

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ФАКУЛЬТЕТ ЕЛЕКТРОНІКИ ТА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА КОМП'ЮТЕРНИХ НАУК

Кваліфікаційна робота бакалавра
**ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ
ІДЕНТИФІКАЦІЇ БЕЗПІЛОТНИХ ЛІТАЛЬНИХ АПАРАТІВ**

Здобувач освіти гр. ІН – 82

Андрій ІВАЩЕНКО

Науковий керівник:
кандидат технічних наук, доцент,
доцент кафедри комп'ютерних наук

Ігор ШЕЛЕХОВ

Завідувач кафедри
доктор технічних наук, професор

Анатолій ДОВБИШ

СУМИ 2022

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ФАКУЛЬТЕТ ЕЛЕКТРОНІКИ ТА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА КОМП'ЮТЕРНИХ НАУК

Затверджую
Зав. кафедри Анатолій ДОВБИШ
“ _____ ” _____ 2022 р.

ЗАВДАННЯ
до кваліфікаційної роботи

здобувача вищої освіти четвертого курсу, групи ІН-82 спеціальності
«122 – Комп'ютерні науки» денної форми навчання Іващенко Андрія
Олександровича

**Тема: «ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ
ІДЕНТИФІКАЦІЇ БЕЗПІЛОТНИХ ЛІТАЛЬНИХ АПАРАТІВ»**

Затверджена наказом по СумДУ
№ _____ від _____ 2022 р.

Зміст пояснювальної записки: 1) інформаційний огляд; 2) постановка завдання; 3) інтелектуальна технологія ідентифікації безпілотних літальних апаратів; 4) інформаційне та програмне забезпечення системи ідентифікації безпілотних літальних апаратів.

Дата видачі завдання « _____ » _____ 2022 р.

Керівник роботи _____ Ігор ШЕЛЕХОВ
Завдання прийняв до виконання _____ Андрій ІВАЩЕНКО

РЕФЕРАТ

Записка: 47 стор., 9 рис., 6 табл. 1 додаток, 41 джерело.

Об'єкт дослідження — процес детектування і ідентифікації безпілотних літальних апаратів.

Мета роботи — розробка інформаційного і програмного забезпечення системи ідентифікації безпілотних літальних апаратів.

Методи дослідження — методи проектування інформаційних інтелектуальних систем, методи розпізнавання образів.

Результати — розроблена інтелектуальна інформаційна система, здатна навчатися розпізнаванню різних видів безпілотних літальних апаратів шляхом аналізу їх вхідного і вихідного трафіку.

КЛАСИФІКАТОР, ВИРІШАЛЬНІ ПРАВИЛА, БЕЗПІЛОТНИЙ ЛІТАЛЬНИЙ
АПАРАТ, РОЗПІЗНАВАННЯ ОБРАЗІВ

ЗМІСТ

ВСТУП	5
1 АНАЛІТИЧНИЙ ОГЛЯД.....	6
1.1 Методи та засоби детектування та ідентифікації безпілотних літальних апаратів.....	6
1.2 Постановка задачі.....	17
2 ТЕХНОЛОГІЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ	19
2.1 Нейромережеві методи аналізу трафіка.....	19
2.2 Навчання нейронної мережі.....	21
3 ІНФОРМАЦІЙНЕ І ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ.....	26
3.1 Формування вхідних даних.....	26
3.2 Короткий опис програми.....	28
3.3 Аналіз результатів моделювання.....	30
ВИСНОВКИ.....	35
СПИСОК ЛІТЕРАТУРИ.....	36
ДОДАТОК.....	41

ВСТУП

Одна з актуальних задач сьогодення полягає в захисті різноманітних об'єктів від впливу безпілотних літальних апаратів (БПЛА), що несуть потенційну загрозу у військовій, господарській та повсякденній діяльності людини. Відносно невисока вартість БПЛА і труднощі їх спостереження і контролю призводить до безкарності і протиправних дій з їх використанням. Для вирішення завдань виявлення, розпізнавання та вимірювання координат безпілотних літальних апаратів використовуються оптичні, інфрачервоні, радіолокаційні, акустичні методи та засоби. Кожен із відомих методів має свої переваги, недоліки та обмеження, які визначаються множиною вимірюваних параметрів з відповідними точностними характеристиками. Оскільки можливості різних методів не співпадають, то з'являється необхідність спільного використання системи різного виду для підвищення ефективності їх функціонування.

В цій роботі розглядається задача формування високоточних класифікаторів БПЛА за результатами аналізу трафіку, яким вони обмінюються з наземними станціями керування.

1 АНАЛІТИЧНИЙ ОГЛЯД

1.1 Методи та засоби детектування та ідентифікації безпілотних літальних апаратів

Розглянемо основні методи детектування та ідентифікації безпілотних літальних апаратів та засоби, що використовують такі методи.

Радіолокаційний метод

Радіолокаційні станції (РЛС) є традиційним, поширеним засобом виявлення літальних апаратів. У порівнянні з іншими методами ця технологія дозволяє виявляти об'єкти на значних видаленнях (десятки кілометрів), при цьому стан навколишнього середовища не має визначального впливу на дальність та основні тактичні характеристики станцій.

Розроблено широку номенклатуру РЛС для вирішення різноманітних завдань при роботі з літальними апаратами [1], що мають значну ефективну площу розсіювання (ЕПР), проте вони малопридатні для виявлення БПЛА. Для спостереження за специфічними цілями була потрібна розробка спеціалізованих РЛС для відокремлення БПЛА від птахів, що мають схожі з БПЛА радіолокаційні характеристики. Можливості розпізнавання і розподілу цілей на підкласи у класичних РЛС досить слабкі, у той час як у спеціалізованих РЛС з виявлення БПЛА ці якості є визначальними.

РЛС, що призначені для виявлення БПЛА, є активними, тобто. вони випромінюють зондуючий сигнал, і отримують корисну інформацію із сигналу, відображеного від об'єктів і надходить на вхід. Використовуються різні види зондувального сигналу - імпульсний, безперервний. Реалізуються різні методи огляду – паралельний, а РЛС кругового огляду – послідовний.

Найбільш поширена характеристика радіолокаційного сигналу РЛС виявлення БПЛА – мікродопплерівська сигнатура (МДС). МДС широко використовується для класифікації різноманітних цілей під час вирішення різних завдань, зокрема останнім часом для класифікації БПЛА. Статистичні характеристики МДС описують обертання лопатей гвинта безпілотного літального апарату або гелікоптера, роботу турбін реактивного двигуна, помах

крил птахів. У літературі розглядаються різні методи обробки сигналів при отриманні сигнатури, процесу формування інформативних ознак та безпосередньо роботи класифікатора.

Автори [2, 3] запропонували формувати МДС з використанням спектрограми (на основі короткочасного перетворення Фур'є (STFT) [2] та кепстрограми [3]). Вони зосередили увагу на формуванні ознак, що дозволяють виділяти з сигналу радара такі характеристики як швидкість обертання та нахил лопатей, діаметр і кількість гвинтів, з метою класифікації гвинтових БПЛА. В [4] запропоновано використовувати короткострокове перетворення Фур'є (STFT) та формувати власні вектори з кореляційної матриці МДС як ознаки для навчання трьох класифікаторів: лінійного, нелінійного методу опорних векторів та байєсівського з метою класифікації десяти різних гвинтових БПЛА та птахів. В [5] використовувалася процедура обробки, аналогічна [4], з подальшим застосуванням декомпозиції сингулярних значень (SVD) до спектрограми. Авторами запропоновано три основні функції, що дозволяють класифікувати швидкість мети, періодичність спектра та ширину спектра. У [6] запропоновано використовувати двовимірне регуляризоване комплексне логарифмічне перетворення Фур'є та об'єктно-орієнтовану методику зменшення розмірності сигналу з метою підвищення інформативності та надійності підпростору, спеціально розробленого для вирішення завдання розпізнавання БПЛА на фоні птахів. В [7] використовувався метод емпіричної модової декомпозиції: отриманий сигнал розкладався на набір коливань, що осцилюють, з яких формувалися вісім статистичних і геометричних ознак. Використовувався нелінійний метод опорних векторів (SVM), який забезпечив вищі результати виявлення БПЛА, ніж у [4].

РЛС кругового огляду для виявлення БПЛА має обертову кругову антену і забезпечує достатні пошукові можливості при виявленні об'єктів, а також для вимірювання їх координат, але час опромінення цілей у цьому випадку виходить досить малим через специфіку їх роботи, що не дозволяє

формувані МДС. І тут класифікація об'єктів складає основні ознак, що описують рух мети – траєкторної інформації.

Автори [7] використовували вихідні дані РЛС кругового огляду, ймовірні моделі руху цілей, що враховують напрямок і швидкість руху, а також застосовували фільтр Калмана для згладжування одержуваних оцінок. Далі здійснювався аналіз ймовірностей опису за допомогою використовуваних моделей траєкторій переміщення БПЛА та птахів. Ефективність запропонованих алгоритмів підтверджена результатами комп'ютерного моделювання та з використанням реальних даних.

В [7] завдання класифікації БПЛА та птахів за даними РЛС кругового огляду вирішувалося шляхом формування дев'яти поляриметричних параметрів, а також використанням алгоритму знаходження найближчого сусіда. Показано, що висока ймовірність правильної класифікації може бути досягнута без урахування ознак, що відображають рух об'єктів.

В [7] використовується двокоординатна РЛС кругового огляду з безперервним лінійно-частотно-модульованим зондувальним сигналом (LFMCW). Розглядається двоетапний процес автоматичної класифікації цілей: спочатку БПЛА відокремлюються від інших об'єктів (люди, літаки, автомобілі, птахи), та був БПЛА поділяються на два класу – гвинтові і негвинтові. Алгоритм класифікації використовує набір параметрів, заснованих на радіолокаційній сигнатурі (відношення сигнал-шум (SNR) і траєкторна інформація (включаючи інформацію про швидкість). Використовується оптимізований класифікатор SVM, навчений за трьома різними схемами. Результати проведених експериментів показали високу точність вирішення завдання обох етапах, особливо у першому етапі – детектування БПЛА.

