (метод опорних векторів) – подвійний класифікатор, який створює в просторі ознаку, розділяючи функцію і задаючи гіперплощину виду:

$$f(x) = w * x + b \quad (2.22)$$

Наприклад внесена послідовність точок простору ознак  $X = \{x_1, x_2, \dots, x_n\}$  з точками  $Y = \{y_1, y_2, \dots, y_n\}, y_i \in \{-1, 1\}, 1 \leq i \leq n$  відповідна двом класам. У разі лінійної роздільності даних умови для знаходження функції  $f(x)$  записуються в вигляді:

$$\begin{cases} w * x_i + b \geq 1, y_i = 1 \\ w * x_i + b \leq -1, y_i = -1 \end{cases} \rightarrow y_i(w * x_i + b) - 1 \geq 0, 1 \leq i \leq n \quad (2.23)$$

Для надійного поділу класів необхідно щоб відстань між роздільними гіперплощинами було як можна, можливо великим.

Відстань обчислюється як  $\frac{2}{|w|}$ , отже, завдання пошуку поділяючої гіперплощини можна звести до мінімізації  $\|w\|$  за вказаних умов. Ця завдання може бути вирішена з допомогою методу множників Лагранжа [6].

У лінійно - нероздільних множин вноситься функція ядра. Принцип полягає в тому, щоб показати вихідний простір вищої розмірності де безлічі вже можуть бути розділені лінійно. При цьому через те, що скрізь в алгоритмі ознаки застосовуються не окремо, а у формі скалярних добутків, немає необхідності відображати це перетворення в явному вигляді. Треба всього лише задати функцію ядра, що визначає скалярний добуток у новому просторі:

$$K(x_i, x_j) = \varphi(x_i) * \varphi(x_j) \quad (2.24)$$

Як збережена модель об'єкта в методі опорних векторів виступають параметри розділяючої функції  $f(x)$ , а також параметри функції ядра. Параметри ядра зазвичай визначають шляхом перебору деякої множини значень і оцінкою методом крос-валідації.

Після того, як вирішальна функція  $f(x)$  обчислено, приналежність вектор  $x'$  відповідного класу визначається знайомий вирази  $f(x')$  Для

застосування методу опорних векторів до задачі багатокласового розпізнавання використовується стратегія "один проти решти». Для цього будуються  $q$  класифікаторів, кожен з яких навчається відрізнити один конкретний клас від решти. При розпізнаванні об'єкт приписується до того класу, чий класифікатор видав найбільше значення розділяючої функції  $f(x)$  [19].

Метод опорних векторів дає високу точність класифікації. теоретичне обґрунтування, дозволяє застосовувати різні підходи до класифікації відповідно до вибору функції ядра. Серед недоліків слід зазначити проблему вибору ядра, а також повільне навчання випадку завдання багатокласового розпізнавання.

### 2.2.5 Gaussian mixture Model

Модель гаусових сумішей є виваженою сумою  $M$  компонентів і може бути описано виразом:

$$P(\bar{x}|\lambda) = \sum_{i=1}^M p_i b_i(\bar{x}) \quad (2.25)$$

де  $\bar{x}$ –  $D$ -мірний вектор випадкових величин,  $p_i, 1 \leq i \leq M$ - ваги компонентів моделі,  $b_i(\bar{x}), 1 \leq i \leq M$ – функції щільності розподілу складових моделі:

$$b_i(\bar{x}) = \frac{1}{(2\pi)^{D/2} |\Sigma_i|^{1/2}} \exp \left\{ -\frac{1}{2} (\bar{x} - \bar{\mu}_i)^T \Sigma_i^{-1} (\bar{x} - \bar{\mu}_i) \right\} \quad (2.26)$$

де  $\bar{\mu}_i$ – вектор математичного очікування та  $\Sigma_i$ – ковариційна матриця. При цьому ваги суміші задовольняють умові:

$$\sum_{i=1}^M p_i = 1 \quad (2.27)$$

Повна модель гаусової суміші складається: з векторів математичного очікування, вагами сумішей та ковариційною матрицею для кожного складника моделі:

$$\lambda = \{p_i, \bar{\mu}_i, \Sigma_i\}, i = 1, \dots, M \quad (2.28)$$

При застосуванні цього методу кожна модель репрезентується моделлю

гаусових сумішей  $\lambda$ .

Для створення моделі БПЛА необхідно зробити оцінку параметрів, які найкраще підходять розподілу ознак векторів для навчального висловлювання. Найбільш застосованим методом розв'язання цього завдання є метод оцінювання максимальної правдоподібності. Метою оцінки максимальної правдоподібності є обчислення параметрів моделі, які збільшують правдоподібність цієї моделі, при заданих навчальних даних.

Для черги навчальних векторів  $X = \{\bar{x}_1, \dots, \bar{x}_T\}$  правдоподібність моделі гаусових сумішей записано у вигляді:

$$P(X|\lambda) = \prod_{t=1}^T P(\bar{x}_t|\lambda) \quad (2.29)$$

Цей вираз є нелінійною функцією від параметрів  $\lambda$ , і її безпосереднє обчислення неможливе, тому зазвичай для оцінки параметрів застосовується ЕМ-алгоритм.

Нехай  $S = \{S_1, S_2, \dots, S_n\}$  – група моделей, які представляються набором моделей гаусових сумішей  $\lambda_1, \lambda_2, \dots, \lambda_n$

При ідентифікації БПЛА потрібно знайти модель, яка має найбільше значення апостеріорної ймовірності для заданого висловлювання:

$$S = \operatorname{argmax} P(\lambda_k|X) = \operatorname{argmax} \frac{P(\lambda_k|X)P(\lambda_k)}{P(X)} \quad (2.30)$$

Використовуючи логарифм та незалежність між спостереженнями, система ідентифікації БПЛА в результаті обчислює:

$$S = \operatorname{argmax} \sum_{t=1}^T \log P(\bar{x}_t|\bar{\lambda}_k) \quad (2.31)$$

Моделі гаусових сумішей є дієвим методом з високою точністю розпізнавання. Проте виникає низка проблем, пов'язаних з вибором кількості компонентів моделі та налаштуванням початкових параметрів.

### 2.2.6 Нейронна мережа

Нейронні мережі, також відомі як штучні нейронні мережі (ANN) або імітовані нейронні мережі (SNN), є підмножиною машинного навчання та є основою алгоритмів глибокого навчання. Їх назва та структура навіяні людським мозком, імітуючи спосіб, яким біологічні нейрони передають сигнали один одному [22]. Узагальнена структура нейронної мережі зображена на рис. 2.3.

Штучні нейронні мережі (ШНМ) мають таку структуру: вузли, що мають вхідний рівень, 1 або безліч прихованих шарів і вихідний рівень. Будь-який вузол, поєднується з іншим і має деяку вагу та поріг.

Якщо вихід деякого вузла перевищує вказаний пороговий рівень, цей вузол повинен активуватися, передаючи інформацію на рівень вище.

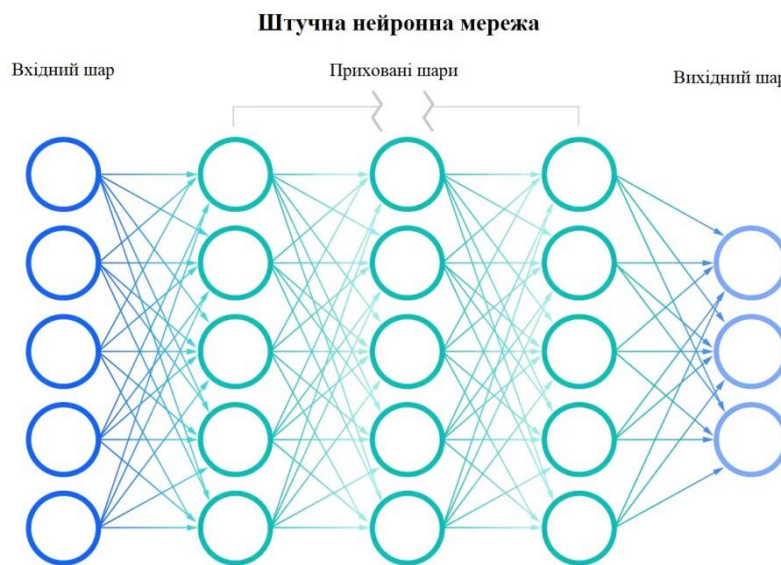


Рис. 2.3. Структура нейронної мережі прямого зв'язку

Нейронні мережі залежать від навчальної бази даних, чим краще відібрані дані, тим більша буде точність моделі. Коли алгоритми навчені точно налаштовані на точність, тоді вони стають могутніми інструментами в галузі інформатики та ШІ, що дає змогу класифікувати та кластеризувати дані на дуже високій швидкості. Задачі з ідентифікування мовлення чи розпізнавання зображень тривають від хвилин до годин, порівняно набагато швидше ніж



ручне розпізнавання людей-експертів. Однією з найвідоміших нейронних мереж є пошуковий алгоритм Google.

### 2.3 Види нейронних мереж

Існує багато різних типів штучних нейронних мереж, що відрізняються за складністю. Вони поділяють заплановану мету віддзеркалення функції людського мозку для вирішення складних проблем або завдань [23]. Структура кожного типу штучної нейронної мережі певним чином відображає нейрони та синапси. Однак вони відрізняються за складністю, варіантами використання та структурою. Відмінності також включають спосіб моделювання штучних нейронів у кожному типі штучної нейронної мережі та зв'язки між кожним вузлом. Інші відмінності включають те, як дані можуть проходити через штучну нейронну мережу та щільність вузлів.

6 прикладів різних типів штучних нейронних мереж включають:

- Штучні нейронні мережі прямого зв'язку
- Персептрон
- Багатошаровий персептрон
- Радіальна основа функції штучних нейронних мереж
- Рекурентні нейронні мережі
- Згорткові нейронні мережі

#### 2.3.1 Штучні нейронні мережі прямого зв'язку.

Штучні нейронні мережі створені на зразок людського мозку, через те що вони створені з елементів, робота яких має аналогію з основними функціями біологічного нейрону [24]. На рис. 2.4 показано узагальнена модель нейрона, використана в якості основного будівельного блоку в нейронних мережах.




Рис. 2.4. Штучний нейрон з активаційною функцією

На входи нейрона подано багато сигналів, кожен із яких множиться на вагу, і потім добутки складаються. Результат підсумовування  $s$  (2.32) буде даною функції активування. Дані функції активації відповідають відгуку нейрона  $y$  (2.33) на довільну комбінацію вхідних дій. Отже за допомогою активації нейрона відбувається перетворення вхідних впливів у вихідний сигнал з бажаними характеристиками.

$$s = \sum_{i=1}^p w_i x_i + w_0 \quad (2.32)$$

$$y = f(s) \quad (2.33)$$

де  $w_i$  - вага нейрона

$w_0$  - коефіцієнт переміщення;

$s$  - підсумок;

$x_i$  - частина вхідного вектора

$y$  - вихідні дані нейрона;

$p$  - кількість входів синапсиса;

$f$  - функція активації.

Зазвичай вхідні дані, вагові змінні і значення зміщення набувають дійсних чисел. Вихід  $y$  називають видом функції активації. Вона може бути як дійсним так і цілим числом. У багатьох експериментах входи, зміщення та ваги отримують тільки деякі сталі значення. Синаптичні зв'язки з додатними вагами називають збуджуючими, а з від'ємними вагами - гальмуючі. Отже, нейрон

повністю або частково описується своїми вагами  $w_i$  і передаючою функцією  $f(x)$ . Крім того, правила коригування вагових значень на вході одного нейрона, правила навчання та вибір функції активації  $f$  є відмінною характеристикою багатьох нейронних структур. Функція активації є звичайною лінійною функцією (2.34).

$$y = k(s), \quad (2.34)$$

де  $k$  - стала порогової функції;

Якщо функція активації скорочує діапазон зміни величини  $s$  (2.34) так, що за любых значень  $s$  значення  $y$  належать іншому кінцевого інтервалу, то  $f$  називають "стискаючою" функцією. Для функції "стискання" дуже часто використовують логістичну функцію, показану на рис. 2.5.




