

УДК 004.9

DOI <https://doi.org/10.35546/kntu2078-4481.2025.2.2.27>**В. О. МАРТОВИЦЬКИЙ**

кандидат технічних наук, доцент,
доцент кафедри електронних обчислювальних машин
Харківський національний університет радіоелектроніки
ORCID: 0000-0003-2349-0578

О. В. ШЕХОВЦОВ

аспірант кафедри електронних обчислювальних машин
Харківський національний університет радіоелектроніки
ORCID: 0009-0002-7400-2925

Д. С. АЛЕЙНИК

магістр кафедри електронних обчислювальних машин
Харківський національний університет радіоелектроніки
ORCID: 0009-0000-6532-7918

Є. В. ПАХОМОВА

магістр кафедри електронних обчислювальних машин
Харківський національний університет радіоелектроніки
ORCID: 0009-0009-9595-6331

Д. І. ІВАНЧЕНКО

магістр кафедри електронних обчислювальних машин
Харківський національний університет радіоелектроніки
ORCID: 0009-0005-3533-5163

ПІДХІД ДО ВИЯВЛЕННЯ ТА КЛАСИФІКАЦІЇ РАДІОКЕРОВАНИХ МОДЕЛЕЙ ЗА ЇХ РАДІОСИГНАЛОМ

Постійний розвиток недорогих вбудованих датчиків, мікроконтролерів та технологій бездротової передачі даних призвів до стрімкого зростання популярності та використання безпілотних літальних апаратів (БПЛА), або дронів, у різних сферах людської діяльності – від сільського господарства та екологічного моніторингу до військових застосувань і розвідки. Проте, одночасно із перевагами, які надають дрони, зростає і ризик їхнього зловмисного використання. Безпілотники можуть становити серйозну загрозу безпеці населення, стратегічних об'єктів, приватних територій та промислових підприємств. У зв'язку з цим виникає гостра потреба у створенні систем виявлення та класифікації таких пристроїв на основі аналізу їхніх радіочастотних сигналів. У даній роботі розглядається підхід до моніторингу та ідентифікації дронів шляхом аналізу радіосигналів, які генеруються їхніми модулями зв'язку. Зокрема, запропонована система базується на можливостях програмно-визначеної радіостанції (SDR), що дозволяє в реальному часі здійснювати прийом, обробку та аналіз сигналів без необхідності використання спеціалізованого апаратного забезпечення. Для реалізації цього підходу використано фреймворк GNU Radio, який забезпечує гнучкість у побудові блок-схем обробки сигналів. Особливу увагу приділено задачі класифікації сигналів зв'язку дронів на основі типу модуляції – зокрема, мультиплексування з ортогональним частотним поділом (OFDM). Аналіз сигналу базується на його енергетичних характеристиках та структурних параметрах, які залежать від використаного протоколу. За допомогою алгоритмів машинного навчання здійснюється автоматизоване навчання моделі для подальшого розпізнавання радіосигналів у польових умовах. Це дозволяє визначати тип пристрою, оцінювати його поведінку, а в деяких випадках – локалізувати джерело сигналу без втручання в сам пристрій. Таким чином, запропоноване дослідження демонструє ефективність підходу до розпізнавання та класифікації БПЛА за допомогою SDR та методів штучного інтелекту, що може бути основою для створення систем раннього попередження та протидії несанкціонованому використанню дронів.

Ключові слова: класифікація радіосигналів, радіочастотні сигнали, програмно-визначена радіостанція, машинне навчання.

V. O. MARTOVYTSKYI

Candidate of Technical Sciences, Associate Professor,
Associate Professor at the Department of Electronic Computers
Kharkiv National University of Radio Electronics
ORCID: 0000-0003-2349-0578

O. V. SHEKHOVTSOV

Postgraduate Student at the Department of Electronic Computers
Kharkiv National University of Radio Electronics
ORCID: 0009-0002-7400-2925

D. S. ALEYNIK

Master's Student at the Department of Electronic Computers
Kharkiv National University of Radio Electronics
ORCID: 0009-0000-6532-7918

E. V. PAKHOMOVA

Master's Student at the Department of Electronic Computers
Kharkiv National University of Radio Electronics
ORCID: 0009-0009-9595-6331

D. I. IVANCHENKO

Master's Student at the Department of Electronic Computers
Kharkiv National University of Radio Electronics
ORCID: 0009-0005-3533-5163