Останнім часом все більшого поширення набувають методи машинного навчання, що застосовуються в різних галузях, у тому числі в області обробки зображень, відео- та аудіо-. Щодо вирішення різноманітних радіолокаційних завдань ці досягнення скромніші, що пов'язано, перш за все, з необхідністю використання достатньо представницького масиву вхідних даних для

навчання. Крім того, радіолокаційні дані є досить специфічними, і для їх використання в системі машинного навчання потрібна відповідна обробка та інтерпретація радіолокаційних сигналів з метою отримання необхідної просторово-часової радіофізичної інформації про об'єкти. Подібна інтерпретація сигналів може бути виконана лише спеціалістами. Незважаючи на складності, методи машинного навчання знаходять останнім часом все більше застосування для обробки радіолокаційних даних у різних завданнях, у тому числі стосовно БПЛА. Основне завдання полягає у формуванні спектра відбитого сигналу БПЛА, формуванні МДС об'єкта та подальшому використанні отриманих даних в мережі, що навчається. Автори [8], використовуючи РЛС з безперервним частотно-модульованим зондувальним сигналом, отримали спектри БПЛА, запропонували метод поліпшення МДС та провели експериментальні дослідження з різними типами БПЛА, використовуючи GoogleNet. В [3] за допомогою РЛС з безперервним зондувальним сигналом в діапазоні S були отримані функції спектральної кореляції (SCF) БПЛА, що відображають доплерівські особливості цілей. Отримані в експерименті результати зіставлялися з чотирма еталонними SCF, далі здійснювалося їхнє зважування та подача на вхід глибокої мережі довіри (DBN). [9] запропоновано метод виявлення БПЛА на основі аналізу спектра за допомогою надточної нейронної мережі CNN. При цьому використовувалися різні вікна для спектрів доплерівських цілей, на тлі різноманітних перешкод і при різних відносинах сигнал-шум. Здійснювалося переміщення вікна в діапазоні значень доплерівської частоти та вирішувалося завдання виявлення БПЛА на фоні перешкод. Аналогічне завдання – класифікація типів БПЛА шляхом аналізу доплерівських спектрів БПЛА з використанням DNN (CNN) вирішувалася у [10]. Експерименти, проведені в X діапазоні радіохвиль, показали не погані результати. В [9] виконувалося навчання мережі безпосередньо по відбитому сигналу, що надходить з виходу РЛС та представленому в комплексному вигляді. Нейронна мережа, що складається з п'яти окремих шарів, навчалася на наявність гвинтів у БПЛА, а потім

визначалася кількість лопатей. Якість вирішення завдання значною мірою залежить від відношення сигнал-шум.

Оптичний метод

Відома значна кількість публікацій, у яких розглядаються питання виявлення БПЛА з використанням відеокамер видимого діапазону хвиль. При цьому як детектор, що виносить рішення про виявлення-розпізнавання БПЛА, використовуються, як правило, нейронні мережі та алгоритми глибокого навчання, що було зумовлено успіхами алгоритмів класифікації зображень за наборами даних бази ImageNet. Попередньо відбувається навчання мережі [11], як правило, з використанням даних про БПЛА із загальнодоступної бази ImageNet. Велика кількість експериментів з використанням мереж глибокої нейронної мережі DNN проведено авторами, у яких найкращі результати показала мережа VGG-16 [12, 13]. Результати експериментів також показують, що наявність птахів збільшує кількість хибних спрацьовувань і для підвищення ефективності роботи алгоритмів пропонується не виключати птахів з відео, що використовуються в процесі навчання, що дозволить навчити систему та виявляти відмінності між птахами та БПЛА.

Авторами [14] запропонована мережа на основі згорткової мережі VGG у поєднанні з RPN для цілей виявлення-розпізнавання БПЛА та птахів. Автори підготували велику базу зображень птахів, БПЛА та фотографій фону, запозичених з Інтернету, провели навчання мережі з використанням цих даних та дійшли висновку, що використання більш різноманітних даних у процесі навчання забезпечує кращі результати виявлення розпізнавання об'єктів. У [15] пропонується перед основним класифікатором розташувати U-мережу, що виконує функції попередньої обробки сукупності послідовних кадрів і виділення областей руху у зображеннях, які можуть містити БПЛА. Далі виділені області обробляються основною мережею, що виносить остаточне рішення. У статті [16] також використовується модуль попередньої обробки зображень, побудований на основі мережі глибокого навчання з використанням методу SISR (Single image super-resolution – надвисоке

зображення одиночного зображення), що дозволяє істотно збільшити роздільну здатність зображення, що надходить з відеокамери. Це дозволяє покращити якість виявлення та збільшити максимальну дальність, на якій може бути виявлений БПЛА. У роботі [17] при виявленні БПЛА використовувалися традиційні методи комп'ютерної обробки зображень, засновані на зіставленні вихідного та зразкового зображень та формуванні функції взаємної кореляції. Для зменшення впливу освітленості на якість виявлення застосовувалася морфологічна фільтрація, що дозволяє розширити можливості виявлення БПЛА у різних умовах, особливо за досить яскравих та темних зображень БПЛА. В [18] також використовуються традиційні методи обробки, такі як формування гістограми градієнтів, для опису малих БПЛА. Крім того, при проведенні машинного навчання застосовувався каскадний метод класифікації для винесення ряду послідовних оцінок на декількох етапах, що характеризуються більш складним набором ознак. Якщо всі етапи пройдені успішно, об'єкт вважається виявленим. Алгоритм регресії опорних векторів (SVR) навчався для сітки різних відстаней з метою оцінки дальності до БПЛА при його виявленні. Ряд алгоритмів обробки зображень, заснованих на методах комп'ютерного зору, викладено у роботах [19-20]. У [21] завдання виявлення БПЛА вирішується з відеопотоку стаціонарної відеокамери. Обробка зображення складається з етапів виявлення об'єктів, що рухаються, і класифікації цих об'єктів з використанням нейромережі. При виявленні БПЛА використані методи виділення об'єктів, що рухаються, на нерухомому фоні та аналізу історії руху. Для класифікації об'єктів, що рухаються, створена і навчена модель нейромережі, що дозволяє класифікувати 12 типів рухомих об'єктів. Перевірка роботи алгоритму виконана з використанням експериментальних відеоданих. В [22] використовувалася згортова нейронна мережа класу YOLO для детектування БПЛА на зображеннях, що забезпечує досить швидке та якісне вирішення завдання. У статті наведено новий набір даних, який може бути використаний для навчання нейронних мереж. Дані отримані шляхом відокремлення БПЛА від фону на наявних зображеннях та

додаванням зображення БПЛА до різних природних зображень з різноманітним та складним фоном. Створена база даних дозволяє проводити глибоке навчання мереж при використанні БПЛА, що знаходяться в різних умовах та на різних дальностях.

Інфрачервоний метод

Відеокамери інфрачервоного діапазону або тепловізійні датчики працюють у невидимому діапазоні електромагнітних хвиль, як правило, у довгохвильовому інфрачервоному діапазоні з довжиною хвилі 9 – 14 мкм, та приймають випромінювання, яке формується нагрітими об'єктами або окремими елементами їх конструкції. Основною перевагою інфрачервоних тепловізійних відеокамер є можливість візуалізації навколишнього світу та певних об'єктів незалежно від ступеня освітлення (навіть за умов повної темряви) та погодних умов [23]. Тепловізійні камери мають гіршу роздільну здатність, ніж камери видимого діапазону, але більш стійкі до змін освітленості. Вони також дорожчі, ніж камери видимого діапазону хвиль. У [24] досліджувалась можливість виявлення БПЛА при несприятливій фоновій обстановці - на фоні дерев при листі, що коливалося. У [25] виконано порівняння ефективності виявлення дронів з використанням тепловізійних камер різних ділянок інфрачервоного діапазону - довгохвильового інфрачервоного (LWIR), середньохвильового (MWIR) та короткохвильового (SWIR). У [26] розглядається можливість визначення кутових координат БПЛА на площині і в просторі при використанні кількох тепловізійних відеокамер.

Загалом кількість експериментальних і теоретичних робіт, присвячених виявленню БПЛА, з використанням тепловізійних відеокамер порівняно невелика. Хоча можливості використання тепловизионних відеокамер на вирішення інших прикладних завдань – виявлення пішоходів, тварин, браконьєрів, розпізнавання осіб розглядаються у літературі досить часто. Найбільш широко обробки тепловізійних зображень під час вирішення різних

завдань використовуються згорткові нейронні мережі CNN і методи глибокого навчання [27].

Акустичний метод

Значна увага при вирішенні задачі виявлення та вимірювання координат БПЛА приділяється акустичному інформаційному каналу, розвитку цього напрямку присвячено значну кількість робіт [28].

Структура та параметри акустичного сигналу, що випромінюється БПЛА, залежать від виду об'єкта, його форми, кількості двигунів, кількості несучих гвинтів тощо. У свою чергу акустична локаційна станція (сонар) має будуватися з урахуванням особливостей структури сигналу, що приймається. Дослідженню особливостей акустичного сигналу, що формується та випромінюється БПЛА, присвячені роботи [29-30].

Експериментальні дослідження структури та параметрів звукового поля БПЛА у вигляді квадрокоптера показали, що спектри його акустичного випромінювання містять яскраво виражені гармонічні складові, що мають частоти, кратні частоті обертання гвинта. Основний тон перебуває у смузі частот 80 – 240 Гц, а кількість гармонік то, можливо від 10 до 40. Спектр сигналу простягається до частот понад 10 – 12 КГц [10].

У режимі польоту спектральні лінії акустичного випромінювання квадрокоптера розмиваються внаслідок відмінності режимів роботи (частоти обертання) чотирьох двигунів при компенсації автоматикою БПЛА впливу дестабілізуючих факторів, що виникають у процесі польоту. Цей фактор може бути однією з інформаційних ознак класифікації БПЛА серед інших об'єктів. Розширення спектральних ліній проявляється сильніше зі збільшенням номера гармоніки [29].