Рис. 2.5. Сигмоїдальна функція

Логістична функція обчислюється формулою (2.35)

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2.35)$$

Іншою часто використовуваною активаційною функцією є гіперболічний тангенс (2.36)

$$f(x) = th(x) \quad (2.36)$$

Графік функції гіперболічного тангенсу представлений на рис. 2.6.




Рис. 2.6. Функція гіперболічного тангенсу

Не зважаючи на те що один нейрон і може робити найпростіші процедури ідентифікації, проте сила нейронних розрахунків відбувається від сполучення нейронів в мережах.

Нейронна мережа є масивом нейронів, поєднаних між собою і охарактеризуються їх внутрішніми властивостями, особистою топологією. Також є правила навчання для одержання потрібного вихідного сигналу.

Мережа навчається, щоб для будь-яких значеннях на входах, давати бажане значення на виході. Кожний такий вхідний або вихідний масив називається як вектор. Навчання проводиться методом послідовного передачею вхідних векторів з синхронним налаштуванням ваг відповідно до певної функції. В процесі навчання ваги мережі поетапно змінюються, щоб всякий вхідний вектор створював вихідний вектор.

Буває три основних види навчання: "з ментором", самонавчання та змішане. За своєю будовою навчання з вчителем (ментором) має в своїй базі достовірні висновки (виходами мережі) за кожен вхідний приклад. Ваги створюють для себе такі налаштування, щоб мережа виготовляла відповіді якомога ближче до тих що ми знаємо. Самонавчання не вимагає знання правильних відповідей, це зразок для навчальною вибірки. У цьому випадку відкривається внутрішня будова даних чи самокореляція між прикладами у базі даних, що може поділити зразки за категоріями. При змішаному навчанні деякі ваги визначаються за допомогою навчання з ментором, а інші навчаються за

допомогою самонавчання.

### 2.3.2 Персептрон.

Одна з простих нейромережових архітектур є одношаровий персептрон. Він утворюється з 1-го шару штучних нейронів, поєднаних за допомогою вагових значень з великою кількістю входів (рис. 2.7). Сукупність нейронів з спільним вхідним сигналом називають шаром. Елемент  $\Sigma$  множить кожен вхід  $x$  на вагу  $w$  і підсумовує зважені входи [25]. Вихід дорівнює одиниці, якщо деяка сума більша за задане порогове значення, а інакше – нулю.




Рис. 2.7. Персептрон

Персептрон навчається передаванням послідовністю багатьох образів по одному на його вхід і зміною ваг до тих пір, доки для всіх образів не буде досягнуто необхідний результат.

Використання такої архітектури доцільно використовувати лише для задач з високою лінійністю. Для прикладу, можливо збудувати нейронну мережу, яка розбиває точки  $(0,0)$  і  $(1,1)$  на 2 класи для двовимірного сигналу, але нездійснено вирішити задачі по розбиванню точок  $(0,0)$ ,  $(1,1)$  - в 1-ий клас, і  $(0,1)$ ,  $(1,0)$  – в 2-ий. Це загальновідомий приклад нездатності простого персептрона вирішити завдання «виключне або».

Є досить великий розряд функцій, не зроблених одношаровою мережею.

Імовірність того, що рандомно вибрана функція виявиться лінійно роздільною, дуже мала навіть для помірних цифр змінних. Через цей фактор одношарові перцептрони на практиці обмежені простими завданнями.

### 2.3.3 Багатошаровий перцептрон.

Досить великі обмеження одношарових мереж можна вирішити, додаючи додаткові шари. Двошарові мережі складаються з одношарових мереж і з'єднуються каскадним типом. Вони можуть робити загальні класифікації. Мережа створює функцію практично будь-якого рівня складності, проте кількість шарів і число елементів у всіх шарах визначають складність функції[26].

На рис. 2.8 зображена двошарова мережа, яка навчається шляхом функції зворотного поширення.

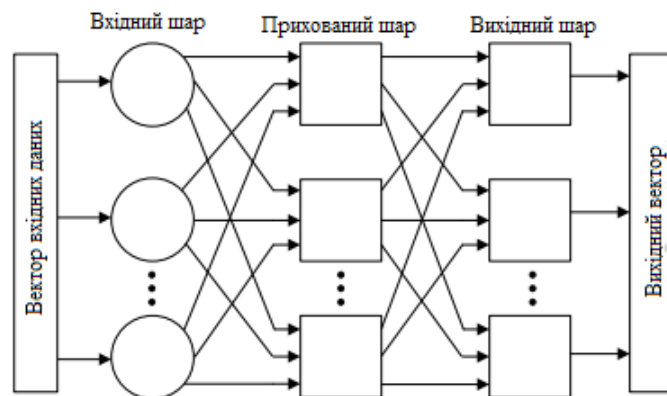


Рис. 2.8. Двошаровий перцептрон

Нейрони які знаходяться в одному шарі нейронної мережі між собою не пов'язані, але пов'язані з кожним нейроном наступного порядку, звичайно, крім останнього шару в якого виходи є загальними виходами. 1-й шар нейронів (пов'язаний з вхідними даними) призначений як розподільчі пункти, з входами тут не виконується жодних математичних дій. Вхідні дані проходять через них до ваг на їх виходах. Отримавши вхідні дані, нейрон наступного шару додає їх з призначеними вагами, потім до цієї суми застосовується передавальну функцію яка надсилає результат на один із входів нейрона 2-го шару. Він

підсумовує здобуті від першого шару дані з деякими вагами. Функціонування мережі прямого типу обчислюється формулою:

$$y_j^k = f \left( \sum_{i=1}^{n(k-1)} w_{ij}^k y_i^{k-1} \right), j = 1:n(k), \quad (2.37)$$

де  $x$  - вхідний сигнал;

$y_j^k$  - значення  $j$ -го виходу нейрона  $k$ -го шару;

$w_{ij}^k$  - вага зв'язку від  $i$ -го нейрона ( $k-1$ )-го шару до  $j$ -му нейрону  $k$ -го шару;

$f$  - функція активації;

$n(k)$  - Число нейронів у  $k$ -му шарі.

У ролі функції активації в мережах зі зворотним розповсюдженням здебільшого застосовується сигмоїдальна функція. Багатошарові мережі більш продуктивні та потужні, ніж одношарові, лише у разі наявності не лінійних характеристик. стискаюча функція забезпечує необхідну продуктивність .

Для старту навчання багатошарових нейронних мереж використовується алгоритм зворотного розповсюдження похибки. Якщо при роботі прямої функції вхідний сигнал розповсюджується по мережі від вхідного шару до вихідного, то при налаштуванні ваг хиба мережі поширюється від вихідного шару до вхідного.

#### 2.3.4 Мережі з радіальною базовою функцією (RBF)

Мережі з радіальною базовою функцією (RBF) мають принципово іншу архітектуру, ніж більшість архітектур нейронних мереж. Більшість архітектур нейронної мережі складається з багатьох рівнів і вводить нелінійність шляхом повторюваного застосування нелінійних функцій активації. З іншого боку, мережа RBF складається лише з вхідного рівня, одного прихованого рівня та вихідного рівня. Структура мережі зображено на рис. 2.9.




Рис. 2.9. Структура RNN мережі.

Вхідний рівень не є обчислювальним, він просто отримує вхідні дані та передає їх на спеціальний прихований рівень мережі RBF. Обчислення, які відбуваються всередині прихованого шару, сильно відрізняються від більшості нейронних мереж, і саме в цьому полягає потужність мережі RBF. Вихідний рівень виконує завдання прогнозування, наприклад класифікацію або регресію. Вхідний рівень просто передає дані на приховані шари.

У результаті кількість нейронів у вхідному шарі має дорівнювати розмірності даних. На вхідних рівнях обчислення не виконуються, як у випадку зі стандартними штучними нейронними мережами. Вхідні нейрони повністю з'єднані з прихованими нейронами та передають свої дані вперед.

Прихований шар приймає вхідні дані, у яких візерунок може не бути лінійно роздільним, і перетворює його на новий простір, який є більш лінійно роздільним. Прихований шар має вищу розмірність, ніж вхідний, тому що шаблон, який не є лінійно роздільним, часто потребує перетворення у простір вищої розмірності, щоб бути більш лінійним розділенням. Це засновано на теоремі Ковера про роздільність шаблонів, який стверджує, що патерн, який перетворюється у простір з більшою вимірністю за допомогою нелінійного перетворення, швидше за все буде лінійно роздільним, тому кількість нейронів у прихованому шарі повинна бути більшою за кількість вхідного нейрона. При



цьому кількість нейронів у прихованому шарі має бути меншою або дорівнювати кількості зразків у навчальному наборі. Коли кількість нейронів у прихованому шарі дорівнює кількості зразків у навчальному наборі, модель можна вважати приблизно еквівалентною навчальним ядрам, таким як регресія ядра та векторні машини підтримки ядра.

Обчислення в прихованих шарах базуються на порівняннях із векторами-прототипами, які є векторами з навчального набору.

Кожен нейрон у прихованому шарі має вектор прототипу та смугу пропускання, позначену  $\mu$  та  $\sigma$  відповідно. Кожен нейрон обчислює подібність між вхідним вектором і його прототипом. Обчислення в прихованому шарі можна математично записати так:

$$\Phi_i = e^{-\left(\frac{\|\bar{x} - \mu_i\|^2}{2\sigma_i^2}\right)} \quad (2.38)$$

де:

- $X$  як вхідний вектор
- $\mu$  як вектор прототипу  $i^{\text{th}}$  нейрона
- $\sigma$  як пропускна здатність  $i^{\text{th}}$  нейрона
- $\rho_i$  як вихід  $i^{\text{th}}$  нейрона

Параметри  $\mu$  і  $\sigma$  вивчаються неконтрольованим способом, наприклад, за допомогою певного алгоритму кластеризації.

Вихідний рівень використовує функцію лінійної активації як для завдань класифікації, так і для завдань регресії.

Обчислення на вихідному рівні виконуються так само, як стандартна штучна нейронна мережа, яка є лінійною комбінацією між вхідним вектором і вектором ваги. Обчислення на вихідному рівні можна математично записати так:

$$y = \sum_i^n w_i \Phi_i, \quad (2.39)$$

де  $w_i$  як зв'язок ваги,  $\Phi$  як вихід  $i^{\text{th}}$  нейрона з прихованого шару а у як результат передбачення

Отриманий прогноз можна використовувати як для завдань класифікації, так і для регресії, це залежить від цільової функції та функції втрат. Параметри  $w$  вивчаються контрольованим способом, наприклад градієнтним спуском.

Незважаючи на те, що вихідний рівень RBF можна використовувати як кінцевий результат, можна стекувати мережі RBF з іншими мережами, наприклад, ми можемо замінити вихідний рівень мережі RBF багаторівневим сприйняттям і навчити мережу від кінця до кінця[27].

### 2.3.5. CNN

Згорточні нейронні мережі ( CNN ) — це тип нейронної мережі, який використовується для класифікації даних на основі певних маркерів або міток. CNN належить до категорії нейронних мереж під наглядом [28]. Це означає, що мережі потрібен набір даних, який уже класифіковано за необхідними класами. Він вивчає ці вже існуючі класи, а потім визначає, до якого класу належать певні невидимі дані.

Нейронна мережа згортки, як випливає з назви, передбачає використання операції згортки. Ви можете уявити собі архітектуру цієї мережі як набір двовимірних матриць, накладених одна на одну. Перший шар представляє вхідне зображення. Після цього виконується математична операція згортки. Далі розмір зображення зменшується, оцінюючи, наприклад, максимальне або середнє значення сусідніх елементів. Ці два етапи згортки та субдискретизації виконуються кілька разів перед розкладанням елементів матриць у лінійний масив. Отримані значення передаються через повністю пов'язані шари нейронної мережі, кінцеві шари якої представляють вихідні дані. На рис. 2.10. зображено градієнтне навчання розпізнавання документів.




Рис. 2.10. Градієнтне навчання розпізнавання документів

Вихід CNN — це просто клас, до якого належать дані, а вхід — це самі дані. Пам'ятаючи, що CNN — це алгоритм навчання під наглядом, його можна використовувати, коли можна анотувати достатньо даних. Анотація даних — це процес позначення даних у потрібний клас. CNN найбільш ефективні, коли працюють із графічними даними, які потрібно згрупувати в певний клас.