APPROACH TO DETECTION AND CLASSIFICATION OF RADIO-CONTROLLED MODELS BY THEIR RADIO SIGNAL

The ongoing development of affordable embedded sensors, microcontrollers, and wireless communication technologies has led to a rapid rise in the popularity and use of unmanned aerial vehicles (UAVs), commonly known as drones, across various fields – including agriculture, environmental monitoring, reconnaissance, and defense. However, alongside these benefits, the potential for malicious or unauthorized drone usage poses significant risks to public safety, critical infrastructure, private property, and industrial facilities. Therefore, there is an increasing need for systems capable of detecting and classifying drones based on the analysis of their radio frequency (RF) communication signals. This paper explores an approach for monitoring and identifying drones by analyzing the RF signals generated by their communication modules. Specifically, the proposed system leverages the capabilities of a software-defined radio (SDR), which enables real-time signal reception, processing, and analysis without the need for specialized hardware. The implementation utilizes the GNU Radio framework, offering flexibility in designing custom signal processing workflows. The focus is placed on classifying drone communication signals based on their modulation type – particularly, orthogonal frequency-division multiplexing (OFDM). Signal classification is achieved by analyzing its energy profile and structural features, which vary depending on the communication protocol used. Machine learning algorithms are employed to train a model that can recognize and classify such signals in real-world environments. This enables the identification of the device type, behavior analysis, and, in some cases, estimation of the operator's location – all without direct interaction with the drone. Overall, the study demonstrates the effectiveness of combining SDR technology with artificial intelligence methods for drone detection and classification, potentially forming the basis for early warning systems and countermeasures against unauthorized drone activity.

Key words: radio signal classification, radio frequency signals, software-defined radio, machine learning.

Постановка проблеми

У сучасному світі безпілотні літальні апарати (БПЛА), або дрони, стали невід'ємною частиною багатьох сфер життя, включаючи рекреаційне, комерційне, освітнє та військове використання. Швидкий розвиток технологій, зокрема впровадження недорогих вбудованих сенсорів, сприяв масовому поширенню дронів серед цивільних користувачів. У літературі та в інформаційних джерелах все експлуатаційне обладнання, яке складається з літака, станції радіо керування та бездротового зв'язку між літальним апаратом та його системою керування, описується як безпілотний літальний апарат або радіокерована модель. Безпілотний літальний апарат – це термін, який в основному використовується для визначення літаючих об'єктів для різних застосувань. Термін «дрон» є більш поширеним серед любителів і по суті є безпілотним або автономним літальним апаратом, який зазвичай використовується у військовому контексті, а також використовується для позначення будь-якої з численних доступних класифікацій або типів літальних безпілотних апаратів загальною мовою. Можна помітити, що в останні роки до безпілотних літальних апаратів (БПЛА) виявляють великий інтерес в різних дослідженнях через їх широкий спектр використання.

Однак, разом із зростанням популярності дронів, з'явилися нові виклики, пов'язані з їхнім використанням, зокрема загрози безпеці, конфіденційності та навіть національній безпеці.

Виявлення та класифікація дронів за їхніми радіосигналами стає все більш актуальною задачею для дослідників і фахівців у галузі радіоелектроніки. Це пов'язано з тим, що дрони можуть використовуватися як для корисних цілей,

так і для порушення закону, наприклад, для несанкціонованого збору даних, контрабанди або навіть атак. Тому розробка ефективних методів виявлення та ідентифікації дронів є важливим кроком у забезпеченні безпеки суспільства.

У цій статті розглядається підхід до виявлення та класифікації радіокерованих моделей за їхніми радіосигналами. Особлива увага приділяється аналізу радіочастотних сигналів (RF-сигналів), які використовуються для зв'язку між дроном і наземною станцією. Також обговорюються сучасні технології, такі як програмно-визначені радіостанції (SDR) та методи машинного навчання, які дозволяють ефективно класифікувати сигнали на основі їхніх характеристик, таких як модуляція та параметри ортогонального частотного мультиплексування (OFDM).

Аналіз останніх досліджень і публікацій

Останні роки відзначені значним зростанням інтересу до проблеми виявлення дронів, що пов'язано з їхнім масовим поширенням та потенційними загрозами, які вони можуть становити. У науковій літературі представлено багато підходів до вирішення цієї проблеми, включаючи використання радарів, акустичних сенсорів, відеоспостереження та аналізу радіочастотних сигналів.

У статті [1] запропонована нова структура глибокого навчання ансамблю моделей, яка має гібридні синтетичні та глибокі функції для виявлення несанкціонованих або зловмисних БПЛА за допомогою акустичних сигналів, зображень/відео та бездротових радіочастотних (РЧ) сигналів для надійного виявлення та класифікації БПЛА. Представлено оцінку продуктивності запропонованого підходу з використанням чисельних результатів, отриманих в результаті експериментів.

У роботі [2] автори використали наступний підхід:

- по-перше, для вибірки даних обрали метод стисненого зондування замість традиційної теореми вибірки і використали багатоканальний випадковий демодулятор для вибірки сигналу;
- по-друге, для виявлення та ідентифікації присутності, типу та схеми польоту БПЛА було запропоновано багатоетапний метод ідентифікації та виявлення БПЛА на основі глибокого навчання, який використовує різницю в сигналах зв'язку між БПЛА та контролерами за різних обставин.