Спектральні гармонічні складові акустичного сигналу квадрокоптера ширші, ніж у моноплана, що пояснюється різницею режимів роботи двигунів у процесі польоту або при відпрацюванні системою компенсації вітрових збурень. У міру збільшення відстані, що пройшло акустичною хвилею в атмосфері, відбуваються зміни в спектрі акустичного випромінювання (АВ),

що супроводжуються помітним послабленням високочастотних складових. Зміни форми спектрів АВ БПЛА у реальних умовах спостереження обумовлені дисперсійними властивостями середовища, а також мінливістю характеристик просторової спрямованості випромінювання у смузі частот [31]. Велике значення для практики мають діаграми випромінювання БПЛА, що характеризують розподіл акустичної енергії, що випромінюється, за напрямками. У ряді робіт розглядалася просторова спрямованість звукового випромінювання БПЛА, зокрема в [29] зроблено висновок про те, що в першому наближенні БПЛА може вважатися ізотропним джерелом випромінювання.

Авторами [32, 33] синтезовані та апробовані на практиці алгоритми виявлення БПЛА за характерними особливостями спектра та розпізнавання на підставі Mel-Frequency Cepstral Coefficients – MFCC. Основна складність при вирішенні задач виявлення та розпізнавання полягає у розрізненні інформаційного сигналу від перешкод, що мають ідентичні з АВ БПЛА спектральні особливості. До таких перешкод слід віднести АВ автомобільних двигунів та звуки мови людини. У публікаціях [34, 35] для виявлення БПЛА автори використовували записані заздалегідь акустичні образи, що відповідають різним типам дронів, та обчислення кореляції між сигналами, що надходять на вхід та наявними в базі. Алгоритм не дозволив працювати в режимі реального часу та мав обмежену базу образів. В [36] для виявлення БПЛА використовувалися мелпепстральні коефіцієнти MFCC і алгоритм SVM. В [37] використана приймальна акустична система з одним мікрофоном, в якій реалізований алгоритм k-найближчих сусідів, що працює за спектрами швидкого перетворення Фур'є. У роботі [38] ці ж автори підвищили ймовірність правильного рішення з 0,83 до 0,86 шляхом використання нейронної мережі та сформувавши перешкодні фонові сигнали, що відповідають звукам різних джерел, використовуючи базу даних UrbanSound8K. У [39] розглянуто бінарний алгоритм розпізнавання, заснований на рекурентній нейронній мережі. Автори також виконали розширення набору вхідних даних,

що використовуються при обробці шляхом адитивного підсумовування сигналів дронів з різними фоновими звуками.

У роботі [40] використовувалася комплексна система РЛС-сонар, дані якої надходили в нейронну мережу із прямим зв'язком. Існує необхідність у формуванні бази звуків БПЛА, яка могла б бути використана розробниками та науковою спільнотою при синтезі, аналізі та верифікації алгоритмів виявлення-розпізнавання дронів. У статті [41] для вирішення задачі виявлення-розпізнавання БПЛА по акустичному сигналу використовується складова модель авторегресії, яка адекватно описує кореляційні властивості сигналу на значних часових інтервалах, та забезпечує підвищення спектрального дозволу в області низькочастотних складових спектра досліджуваного сигналу. Складова модель авторегресії дозволяє виділяти низькочастотний пік акустичного сигналу, наявність якого є ефективною інформаційною ознакою БПЛА. Насправді рекомендується використовувати шостий порядок складової моделі авторегресії. Проведено експериментальні дослідження з використанням запропонованої математичної моделі, які показали суттєві відмінності спектральної густини потужності (СГП) АВ БПЛА від СПМ акустичних шумів різних джерел, що дозволило підвищити ефективність розв'язання задачі виявлення-розпізнавання БПЛА. Показано, що завдання розпізнавання буває зручніше використовувати інформацію про частоти піків спектра, а чи не сам спектр. Запропоновано алгоритм визначення частот піків СГП на базі запропонованої моделі авторегресії без обчислення спектра, що дозволяє порівняно легко розраховувати параметричні оцінки частот піків СГП і який доцільно використовувати у содарах виявлення БПЛА під час роботи у реальному масштабі часу. Використання методів класичного спектрального аналізу, котрим характерна робота з сигналами великої тривалості, для виявлення сигналу БПЛА пов'язані з низькою труднощів. Сигнал БПЛА є набором дискретних гармонік, параметри яких змінюються на порівняно невеликих інтервалах часу, зокрема, внаслідок зміни режимів роботи двигунів. Визначена таким чином спектральна щільність наближається

формою до безперервної. Природно, при цьому губляться характерні особливості форми спектра БПЛА, що становлять основний набір інформаційних ознак під час вирішення завдання виявлення-розпізнавання. Аналіз властивостей сигналу на невеликих проміжках часу дозволить виявити його справжню структуру та ефективно вирішити задачу виявлення БПЛА на тлі перешкод. При обробці акустичних сигналів БПЛА необхідно враховувати стан атмосфери та особливості поширення коливань. Ряд робіт присвячений питанням пеленгування БПЛА щодо їх акустичного випромінювання, дослідження можливостей різних методів. При використанні класичних методів для пеленгування БПЛА щодо їх акустичного випромінювання процес пеленгування можливий лише за наявності в діаграмі спрямованості содару лише одного об'єкта. Наявність у діаграмі спрямованості антени (ДНА) кількох об'єктів (наприклад, роя БПЛА) призводить до появи аномальних похибок результатів вимірювань кутових координат. Це зумовлено формуванням амплітудно-фазового розподілу звукового поля у розкритті антени шляхом суперпозиції хвиль, отриманих від окремих БПЛА. Внаслідок невеликих розмірів антеної системи содарів виявлення БПЛА кутовий дозвіл окремих БПЛА у цьому випадку важко. Неадаптивний метод Бартлетта досить простий при реалізації системи пеленгації БПЛА з використанням АР, але його кутовий дозвіл обмежений релеївською межею, а для підвищення просторового дозволу необхідно збільшувати кількість елементів мікрофонних ґрат.

Більш високі характеристики просторового дозволу джерел акустичного випромінювання забезпечують методи надроздільної здатності – Кейпона, методи MUSIC, а також його різновиди ROOT-MUSIC та ESPRIT. Недолік даних методів полягає у формуванні вибіркової кореляційної матриці, а також виконанні сингулярного розкладання або розкладання власними векторами отриманих матриць. При пеленгуванні малих БПЛА в умовах динамічної обстановки, що швидко змінюється, ця умова накладає певні обмеження на тимчасові та обчислювальні ресурси содару. При використанні

методів Бартлетта та Кейпона передбачається використання вузькосмугових сигналів. Внаслідок цього прийому та обробці широкосмугового випромінювання БПЛА потрібна деяка адаптація даних алгоритмів. Для визначення напрямку приходу АВ широкосмугових сигналів широко використовується метод взаємної кореляційної функції (МВКФ). Зсув часу приходу широкосмугового акустичного сигналу до окремих мікрофонів антенної решітки вимірюється шляхом обчислення положення в часі максимумів ВКФ сигналів, що приймаються різними елементами антенної решітки. З метою підвищення ефективності роботи алгоритму МВКФ при обробці акустичних сигналів БПЛА слід вживати заходів щодо зменшення впливу низькочастотних природних акустичних шумів. Експерименти визначення пеленгу БПЛА в широкій смузі частот у відкритому просторі з використанням методу МВКФ показують хорошу відповідність результатів експерименту заданим значенням пеленгу. Аналіз показує, що сьогодні неможливо виділити серед алгоритмів пеленгування БПЛА найкращий, що перевершує всі інші методи за різних умов функціонування. Вибір методу пеленгування БПЛА при розробці содару слід проводити з урахуванням наявної апіорної інформації про об'єкти, що спостерігаються, існуючої сигнально-перешкодової обстановки, з урахуванням конфігурації мікрофонної антенної решітки, кількості елементів і її геометричних розмірів.

1.2 Постановка задачі

Результати проведеного аналітичного огляду доводять актуальність і практичну значущість задачі детектування і ідентифікації безпілотних літальних апаратів (БПЛА). Метою цієї роботи є розробка і програмна реалізація системи, що здатна навчатися розпізнаванню виду БПЛА за результатами аналізу трафіка, який передається ним на наземну станцію керування. При цьому перспективним вбачається використання неймережевого підходу до формування класифікатора. Таким чином, основними завданнями роботи є:

1. Формування вхідного математичного опису інтелектуальної системи ідентифікації виду БПЛА за результатами аналізу його трафіку.
2. Вибір типу та структури класифікатору мережевого трафіку, що використовується інтелектуальною системою.
3. Розробка та реалізація алгоритмів оптимізації функціональних параметрів інтелектуальної системи
4. Перевірка працездатності розробленої інтелектуальної системи на задачі ідентифікації 3-х видів БПЛА.

2 ТЕХНОЛОГІЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

2.1 Нейромережеві методи аналізу трафіка

Більшість сучасних систем аналізу трафіка, наприклад, для виявлення його аномалій, базується на використанні різних методів пошуку сигнатур, тобто специфічних ознак (індикаторів) того, що передача мережевого трафіку здійснюється в рамках тієї чи іншої дії інформаційної системи. Процес обробки інформації при цьому включає в себе наступні етапи (рис. 2.1):

- 1) визначення переліку ознак (параметрів);
- 2) попередня обробка параметрів;
- 3) розпізнавання атак (класифікація).