Розглянемо ситуацію на фабриці по виготовленню консервації, де манго потрібно відправляти в секцію соління, а яблука — у секцію варення. Тепер CNN доручено розділити манго та яблука, дивлячись на зображення фруктів. Його слід навчити за допомогою графічного набору даних манго, позначеного як такого, та іншого набору графічних даних яблук із відповідною міткою.

Коли CNN дізнається, як виглядає кожен фрукт, він може класифікувати свіжі та небачені фотографії фруктів на манго та яблука. Це головна функція CNN.

### 2.3.6 RNN

Повторювана нейронна мережа ( RNN ) — це клас алгоритмів машинного навчання, які підпадають під категорію неконтрольованого навчання. Неконтрольоване навчання — це тип машинного навчання, якому не потрібен набір даних, позначений у необхідних класах. Такі алгоритми використовують вихідні дані одного кроку як частину вхідних даних для наступного кроку. Оскільки вони можуть використовувати вихідні дані попереднього кроку, вони швидше за все зможуть дізнатися, чи попередні вхідні дані пов'язані з поточними. Встановлення кореляції між останнім введенням і поточним введенням даних є основним завданням RNN [29].

Якщо ви пошукаєте значення слова «повторний» у словнику, ви побачите, що воно означає «повторюваний або часто». Слово відображає те, що існує математична операція, яка виконується кілька разів. У RNN вихідні дані в заданий момент часу оцінюються як функція вихідних даних мережі за попередньою міткою часу. Один важливий момент, який слід зазначити, полягає в тому, що всі вихідні значення використовують однакові правила підвищення градації, оскільки рівні RNN підтримують розподіл ваги. Розгляньте рис. 2.11, щоб мати більш чітке розуміння RNN, воно представляє роботу RNN.




Рис. 2.11. Структура RNN мережі.

Оскільки RNN найкраще підходять для завдань, які потребують передбачення наступних даних, вони широко використовуються для тимчасових даних, таких як послідовність слів. Якщо введенням є послідовність слів, RNN передбачить наступне слово послідовності. Він не потребує набору даних із мітками, щоб досягти своєї функції передбачення.

Розгляньте послідовність слів, які описують певний твір мистецтва на художній виставці. Там можна було б написати: “Митець, здається, занурився в глибини культурного вираження свого часу, щоб створити це вишукане мистецтво. Мазки пензля більш впевнені, ніж.....”. Коли це речення надходить

до RNN, воно аналізуватиме кожне слово відносно попереднього слова та намагатиметься імітувати той самий стиль написання.

Вихідні дані передбачені алгоритмом, можуть бути такими: «...інші художники свого часу». Але фактично написаний текст може бути «попередніми роботами художників». Кінцева мета полягає в тому, щоб максимально наблизити передбачені слова до фактичних слів.

#### 2.4. Висновки

На даний момент існують методи класифікації мовного сигналу, що дозволяють вирішувати завдання ідентифікації БПЛА по звуку. Багато з них ще знаходяться в стадії розробки і закриті від спільного доступу тому вирішено розробити свій метод ідентифікації БПЛА. Для виділення акустичних ознак обрано Mel - спектрограму. Для вирішення задачі класифікації раціонально використовувати нейронну мережа з архітектурою CNN. До її переваг можна віднести порівняльну простоту аналізу і достатньо високу ефективність класифікації. Завдяки використанню безперервної функції такі мережі здатні до узагальнення навчальної вибірки.

## РОЗДІЛ 3 НАУКОВО-ДОСЛІДНА ЧАСТИНА

### 3.1 Метод виявлення та ідентифікації БПЛА

Розроблений метод виявлення та ідентифікації БПЛА зображено на рис.

3.1.

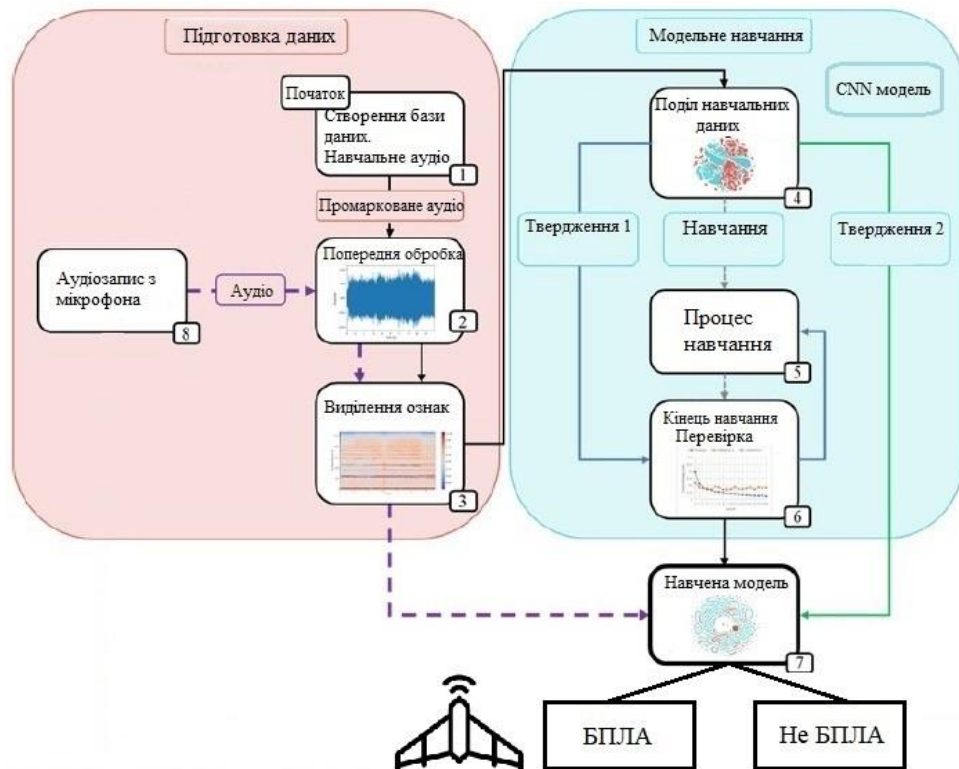


Рис. 3.1. Метод виявлення та ідентифікації БПЛА

Відповідно до структури, метод передбачає застосування таких етапів:

#### 1. Створення бази даних:

- пошук звукових сигналів: безпілотних літальних апаратів, інших звукових сигналів зовнішнього середовища, які можуть викликати помилкове спрацювання;

- маркування сигналів на 2 класи: БПЛА, не БПЛА.

#### 2. На вхід системи надходить звуковий сигнал, який підлягає попередній обробці, що включає такі етапи:

- перетворення звукового монофонічного сигналу на стерео сигнал;

- застосування передискретизації сигналу до частоти 44,1 кГц;
- стандартизація тривалості сигналу до фіксованої тривалості - 4 секунди.

3. На наступному етапі проводиться виділення ознак:

- звук перетворюється на спектрограму, що складається з 257-ми відліками частоти, за допомогою короткочасного перетворення Фур'є (STFT) із розміром вікна 25 мс та перекриттям вікна Ганна 10 мс.

- спектрограма перетворюється на Mel-спектрограму з 64-ма ділянками.

4. Mel-спектрограми передаються, як окремі вхідні дані попередньо навченим моделям CNN(згортова нейронна мережа).

5. Моделі CNN створюють вектор ознак для кожної Mel-спектрограми.

6. Навчена модель підтверджує гіпотезу, щодо того, чи являється вхідний звуковий сигнал з класу БПЛА чи не БПЛА.

Було розроблено програму на ЕОМ з реалізацією CNN архітектури мовою програмування Python з використанням бібліотек: scikit-learn, tensorflow, librosa.

Scikit-learn використовувався для підготовки навчальних даних для модельного навчання, розділивши набір даних у підмножини навчання та перевірки. TensorFlow використовувався для створення та навчання глибокої нейронної мережі. Librosa використовується для перетворення не обробленого аудіо на Mel-спектрограму. Код програми відображено в додатку Б.

Система складається:

- бази даних
- навчання
- результатів

### 3.1.1 База даних

Великі обсяги даних необхідні для навчання моделей глибокого навчання, спонукали до створення ряду наборів даних, що містять міські, побутові, промислові та загальні звуки середовищ. Тим не менш, звуки для нашої

програми є рідкісними, і їх важко створити враховуючи особливу спрямованість нашої системи.

Щоб точно налаштувати існуючі моделі SED, підготовлено набір даних звуків квадрокоптерів (набір даних «UAV»), що представляє клас «БПЛА». Ці аудіозаписи спочатку були зібрані з безкоштовних онлайн баз даних, доступ до яких можна отримати безпосередньо через їхні веб-сайти. Оскільки не було достатньо доступних аудіо даних безпілота Shahed-136 на веб-сайтах для успішного навчання моделей, тому аудіо завантажувалися з telegram каналів.

Враховуючи, що людське вухо може виявляти коливання повітря в діапазоні від 20 Гц до 20 000 Гц, більшість звуків літаків знаходяться в діапазоні від 100 Гц до 1000 Гц, а вибрана нейронна мережа обмежена частотами нижче 7,5 кГц, маркування виконано людиною. Критеріями виключення були відсутність чітких звуків БПЛА, наявність надмірного шуму, наявність кількох звуків разом із звуками БПЛА

Після ручного маркування загальна тривалість звуків БПЛА з безкоштовних онлайн-джерел (для навчання) становила 52 хвилини.

Крім того, набір даних «UrbanSound8K», який містить понад 8000 міських звуків (<4 с), спочатку розділених на 10 класів звуку, використовувався для представлення класу «не БПЛА» із загальною тривалістю 8,75 год. Цей набір даних вибрано, оскільки він містить декілька звуків (наприклад “свердління”, “автомобіль”, “відбійний молоток” і “кондиціонер”), які ймовірно спричинять помилкове виявлення БПЛА в міській місцевості.

Однак через велику різницю в загальній тривалості між обома наборами даних виникає проблема дисбалансу класів, коли менший клас (тобто “клас БПЛА”) містить набагато меншу кількість вибірок (тобто векторів ознак), ніж основний клас (тобто “не клас БПЛА”) як показано в таблиці 3.1.

Щоб подолати цю проблему, використано дві різні стратегії для навчальних даних.



По-перше зменшено вибірку для класу “не БПЛА” на четвертину, випадковим чином вилучаючи вибірки, щоб розмір обох класів збігався. Отриманий набір даних це “Дефіцитна вибірка”.

По-друге, збільшено вдвічі вибірку до класу “БПЛА”, щоб відповідати розміру класу “Не БПЛА”. Стратегії збільшення даних складаються з довільного застосування наступних модифікацій до звукової форми: розтягування або стиснення часу; повторна вибірка; зміна обсягу; і додавання випадкового шуму з рівномірним розподілом. Діапазони значень для кожного доповнення представлені в таблиці 3.1.

*Таблиця 3.1.*

### **Розмір вибірки для класів “БПЛА” і “не БПЛА”**

База даних	Розмір вибірки БПЛА	Розмір вибірки не БПЛА
Нормальна вибірка	780	7875
Дефіцитна вибірка	780	1968
Збільшення даних	1560	1968

#### 3.1.2 Навчання нейронної мережі

Навчальний набір даних потрібно розділити на три підмножини (навчання, перевірка 1 і перевірка 2), перш ніж можна було розпочати навчання моделі. Розподіл використаний для цього проекту, був таким: 55% навчання, 20% перевірка 1 і 25% перевірка 2. Втрата перехресної ентропії (тут також називається втратою інформації) обчислюється за допомогою TensorFlow. Збільшення втрати інформації вказуватиме на розбіжність прогнозованої ймовірності від реального класу.

Примусова зупинка та контрольні точки моделі були використані, щоб зберегти найкращу модель під час навчання та обмежити ймовірність перепідготовки моделі до навчального набору даних. Крос-ентропійні втрати були використані для коригування ваг нейронної мережі та моніторингу моделі навчання .