Зразки даних спочатку проходять через детектори, які виявляють наявність БПЛА, потім використовуються класифікатори для ідентифікації типу БПЛА. Моделі польоту оцінюються відповідними класифікаторами, для чого за допомогою алгоритмів глибокого навчання будуються дві нейромережові структури (DNN і CNN), які оцінюються і підтверджуються методом 10-кратної перехресної перевірки, причому мережа DNN використовується для детекторів, а мережа CNN – для подальшої класифікації типу і режиму польоту. Результати експерименту демонструють ефективність використання стисненого зондування для дискретизації сигналів зв'язку БПЛА і наземних станцій.

У статті [3] автори запропонували систему виявлення та класифікації БПЛА різними методами, включаючи підхід на основі аудіо. Однак кількість загальнодоступних аудіоданих БПЛА обмежена. Щоб заповнити цю прогалину, автори вибрали 10 різних БПЛА, починаючи від іграшкових ручних дронів і закінчуючи дронами класу I, і записали аудіодані загальною тривалістю 5215 секунд. На основі зібраних даних реалізували модель згорткової нейронної мережі (CNN) для класифікації БПЛА за 10 класами. Загальна точність тестування навченої моделі становить 97,7 %, а втрата тесту становить 0,085.

У роботі [4] досліджується проблема ідентифікації безпілотних літальних апаратів за їх радіолокаційною сигнатурою (RCS). RCS шести комерційних БПЛА вимірюється на частотах 15 ГГц і 25 ГГц у безеховій камері для вертикальної та горизонтальної поляризації. Отримані сигнатури RCS використовувалися для навчання 15 різних алгоритмів класифікації, кожен з яких належить до однієї з трьох категорій: статистичне навчання, машинне навчання та глибоке навчання. Дослідження показує, що хоча точність класифікації всіх алгоритмів зростає із збільшенням співвідношення сигнал/шум, алгоритми машинного навчання досягають вищої точності порівняно з алгоритмами статистичного навчання та глибокого навчання.

Автори роботи [5] пропонують підхід, заснований на техніці синтезу глибокого навчання, який об'єднує частототон-модульовані радіолокаційні мікродоплерівські сигнали безперервної хвилі, сигнали діаграми швидкості обертання і сигнали кепстра. Цей синтез завершується класифікацією БПЛА з винятковою точністю. У цьому дослідженні було застосовано два підходи до глибокого навчання з використанням мережі ResNet34: злиття на рівні даних і злиття на рівні функцій.

У даному розділі було проведено аналіз публікацій, присвячених методам виявлення та класифікації радіокерованих моделей. На основі досліджень виявлено, що сучасні підходи до вирішення цієї задачі базуються на використанні методів машинного навчання, цифрової обробки сигналів та аналізу спектральних характеристик. Особливу увагу приділено методам, які дозволяють ідентифікувати тип радіокерованої моделі, її параметри та джерело сигналу навіть у умовах наявності перешкод або шумів.

Аналіз показав, що існуючі методи мають високий потенціал для застосування у сфері безпеки, моніторингу та контролю радіоефіру. Проте, існують певні обмеження, пов'язані зі складністю розпізнавання сигналів у реальному часі, а також з необхідністю вдосконалення алгоритмів для підвищення точності класифікації. Майбутні дослідження можуть бути спрямовані на інтеграцію глибокого навчання та адаптивних методів обробки сигналів для покращення ефективності розпізнавання радіокерованих моделей.

Таким чином, розробка нових підходів до виявлення та класифікації радіокерованих моделей за їх радіосигналами є актуальною задачею, яка потребує подальших досліджень та впровадження сучасних технологій.

Формулювання мети дослідження

Метою є розробка підходу до виявлення та класифікації радіокерованих моделей за їх радіосигналом.

Для досягнення поставленої мети необхідно проаналізувати радіочастотні сигнали, які використовуються для зв'язку між дроном і наземною станцією. Також розробити модель комп'ютерної системи на основі програмно-визначені радіостанції та методів машинного навчання, які дозволяють ефективно класифікувати сигнали на основі їхніх характеристик, таких як модуляція та параметри ортогонального частотного мультиплексування.

Викладення основного матеріалу дослідження

Для більш точного розуміння запропонованого підходу розглянемо спочатку особливості функціонування БПЛА.

Дрон складається з двох основних частин – пульта дистанційного керування та літального апарату. Обидві частини зв'язуються між собою за допомогою радіочастотного каналу зв'язку. На рисунку 1 представлено архітектуру, конструкцію та компоненти більшості дронів.