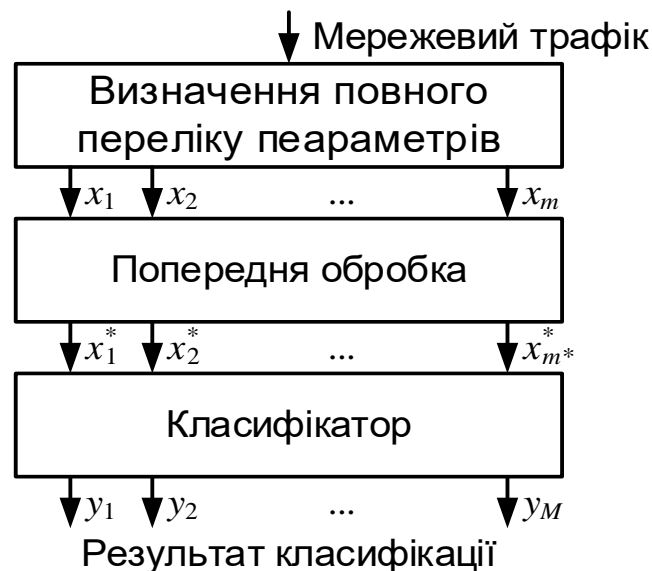


Рисунок 2.1 – Схема процесу обробки інформації при аналізі трафіку

На першому етапі здійснюється захоплення трафіку мережі (feature selection). Збір необхідних даних проводиться за допомогою спеціального програмного модуля – сніферу пакетів, який перехоплює всі пакети і здійснює їх фільтрацію. Первинними ознаками (параметрами) трафіку, що аналізується, є значення полів заголовків мережевих пакетів.

Другий етап (feature preprocessing) пов'язаний з виділенням (на базі вхідних даних) найбільш істотних параметрів, що характеризують активність

мережі і представлених в такій формі, в якій вони найбільш ефективно можуть використовуватися для їх подальшої обробки за допомогою класифікатора.

Третій етап (classification) полягає у виявленні і розпізнаванні тієї чи іншої дії. Використання неймереж (НМ) на даному етапі є кращим у порівнянні з класичними підходами, що здійснюють просте порівняння даних заголовків пакетів з відомими сигнатурами, оскільки НМ завжди намагається визначити, наскільки подібні ознаки поточної мережевої активності на зразки атак з навчальної вибірки. Здатність НМ до узагальнення, при достатньому обсязі і показності навчальної вибірки дозволяє НМ екстраполювати свої знання про відомих видах мережевих дій на невідомі види. При цьому вирішальну роль відіграє вибір адекватної поставленим завданням архітектури НМ.

Вихідні дані для аналізу будемо отримувати через певний проміжок часу, умовно званий тактом. Для аналізу наявності атак скористаємося схемою НМ, наведеної на рис. 2.2, де MLP - багатошаровий перцептрон (Multi-Layer Perceptron); z^{-1} - елемент часової затримки на один такт.




Рисунок 2.2 – Структурна схема нейронної мережі

Тут на входи перцептрона подаються дані про стан сервера: на перший вхід подається поточне значення ΔN , на другий вхід - його попереднє

значення, на третій - значення ΔN , затримане за два такти. Вихід НМ приймається рівним «1», якщо виявлено трафік, що відповідає певному виду БПЛА, і «0» в іншому випадку.

2.2 Навчання нейронної мережі

Важливою перевагою НМ є можливість виявлення за допомогою однієї і тієї ж мережі різних типів БПЛА за їх трафіком. Для цього кількість нейронів вихідного прошарку збільшують до кількості типів БПЛА. Таким чином кожний з нейронів призначено для ідентифікації трафіку, що відповідає певному виду БПЛА (рис. 2.3)

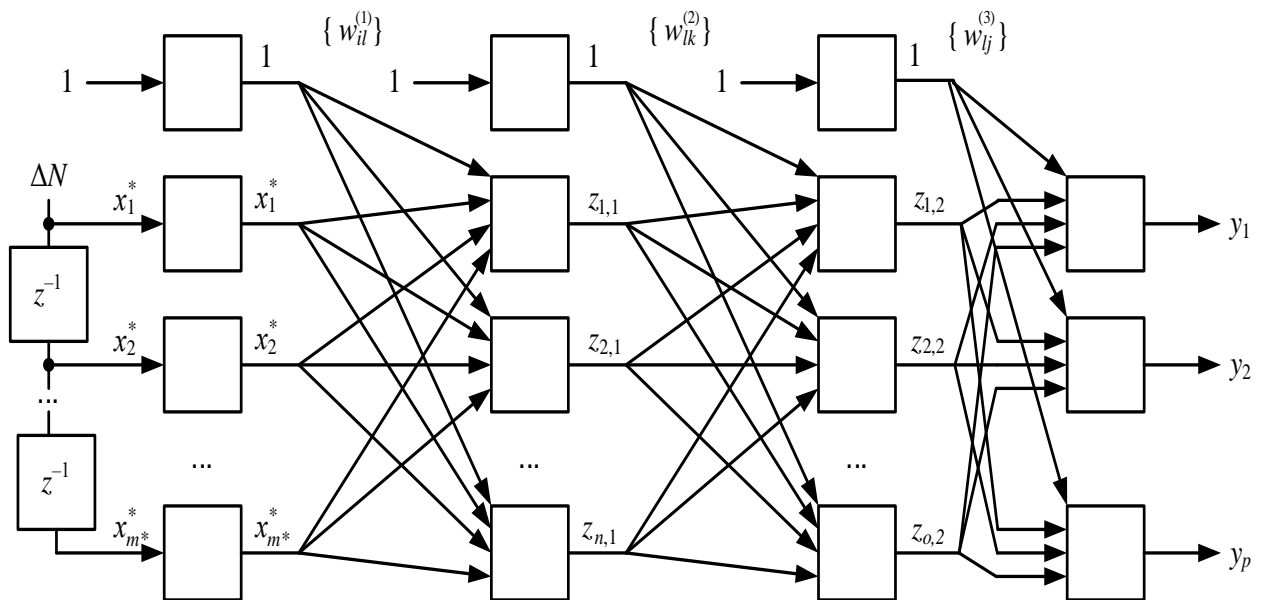


Рисунок 2.3 – Структурна схема нейронної мережі

Така мережа містить чотири прошарки нейронів:

- вхідний прошарок, на який подаються компоненти вектору ознак x^* і який передає їх на нейрони наступного прошарку, не виконуючи жодних перетворень;
- приховані прошарки, що здійснюють нелінійне перетворення координат $(x_1^*, x_2^*, \dots, x_m^*)$ до деяких величини (z_1, z_2, \dots, z_n) - виходи нейронів прихованого прошарку;

- вихідний прошарок - формує вектор вихідних реакцій (y_1, y_2, \dots, y_M) , що складається з M нейронів (по числу класів розпізнавання).

Вихідні значення нейронів прихованого та вихідного прошарків обчислюються за такими рівняннями:

$$z_l = f \left(\sum_{i=1}^{m^*} w_{il}^{(1)} x_i^* + w_{0l}^{(1)} \right), l = 1, 2, \dots, n$$

$$y_j = f \left(\sum_{l=1}^n w_{lj}^{(2)} z_l + w_{0j}^{(2)} \right), j = 1, 2, \dots, M$$

де $f(s)$ нелінійна передатна функція нейрона; $\{w_{il}^{(1)}\}$ і $\{w_{lj}^{(2)}\}$ - матриці ваг синаптичних зв'язків; $\{w_{0l}^{(1)}\}$ і $\{w_{0j}^{(2)}\}$ - зміщення. Варіанти завдання передатної функцій $f(s)$ у вигляді порогової (логічної) (рис. 2.4 а,в), сігмоїдної функції (рис. 2.4 б) або функції у вигляді гіперболічного тангенсу (рис. 2.4 г).




Рисунок 2.4 – Передатні функції: а) порогова (логічна), б) сігмоїдна, в) порогова; г) у вигляді гіперболічного тангенсу

Нехай, що є деяка навчальна вибірка

$$\left\{ \begin{array}{l} \left((x_{1,1}^*, x_{2,1}^*, \dots, x_{m^*,1}^*)^T; (d_{1,1}, d_{2,1}, \dots, d_{M,1})^T \right); \\ \left((x_{1,2}^*, x_{2,2}^*, \dots, x_{m^*,2}^*)^T; (d_{1,2}, d_{2,2}, \dots, d_{M,2})^T \right); \\ \dots; \\ \left((x_{1,T}^*, x_{2,T}^*, \dots, x_{m^*,T}^*)^T; (d_{1,T}, d_{2,T}, \dots, d_{M,T})^T \right) \end{array} \right\},$$

складена з пар векторів де $x_t^* = (x_{1,t}^*, x_{2,t}^*, \dots, x_{m^*,t}^*)^T$ і $d_t = (d_{1,t}, d_{2,t}, \dots, d_{M,t})^T$ - відповідно вхідний вектор і вектор бажаних вихідних реакцій мережі в t -му навчальному прикладі; T - число таких прикладів в навчальній вибірці. Зауважимо, що число навчальних прикладів має бути не менше числа класів розпізнавання ($T > M$), тобто в навчальну вибірку має входити принаймні по одному представнику (вектору ознак) кожного з класів розпізнавання.