Навчання мало на меті мінімізувати втрати шляхом коригування ваг моделі в кінці кожної епохи, і модель епохи з найнижчим показником втрати

інформації перевірки 1 буде збережена. Якщо надалі не відбуватиметься зменшення втрати значення крос-ентропії після 10 послідовних епох, навчання зупиняється. Це продемонстровано на рисунку 3.2.

На рисунку 3.2 мінімальна втрата ентропії перевірки №1 сталася в епоху 9, а навчання зупинилося на епоха 19. Перевага доповнення контрольних точок моделі демонструє зростаюча розбіжність між втрата перевірки №1 і криві втрат при навчанні після епохи 9. Після перевірки №1 втрати більше не покращуються, модель почала підлаштовуватися під навчальні дані, як показано безперервно зменшується крива втрат при навчанні. Низькі втрати, отримані після перевірки №2 дає висновок, що модель класифікації працюватиме належним чином із новим аудіо.

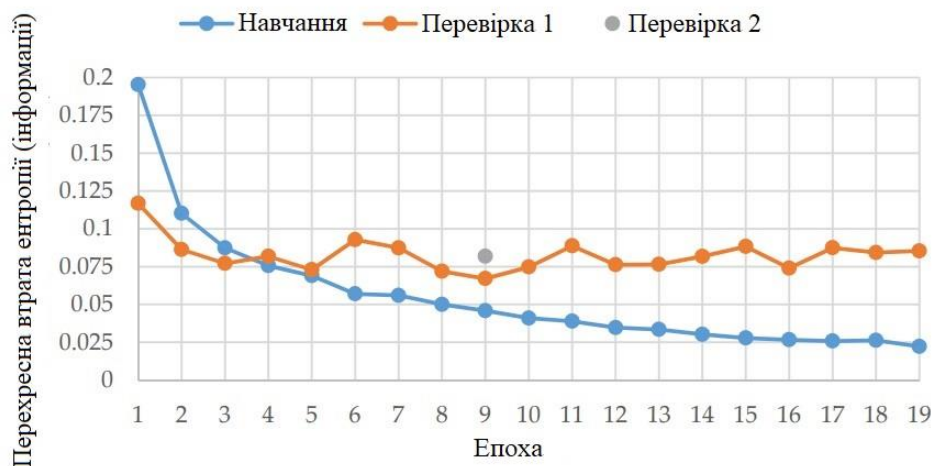


Рисунок 3.2. Історія навчання моделі CNN.

### 3.1.3 Результати

У табл. 3.2 наведено результати роботи різних методів виявлення та ідентифікації безпілотної.

Таблиця 3.2.

#### Порівняння точності методів ідентифікації БПЛА

Результат (%)	SVM	HMM	DTW	RNN	CRNN	CNN
Точність(Precision)	87.147	91.632	67.255	82.421	91.846	94.725
Точність(Recall)	87.723	92.458	66.586	80.257	91.911	94.815

Recall (точність позитивних зразків) розраховується як відношення між кількістю позитивних зразків, правильно класифікованих як позитивні, до загальної кількості позитивних зразків. Recall вимірює здатність моделі виявляти позитивні зразки. Чим вище Recall, тим більше виявлено позитивних зразків. Recall розраховується за формулою 3.1.

$$\text{Recall} = \frac{\text{True}_{\text{positive}}}{\text{True}_{\text{positive}} + \text{False}_{\text{negative}}} \quad (3.1)$$

Precision (точність всіх зразків) розраховується як відношення між кількістю правильно класифікованих позитивних зразків до загальної кількості зразків, класифікованих як позитивні (правильно чи неправильно). Точність вимірює точність моделі в класифікації зразка як позитивного. Precision розраховується за формулою 3.2.

$$\text{Precision} = \frac{\text{True}_{\text{positive}}}{\text{True}_{\text{positive}} + \text{False}_{\text{positive}}} \quad (3.2)$$

Для наглядності табл 3.2. перетворена в гістограму порівняння методів яка зображена на рис 3.3.

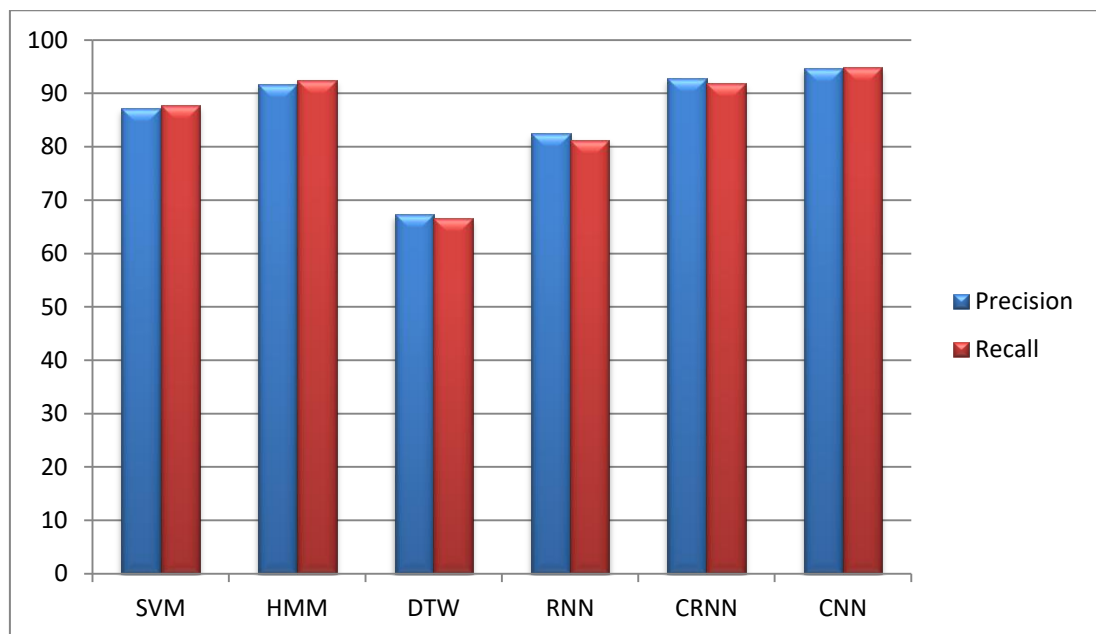


Рисунок 3.3 Порівняння точності методів виявлення та ідентифікації БПЛА.

Цей метод продемонстрував ефективність моделей гнучкого навчання для акустичного виявлення та ідентифікації багатороторних БПЛА, які досягли точності класифікації 94,725 і 94,815%. Дослідження, проведене на оптимізованій архітектурі індивідуальної моделі, показало, що моделі CNN перевершують відтворену найефективнішу з моделей - модель CRNN. У цьому дослідженні акустичні сигнали були перетворені в Mel – спектрограми і було показано, що CNN найкраще підходять в сукупності з Mel – спектрограмами. Таким чином, і було показано, що модель CNN найкраще підходить для акустичної ідентифікації БПЛА.

Єдиним недоліком використання мереж CNN є те, що вони займають значно більше часу для навчання. Однак це не суттєво, бо час має більше значення, коли моделі роблять прогнози (висновки). Як тільки всі моделі є навченими, час передбачення залишається незначним.

Відстань між дроном і мікрофоном є обмежуючим фактором, який впливає на продуктивність виявлення. Тому для подальшої роботи було б корисно вивчити, на яких відстанях безпілотник більше не буде виявлено, і як оптимізувати розташування мікрофонів по периметру території, щоб гарантувати, що безпілотники завжди можна виявити в певному радіусі. Це також призведе до акустичної локалізації БПЛА. Умови польоту, такі як зависання, низьку та високу швидкість, є ще одним корисним фактором для аналізу під час оцінки продуктивності виявлення.

Майбутня робота може оцінити характеристики моделі в різних умовах польоту. У той час як розроблена основа може бути застосована до інших надійних класифікаційних проблем, такі як повітряні та дорожні транспортні засоби, двигуни, мережі створені та оптимізовані тут були спеціально для виявлення БПЛА, оскільки вони були навчені використовуючи Mel-спектрограми як вхідні дані, що представляють ключові акустичні характеристики дрона/фононих звуків. Запропонований метод також може бути використаний для подальшої роботи з іншими методами виявлення. Його

можна застосувати для створення системи на основі комбінації акустичних, радіолокаційних та візуальних моделей, які потім покращать загальну ефективність виявлення.

### 3.2 Дослідження акустичного спектру БПЛА

Аудіосигнали безпілотних літальних апаратів мають багаторівневу періодичну структуру, частоти гармонік яких є кратні числа. Дуже мало проведено досліджень щодо впливу шумових характеристик на якість виявлення БПЛА за аудіосигналом, а в алгоритмах виявлення не використовується ознака кратності частот. У рамках проведення акустичних досліджень, які як правило відбуваються на фоні шумів та перешкод слід приділяти серйозну увагу використанню алгоритмів стійких до зовнішніх завад. Дослідження спектральних характеристик проводиться в програмному забезпеченні MATLAB. Скрипт дослідження спектру аудіосигналу відображено в додатку В.

Типовий спектр акустичного випромінювання БПЛА з бензиновим двигуном Shahed-136 зображено на рис.3.4.

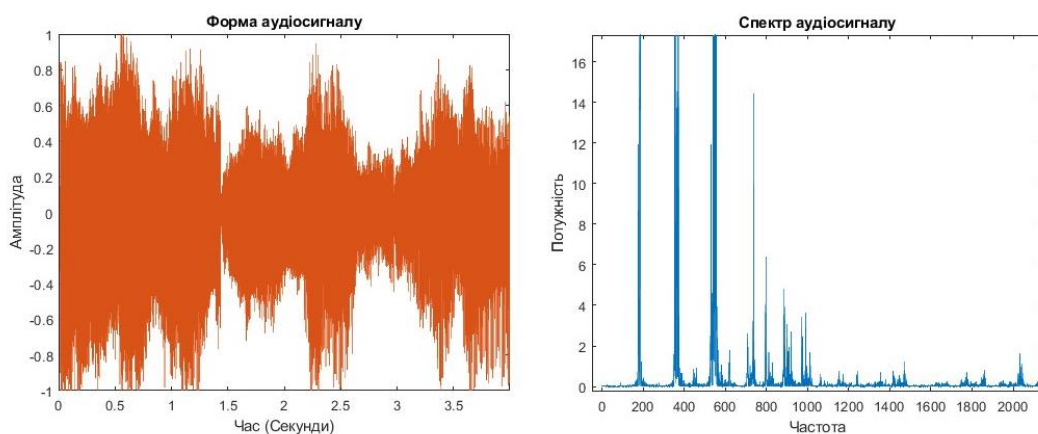


Рис 3.4 Форма і спектр аудіосигналу Shahed-136

Спектр випромінювання містить набір дискретних складових, максимуми потужності гармонік розміщено в області частот 200-2000 Гц. Частота першої

гармоніки становить 200 Гц, що дорівнює частоті руху одного повітряного гвинта. Наступні гармоніки кратні частоті  $f_1$ .

Спектр акустичного випромінювання БПЛА з 4 електродвигунами зображено на рис. 3.5.




Рис 3.5. Форма і спектр квадрокоптера

Максимуми потужностей розміщуються в області частот 80-3000 Гц. Частота першої гармоніки становить 80 Гц, що дорівнює частоті руху чотирьох повітряних гвинтів. Наступні гармоніки кратні частоті  $f_1$ .

При акустичному експерименту до точки спостереження надходять хвилі, що створені рухом кожної лопаті, ці хвилі будуть повторюватись відповідну кількість разів. Через цю особливість можна виявити сигнал, що знаходиться нижче рівня власних шумів приймача та зовнішніх шумів. Це отримується завдяки некорельованості шумів, що надходять на вхід приймача.

Амплітуди гармонік обертання лопасті зі збільшенням частоти будуть зменшуватись, що також є акустичною ознакою БПЛА. В загальному випадку амплітуди є випадковими величинами. Фази гармонік розподілені за нормальним законом і також є випадковими.

Математично випромінювання гвинта можна представити:

$$S(t) = \sum_{i=1}^k A_i \cos(2\pi M F * i * t + \varphi_i), \quad (3.3)$$

де  $k$  – кількість гармонік акустичного випромінювання, що розглядають;  
 $A_i$  – амплітуда  $i$ -ої гармоніки;  $\phi_i$  – фаза  $i$ -ої гармоніки.