Рис. 1. Компоненти БПЛА

Для радіочастотної класифікації зосередимося на зв'язку між землею (пульт дистанційного керування) і БПЛА. Пульт дистанційного керування може безпосередньо керувати дроном за допомогою засобів керування, передачі даних і відео, обмінюватися та надсилати інформацію один одному. Більшість контролерів використовують спектр у діапазонах 868, 915 та 2400 МГц (обладнання дозволяє розширити цей діапазон 360–1050 МГц) із власною модуляцією розширеного спектра зі стрибками частоти (FHSS) [6]. FHSS використовується для максимізації надійності та контролю відстані. Цей тип модуляції сигналу використовуються у військових застосуваннях, а також у деяких доступних електронних пристроях, таких як мобільні телефони. Ще одна важлива характеристика цих сигналів полягає в тому, що вони дуже стійкі до перешкод. У військовій сфері ця технологія може мати важливе застосування, оскільки її можна використовувати для низької ймовірності виявлення сигналу. Однак ця властивість ускладнює виявлення дрона. Контролери FHSS також можуть бути ефективними проти глушіння завдяки тому факту, що вони не просто передають інформацію на статичній частоті, а й по всій ширині спектру, в якому стрибає сигнал між дроном та наземною станцією.

У таблиці 1 наведено інформацію, пов'язану з керуючими сигналами деяких доступних дронів, що використовуються аматорами або дослідниками.

Таблиця 1

Характеристики набору даних

Бренд	Частота	Модуляція	Технологія
DJI Phantom	2.4 ГГц / 5.8 ГГц	FHSS/DSSS	FASST/Lightbridge
Futaba	2.4 ГГц	FHSS/DSSS	FASST
Spektrum	2.4 ГГц	FHSS/DSSS	DSMX
JR	2.4 ГГц	FHSS/DSSS	DMSS
Hitec	2.4 ГГц	FHSS/DSSS	AFHSS
Graupner	2.4 ГГц	FHSS/DSSS	HOTT
Yuneec	2.4 ГГц	DSSS	ZigBee
Parrot AR2	2.4 ГГц	OFDM	Wi-Fi
Кастомні FPV	360 – 1050 МГц 1.2 ГГц, 2.4 ГГц, 3.3 ГГц, 5.8 ГГц	FHSS	Lora

Запропонований підхід базується на використати знання про радіочастотне випромінювання від БПЛА, щоб досягти виявлення, виділення ознак і класифікації сигналів дронів за допомогою машинного навчання. Спочатку пропонується виділити OFDM-параметри сигналу безпілотної, а також енергію та інші статистичні характеристики прийнятого сигналу. Іншими словами, для виявлення сигналу будемо реалізовувати енергетичне виявлення бездротового сигналу. В літературі та на практиці існують й інші доступні методи виявлення, але в дослідженні вирішили використати енергетичне виявлення через його простоту, оскільки воно не вимагає великих обчислювальних ресурсів. Після того, як з вхідного сигналу, що нас цікавить, виокремлено ознаки, проводиться додаткова обробка отриманих ознак. Ця обробка включає в себе маркування та навчання на отриманій вибірці зібраних ознак. Це необхідно, оскільки для класифікації сигналів дронів використовуємо методи контрольованого машинного навчання. Для реалізації виявлення, виділення, класифікації та тестування будуть використані блоки GNU Radio. Навчання та обробка даних буде здійснюватися за допомогою Python. Після завершення навчання на Python буде створено тестовий файл, який буде завантажено в радіоблок GNU Radio для тестування та аналізу в реальному часі.

GNU Radio – це набір інструментів з відкритим вихідним кодом, який був однією з основ для програмно-керованого радіо (SDR). Його активна підтримка спільноти, велика бібліотека інструментів обробки та універсальність є основними перевагами, які приваблюють академічних дослідників, комерційні компанії та студентів до використання фреймворку [7]. Радіо GNU також сумісне з усіма операційними системами персональних комп'ютерів (Ubuntu/Linux, Windows і Mac OS), хоча продуктивність залежить від різних платформ. Наразі було відмічено, що Ubuntu працює краще, оскільки надає користувачам більшу гнучкість і доступ до інших сумісних фреймворків. Його можна використовувати з USRP, HackRF, Raspberry Pi та іншими апаратними компонентами для розробки SDR [7]. C++ використовується як мова для запису обробки сигналів, Python також може використовуватися для запису блоків сигналів, але вони повільніші з точки зору продуктивності, ніж блоки, створені за допомогою C++.

Виявлення енергії буде реалізовано за допомогою програмно-визначеного радіо. Це буде досягнуто за допомогою двох комп'ютерів з встановленим програмним забезпеченням GNU radio companion і двох апаратних засобів HackRf для передачі і прийому.