Мета навчання НМ полягає в тому, щоб при поданні на входи мережі вектору ознак x_t^* , що належить k -му класу, вихідний сигнал НМ (тобто вектор y_t) вказував би (у прийнятій кодуванні) номер цього класу. Процес навчання зводиться до вибору таких значень ваг $\{w_{il}^{(1)}\}$ і $\{w_{lj}^{(2)}\}$, де $i = 0, 1, \dots, m^*$, $l = 0, 1, \dots, n$, $j = 1, \dots, M$ які мінімізують сумарну квадратичну помилку мережі.

$$E = \sum_{t=1}^T \left(\sum_{j=1}^M (d_{j,t} - y_{j,t})^2 \right) \quad (2.1)$$

де $y_{j,t}$ і $d_{j,t}$ - фактичне і бажане значення j -го виходу мережі для t -го прикладу з навчальної вибірки. Найбільш простим (але не найкращим) є градієнтний алгоритм навчання НМ, відповідно до якого настройка ваг мережі здійснюється за правилом

$$w_{il}^{(1)}(k+1) = w_{il}^{(1)}(k) - \eta \frac{\partial E(k)}{\partial w_{il}^{(1)}(k)}$$

$$w_{lj}^{(2)}(k+1) = w_{lj}^{(2)}(k) - \eta \frac{\partial E(k)}{\partial w_{lj}^{(2)}(k)}$$

де $\frac{\partial E(k)}{\partial w_{il}^{(1)}(k)}$ та $\frac{\partial E(k)}{\partial w_{lj}^{(2)}(k)}$ частинна похідні помилки навчання E по вагам $w_{il}^{(1)}$ та $w_{lj}^{(2)}$, $k = 0, 1, 2, \dots$ – дискретний час (крок навчання). Якість навчання вважається прийнятною, якщо помилка навчання приймає досить малі значення ($E = 10^{-3} \dots 10^{-4}$). Зауважимо, що оскільки в процесі навчання НМ «запам'ятала» образи всіх поданих в початковій вибірці представників M класів, то навчена НМ одночасно з вирішальним правилом виконує функцію зберігання відповідних параметрів трафіку видів БПЛА

Доведено, що перцептрон з одним прихованим шаром і пороговою передатною функцією нейронів (рис. 2.4, а) здатен за кінцеве число кроків вирішити задачу формування вирішального правила для M довільних класів за допомогою M роздільних гіперплощин в m -вимірному просторі ознак в тому випадку, якщо ці класи представлені опуклими обмеженими областями. Безпомилкове вирішальне правило можливо, якщо такі класи не перетинаються. В загальному випадку, помилка вирішального правила залежить тільки від ступеня перетину класів. Наприклад, при використанні сігмоїдної передатної функції (рис. 2.4, б) і двох прихованих шарів, за допомогою перцептрона можливе формування із заданою похибкою будь-яких опуклих областей в просторі ознак, а додаванні третього прихованого шару - областей будь-якої складності, в тому числі і неопуклого форми.

Основні труднощі, що виникають при навчанні НМ:

- наявність локальних мінімумів цільової функції E - призводить до «зависання» процесу пошуку в «пастках» («лакунах»);
- шум у вхідних даних - призводить до зміни напрямку пошуку, і в кінцевому підсумку, до суттєвого його уповільнення;

- помилки класифікації - виникають внаслідок близькості (перетину) образів сусідніх класів розпізнавання;

- «прокляття розмірності» - при збільшенні числа ваг, що налаштовуються, обчислювальні витрати на пошук їх оптимальних значень ростуть експоненційно.

На сьогодні відомо більше сотні різних алгоритмів навчання НМ, що ставлять собі за мету в тій чи іншій мірі уникнути вказаних труднощів. Одним із способів скорочення часу навчання НМ є застосування «швидких» алгоритмів навчання, заснованих на процедурі обчислення ваг мережі з попередньої декореляції (ортогоналізації) її вхідних даних.

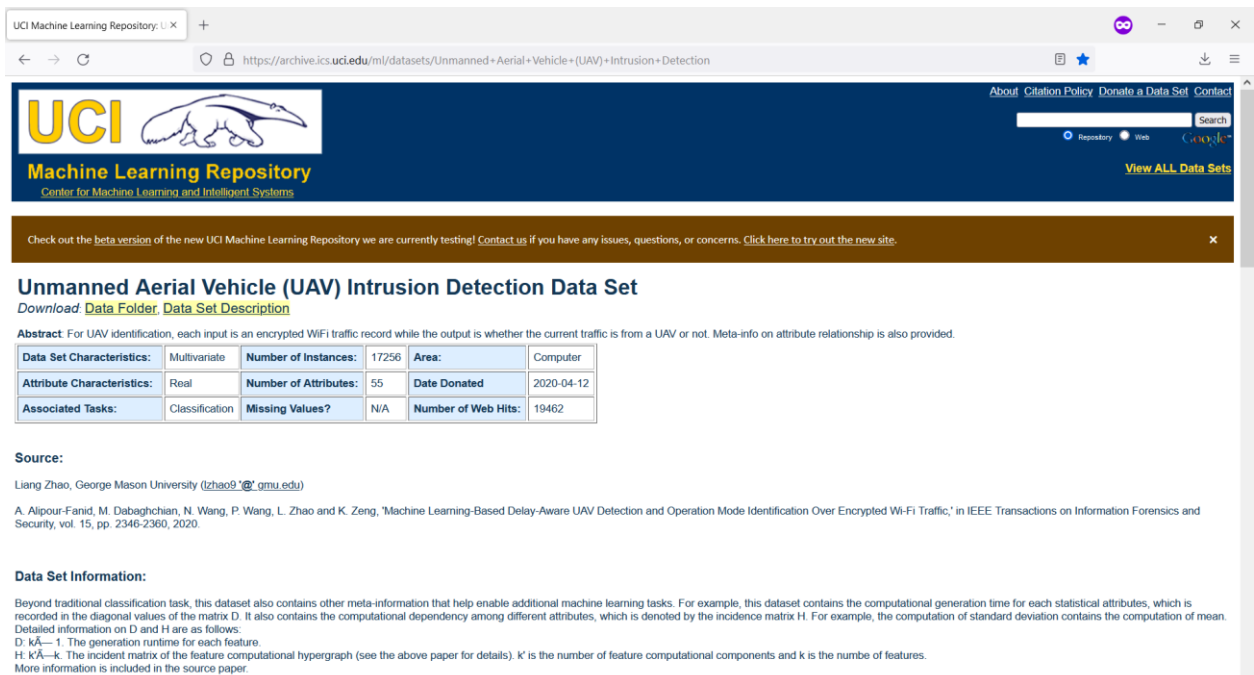
Крім багат шарових перцептронів, в даний час ведуться активні дослідження щодо застосування ряду інших архітектур НМ для вирішення завдань ідентифікації:

- модулярні НМ (Modular neural networks);
- машини опорних векторів (Vector Support Machines);
- згорткові НМ (Convolutional networks);
- вейвлет-мережі (Wavelet networks);
- асоціативні НМ (Associative networks);
- карти Кохонена, що самоорганізуються (Self-organizing maps, SOM);
- радіально-базисні мережі (Radial-Basis Function networks, RBFN);
- сигма-пі НМ (Σ - Π neural networks) тощо.




3 ІНФОРМАЦІЙНЕ І ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ


3.1 Формування вхідних даних

Формування вхідного математичного опису для інтелектуальної системи, що здатна навчатися ідентифікувати БПЛА за їх трафіком, виконувалося за даними розміщеними на репозитарії даних для машинного навчання (Machine Learning Repository) Center for Machine Learning and Intelligent Systems, University of California, Irvine (США) (<https://archive.ics.uci.edu/ml/datasets/Unmanned+Aerial+Vehicle+%28UAV%29+Intrusion+Detection>).





UCI Machine Learning Repository: U x +

← → ↻ [https://archive.ics.uci.edu/ml/datasets/Unmanned+Aerial+Vehicle+\(UAV\)+Intrusion+Detection](https://archive.ics.uci.edu/ml/datasets/Unmanned+Aerial+Vehicle+(UAV)+Intrusion+Detection)   


UCI 
Machine Learning Repository
 Center for Machine Learning and Intelligent Systems

About Citation Policy Donate a Data Set Contact

Search 

Repository Web 

[View ALL Data Sets](#)

Check out the beta version of the new UCI Machine Learning Repository we are currently testing! Contact us if you have any issues, questions, or concerns. Click here to try out the new site. 

Unmanned Aerial Vehicle (UAV) Intrusion Detection Data Set

Download: [Data Folder](#), [Data Set Description](#)

Abstract: For UAV identification, each input is an encrypted WiFi traffic record while the output is whether the current traffic is from a UAV or not. Meta-info on attribute relationship is also provided.

Data Set Characteristics:	Multivariate	Number of Instances:	17256	Area:	Computer
Attribute Characteristics:	Real	Number of Attributes:	55	Date Donated	2020-04-12
Associated Tasks:	Classification	Missing Values?	N/A	Number of Web Hits:	19462

Source:
 Liang Zhao, George Mason University (lzhao9@gmu.edu)
 A. Alipour-Farid, M. Dabaghchian, N. Wang, P. Wang, L. Zhao and K. Zeng, 'Machine Learning-Based Delay-Aware UAV Detection and Operation Mode Identification Over Encrypted Wi-Fi Traffic,' in IEEE Transactions on Information Forensics and Security, vol. 15, pp. 2346-2360, 2020.

Data Set Information:
 Beyond traditional classification task, this dataset also contains other meta-information that help enable additional machine learning tasks. For example, this dataset contains the computational generation time for each statistical attributes, which is recorded in the diagonal values of the matrix D. It also contains the computational dependency among different attributes, which is denoted by the incidence matrix H. For example, the computation of standard deviation contains the computation of mean. Detailed information on D and H are as follows:
 D: $k \times k$ - 1. The generation runtime for each feature.
 H: $k \times k$ - k. The incident matrix of the feature computational hypergraph (see the above paper for details). K' is the number of feature computational components and k is the number of features.
 More information is included in the source paper.

Рисунок 3.1 - Репозитарій даних для машинного навчання University of California, Irvine (США)

Навчальна матриця формувалася для трьох типів БПЛА (рис. 3.2) Parrot Bebop, DBPower UDI, DJI Spark.