Такі сигнали на коротких інтервалах часу можна розглянути як стаціонарні і для аналізу використовують методи спектрального оцінювання.

Порівнюючи результати досліджень безпілотників з нерухомим крилом та багатороторного типу то для першого гармонійна структура простежується досить добре. В БПЛА багатороторного типу виділення лінії гармонік викликають труднощі, так як максимуми спектральної потужності більш згруповані. Якщо збільшувати кількість повітряних гвинтів тоді спектр звукового сигналу стає подібним до шуму і в ньому майже неможливо відстежити гармоніки.

При проведенні звукових досліджень вітер завдає великого шумового впливу. Форма і спектр аудіосигналу зображено на рис. 3.6. Максимум енергії вітру розташовано на частотах від 30 Гц і досягає 400-450 Гц, а починаючи з 1 кГц спектр стає близький до рівномірного.




Рис 3.6. Форма і спектр аудіосигналу вітру

Шум вітру в корисному сигналі можна зменшити шляхом фільтрації низьких частот (зазвичай гармоніки звукового сигналу БПЛА знаходяться у вищих частотах ніж вітер), але якщо сигнал малопотужний (БПЛА знаходиться на далекій відстані) тоді шуми вітру можуть його заглушувати. При маскуванні корисного сигналу потрібно переглянути взаємно-кореляційні властивості

шуму вітру. Також негативний вплив має дощ оскільки він утворює завади в ширшій смузі частот і низькочастотна фільтрація стає тоді недієвою. Mel-спектрограми зображено на рис. 3.7.




Рис 3.7. Mel-спектрограми Shahed-136 та вітру.

На основі проведеного спектрального акустичного аналізу БПЛА можна зробити висновок, що БПЛА з бензиновими і електричними двигунів мають гармоніки сигналу які видно на амплітудному спектрі, це є особливою акустичною ознакою, що дозволяє їх відрізнити від звуків навколишнього середовища.

### 3.3. Висновки до розділу 3

В даному розділі було досліджено метод виявлення та ідентифікації БПЛА з застосуванням згорткової нейронної мережі. Створено навчальну базу БПЛА і наповнено аудіосигналами квадрокоптерів та безпілотників Shahed-136. Розроблено код виявлення та ідентифікації на мові програмування Python. Проведено аналіз точності різних видів нейронних мереж та методів ідентифікації, згідно з якими CNN мережа має найбільшу точність виявлення.

Досліджено акустичний спектр звуків: БПЛА ( дрона-камікадзе Shahed-136, квадрокоптера DJI Mavic Pro Platinum ), а також шуму вітру в програмному середовищі Matlab. Зроблено висновок: безпілотний літальний апарат можна відрізнити від шуму вітру за його звуковими гармонічними складовими.



## РОЗДІЛ 4

## ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1. Планування заходів з охорони праці. Види планування та контролю стану охорони праці.

Метою планування заходів з охорони праці є визначення необхідних вкладень у заходи з охорони праці для ефективного впливу на стан охорони праці.

Система планів з охорони праці окремого підприємства може включати:

- перспективне планування (на період, більший одного року) ;
- поточне планування (на рік) ;
- оперативне планування (детальні плани, спрямовані на вирішення конкретних питань працезахоронної діяльності на підприємстві в короткостроковому, до одного року, періоді).

Планування в охороні праці може включати:

- визначення цілей діяльності з охорони праці на підприємстві та засобів їх досягнення;
- вибір методів і базових показників, за допомогою яких може здійснюватися оцінка необхідних вкладень в охорону праці;
- розрахунок суми вкладень у заходи з охорони праці та раціональний розподіл цієї суми за напрямками діяльності;
- забезпечення організації контролю виконання плану (при необхідності здійснення коригування запланованих показників) ;
- здійснення постійного контролю умов і безпеки праці на підприємстві та оперативне реагування на відхилення від нормативних вимог.

Перспективне планування вміщує найбільш важливі, трудомісткі і довгострокові за терміном виконання заходи з охорони праці, виконання яких, як правило, вимагає сумісної роботи кількох підрозділів підприємства. Можливість виконання заходів перспективного плану повинна бути

підтверджена обґрунтованим розрахунком необхідного матеріально-технічного забезпечення і фінансових витрат з зазначенням джерел фінансування.

До перспективних планів належить комплексний план покращення умов праці і санітарно-оздоровчих заходів, що передбачає створення, відповідно до нормативних актів з охорони праці, умов праці, пов'язаних з перспективними змінами підприємства. Таке планування, як правило, розраховане на термін від 2 до 5 років. Реалізація цих планів забезпечується через річні плани номенклатурних заходів з охорони праці, які вносяться до угоди, що є невід'ємною частиною колективного договору.

Поточне планування здійснюється у межах календарного року через розроблення відповідних заходів у розділі «Охорона праці» колективного договору.

Поточні плани передбачають реалізацію заходів із покращення умов праці, створення кращих побутових і соціальних умов на виробництві. Ці плани обов'язково забезпечуються фінансуванням згідно з розробленими кошторисами.

Питання охорони праці можуть віддзеркалюватися в інших поточних планах, які підприємства та організації можуть складати на вимогу трудових колективів:

- план соціального розвитку колективу;
- наукової організації праці;
- механізації важких і ручних робіт;
- охорони праці жінок;
- підготовки підприємства до робіт в осінньо-зимовий період;
- підвищення культури виробництва та ін.

Оперативне планування роботи з охорони праці здійснюється за підсумками контролю стану охорони праці в структурних підрозділах і на підприємстві в цілому.

Оперативні плани складаються для швидкого виправлення виявлених в процесі державного, відомчого і громадського контролю недоліків в стані охорони праці, а також для ліквідації наслідків аварій або стихійного лиха.

Оперативні заходи щодо усунення виявлених недоліків зазначаються безпосередньо у наказі власника підприємства, який видається за підсумками контролю, або у плані заходів, як додатку до наказу.

Організаційно-методичну роботу щодо складання перспективних, поточних та оперативних планів здійснює служба (спеціаліст) охорони праці.

#### 4.2. Оцінка стійкості роботи приладобудівних підприємств до впливу уражаючих факторів ядерної зброї

Оцінка стійкості об'єкта полягає у виявленні слабких елементів, щоб в подальшому провести інженерно-технічні заходи, направлені на підвищення стійкості об'єкта в цілому, а також його автоматизованого обладнання, щоб запобігти перериванню технологічного процесу.

Заходи щодо підвищення стійкості роботи об'єкта проводяться як у мирний час, і при загрозі нападу противника. Одним із таких заходів є прогнозування та оцінка стійкості його роботи при впливі факторів ядерного вибуху (ЯВ). При виконанні розрахунків закладаються необхідні вихідні дані, враховуються зони можливих руйнувань, у яких виявиться об'єкт, та максимальні значення параметрів вражаючих факторів ядерного вибуху.

Основними вражаючими чинниками ядерного вибуху є:

- повітряна ударна хвиля;
- світлове випромінювання;
- проникаюча радіація;
- радіоактивне зараження;
- електромагнітний імпульс (ЕМІ).

Стійкість об'єкта оцінюється стосовно кожного їх.

При ЯВ виникають вторинні фактори, що вражають, які враховуються при оцінці стійкості, а це: пожежі, вибухи, зараження АХОВ (аварійно-хімічно небезпечні речовини), катастрофічне затоплення тощо.

Під час проведення оціночних розрахунків допускається, що це елементи об'єктів піддаються майже одночасному впливу вражаючих факторів та значення їх можна вважати однаковими на всієї площі об'єкта.

Доцільна межа підвищення стійкості об'єкта визначається але ймовірному максимальному значенню параметрів, що вражають фактори очікувані на об'єкті.

При визначенні максимальних значень параметрів, що вражають факторів ЯВ, очікуваних на об'єкті, необхідно виходити з того, що потужність ядерного боєприпасу вибирається такою, щоб у зоні можливих сильних руйнувань виявилось 60 – 70 % забудови міста.

Оцінка стійкості роботи об'єкту – це всебічне вивчення підприємства з точки зору властивості його протистояти дії уражаючих факторів ядерного вибуху, продовжувати роботу і відновлювати виробництво при одержанні слабких уражень.

Промислові підприємства народного господарства відрізняються один від одного як по конструктивному вирішенню, так і по технологічному процесу. Різниця об'єктів полягає в будівлях і спорудах, обладнані і технології виробництва, комунально – енергетичних сітках і території, на якій розташований об'єкт. Тому по всіх випадках оцінка стійкості кожного об'єкта має свої особливості і потребує конкретного підходу до вирішення цього питання. У даному випадку можливо розглянути тільки загальне для всіх об'єктів питання оцінки стійкості до дії уражаючих факторів зброї масового ураження.

Оцінка стійкості роботи об'єкта починається з району розміщення. Об'єкт може знаходитись у місті, за межею його проектної забудови і на деякій відстані від міста. Досліджується територія району, його структура, густота і тип забудови, сусідні об'єкти і можливість виникнення на них другорядних

факторів ураження. На об'єкті визначається густина забудови, розміщення основних будівель і споруд, які здійснюють вплив на характер ураження, можливе утворення завалів і виникнення пожеж. Особлива увага звертається на ділянки, де можливе виникнення небезпечних другорядних факторів ураження.

Беруться на облік всі будівлі і споруди, проводиться оцінка їх статичної стійкості. Вивчається кожен цех і його окремі елементи як по конструктивному вирішенню, так і по матеріалам які були використані в будівництві. Розглядаються умови розташування технологічного обладнання і визначаються види уражень і пошкоджень, які можуть мати місце при ядерному вибуху і завалі загороджуючих конструкцій цехів. Особливо важливо визначити захист цінного і особливого обладнання, насиченість виробництва автоматикою і можливість продовження виробництва у випадку виходу з ладу контрольно – вимірювального обладнання.

Досліджуються комунально – енергетичні системи об'єкта і проводиться оцінка стійкості споруд і ліній, тобто, визначаються параметри уражаючих факторів, при яких комунально – енергетичні сітки те чи інше ураження.

Визначається забезпечення працюючого персоналу захисними спорудами: встановлюється кількість сховищ, укриттів і оцінюються їх захисні властивості.

Вивчається система керування, зв'язку і оповіщення на основі вивчення стану захисних пунктів керування, вузлів і ліній зв'язку.

Аналізується система матеріально – технічного забезпечення і виробничих зв'язків. Встановлюється об'єм запасів і можливих строків продовження роботи без постачань; визначається відповідність їх кількості і номенклатури потреби, які потребуються для виробництва військового часу. Оцінюється стійкість складів сировини, комплектуючих виробів, готової продукції і інших матеріалів, а також сховища горючих матеріалів.

Вивчається підготовка об'єкту до відновлення виробництва у випадку одержання слабких чи середніх уражень. Аналіз виробничої діяльності об'єкта дозволяє виявити слабкі елементи, ділянки і підготувати план підвищення

стійкості їх роботи і план відновлювальних робіт, а також забезпечити їх будівельно – монтажною і проектною документацією.

Оцінка стійкості роботи об'єкта здійснюється за уражаючими факторами ядерного вибуху. Відстані, на якій може бути надлишковий тиск ударної хвилі, дані про надлишковий тиск беруться з таблиці у відповідності до відстані від центру вибуху і потужності ядерного боезапасу.

Критерієм для визначення стійкості об'єкта народного господарства до дії ударної хвилі ядерного вибуху являється величина надлишкового тиску, при якій будівлі і споруди об'єкта зберігаються чи одержать слабкі, або середні ураження.

При оцінці стійкості об'єкта необхідно виявити найбільш слабкі елементи і ділянки, від яких залежить робота всього підприємства.

Проводячи оцінку стійкості, доцільно всі дані розрахунків по надлишковому тиску звести до робочої таблиці. Характеристика будівель, споруд і величина надлишкового тиску, яка викликає слабкі чи середні ураження вибираються з таблиць.