На рисунку 2 показано блок-схему приймача, в якому відбувається детектування енергії переданого сигналу.




Рис. 2. Блок-схема детектора енергії на GNU Radio

Приймачем є HackRF, де налаштовуються деякі параметри, такі як частота дискретизації, робоча частота і смуга пропускання. Отримані дані сигналу обробляються в комп'ютері, на якому встановлено GNU Radio. Блок throttle використовується для керування завантаженням процесора комп'ютера. Прийнятий сигнал перетворюється у вектор з 1024 точок за допомогою блоку перетворення потоку у вектор (stream to vector). У той же час, вихідний сигнал відображається за допомогою блоку QT GUI Sink. Він відображає спектральну щільність потужності (PSD), водоспад та часової залежності. Після перетворення до 1024 точок йде блок швидкого перетворення фур'є (FFT). Блок FFT виконує швидке перетворення Фур'є над вхідним потоком даних, а вихідні

дані надсилаються до блоку `complex to mag2`. У цьому блоці також виконується віконне перетворення для того, щоб мінімізувати крайові ефекти і запобігти спектральному витоку в спектрі FFT. Для цього було обрано вікно Блекмана-Харріса. Далі відбувається видалення масштабування, зробленого самим блоком FFT. Потім величина комплексного значення підноситься до квадрату ($a + jb \rightarrow a^2 + b^2$) а допомогою блоку `complex to mag2`. Вихід цього блоку надсилається до спеціального блоку `Energy-detection-fft`, в якому реалізовано алгоритм детектування. Блок дозволяє користувачеві вибрати кількість зразків сигналу та ймовірність хибної тривоги, які будуть використовуватися для розрахунку. Із вхідних даних блок обчислює середнє значення отриманого сигналу, його дисперсію та стандартне відхилення. Ці параметри використовуються для визначення динамічного порога виявлення. Далі розраховуються логарифмічні значення середнього сигналу та порогового рівня. Середня енергія сигналу порівнюється з порогом для визначення наявності сигналу: якщо енергія сигналу перевищує порогове значення, сигнал вважається присутнім, і його енергія передається на вихід.

Для візуалізації використовується QT GUI Sink блок, що відображає потужність отриманих сигналів у частотній області. Для усереднення в детекторному блоці застосовується наступна формула:

$$Y = \sum_{n=1}^N \frac{1}{N} X(n)^2, \quad (1)$$

де $X(n)$ відповідає прийнятим значенням в частотній області.

Щоб прийняти рішення про наявність чи відсутності сигналу, потрібно визначити поріг:

$$T = \mu + Q^{-1}(pfa)\sigma, \quad (2)$$

де μ і σ є середнім і стандартним відхиленням усереднених за часом точок БПФ відповідно, Q представляє обернену Q -функцію, а pfa є ймовірністю того, що модуль виявлення вибере H_1 , тоді як правильним рішенням є H_0 . Правило рішення можна визначити як Рішення про виявлення $Y > T \rightarrow H_1$ (сигнал присутній) і $Y \leq T \rightarrow H_0$ (сигнал відсутній)

Оскільки в роботі пропонується використовувати ортогональне мультиплексування з частотним розділенням каналів, то коротко розглянемо принцип його роботи.

Ортогональне частотне мультиплексування (OFDM) є базовим елементом для багатьох поточних схем модуляції, включаючи; 802.11 WLAN, 802.16 WiMAX і 3GPP LTE [8]. Ортогональне частотне мультиплексування – це цифрова схема модуляції з кількома несучими, яка використовує кілька піднесучих в одному каналі. Він використовує велику кількість близько розташованих ортогональних піднесучих, які передаються паралельно. Кожну піднесучу можна модулювати за допомогою однієї зі звичайних схем цифрової модуляції (таких як QPSK, 16QAM тощо) з низькою швидкістю символу. Однак поєднання більш ніж однієї піднесучої забезпечує швидкість передачі даних, подібну до звичайних схем модуляції з однією несучою в еквівалентних смугах пропускання [8].

Класичний підхід до класифікації OFDM-сигналів здійснюється на основі параметрів центральної частоти, тривалості OFDM-символу, довжини циклічного префікса та кількості піднесучих. Також є підхід до класифікації OFDM сигналів на основі циклостационарних ознак [9], де розглядають циклостационарну ознаку преамбули кадру та піднесучої.

Також для класифікації використовую такі параметри OFDM-сигналів як: несуча частота, загальна ширина смуги пропускання, кількість піднесучих, відстань між піднесучими, довжина циклічного префікса, період дискретизації та тривалість OFDM-кадру. Для класифікації OFDM-сигналів можна також розглянути наступні параметри: швидкість передачі некодованих даних = 390 млн. біт/с, тривалість вихідного символу $TD = 15,385$ нс, тривалість символу передачі $TS = 12,5$ нс, загальна тривалість символу OFDM $TS = 3,60$ мс, захисний час $TG = 0,4$ мс, інтервал між піднесучими $FS = 0,3125$ МГц, ширина смуги Найквіста $BN = 76,5625$ МГц.