Рисунок 3.2 – Види БПЛА, які ідентифікуються за трафіком

Словник ознак складається з 54 характеристик мережевого трафіку (табл. 3.1)

Таблиця 3.1 – Характеристики мережевого трафіку

№	Характеристика	№	Характеристика	№	Характеристика
1	uplink_size_mean	19	both_links_size_mean	37	downlink_interval_mean
2	uplink_size_median	20	both_links_size_median	38	downlink_interval_median
3	uplink_size_MAD	21	both_links_size_MAD	39	downlink_interval_MAD
4	uplink_size_STD	22	both_links_size_STD	40	downlink_interval_STD
5	uplink_size_Skewness	23	both_links_size_Skewness	41	downlink_interval_Skewness
6	uplink_size_Kurtosis	24	both_links_size_Kurtosis	42	downlink_interval_Kurtosis
7	uplink_size_MAX	25	both_links_size_MAX	43	downlink_interval_MAX
8	uplink_size_MIN	26	both_links_size_MIN	44	downlink_interval_MIN
9	uplink_size_MeanSquare	27	both_links_size_MeanSquare	45	downlink_interval_MeanSquare
10	downlink_size_mean	28	uplink_interval_mean	46	both_links_interval_mean
11	downlink_size_median	29	uplink_interval_median	47	both_links_interval_median
12	downlink_size_MAD	30	uplink_interval_MAD	48	both_links_interval_MAD
13	downlink_size_STD	31	uplink_interval_STD	49	both_links_interval_STD
14	downlink_size_Skewness	32	uplink_interval_Skewness	50	both_links_interval_Skewness
15	downlink_size_Kurtosis	33	uplink_interval_Kurtosis	51	both_links_interval_Kurtosis
16	downlink_size_MAX	34	uplink_interval_MAX	52	both_links_interval_MAX
17	downlink_size_MIN	35	uplink_interval_MIN	53	both_links_interval_MIN
18	downlink_size_MeanSquare	36	uplink_interval_MeanSquare	54	both_links_interval_MeanSquare

Тут розглядаються характеристики вхідного (uplink) потоку даних, вихідного (downlink) і загального (both_links) потоку даних. При цьому для кожного типу потоку даних є розміри пакетів (size) і час між надходженням пакетів (interval). Для кожного джерела було розраховано 9 статистичних показників (табл. 3.2):

Таблиця 3.2 – Статистичні показники трафіку

Показник	Опис
<i>mean</i>	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x(i)$
<i>median</i>	Медіана
<i>MAD</i>	$MAD = \text{median}(x(i) - \text{median}(x))$
<i>STD</i>	$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x(i) - \bar{x})^2}$
<i>Skewness</i>	$\gamma = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x}/\sigma)^3$
<i>Kurtosis</i>	$\beta = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x}/\sigma)^4$
<i>MAX</i>	$H = \max_i x(i)$
<i>MIN</i>	$H = \min_i x(i)$
<i>MeanSquare</i>	$MS = \frac{1}{N} \sum_{i=1}^N x(i)^2$

Навчальна матриця складалася з 957, 787 та 235 реалізації характеристик для БПЛА типу Parrot Bebop, DBPower UDI та DJI Spark відповідно.

3.2 Короткий опис програми

Програмна реалізація системи виконувалась за допомогою спеціалізованого пакету Neural Network Toolbox середовища для інженерних і наукових розрахунків MATLAB. Цей пакет забезпечує основу для проектування та реалізації нейронних мереж, використовуючи як попередньо навчені моделі, так і програми та інструменти для проектування розробки власних архітектур нейронних мереж.

При цьому розробник може використовувати 19 видів нейронних мереж для розв'язання задач класифікації, кластеризації та прогнозування. Вхідними даними можуть бути зображення, часові ряди та текстові дані. Програми MATLAB Apps та різні графіки допомагають візуалізувати характеристики активації шарів мережі, редагувати архітектуру мережі та відстежувати хід навчання.

Під час навчання на невеликих наборах можна використовувати методику перенесення навчання для вже навчених мереж і не починати навчання мережі з нуля. Наприклад, можна використовувати мережі SqueezeNet, Inception-v3, ResNet-101, GoogLeNet, VGG-19 тощо. або імпортувати мережу з TensorFlow, Keras та Caffe.

Для прискорення навчання на великих наборах даних застосовують розпаралелювані обчислення на багатоядерних процесорах та на графічних процесорах GPU на вашому комп'ютері, використовуючи Parallel Computing Toolbox, або використовувати для навчання кластери та хмари, наприклад, Amazon EC2® P2, P3 та G3 GPU, використовуючи MATLAB Distributed Computing Server.

В табл. 3.3 наведено основні змінні, що використовуються в програмі та їх короткий опис

Таблиця 3.3 – Опис основних змінних

Назва	Опис
M	Кількість класів
N	Кількість характеристик
n	Вектор кількостей реалізацій
tmp	Тимчасова змінна для збереження навчальної матриці одного класу
P	Навчальна матриця, що містить реалізації всіх класів
T	Матриця бажаних вихідних значень
a, b	Вектори максимальних і мінімальних значень характеристик
net	Нейромережа
y	Матриця реальних вихідних значень
tx	Матриця точносних характеристик
e	Вектор значень сумарних квадратичних помилок нейромережі

3.3 Аналіз результатів моделювання

Спочатку виконаємо навчання нейромережі зворотного розповсюдження помилки з використанням таких параметрів:

- кількість прошарків – 3;
- кількість нейронів – 54 (перший (вхідний) прошарок), 10 (другий прошарок), 3 (третій (вихідний) прошарок);
- передатна функція – гіперболічний тангенс;
- кількість епох навчання -100.

На рис. 3.3 наведено графік динаміки зміни значення середньоквадратичної помилки в процесі навчання нейромережі з такими параметрами та передатною функцією нейронів прихованого та вихідного прошарку у вигляді гіперболічного тангенса:

$$f(s) = \text{tansig}(s) = \frac{2}{(1 - e^{-2s})} - 1$$

де s – результат роботи суматора штучного нейрону.

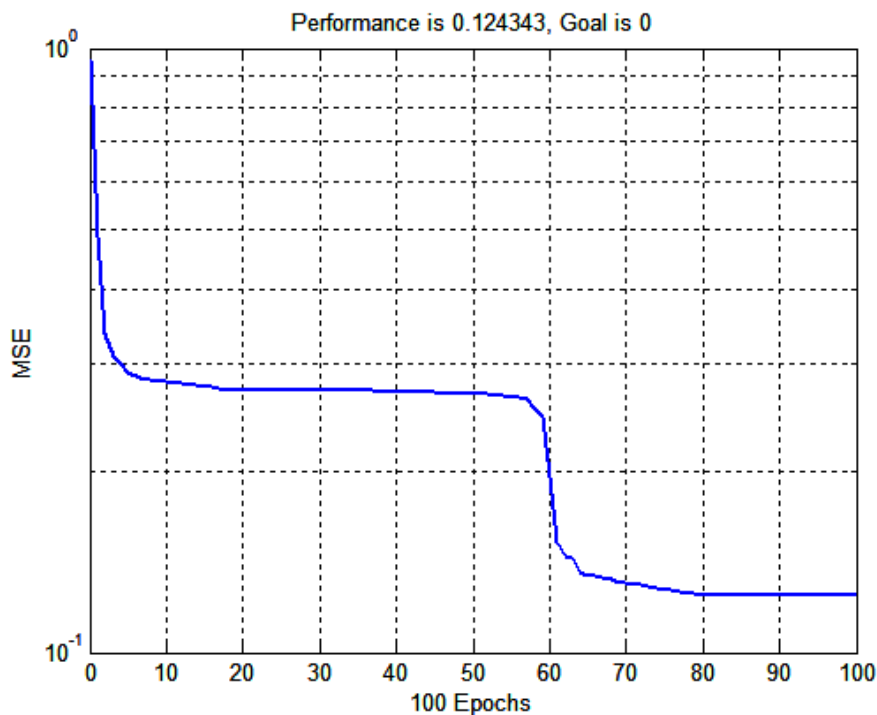


Рисунок 3.3 – Динаміка зміни значення середньоквадратичної помилки при навчанні штучної нейромережі з передатною функцією у вигляді гіперболічного тангенсу

Аналіз рис. 3.3 показує, що значення середньоквадратичної помилки складає $E=0,124343$. При цьому точність розпізнавання реалізацій першого класу $D_1= 67.85 \%$, а для другого класу $D_2= 90.50 \%$, а для другого класу $D_3= 50.40 \%$.

Змінимо передатну функцією нейронів прихованого та вихідного прошарку на логарифмічну

$$f(s) = \text{logsig}(s) = \frac{1}{1 + e^{-s}}$$

де s – результат роботи суматора штучного нейрону.

На рис. 3.4 наведено графік динаміки зміни значення середньоквадратичної помилки в процесі навчання нейромережі за таких параметрів.

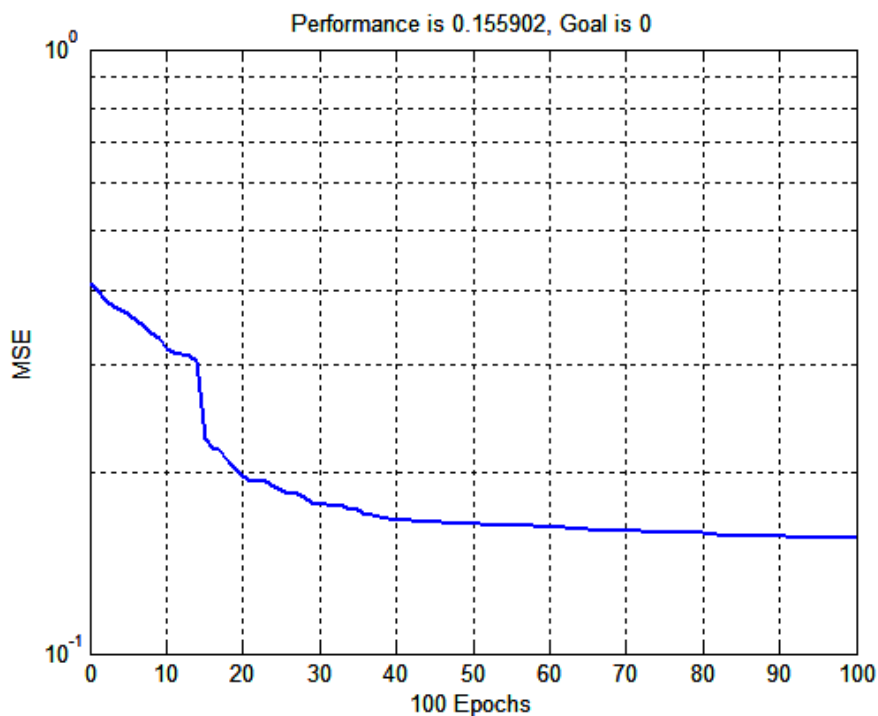


Рисунок 3.4 – Динаміка зміни значення середньоквадратичної помилки при навчанні штучної нейромережі з логарифмічною передатною функцією

Аналіз рис. 3.4 показує, що значення середньоквадратичної помилки складає $E=0,155602$. При цьому точність розпізнавання реалізацій першого

класу $D_1= 63.74 \%$, а для другого класу $D_2= 53.15 \%$, а для другого класу $D_3= 71.20 \%$.