Після оцінки окремих будівель оцінюється об'єкт в цілому. При цьому стійкість об'єкту визначається по тій будівлі чи споруді, яке руйнується при найменшому надлишковому тиску.

Після оцінки стійкості об'єкта розробляються заходи, які необхідно провести для підвищення стійкості роботи об'єкта до дії ударної хвилі ядерного вибуху. Для цього визначають доцільні межі підвищення стійкості кожної споруди.

Критерієм стійкості об'єкта до дії світлового випромінювання являється світловий імпульс, при якому проходить згорання тих чи інших будівель і споруд та виникнення пожеж.

При оцінці стійкості враховується якість будівельного матеріалу, характеристика будівель і споруд, особливості виробництва. Виникнення пожеж, в першу чергу, залежить від того, які будівельні матеріали використані при спорудженні будівель і споруд об'єкта.

Всі будівельні матеріали по загоранню діляться на три групи: ті які не загоряються, важкогорючі, і ті які згорають.

Ті що не загоряються – це такі матеріали, які під дією полум'я чи високої температури не загоряються, не тліють і не обвуглюються. До них відносяться всі натуральні і штучні неорганічні матеріали, а також ті, що використовуються в будівництві метали.

Важкогорючі – це такі матеріали, які під дією полум'я чи високої температури важко загоряються, тліють чи обвуглюються і продовжують горіти чи тліти тільки при наявності джерела вогню, а при його відсутності горіння чи тління зупиняється.

До таких матеріалів відносяться матеріали, які складаються з негорючих і горючих складових, наприклад: асфальтовий бетон, гіпсові і бетонні деталі з органічними заповнювачами; глиносолом'яні матеріали чи густиною не менше 900 кг/ м<sup>3</sup> ; цементний фіброліт; деревина, яка була піддана глибокому пропитуванню антипіренами; войлок, вимочений в глиняному розчині, та інші. Ті що згорають – це такі матеріали, які під дією полум'я чи високої температури загоряються чи тліють і продовжують горіти чи тліти після знищення джерела вогню. До таких матеріалів відносяться всі органічні матеріали, які не були піддані глибокій пропитці антипіренами. Самими небезпечними являються будівлі і споруди, виконані з матеріалів, що згорають.

Але і будівлі виконані з матеріалів які не згорають, можуть витримати дію полум'я чи високої температури тільки певний час. Межа вогнестійкості конструкцій визначається часом в годинах, під час якого не появляються наскрізні отвори, конструкція не втрачає несучої здатності, не руйнується і не нагрівається до температур порядку 200С на протилежній стороні.

#### 4.3. Висновки до розділу 4

У підрозділі з охорони праці проаналізовано питання планування заходів з охорони праці. Розглянуто основні види планування та контролю стану охорони праці.

У підрозділі з безпеки в надзвичайних ситуаціях проаналізовано питання аналізу стійкості роботи приладобудівних підприємств до впливу уражаючих факторів ядерної зброї.



## ЗАГАЛЬНІ ВИСНОВКИ

У роботі розроблено метод виявлення та ідентифікації БПЛА з застосуванням нейронної мережі.

Отримані результати:

1. Проведено огляд сучасних методів виявлення безпілотних літальних апаратів. Зроблено порівняльну характеристику методів виявлення, проаналізовано переваги і недоліки кожного методу. Акустичний метод найкраще підходить для виявлення міні-БПЛА або БПЛА з бензиновим двигуном.

2. Проаналізовано основні види акустичного виявлення. Визначено що пасивне акустичне виявлення найкраще задовільняє умову скритності системи, що актуально у військових цілях.

3. Проаналізовано методи акустичного виділення акустичних ознак та розпізнавання БПЛА. Визначено ефективні методи для вирішення поставленого завдання: метод виділення - Mel спектрограма, та метод ідентифікації згорткова нейронна мережа(CNN).

4. Розроблено та реалізовано в програмному забезпеченні Python метод виявлення та ідентифікації БПЛА, який показав точність розпізнавання 94%, перевершивши наявні методи.

5. Досліджено акустичні спектри звуків: БПЛА та фонових звуків в програмному середовищі Matlab.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Different Types of Drones and Uses [Електронний ресурс] // Режим доступу: <https://www.jouav.com/blog/drone-types.html> // (дата звернення 25.09.2022). Назва з екрану.
2. Shahed 136 [Електронний ресурс] // Режим доступу: [http://www.military-today.com/aircraft/shahed\\_136.htm](http://www.military-today.com/aircraft/shahed_136.htm) // (дата звернення 28.09.2022). Назва з екрану.
3. Квадрокоптер Dji Mavic Pro Platinum [Електронний ресурс] // URL: <https://wazza.com.ua/products/kvadrokopter-dji-mavic-pro-platinum/> // (дата звернення 28.09.2022). Назва з екрану.
4. Горбунов В. А. Эффективность обнаружения целей [Текст]: 1979. – С. 16.
5. Zelnio A.M. Detection of small aircraft using an acoustic array [Текст]: Thesis. B.S. – Electrical Engineering, Wright State University, 2007. – 55 p.
6. Соловьев В. А. Проблемы обнаружения беспилотных летательных аппаратов оптико-электронными устройствами [Текст]: // Электронный математический и медико-биологический журнал. – 2011. – Т. 10. – Вып. 3. – С. 1–13.
7. Kartashov V.M. Systematic errors in measurement of meteorological variables in correlation processing radioacoustic sounding system signals [Текст]: / Kartashov V.M., Babkin S.I., Tolstykh E.G., Lepcha N.G // Telecommunications and Radio Engineering (English translation of *Electrosvyaz and Radiotekhnika*). -2016.,- V.75 (9). Pp. 835-843.
8. Acoustic location [Електронний ресурс] // Режим доступу: [https://en.wikipedia.org/wiki/Acoustic\\_location](https://en.wikipedia.org/wiki/Acoustic_location) // (дата звернення 29.09.2022). Назва з екрану.
9. Карташов В.М. Особенности обнаружения и распознавания малых беспилотных летательных аппаратов [Текст] / В.М.Карташов, В.Н. Олейников,

С.А. Шейко, С.И. Бабкин, И.В. Корытцев, О.В. Зубков // Радиотехника. - 2018. - №195, - С.235-243

10. Processing and Recognition of Small Unmanned Vehicles' Sound Signals. Department of Media Engineering and Information Radio Electronic Systems Kharkiv National University of Radio Electronics [Электроний ресурс]/ V. Kartashov, V. Oleynikov, I. Koryttsev– Режим доступа: [www/ URL: http://openarchive.nure.ua/handle/document/](http://www.openarchive.nure.ua/handle/document/) – 09.11.2019 р. – Загл. з екрану.

11. Информационные характеристики звукового излучения малых беспилотных летательных аппаратов [Электроний ресурс]/ В.М.Карташов, В.Н.Олейников, С.А.Шейко С.И.Бабкин, , И.В. Корытцев – Режим доступа: [www/ URL: http://openarchive.nure.ua/handle/document/5740/](http://www.openarchive.nure.ua/handle/document/5740/) – 07.11.2019 р. – Загл. з екрану.

12. С. Panagiotakis and G. Tziritas, “A speech/music discriminator based on rms and zero-crossings,” IEEE Transactions on multimedia, vol. 7, no. 1, pp. 155–166, 2005.

13. S. Adavanne, G. Parascandolo, P. Pertila, T. Heittola, and T. Virtanen, “Sound event detection in multichannel audio using spatial and harmonic features,” in Scenes and Events 2016 Workshop (DCASE2016), p. 6, 2016.

14. V. Peltonen, J. Tuomi, A. Klapuri, J. Huopaniemi, and T. Sorsa, “Computational auditory scene recognition,” in 2002 IEEE International Conference on Acoustics, Speech, and Signal Processing, vol. 2, pp. II– 1941–II–1944, May 2002.

15. D. G. Bhalke, C. B. R. Rao, and D. S. Bormane, “Automatic musical instrument classification using fractional fourier transform based- mfcc features and counter propagation neural network,” Journal of Intelligent Information Systems, vol. 46, pp. 425–446, Jun 2016.

16. Eichner, M. and M. Wolff, "Data-Driven Generation of Pronunciation Dictionaries In The German Verbmobil Project - Discussion of Experimental Results," IEEE Int. Conf. on Acoustics, Speech and Signal Processing, 2000, Istanbul pp. 1687-1690.

17. What is a Spectrogram [Електронний ресурс] // Режим доступу: <https://pnsn.org/spectrograms/what-is-a-spectrogram> // (дата звернення 10.10.2022). Назва з екрану.

18. E. Çakır, G. Parascandolo, T. Heittola, H. Huttunen, and T. Virtanen, “Convolutional recurrent neural networks for polyphonic sound event detection,” *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 25, pp. 1291–1303, June 2017

19. X. Yu and Y. Zhang, “Sense and avoid technologies with applications to unmanned aircraft systems: Review and prospects,” *Progress in Aerospace Sciences*, vol. 74, pp. 152–166, 2015.

20. T. Zsedrovits, A. Zarandy, B. Vanek, T. Peni, J. Bokor, and T. Roska, “Visual detection and implementation aspects of a uav see and avoid system,” in *2011 20th European Conference on Circuit Theory and Design (ECCTD)*, pp. 472–475, IEEE, 2011.

21. G. J. J. Ruijgrok, *Elements of Aviation Acoustics*. VSSD, 2007.

22. Нейронні мережі [Електронний ресурс] // Режим доступу: <https://www.ibm.com/cloud/learn/neural-networks> // (дата звернення 10.10.2022). Назва з екрану.

23. Neural Network Models Explained [Електронний ресурс] // Режим доступу: <https://www.seldon.io/neural-network-models-explained>

24. 9 Types of Neural Networks: Applications, Pros, and Cons [Електронний ресурс] // Режим доступу: <https://www.knowledgehut.com/blog/data-science/types-of-neural-networks> // (дата звернення 15.10.2022). Назва з екрану.

25. TensorFlow – одношаровий перцептрон [Електронний ресурс] // Режим доступу: <https://coderlessons.com/tutorials/mashinnoe-obuchenie/vyuchit-tensorflow/tensorflow-odnosloinyi-perseptron> // (дата звернення 18.10.2022). Назва з екрану.

26. Що таке багатосаровий перцептрон [Електронний ресурс] // Режим доступу: <https://uk.theastrologypage.com/multilayer-perceptron> // (дата звернення 20.10.2022). Назва з екрану.

27. What are Radial Basis Functions Neural Networks? [Електронний ресурс] // Режим доступу: <https://www.simplilearn.com/tutorials/machine-learning-tutorial/what-are-radial-basis-functions-neural-networks> // (дата звернення 20.10.2022). Назва з екрану.

28. 5 Different Types of Neural Networks [Електронний ресурс] // Режим доступу: <https://www.projectpro.io/article/5-different-types-of-neural-networks/431> // (дата звернення 25.10.2022). Назва з екрану.

29. Introduction to Recurrent Neural Network [Електронний ресурс] // Режим доступу: <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/> // (дата звернення 2.11.2022). Назва з екрану.

30. Бачинський М.В., Дедів І.Ю., Дозорський В.Г. Обґрунтування структури системи відбору акустичних сигналів для задач медичної діагностики систем дихання та голосотворення. Вісник Хмельницького національного університету : Збірник наук. праць. Вип. №3 (177): Технічні науки. Хмельницький. 2011. С. 192- 195.

31. Бачинський М.В., Дедів І.Ю. Обґрунтування інформативності ознак дихальних шумів для задачі діагностики дихальної системи. Збірник наукових праць SWorld. Матеріали міжнародної науково-практичної конференції «Сучасні проблеми та шляхи їх вирішення в науці, транспорті, виробництві та освіті '2011». 4. Том 5. Технічні науки. Одеса, 2011. Т. 5. З 83-85.

32. Джичка Н., Дедів І., Дозорський В., Драган Я. Модель акустичного сигналу для виявлення порушень стану дихальної системи та голосового апарату як частковий випадок стохастичної коливної системи. Вісн. Нац. ун-ту "Львів. політехніка". 2011. № 710. С. 155-158.