В літературі існують різні доступні параметри, які дослідники використовують як ознаки для класифікації OFDM-сигналу від не OFDM сигналу. В таблиці 2 наведено приклад того, як виглядають деякі з цих параметрів.

У проведеному експерименті використовується чотири параметри. Блок оцінки параметрів OFDM, який оцінює ці параметри, був включений у блок виявлення енергії сигналу, а результат двох блоків об'єднано разом, щоб сформувати один блок оцінки параметрів сигналу. Нижче наведено короткий опис контролюючих параметрів.

Розглянемо визначення довжини циклічного префікса. Корисна довжина символу (T_u) – це величина, обернена до інтервалу між піднесучими. Тоді, довжина CP дорівнює ($T_g = G \cdot T_u$), де G – це відношення часу CP до корисного часу. Вибір G здійснюється відповідно до параметрів каналу. Загальна довжина символу OFDM складається з корисної довжини символу і довжини CP. Кількість піднесучих складається як з пілотного сигналу, так і з сигналів носіїв даних. Розмір FFT може варіюватися від 64, 128, 256, 512 та інші варіації. Тривалість символу OFDM-сигналу – це зворотний інтервал між піднесучими. Інтервал між піднесучими: $spr = 1/T_s$, T_s – час символу [9].

У блоці оцінювання параметрів OFDM у GNUradio було використано деякі алгоритми для реалізації оцінювання деяких параметрів OFDM. Далі наведено необхідні етапи, які було зроблено для реалізації цих алгоритмів.

Таблиця 2

Параметри, які дослідники використовують як ознаки для класифікації OFDM сигналу

Параметр	Значення
Кількість піднесучих даних	48
Кількість пілотних піднесучих	4
Інтервал між піднесучими	156.2 кГц
Займана смуга частот	8.28125 МГц
Тривалість короткої тренувальної послідовності	16 мкс
Тривалість довгої тренувальної послідовності	16 мкс
Захисний інтервал тренувальної послідовності	3.2 мкс
Тривалість преамбули PLCP	32 мкс
Тривалість захисного інтервалу	1.6 мкс
Тривалість символу POOFDM	8 мкс

1. Обчислення автокореляційної функції вхідного вектора для оцінки довжини піднесучих (FFT) за допомогою дискретної автокореляційної функції.

2. Обчислення ЦАФ (циклічної автокореляційної функції). Найпростіший спосіб обчислити ЦАФ полягає в тому, що вона є коефіцієнтом у розкладенні в ряд Фур'є автокореляції, що змінюється в часі, циклостационарного випадкового процесу (циклостационарного сигналу). Обчислення функції циклічної кореляції, що змінюється в часі, для знаходження довжини циклічного префікса.

3. Визначення інтервалу між піднесучими обчислюється наступним чином: $\text{sub-spc} = (\text{samplerate}/\text{FFTlength})$ та символний час $\text{symtime} = (1/\text{subspc})$.

Також для оцінки параметрів сигналу було використано модуль GNU Radio під назвою Gr-inspector.

У Gr-inspector було додано модуль, який реалізує оцінку параметрів у GNU Radio Companion. Цей модуль GNU Radio розроблено спеціально для того, щоб реалізувати можливості аналізу сигналів у типовій блоковій структурі. Модуль здатний виконувати наступні функції:

- енергетичне детектування неперервних сигналів;
- фільтрація виявлених сигналів;
- оцінка параметрів OFDM (інтервал між несучими, час символу);
- сліпа OFDM синхронізація;
- передискретизація сигналів до постійної частоти;
- 3D візуалізація даних FAM, з gr-specest;
- використання моделей TensorFlow для AMC [10].

Для вирішення поставленої задачі одним із головних елементів є блок оцінки параметрів OFDM, який виконує оцінку чотирьох параметрів OFDM і виводить їх у вигляді повідомлень (інтервал між несучими, час символу, розмір FFT, тривалість символу). Об'єднавши цей блок з реалізацією енергетичного детектора і використавши вихідні дані обох блоків, отримаємо набір ознак для виявлення та класифікації БПЛА.

Далі за допомогою отриманого набору ознак направивши їх на блок машинного навчання представленого на рисунку 3 буде здійснюватися навчання різних моделей та подальша класифікація сигналу.




Рис. 3. Блок-схема детектора енергії на GNU Radio

Оцінені параметри спочатку використовуються для побудови навчальних даних і зберігаються в бібліотеці даних для подальшої обробки. Класифікатор в режимі навчання створює моделі на основі обраного алгоритму класифікації машинного навчання. Потім проводиться тестування нового сигналу за допомогою обраної моделі з бібліотеки даних.