Змінимо передатну функцію нейронів прихованого та вихідного прошарку на лінійну

$$f(s) = \text{purelin}(s) = s$$

де s – результат роботи суматора штучного нейрону.

На рис. 3.5 наведено графік динаміки зміни значення середньоквадратичної помилки в процесі навчання нейромережі за таких параметрів.

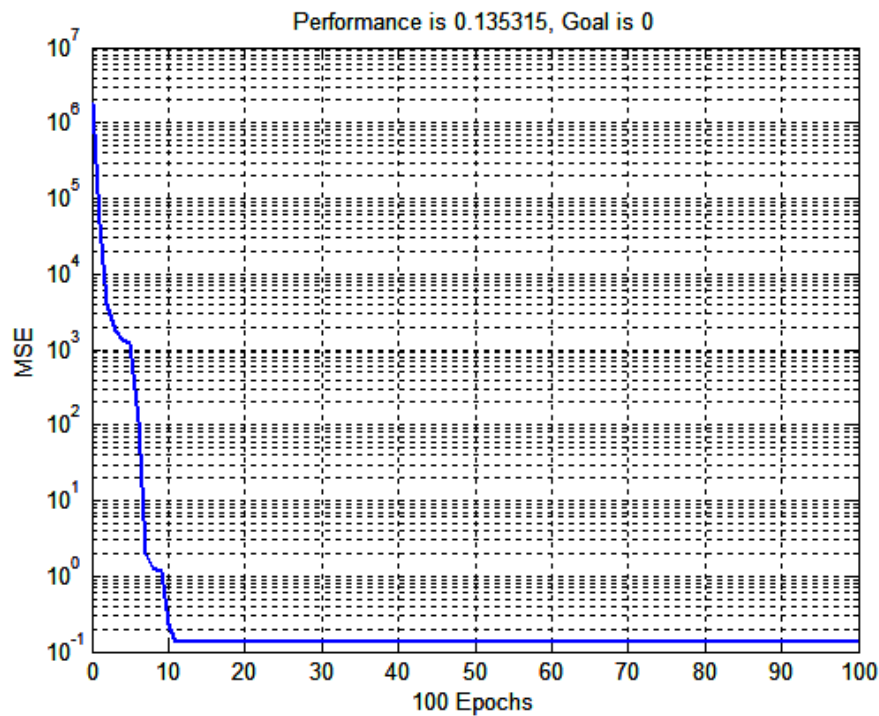


Рисунок 3.5 – Динаміка зміни значення середньоквадратичної помилки при навчанні штучної нейромережі з лінійною передатною функцією

Аналіз рис. 3.5 показує, що значення середньоквадратичної помилки складає $E=0,135315$. При цьому точність розпізнавання реалізацій першого класу $D_1= 76.7 \%$, а для другого класу $D_2= 72.02 \%$, а для другого класу $D_3= 36.00 \%$.

Результати перенавчання наведені в таблиці 3.4

Таблиця 3.4 – Вибір передатної функції нейромережі

Передатна функція	Значення середньоквадратичної помилки	Точнісні характеристики			Кількість епох навчання
		D_1	D_2	D_3	
<i>tansig(s)</i>	0,124343	67.85%	90.50%	50.40%	100
<i>logsig(s)</i>	0,155602	63.74%	53.15%	71.20%	100
<i>purelin(s)</i>	0,135315	76.70%	72.02%	36.00%	100

Аналіз табл. 3.4 показує, що оптимальною в інформаційному розумінні є нейромережа, що використовує передатні функції у вигляді гіперболічного тангенсу для нейронів прихованого та вихідного прошарку.

Збільшимо кількість епох навчання до 200. (Табл. 3.5)

Таблиця 3.5 – Вибір передатної функції нейромережі

Передатна функція	Значення середньоквадратичної помилки	Точнісні характеристики			Кількість епох навчання
		D_1	D_2	D_3	
<i>tansig(s)</i>	0.11469	81.84%	74.25%	49.40%	200
<i>logsig(s)</i>	0.11150	82.98%	77.50%	47.80%	200
<i>purelin(s)</i>	0,135315	76.58%	72.15%	36.60%	200

Аналіз табл. 3.5 показує, що при збільшенні кількості епох навчання оптимальною в інформаційному розумінні є нейромережа, яка використовує передатні логарифмічні функції для нейронів прихованого та вихідного прошарку.

Проведемо дослідження впливу кількості нейронів прихованого прошарку на точність нейромережевого класифікатора. При цьому будемо змінювати кількість нейронів прихованого прошарку з 1 до 30 (табл. 3.6)

Таблиця 3.6 – Вибір кількості нейронів прихованого прошарку

Кількість нейронів прихованого прошарку	Значення середньоквадратичної помилки	Точнісні характеристики		
		D_1	D_2	D_3
1	0,15519	82,07%	72,28%	0,00%
2	0,15154	93,66%	60,80%	0,00%
3	0,15412	67,16%	90,76%	1,20%
4	0,14089	73,39%	86,62%	0,00%
5	0,09611	89,89%	65,65%	53,80%
6	0,11168	75,56%	85,53%	40,20%
7	0,07576	87,72%	89,61%	56,00%
8	0,10797	78,41%	81,01%	49,80%
9	0,09494	81,78%	83,24%	48,20%
10	0,11150	82,98%	77,50%	47,80%
11	0,12589	80,01%	75,59%	45,00%
12	0,11836	78,18%	79,22%	47,60%
13	0,08865	86,35%	80,56%	58,40%
14	0,09070	86,12%	84,51%	49,40%
15	0,09301	86,29%	80,82%	51,80%
16	0,09667	85,72%	81,07%	50,40%
17	0,08061	89,15%	86,04%	53,80%
18	0,07921	89,32%	87,00%	58,20%
19	0,13240	76,30%	78,71%	39,60%
20	0,07892	89,21%	85,66%	61,40%
21	0,08384	88,35%	84,89%	58,00%
22	0,07420	89,55%	87,19%	59,20%
23	0,07587	88,58%	88,46%	59,20%
24	0,08186	88,92%	85,98%	55,80%
25	0,20822	85,09%	21,03%	0,00%
26	0,07489	89,32%	87,76%	56,40%
27	0,07305	89,83%	89,42%	58,20%
28	0,13623	82,12%	75,27%	38,80%
29	0,07112	90,52%	89,17%	60,40%
30	0,13398	88,64%	63,54%	42,80%

Аналіз табл. 3.6 показує, що при 29 нейронах прихованого прошарку середньоквадратична помилка набуває свого мінімального значення 0,07112. При цьому точність розпізнавання реалізацій першого класу $D_1=90,52\%$, а для другого класу $D_2=89,17\%$, а для другого класу $D_3=60,40\%$.

Таким чином, запропоновані процедури оптимізації функціональних параметрів нейромережі зворотного розповсюдження помилки дозволяють не тільки відтворити високоточний класифікатор різних видів безпілотних літальних апаратів шляхом аналізу їх вхідного і вихідного трафіку.

ВИСНОВКИ

В ході виконання кваліфікаційної роботи було розроблено і програмно реалізовано систему, що здатна навчатися розпізнаванню виду БПЛА за результатами аналізу трафіка, який передається ним на наземну станцію керування. При цьому було використано нейромережвий підхід до формування класифікатору в рамках якого виконано такі завдання:

1. Сформовано вхідний математичний опис інтелектуальної системи ідентифікації виду БПЛА за результатами аналізу його трафіку.
2. Обрано тип та структуру класифікатору мережевого трафіку, що використовується інтелектуальною системою.
3. Реалізація ряд алгоритмів оптимізації функціональних параметрів інтелектуальної системи
4. Проведено перевірку працездатності розробленої інтелектуальної системи на задачі ідентифікації 3-х видів БПЛА.

СПИСОК ЛІТЕРАТУРИ

1. Карташов В.М., Ситнік О.В. Радіотехнічні системи : навч. посібник. Харків : Сміт, 2009. – 448 с.
2. De Wit J.M., Harmanny R., Premel-Cabic G. Micro-Doppler analysis of small UAVs // Proceedings of the 2012 9th European Radar Conference; Amsterdam, The Netherlands. 31 October–2 November 2012. P. 210–213.
3. Harmanny R., De Wit J., Cabic G.P. Radar micro-Doppler feature extraction using the spectrogram and the cepstrogram // Proceedings of the 2014 11th European Radar Conference; Cincinnati, OH, USA. 11–13 October 2014. –P. 165–168.
4. Molchanov P., Harmanny R.I., de Wit J.J., Egiazarian K., Astola J. Classification of small UAVs and birds by micro-Doppler signatures // J. Microw. Wirel. Technol. 2014. 6:435–444.
5. De Wit J., Harmanny R., Molchanov P. Radar micro-Doppler feature extraction using the singular value decomposition // Proceedings of the 2014 International Radar Conference. Lille, France. 13–17 October 2014. P. 1–6.
6. Ren J., Jiang X. Regularized 2D complex-log spectral analysis and subspace reliability analysis of microdoppler signature for UAV detection // Pattern Recognit. 2017. 69:225–237.
7. Oh B.S., Guo X., Wan F., Toh K.A., Lin Z. Micro-Doppler mini-UAV classification using empirical-mode decomposition features // IEEE Geosci. Remote Sens. Lett. 2017. 15:227–231.
8. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Boston, MA, USA. 7–12 June 2015. P. 1–9.
9. Mendis G.J., Randeny T., Wei J., Madanayake A. Deep learning based doppler radar for micro UAS detection and classification // Proceedings of the MILCOM 2016-2016 IEEE Military Communications Conference.