33. Дедів І., Дозорський В. Обґрунтування структури системи відбору акустичних сигналів для задач діагностики систем дихання та голосотворення. Матеріали науково-технічної конференції «Теоретичні та прикладні аспекти радіотехніки і приладобудування». Тернопіль : ТНТУ ім. І.Пуллюя, 2011. С. 24-2

# ДОДАТКИ

ДОДАТОК А

Копія тези

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ**  
Тернопільський національний технічний університет імені Івана Пулюя (Україна)  
Університет імені П'єра і Марії Кюрі (Франція)  
Маріборський університет (Словенія)  
Технічний університет у Кошице (Словаччина)  
Вільнюський технічний університет ім. Гедимінаса (Литва)  
Міжнародний університет цивільної авіації (Марокко)  
Наукове товариство ім. Т.Шевченка

# **АКТУАЛЬНІ ЗАДАЧІ СУЧАСНИХ ТЕХНОЛОГІЙ**

**Збірник**  
тез доповідей

**XI Міжнародної науково-практичної  
конференції молодих учених та студентів**  
7-8 грудня 2022 року



**УКРАЇНА**  
**ТЕРНОПІЛЬ – 2022**

23.	<b>А.М. Паламар, Ю.А. Гук</b> КОМП'ЮТЕРНА СИСТЕМА ДЛЯ ВИЗНАЧЕННЯ ІНТЕНСИВНОСТІ РУХУ АВТОМОБІЛЬНОГО ТРАНСПОРТУ	147
24.	<b>Д.Р. Колісник, Д.В. Мидлик, І.Ю. Дедів, Л.Є. Дедів</b> ЗАДАЧА ОЦІНЮВАННЯ ПОШИРЕННЯ РАДІОСИГНАЛІВ У ВІДКРИТОМУ ПРОСТОРІ	148
25.	<b>С.Р. Пискальний, Б.В. Сарняк, І.Ю. Дедів</b> ЗАДАЧА УЩІЛЬНЕННЯ НЕСТАЦІОНАРНИХ СИГНАЛІВ ДЛЯ ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМ	149
26.	<b>М.П. Мотелюк, С.Т. Боїло, І.Ю. Дедів, В.Г. Дозорський</b> МЕТОДИ ОБРОБКИ МОВНИХ СИГНАЛІВ ДЛЯ БЕЗПЕКОВИХ СИСТЕМ	150
27.	<b>Б.Є Томс, Г.П. Химич</b> ЕФЕКТИВНІСТЬ ОПТОВОЛОКОННИХ ЛІНІЙ У МІСЬКИХ УМОВАХ	151
28.	<b>А.О. Naida, L.V. Moroz</b> DATAFICATION: THE PROBLEM BENEATH THE SURFACE	153
29.	<b>О.В. Палка</b> МІКРОСЕРВІСНА АРХІТЕКТУРА РОЗУМНОГО МІСТА	155
30.	<b>О.В. Палка</b> ІНТЕГРОВАНА АРХІТЕКТУРА РОЗУМНОГО МІСТА З БЛОКЧЕЙНОМ ТА ІОТ	157
31.	<b>І. Гунчак, Г. Химич</b> ДОСЛІДЖЕННЯ МЕТОДУ РАДІОЕЛЕКТРОННОЇ БОРОТЬБИ З СУПУТНИКОВИМИ СИСТЕМАМИ ТЕЛЕКОМУНІКАЦІЙ ДРОНІВ	158
32.	<b>А.В. Атаманчук, І.Ю. Дедів</b> МЕТОД ВИЯВЛЕННЯ ТА ІДЕНТИФІКАЦІЇ БПЛА З ЗАСТОСУВАННЯМ НЕЙРОННОЇ МЕРЕЖІ	160
33.	<b>В.Л. Дунець, Н.І. Шилівський, О.Ю. Щирба, Д.О. Гуменок, Т.В. Чирський</b> АЛГОРИТМ ОЦІНЮВАННЯ ЗАВАДОЗАХИЩЕНОСТІ КАНАЛУ ЗВ'ЯЗКУ	162
34.	<b>В.В. Никитюк, к.т.н., О.Ф. Дозорська, к.т.н., А.К. Карнаухов</b> МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ МОВНИХ СИГНАЛІВ ДЛЯ ЗАДАЧ АВТЕНТИФІКОВАНОГО ВХОДУ КОРИСТУВАЧІВ	163
35.	<b>С.В. Уніят, М.О. Хвостівський</b> АКТУАЛЬНІСТЬ ОБРОБКИ ПУЛЬСОВИХ СИГНАЛІВ ПРИ ФІЗИЧНИХ НАВАНТАЖЕННЯХ У КАРДІОДІАГНОСТИЧНИХ СИСТЕМАХ	164
36.	<b>Ю.Б. Канаціла, С.Р. Діаур</b> ДОСЛІДЖЕННЯ ТА РОЗРОБКА МЕТОДІВ ПЛАНУВАННЯ ТРАСЕКТОРІЇ МОБІЛЬНИХ РОБОТІВ	165
37.	<b>Н.А. Гарматюк, П.О. Скалецький, В.О. Дуда</b> ХМАРНІ ОБЧИСЛЮВАЛЬНІ ПЛАТФОРМИ ТА MICROSOFT AZURE	167
38.	<b>Н.В. Лісовий, А.Р. Ставицька, А.В. Гіжовський</b> ХМАРНІ ІНФОРМАЦІЙНО-ТЕХНОЛОГІЧНІ ПЛАТФОРМИ АНАЛІТИЧНОГО ОПРАЦЮВАННЯ ДАНИХ	168
39.	<b>П.О. Скалецький, Н.А. Гарматюк, В.О. Дуда</b> ПЕРЕНЕСЕННЯ ДАНИХ УСТАНОВ ТА ОРГАНІЗАЦІЙ З ЛОКАЛЬНИХ СИСТЕМ ДО ХМАРНИХ ОБЧИСЛЮВАЛЬНИХ ПЛАТФОРМ	169
40.	<b>Р. Новчук, Р. Трач, Р. Трембач</b> АВТОМАТИЗОВАНА СИСТЕМА ЗБОРУ РОЗПОДІЛЕНОЇ ІНФОРМАЦІЇ	171



*Матеріали XI Міжнародної науково-практичної конференції молодих учених та студентів  
«АКТУАЛЬНІ ЗАДАЧІ СУЧАСНИХ ТЕХНОЛОГІЙ» – Тернопіль, 7-8 грудня 2022 року*

**УДК 623.746.-519: 004.89.**

**А.В. Атаманчук, І.Ю. Дедів, к.т.н., доцент**

Тернопільський національний технічний університет імені Івана Пулюя, Україна

### **МЕТОД ВИЯВЛЕННЯ ТА ІДЕНТИФІКАЦІЇ БПЛА З ЗАСТОСУВАННЯМ НЕЙРОННОЇ МЕРЕЖІ**

**A.V. Atamanchuk, I.Y. Dediv, Ph.D**

### **METHOD OF DETECTION AND IDENTIFICATION UAV WITH USING A NEURAL NETWORK**

На сьогоднішній день, в умовах жорстоких воєнних дій, які відбуваються на території України, важливим є виявлення та знищення ворожих безпілотних літальних апаратів (БПЛА), які використовують для ведення повітряної розвідки — як тактичної, так і стратегічної, для коригування вогневих ударів по наземних цілях, як ударні та дрони-камікадзе. Жодна держава не готова протистояти спланованим атакам БПЛА. Традиційні види озброєння ППО розраховані на великі і віддалені цілі, в той час як сучасні безпілотники складаються з нано-, мікро- і міні-апаратів, що літають на малих висотах. Тому, розробка методів виявлення та ідентифікації БПЛА є актуальним завданням.

Для виявлення БПЛА в сучасних умовах застосовують ряд методів: оптичний, радіолокаційний, радіочастотний, інфрачервоний, лідар та акустичний. Порівняльний аналіз використання цих методів представлено в таблиці 1. Як видно з аналізу, кожен з методів має, як позитивні сторони, так і недоліки. Зокрема, при використанні оптичного методу, камери іноді можуть не ідентифікувати присутність БПЛА, оскільки, вони можуть бути дуже малих розмірів та можуть маскуватись в навколишньому середовищі, радары також важко відбивають сигнали від малої цілі, а автономні дрони можуть обходити радіовиявлення. Також, більшість методів відрізняються високою вартістю обладнання, яке використовується для виявлення та ідентифікації БПЛА та умовою наявності прямої видимості безпілотника.

*Табл. 1. Порівняльний аналіз методів виявлення БПЛА*

Принцип роботи датчика	Максимальна дальність, м	Фактори які впливають на якість роботи	Особливості функціонування	Робота в режимі радіомовчання
Акустичний	100-1000	Шум зовнішнього середовища	-	Так
Оптичний	500-600	Освітлення, погодні умови (туман, опади)	Потрібна наявність прямої видимості	Так
Інфрачервоний	500-600	Погодні умови (туман, опади)	Потрібна наявність прямої видимості	Так
Лідар	1000	Погодні умови (туман, опади)	Потрібна наявність прямої видимості	Ні
Радіолокаційний	>2000	Розмір БПЛА (ефективна площа розсіювання)	Потрібна наявність прямої видимості	Ні
Радіочастотний	2000	Потужність випромінювання передавача на БПЛА	БПЛА який керується дистанційно, можливо виявити до зльоту	Так

Сумарний спектр акустичного випромінювання тактичного БПЛА при використанні акустичного методу обумовлений гармонійними і широкосмуговими складовими. Він включає в себе гармонійні складові випромінювання двигуна, шуму обертів гвинта, випромінювання механічної природи, а також високочастотну і низькочастотну складові шуму двигуна з безперервними по частоті спектрами.

Тому, запропонований метод, структура, якого представлена на рис. 1, передбачає обробку звукових сигналів з навколишнього середовища, що дає

можливість виявлення та ідентифікації БПЛА за шумами, які виникають під час його роботи та ідентифікація його, за відповідними параметрами сигналів, які змінюються, залежно від типу безпілота.

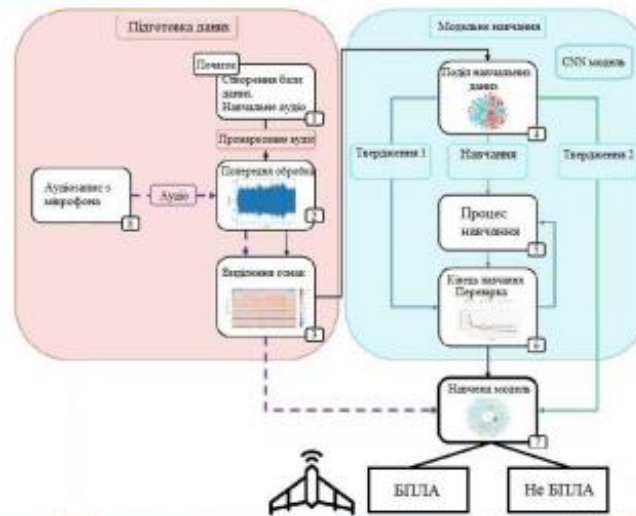


Рисунок 1. Структура методу виявлення та ідентифікації БПЛА

Відповідно до структури, метод передбачає застосування таких етапів:

- Створення бази даних:
  - пошук звукових сигналів: безпілотної літальної апаратури, інших звукових сигналів зовнішнього середовища, які можуть викликати помилкове спрацювання;
  - маркування сигналів на 2 класи: БПЛА, не БПЛА.
- На вхід системи надходить звуковий сигнал, який підлягає попередній обробці, що включає такі етапи:
  - перетворення звукового сигналу на двоканальний;
  - застосування передискретизації сигналу до частоти 44,1 кГц;
  - стандартизація тривалості сигналу до фіксованої тривалості - 4 секунди.
- На наступному етапі проводиться виділення ознак:
  - звук перетворюється на спектрограму, що складається з 257 відліків частоти, за допомогою короткочасного перетворення Фур'є (STFT) із розміром вікна 25 мс та перекриттям вікна Ганна 10 мс.
  - спектрограма перетворюється на Mel-спектрограму з 64 ділянками.
- Mel-спектрограми передаються, як окремі вхідні дані попередньо навченим моделям CNN (згортова нейронна мережа).
- Моделі CNN створюють вектор ознак для кожної Mel-спектрограми.
- Навчена модель підтверджує гіпотезу, щодо того, чи являється вхідний звуковий сигнал з класу БПЛА чи не БПЛА.