Для експерименту було розроблено налаштований тестовий блок машинного навчання, виявлення енергії та блок оцінки параметрів для виявлення та класифікації сигналів дронів за допомогою GNU Radio та обладнання

НаскRF. Необроблені дані радіочастотного сигналу будуть зібрані після реалізації та підключення всіх блоків. Для того, щоб провести експеримент і зібрати дані з модуля виявлення, необхідно вміти визначити і точно знати частоту передачі дрона. Таким чином можливо контролювати спектр і збирати дані для навчання, а потім тестувати класифікацію за допомогою спеціального блоку тестування машинного навчання. Для експерименту було зібрано дані для різних сценаріїв, які будуть використані як основа класифікації.

Під час експерименту було використано дві моделі дронів фірми DJI.

Перший випадок – це коли єдиним сигналом, що передається є сигнал від DJI phantom; другий випадок – це коли єдиним сигналом, що передається є сигнал від Mavic. У налаштуваннях дрона режим передачі DJI phantom і Mavic RF було змінено з Auto на Custom. Спеціальне налаштування дозволяє користувачеві вибрати конкретну частоту, на якій буде передавати дрон. Це спрощує налаштування та моніторинг частотного спектру GNU Radio під час тестування. Щоб збирати дані з блоку виявлення, повинні мати можливість передавати на певній частоті, контролювати та збирати дані для навчання, а потім тестувати класифікацію за допомогою спеціального блоку тестування машинного навчання представленого на рисунку 3. Для цього експерименту дрон передає на каналі 13, а модуль приймача на GNU Radio центрується на частоті 2,411 ГГц, щоб виявити наявність активності на каналі.

В якості класифікатора нами було обрано метод К-найближчий сусідів. Алгоритми К-найближчих сусідів є одними з найпростіших алгоритмів машинного навчання. Ідея полягає в запам'ятовуванні навчальної множини, а потім у прогнозуванні мітки будь-якого нового екземпляра на основі міток його найближчих сусідів у навчальній множині. Обґрунтування такого методу базується на припущенні, що ознаки, які використовуються для опису точок домену, мають відношення до їхніх міток таким чином, що сусідні точки з великою ймовірністю матимуть однакові мітки. Крім того, в деяких ситуаціях, навіть коли навчальна множина величезна, пошук найближчого сусіда може бути виконаний надзвичайно швидко. К в k-найближчому сусіді – це кількість точок даних, найближчих до нового екземпляра. Наприклад, якщо $k = 2$, то алгоритм вибере найближчі два екземпляри або якщо $k = 5$, то алгоритм вибере найближчі п'ять сусідніх екземплярів і на їх основі класифікує їх відповідним чином.

Для нашого експерименту будемо використовувати метод керованої класифікації машинного навчання для навчання моделей, які будуть використовуватися для виявлення та класифікації, а дані, що використовуються для класифікації, будуть позначені відповідним чином. Навчальні дані містять параметри, які будуть використовуватися для класифікації, і для кожного об'єкта, що підлягає класифікації, збирається однакова кількість даних. Для першого тесту керованого навчання було зібрано 200 вибірок, коли DJI phantom був увімкнений, і 200 вибірок, коли Mavic був увімкнений. Обидві вибірки були позначені, щоб створити клас для класифікації. Загальна вибірка, використана для тренувальних даних, становить 400 значень. Для початку було вирішено почати з менших навчальних вибірок, а пізніше збільшити кількість вибірок, що використовуються для навчання. Для другого тесту загальна кількість вибірок, використаних для навчання, становила 3000; 1500 для сигналів Mavic і ще 1500 для сигналів DJI phantom.

В таблиці 3 наведено приклад зібраних даних.

На основі даних, використаних для навчання та тестування, нижче наведено метрику ефективності класифікації в Python після того, як навчальні дані були розділені на навчальні та тестові для перевірки.

На рисунку 4 представлено діаграму, що складається з метрики ефективності, згенерованої в Python з використанням KNN-класифікатора для навчання вибірки даних.

Таблиця 3

Параметри, які дослідники використовують як ознаки для класифікації OFDM сигналу

Subcarrier-Spacing	Symbol-time	fft-length	cp-length	Signal-Power	Detection	class
97.65625	0.01024	1024	32	463.655823	1	Mavic
390.625	0.00256	256	32	466.324219	1	Mavic
97.65625	0.01024	1024	32	462.016113	1	Mavic
195.3125	0.00512	512	32	470.765259	1	Mavic
97.65625	0.01024	1024	32	470.765259	1	Mavic
1562.5	0.00064	64	32	452.020081	1	Phantom
195.3125	0.00512	512	32	452.105621	1	Phantom
1562.5	0.00064	64	16	450.157654	1	Phantom
390.625	0.00256	256	16	450.232574	1	Phantom
390.625	0.00256	256	32	265.731476	1	Phantom

Для класифікатора було використано KNN після порівняння точності різних класифікаторів, таких як дерево рішень, лінійна регресія та машина опорних векторів.