10. Massey K., Gaeta R. Noise Measurements of Tactical UAVs. // Georgia Inst. of Technology / GTRI / ATAS, Atlanta. 16th AIAA / CEAS Aeroacoustics Conference. American Institute of Aeronautics and Astronautics, 2010. P. 1–16.
11. Freund Y., Schapire R.E. Large margin classification using the perceptron algorithm. *Mach. Learn.* 1999. 37:277–296.
12. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv.20141409.1556*.
13. Zeiler M.D., Fergus R. Visualizing and understanding convolutional networks // *Proceedings of the European Conference on Computer Vision; Zurich, Switzerland. 6–12 September 2014. P. 818–833*
14. Schumann A., Sommer L., Klatte J., Schuchert T., Beyerer J. Deep cross-domain flying object classification for robust UAV detection // *Proceedings of the 2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS). Lecce, Italy. 29 August–1 September 2017. P. 1–6.*
15. Craye C., Ardjoune S. Spatio-temporal Semantic Segmentation for Drone Detection // *Proceedings of the 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS); Taiwan, China. 18–21 September 2019.*
16. Vasileios Magoulianitis D.A., Anastasios Dimou D.Z., Daras P. Does Deep Super-Resolution Enhance UAV Detection // *Proceedings of the 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS); Taiwan, China. 18–21 September 2019.*
17. Opromolla R., Fasano G., Accardo D. A Vision-Based Approach to UAV Detection and Tracking in Cooperative Applications. *Sensors.* 2018. 8:3391.
18. Gökçe F., Üçoluk G., Şahin E., Kalkan S. Vision-based detection and distance estimation of microunarmed aerial vehicles. *Sensors.* 2015. 15:23805–23846.

19. Ivanov M., Sergiyenko O., Mercorelli P., Tyrsa V., Kartashov V., Hernandez W., Sheiko S., Kolendovska M. Individual scans fusion in virtual knowledge base for navigation of mobile robotic group with 3D TVS // Proceedings of 44th Annual Conference of IEEE Industrial Electronics Society (IECON), Washington DC, USA. 2018. P. 3187-3192.
20. Ivanov M., Sergiyenko O., Mercorelli P., Hernandez W., Rodriguez Quinonez J.C., Kartashov V., Kolendovska M., Iryna T. Effective informational entropy reduction in multi-robot systems based on real-time TVS // IEEE International Symposium on Industrial Electronics, June, 8781209, 2019. P. 1162–1167
21. Kartashov V., Oleynikov V., Zubkov O., Sheiko S. Optical detection of unmanned air vehicles on a video stream in a real-time // The Fourth International Conference on Information and Telecommunication Technologies and Radio Electronics (UkrMiCo'2019), 9–13 September 2019, Odessa, Ukraine, 4 p.
22. Aker C., Kalkan S. Using deep networks for drone detection // Proceedings of the 2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS); Lecce, Italy. 29 August–1 September 2017. P. 1–6.
23. Карташов В.М., Олейников В.Н., Колендовская М.М., Тимошенко Л.П., Капуста А.И., Рыбников Н.В. Комплексование изображений при обнаружении беспилотных летательных аппаратов // Радиотехника. 2020. Вып. 201. С. 120–129
24. Müller T. Robust drone detection for day/night counter-UAV with static VIS and SWIR cameras // Proceedings of the Ground/Air Multisensor Interoperability, Integration, and Networking for Persistent ISR VIII, International Society for Optics and Photonics; Anaheim, CA, USA. 4 May 2017. P. 1019018.
25. Birch G.C., Woo B.L. Counter unmanned aerial systems testing: Evaluation of VIS SWIR MWIR and LWIR passive imagers. Sandia Rep. 2017.

26. Thomas A., Cotinat A., Gilber M. UAV localization using panoramic thermal cameras // Proceedings of the 12th International Conference on Computer Vision Systems (ICVS); Thessaloniki, Greece. 23–25 September 2019.
27. Samaras S., Diamantidou E., Ataloglou D., Sakellariou N., Vafeiadis A., Magoulianitis V., Lalas A., Dimou A., Zarpalas D., Votis K., Daras P., Tzovaras D. Deep Learning on Multi Sensor Data for Counter UAV Applications // A Systematic Review. Sensors (Basel). 2019 Nov 6. 19(22): 4837. Published online 2019, Nov 6.
28. Massey K., Gaeta R. Noise Measurements of Tactical UAVs. // Georgia Inst. of Technology / GTRI / ATAS, Atlanta. 16th AIAA / CEAS Aeroacoustics Conference. American Institute of Aeronautics and Astronautics, 2010. P. 1–16.
29. Marino L. Experimental analysis of UAV-propellers noise // 16th AIAA/CEAS Aeroacoustics Conference. University La Sapienza, Rome, Italy, American Institute of Aeronautics and Astronautics, 2010. P. 1–14.
30. Zaslavsky Yu. M., Zaslavsky V. Yu. Acoustic noise of a low flying quadcopter // NOUSE Theory and Practice. V.5, No3, 2019. P. 21–27.
31. Kartashov V.M., Tikhonov V.A., Voronin V.V. and Tymoshenko L.P. Complex model of random signal in problems of acoustic sounding of atmosphere // Telecommunications and Radio Engineering. 2016. V. 75. Iss. 20. P.1885–1892.
32. Oleynikov V. N., Zubkov O. V., Kartashov V. M., Korytsev I. V., Babkin S. I., Sheiko S. A. Investigation of detection and recognition efficiency of small unmanned aerial vehicles on their acoustic emission // Telecommunications and Radio Engineering, 2019. V. 78, Issue 9. P. 759–770.
33. Kartashov V., Oleynikov V., Koryttsev I., Zubkov O., Babkin S., Sheiko S. Processing and Recognition of Small Unmanned Vehicles Sound Signals // International Scientific-Practical Conference on Problems of Infocommunications Science and Technology, PIC S and T 2018 Proceedings 31 January 2019. P. 392–396.

34. Chowdhury A.S.K. Master's Thesis. University of Nevada. Las Vegas, NV, USA: 2016. Implementation and Performance Evaluation of Acoustic Denoising Algorithms for UAV.
35. Mezei J., Molnár A. Drone sound detection by correlation // Proceedings of the 2016 IEEE 11th International Symposium on Applied Computational Intelligence and Informatics (SACI); Timisoara, Romania. 12–14 May 2016. P. 509–518.
36. Liu H., Wei Z., Chen Y., Pan J., Lin L., Ren Y. Drone detection based on an audio-assisted camera array // Proceedings of the 2017 IEEE Third International Conference on Multimedia Big Data (BigMM); Laguna Hills, CA, USA. 19–21 April 2017. P. 402–406.
37. Kim J., Park C., Ahn J., Ko Y., Park J., Gallagher J.C. Real-time UAV sound detection and analysis system // Proceedings of the 2017 IEEE Sensors Applications Symposium (SAS); Glassboro, NJ, USA. 13–15 March 2017. P. 1–5.
38. Kim J., Kim D. Neural Network based Real-time UAV Detection and Analysis by Sound // J. Adv. Inf. Technol. Converg. 2018. 8:43–52.
39. Oleynikov V.N., Kartashov, V.M., Babkin, S. I., Zubkov, O.V., Korytsev I.V., Sheiko, S.A., Seleznev I.S. Structure and Parameter Unmanned Aerial Vehicles Sound Fields // Telecommunications and Radio Engineering. New York. 2020. Vol. 79, No17. P.1539-1550.
40. A. Bernardini, F. Mangiatordi, E. Pallotti, L. Capodiferro, F. Ugo Bordon. Drone detection by acoustic signature identification // Electronic Imaging, Imaging and Multimedia Analytics in a Web and Mobile World. 2017. P. 60–64.
41. Semenets V. V., Kartashov V.M., Leonidov V. I. Registration of refraction Phenomenon in the Problem of acoustic Sounding of Atmosphere in Airport Zone // Telecommunications and Radio Engineering. 2018. Vol. 77, Iss. 5. P.461–468.

ДОДАТОК

```

p1=data_tr1(:,1:54)';
p1=[p1 data_tr2(:,1:54)'];
p1=[p1 data_tr3(:,1:54)'];
n1=[ size(data_tr1,1) size(data_tr2,1) size(data_tr3,1)];
for i=1:n1(1)
T1(:,i)=[1 0 0]';
end;
for i=1+n1(1):n1(1)+n1(2)
T1(:,i)=[0 1 0]';
end;
for i=1+n1(1)+n1(2):n1(1)+n1(2)+n1(3)
T1(:,i)=[0 0 1]';
end;

net=newff(minmax(p1), [10,3], {'purelin' 'purelin'});
net.trainParam.show=1;
net.trainParam.epochs=200;
net=train(net,p1,T1);
y=sim(net,p1);
for i=1:sum(n1)
ymax=max(y(:,i));
tmp=find(y(:,i)==ymax);
Y(i)=tmp(1);
end;
[mean(Y(1:n1(1)))==1)
mean(Y(1+n1(1):n1(1)+n1(2)))==2)
mean(Y(1+n1(1)+n1(2):n1(1)+n1(2)+n1(3)))==3]

```

```

p1=data_tr1(:,1:54)';
p1=[p1 data_tr2(:,1:54)'];
p1=[p1 data_tr3(:,1:54)'];
n1=[1751 1569 500];
for i=1:n1(1)
T1(:,i)=[1 0 0]';
end;
for i=1+n1(1):n1(1)+n1(2)
T1(:,i)=[0 1 0]';
end;
for i=1+n1(1)+n1(2):n1(1)+n1(2)+n1(3)
T1(:,i)=[0 0 1]';
end;
for h=1:30
net=newff(minmax(p1), [h,3], {'logsig' 'logsig'});
net.trainParam.show=1;
net.trainParam.epochs=100;
net=train(net,p1,T1);
y=sim(net,p1);
for i=1:sum(n1)
ymax=max(y(:,i));
tmp=find(y(:,i)==ymax);
Y(i)=tmp(1);
end;
E(h)=mse(y,T1);
TX(h,:)=[mean(Y(1:n1(1)))==1)
mean(Y(1+n1(1):n1(1)+n1(2))==2)
mean(Y(1+n1(1)+n1(2):n1(1)+n1(2)+n1(3))==3)];
end;

```