В основі представленого методу лежить опрацювання звукових сигналів, які виникають в процесі роботи двигуна та інших складових БПЛА. Метод не потребує прямої видимості безпілота для його виявлення. Також, використання нейронної мережі, дає можливість автоматизувати процес виявлення та ідентифікації БПЛА та підвищити достовірність отриманих результатів.

#### Література:

- Casabianca P., Zhang Y. Acoustic-Based UAV Detection. Loughborough University 2021.- 54с

## ДОДАТОК Б

## Код виявлення та ідентифікації БПЛА

```

import math, random
import torch
import torchaudio
from torchaudio import transforms
from IPython.display import Audio
class AudioUtil():
    # Load an audio file. Return the signal as a tensor and the
    sample rate
    @staticmethod
    def open(audio_file):
        sig, sr = torchaudio.load(audio_file)
        return (sig, sr)
    # Convert the given audio to the desired number of channels
    @staticmethod
    def rechannel(aud, new_channel):
        sig, sr = aud
        if (sig.shape[0] == new_channel):
            # Nothing to do
            return aud
        if (new_channel == 1):
            # Convert from stereo to mono by selecting only the first
channel
            resig = sig[:1, :]
        else:
            # Convert from mono to stereo by duplicating the first
channel
            resig = torch.cat([sig, sig])
        return ((resig, sr))
    @staticmethod
    def resample(aud, newsr):
        sig, sr = aud
        if (sr == newsr):
            # Nothing to do
            return aud
        num_channels = sig.shape[0]
        # Resample first channel
        resig = torchaudio.transforms.Resample(sr, newsr)(sig[:1,:])
        if (num_channels > 1):
            # Resample the second channel and merge both channels
            retwo = torchaudio.transforms.Resample(sr, newsr)(sig[1:,:])
            resig = torch.cat([resig, retwo])
        return ((resig, newsr))
    # Pad (or truncate) the signal to a fixed length 'max_ms' in
milliseconds
    @staticmethod
    def pad_trunc(aud, max_ms):
        sig, sr = aud
        num_rows, sig_len = sig.shape
        max_len = sr//1000 * max_ms

```

```

if (sig_len > max_len):
    # Truncate the signal to the given length
    sig = sig[:, :max_len]
elif (sig_len < max_len):
    # Length of padding to add at the beginning and end of the
signal
    pad_begin_len = random.randint(0, max_len - sig_len)
    pad_end_len = max_len - sig_len - pad_begin_len
    # Pad with 0s
    pad_begin = torch.zeros((num_rows, pad_begin_len))
    pad_end = torch.zeros((num_rows, pad_end_len))
    sig = torch.cat((pad_begin, sig, pad_end), 1)
    return (sig, sr)
# Generate a Spectrogram
@staticmethod
def spectro_gram(aud, n_mels=64, n_fft=1024, hop_len=None):
    sig, sr = aud
    top_db = 80
    # spec has shape [channel, n_mels, time], where channel is
mono, stereo etc
    spec = transforms.MelSpectrogram(sr, n_fft=n_fft,
hop_length=hop_len, n_mels=n_mels)(sig)
    # Convert to decibels
    spec = transforms.AmplitudeToDB(top_db=top_db)(spec)
    return (spec)
    # Augment the Spectrogram by masking out some sections of it in
both the frequency
    # dimension (ie. horizontal bars) and the time dimension
(vertical bars) to prevent
    # overfitting and to help the model generalise better. The
masked sections are
    # replaced with the mean value.
@staticmethod
def spectro_augment(spec, max_mask_pct=0.1, n_freq_masks=1,
n_time_masks=1):
    _, n_mels, n_steps = spec.shape
    mask_value = spec.mean()
    aug_spec = spec
    freq_mask_param = max_mask_pct * n_mels
    for _ in range(n_freq_masks):
        aug_spec =
transforms.FrequencyMasking(freq_mask_param)(aug_spec, mask_value)
    time_mask_param = max_mask_pct * n_steps
    for _ in range(n_time_masks):
        aug_spec = transforms.TimeMasking(time_mask_param)(aug_spec,
mask_value)
    return aug_spec
from torch.utils.data import DataLoader, Dataset, random_split
import torchaudio
# Sound Dataset
class SoundDS(Dataset):
    def __init__(self, df, data_path):
        self.df = df

```

```

self.data_path = str(data_path)
self.duration = 4000
self.sr = 44100
self.channel = 2
self.shift_pct = 0.4
# Number of items in dataset
def __len__(self):
    return len(self.df)
# Get i'th item in dataset
def __getitem__(self, idx):
    # Absolute file path of the audio file - concatenate the audio
directory with
    # the relative path
    audio_file = self.data_path + self.df.loc[idx,
'relative_path']
    # Get the Class ID
    class_id = self.df.loc[idx, 'classID']
    aud = AudioUtil.open(audio_file)
    # Some sounds have a higher sample rate, or fewer channels
compared to the
    # majority. So make all sounds have the same number of
channels and same
    # sample rate. Unless the sample rate is the same, the
pad_trunc will still
    # result in arrays of different lengths, even though the sound
duration is
    # the same.
    reaud = AudioUtil.resample(aud, self.sr)
    rechan = AudioUtil.rechannel(reaud, self.channel)
    dur_aud = AudioUtil.pad_trunc(rechan, self.duration)
    shift_aud = AudioUtil.time_shift(dur_aud, self.shift_pct)
    sgram = AudioUtil.spectro_gram(shift_aud, n_mels=64,
n_fft=1024, hop_len=None)
    aug_sgram = AudioUtil.spectro_augment(sgram, max_mask_pct=0.1,
n_freq_masks=2, n_time_masks=2)
    return aug_sgram, class_id
from torch.utils.data import random_split
myds = SoundDS(df, data_path)
# Random split of 80:20 between training and validation
num_items = len(myds)
num_train = round(num_items * 0.8)
num_val = num_items - num_train
train_ds, val_ds = random_split(myds, [num_train, num_val])
# Create training and validation data loaders
train_dl = torch.utils.data.DataLoader(train_ds, batch_size=16,
shuffle=True)
val_dl = torch.utils.data.DataLoader(val_ds, batch_size=16,
shuffle=False)
import torch.nn.functional as F
from torch.nn import init
# Audio Classification Model
class AudioClassifier (nn.Module):
    # Build the model architecture

```

```

def __init__(self):
    super().__init__()
    conv_layers = []
    # First Convolution Block with Relu and Batch Norm. Use
    Kaiming Initialization
    self.conv1 = nn.Conv2d(2, 8, kernel_size=(5, 5),
stride=(2, 2), padding=(2, 2))
    self.relu1 = nn.ReLU()
    self.bn1 = nn.BatchNorm2d(8)
    init.kaiming_normal_(self.conv1.weight, a=0.1)
    self.conv1.bias.data.zero_()
    conv_layers += [self.conv1, self.relu1, self.bn1]
    # Second Convolution Block
    self.conv2 = nn.Conv2d(8, 16, kernel_size=(3, 3),
stride=(2, 2), padding=(1, 1))
    self.relu2 = nn.ReLU()
    self.bn2 = nn.BatchNorm2d(16)
    init.kaiming_normal_(self.conv2.weight, a=0.1)
    self.conv2.bias.data.zero_()
    conv_layers += [self.conv2, self.relu2, self.bn2]
    # Second Convolution Block
    self.conv3 = nn.Conv2d(16, 32, kernel_size=(3, 3),
stride=(2, 2), padding=(1, 1))
    self.relu3 = nn.ReLU()
    self.bn3 = nn.BatchNorm2d(32)
    init.kaiming_normal_(self.conv3.weight, a=0.1)
    self.conv3.bias.data.zero_()
    conv_layers += [self.conv3, self.relu3, self.bn3]
    # Second Convolution Block
    self.conv4 = nn.Conv2d(32, 64, kernel_size=(3, 3),
stride=(2, 2), padding=(1, 1))
    self.relu4 = nn.ReLU()
    self.bn4 = nn.BatchNorm2d(64)
    init.kaiming_normal_(self.conv4.weight, a=0.1)
    self.conv4.bias.data.zero_()
    conv_layers += [self.conv4, self.relu4, self.bn4]
    # Linear Classifier
    self.ap = nn.AdaptiveAvgPool2d(output_size=1)
    self.lin = nn.Linear(in_features=64, out_features=10)
    # Wrap the Convolutional Blocks
    self.conv = nn.Sequential(*conv_layers)
    # Forward pass computations
    def forward(self, x):
        # Run the convolutional blocks
        x = self.conv(x)
        # Adaptive pool and flatten for input to linear layer
        x = self.ap(x)
        x = x.view(x.shape[0], -1)
        # Linear layer
        x = self.lin(x)
        # Final output
        return x
# Create the model and put it on the GPU if available

```

```

myModel = AudioClassifier()
device = torch.device("cuda:0" if torch.cuda.is_available() else
"cpu")
myModel = myModel.to(device)
# Check that it is on Cuda
next(myModel.parameters()).device
# Training Loop
def training(model, train_dl, num_epochs):
    # Loss Function, Optimizer and Scheduler
    criterion = nn.CrossEntropyLoss()
    optimizer = torch.optim.Adam(model.parameters(),lr=0.001)
    scheduler = torch.optim.lr_scheduler.OneCycleLR(optimizer,
max_lr=0.001,

steps_per_epoch=int(len(train_dl)),
epochs=num_epochs,anneal_strategy='linear')
    # Repeat for each epoch
    for epoch in range(num_epochs):
        running_loss = 0.0
        correct_prediction = 0
        total_prediction = 0
        # Repeat for each batch in the training set
        for i, data in enumerate(train_dl):
            # Get the input features and target labels, and put them
on the GPU
            inputs, labels = data[0].to(device), data[1].to(device)
            # Normalize the inputs
            inputs_m, inputs_s = inputs.mean(), inputs.std()
            inputs = (inputs - inputs_m) / inputs_s
            # Zero the parameter gradients
            optimizer.zero_grad()
            # forward + backward + optimize
            outputs = model(inputs)
            loss = criterion(outputs, labels)
            loss.backward()
            optimizer.step()
            scheduler.step()
            # Keep stats for Loss and Accuracy
            running_loss += loss.item()
            # Get the predicted class with the highest score
            _, prediction = torch.max(outputs,1)
            # Count of predictions that matched the target label
            correct_prediction += (prediction == labels).sum().item()
            total_prediction += prediction.shape[0]
            #if i % 10 == 0:      # print every 10 mini-batches
            #    print('[%d, %5d] loss: %.3f' % (epoch + 1, i + 1,
running_loss / 10))
            # Print stats at the end of the epoch
            num_batches = len(train_dl)
            avg_loss = running_loss / num_batches
            acc = correct_prediction/total_prediction
            print(f'Epoch: {epoch}, Loss: {avg_loss:.2f}, Accuracy:
{acc:.2f}')

```

```
    print('Finished Training')
num_epochs=20    # Just for demo, adjust this higher.
training(myModel, train_dl, num_epochs)
```



## ДОДАТОК В

## Скрипт дослідження акустичного спектру

```
pathFile=('C:\Users\Andrii\Downloads\Shahed136.wav');
[x,fs] = audioread(pathFile);
t = 0:1/fs:(length(x)-1)/fs;
plot(t,x)
xlabel('Час (Секунди)')
ylabel('Амплітуда')
xlim([0 t(end)])
title('Форма аудіосигналу')
m = length(x); % original sample length
n = pow2(nextpow2(m)); % transform length
y = fft(x,n); % DFT of signal
f = (0:n-1)*(fs/n);
power = abs(y).^2/n;
plot(f(1:floor(n/2)),power(1:floor(n/2)))
xlabel('Частота')
ylabel('Потужність')
title('Спектр аудіосигналу')
S = melSpectrogram(x,fs);
[numBands,numFrames] = size(S);
melSpectrogram(x,fs)
title('Mel-спектрограма Shahed-136')
xlabel('Час (с)')
ylabel('Частота (кГц)')
```