Рис. 4. Результати роботи класифікатора

Висновки

На основі проведеного експерименту та отриманих результатів можна зробити висновок про ефективність застосування методів машинного навчання для класифікації сигналів, що передаються з дронів DJI Phantom та Mavic. Ретельний аналіз параметрів сигналу, таких як Subcarrier-Spacing, Symbol-time, fft-length, cp-length та Signal-Power, дозволив сформувати інформативний набір ознак, які були використані для побудови моделей класифікації.

Серед протестованих алгоритмів машинного навчання, найкращі результати продемонстрував метод K-найближчих сусідів (KNN), який забезпечив найвищі показники точності, повноти та F1-міри для обох класів дронів. Це свідчить про те, що KNN добре справляється з розпізнаванням навіть при мінімальних відмінностях у параметрах сигналів, що є характерним для пристроїв одного виробника.

Однак, попри високу якість класифікації, залишається простір для вдосконалення. Подальші дослідження будуть спрямовані на підвищення точності моделі, зокрема шляхом виявлення нових інформативних ознак на основі тестової статистики та аналізу вхідних сигналів. Це дозволить створити більш надійну систему розпізнавання, що може бути використана в реальних умовах, зокрема в системах безпеки, моніторингу повітряного простору або при виявленні несанкціонованих БПЛА.

Загалом, проведена робота демонструє потенціал інтеграції сучасних підходів машинного навчання в задачі класифікації сигналів від дронів, що відкриває нові перспективи у сфері радіомоніторингу та безпілотних технологій.

Список використаної літератури

1. J. McCoy, A. Rawal, D. B. Rawat and B. M. Sadler, "Ensemble Deep Learning for Sustainable Multimodal UAV Classification", in *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 12, pp. 15425–15434, Dec. 2023, doi: 10.1109/TITS.2022.3170643
2. Mo Y, Huang J, Qian G. Deep Learning Approach to UAV Detection and Classification by Using Compressively Sensed RF Signal. *Sensors*. 2022; 22(8):3072. <https://doi.org/10.3390/s22083072>
3. Y. Wang, Z. Chu, I. Ku, E. C. Smith and E. T. Matson, "A Large-Scale UAV Audio Dataset and Audio-Based UAV Classification Using CNN", *2022 Sixth IEEE International Conference on Robotic Computing (IRC)*, Italy, 2022, pp. 186–189, doi: 10.1109/IRC55401.2022.00039
4. Ezuma, Martins, et al. "Comparative analysis of radar cross section based UAV classification techniques". *arXiv preprint arXiv:2112.09774* (2021). <https://doi.org/10.48550/arXiv.2112.09774>
5. X. Chen, C. Ma, C. Zhao and Y. Luo, "UAV Classification Based on Deep Learning Fusion of Multidimensional UAV Micro-Doppler Image Features", in *IEEE Geoscience and Remote Sensing Letters*, vol. 21, pp. 1–5, 2024, Art no. 3503205, doi: 10.1109/LGRS.2024.3371171
6. Shaye, I.; Dushi, P.; Banafaa, M.; Rashid, R. A.; Ali, S.; Sarijari, M. A.; Daradkeh, Y. I.; Mohamad, H. Handover Management for Drones in Future Mobile Networks – A Survey. *Sensors* 2022, 22, 6424. <https://doi.org/10.3390/s22176424>

7. Del Barrio, Alberto A., et al. "HackRF+ GNU Radio: A software-defined radio to teach communication theory". *The International Journal of Electrical Engineering & Education* 60.1 (2023): 23–40. <https://doi.org/10.1177/0020720919868144>
8. C. Liu, C. Guo, Y. Yang, W. Ni and T. Q. S. Quek, "OFDM-Based Digital Semantic Communication With Importance Awareness", in *IEEE Transactions on Communications*, vol. 72, no. 10, pp. 6301–6315, Oct. 2024, doi: 10.1109/TCOMM.2024.3397862
9. Amar Al-Jzari, Kostanic Iviva, Cyclic Prefix Length Determination for Orthogonal Frequency Division Multiplexing System over Different Wireless Channel Models Based on the Maximum Excess Delay Spread, *American Journal of Engineering and Applied Sciences* 8 (2015), <https://doi.org/10.3844/ajeassp.2015.82.93>
10. GNU Radio. gr-inspector [Електронний ресурс] / GitHub. – Режим доступу: <https://github.com/gnuradio/gr-inspector>