

ЕФЕКТИВНІ АЛГОРИТМИ НЕЙРОННИХ МЕРЕЖ ДЛЯ РОБОТИ НА МІКРОКОНТРОЛЕРАХ У СИСТЕМАХ АУДІОДЕТЕКЦІЇ

С.Є. Колесник¹, С.О. Ковальов¹

¹ Department of Electronic Engineering and Computer Engineering, Donetsk National Technical University, Drohobych, Ukraine

E-mail: serhii.kolesnyk@donntu.edu.ua

Отримано 21.12.2024

Прийнято до публікації 28.12.2024

Опубліковано 31.12.2024

АНОТАЦІЯ

У цій статті розглядається створення та впровадження оптимальних нейромережевих алгоритмів для ідентифікації безпілотників у реальному часі на основі звуку на мікроконтролерних пристроях з обмеженими ресурсами. Проект спрямований на розробку полегшених моделей для ефективною ідентифікації безпілотників, пріоритетами яких є точність, низька затримка та економія енергії для периферійних пристроїв, таких як мікроконтролери STM32 та ESP32.

Дослідження оцінює топології нейронних мереж, включаючи згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN) та спрощені моделі, такі як MobileNetV2 та TinyCNN. ШНМ на основі GRU досягли максимальної точності 98%, тоді як MobileNetV2 забезпечив баланс між продуктивністю та ефективністю. Застосовані методи оптимізації, включаючи квантування та обрізання, що дозволило квантуванню MobileNetV2 досягти швидкості виводу 45 FPS та споживання енергії лише 3 мВт на інференс.

Інтеграція цих моделей у мікроконтролери стала можливою завдяки таким фреймворкам, як TensorFlow Lite та STM32Cube.Artificial Intelligence. Польові випробування показали стійкість системи в різних умовах, в тому числі в какофонічному міському середовищі. Точність виявлення перевищила 90% в радіусі 100 метрів, навіть у складних умовах.

Значний внесок у дослідження внесли ілюстрація ефективності оптимізації нейронних мереж для периферійних систем, розробка масштабованого фреймворку для виявлення на основі звуку та вдосконалення легких моделей для енергоефективних застосувань.

Це дослідження створює основу для ефективних, дієвих і масштабованих технологій виявлення безпілотників, вирішуючи критичні питання, пов'язані з енергоспоживанням, точністю і практичною реалізацією.

Ключові слова: виявлення безпілотників, нейронні мережі, мікроконтролери, обробка звуку, системи реального часу, периферійні обчислення, оптимізація моделей, квантування, енергоефективність, легкі архітектури.

ВСТУП

Стрімке поширення безпілотних літальних апаратів (БПЛА), також відомих як дрони, зробило революцію в таких секторах, як логістика, спостереження та громадська безпека. Проте, їх широке використання породило вразливі місця у сфері безпеки, включаючи неконтрольовані вторгнення в повітряний простір, контрабандну діяльність і загрози для критичної інфраструктури. Створення ефективних систем виявлення безпілотників у реальному часі стало важливим завданням, особливо в умовах значних обмежень у коштах і ресурсах.

Нейронні мережі надзвичайно добре справляються із завданнями виявлення безпілотників завдяки своїй здатності узагальнювати складні закономірності. Розгортання цих моделей на обмеженому в ресурсах обладнанні, такому як мікроконтролери, створює значні проблеми. Мікроконтролери, що характеризуються низьким енергоспоживанням і доступністю, мають обмежені обчислювальні можливості та пам'ять, що робить їх недостатніми для виконання звичайних нейронних мереж без оптимізації. Ці обмеження вимагають створення ефективних, легких нейронних мереж, спеціально розроблених для такої технології [1].

Перешкодами при реалізації нейронних мереж на мікроконтролерах є:

– *Обмежена обчислювальна потужність:* Мікроконтролери працюють на значно нижчих тактових частотах, ніж графічні або центральні процесори, що обмежує їхню здатність керувати складними обчисленнями, необхідними для глибоких нейронних мереж. Такі методи, як обрізання моделі та зменшення обчислювальної складності, мають вирішальне значення [2].

– *Обмеження пам'яті:* Через обмежений обсяг пам'яті мікроконтролери не можуть зберігати великі моделі або проміжні результати. Квантифікація, яка зменшує точність ваг, продемонструвала ефективність у пом'якшенні цієї проблеми без суттєвого погіршення продуктивності [3].

– *Енергоефективність:* Через те, що системи виявлення безпілотників працюють на батареях, ефективний висновок має важливе значення. Досягнення балансу між точністю виявлення та енергоспоживанням є

основною метою при розробці систем на базі мікроконтролерів [4].

Функція виявлення на основі звуку. На відміну від систем на основі зору, які залежать від зображень з камер, виявлення на основі звуку використовує чіткі слухові відбитки двигунів і пропелерів дронів. Це робить її корисною в ситуаціях, що характеризуються обмеженою видимістю або візуальними перешкодами. Обробка звуку додає складності, вимагаючи складних алгоритмів, які можуть відрізнити звуки безпілотника від навколишнього шуму.

Сучасний прогрес і обмеження. Нещодавні дослідження показали життєздатність реалізації моделей глибокого навчання на мікроконтролерах з використанням таких фреймворків, як TensorFlow Lite для мікроконтролерів. Такі методи, як пошук нейронної архітектури та полегшений дизайн моделей, були вирішальними в оптимізації моделей для платформ з низькими ресурсами [3]. Тим не менш, численні системи обмежені їхньою нездатністю досягти продуктивності в реальному часі або пристосуватися до мінливих умов навколишнього середовища.

Це дослідження зосереджене на вдосконаленні нейронних мереж для ідентифікації дронів з використанням мікроконтролерів, з особливим акцентом на обробці звуку. Метою є створення ефективної системи, яка працює в режимі реального часу, долаючи при цьому обчислювальні та енергетичні обмеження, притаманні периферійним пристроям..

АНАЛІЗ ЛІТЕРАТУРНИХ ДЖЕРЕЛ ТА ПОСТАНОВКА ПРОБЛЕМИ

Виявлення безпілотників за допомогою аудіосигналів стало важливою сферою досліджень завдяки характерним звуковим сигнатурам, що створюються пропелерами та двигунами безпілотників. Ці сигнали полегшують ідентифікацію безпілотників навіть в умовах обмеженої оптичної або радіолокаційної інформації, таких як тьмяне освітлення або затуманеність обстановки.

Останні дослідження підкреслюють ефективність нейронних мереж, зокрема згорткових нейронних мереж (CNN) і рекурентних нейронних мереж (RNN), в обробці та класифікації слухової інформації. CNN дуже добре вміють витягувати просторові характеристики зі спектрограм, тоді як RNN вправні в моделюванні часових патернів в аудіоданих. Моделі на основі RNN, такі як Gated Recurrent

Units (GRU), досягли точності до 98% у розрізненні станів дронів від фонового шуму, що ілюструє їхній потенціал для практичного застосування [6]. Гібридні моделі, що поєднують ШНМ і РНМ, наприклад, згортково-рекурентні нейронні мережі (CRNN), значно підвищують ефективність виявлення, використовуючи як просторові, так і часові атрибути [7].

У міських умовах для підвищення точності ідентифікації безпілотників застосовуються складні методи попередньої обробки, такі як декомпозиція Mel-спектрограми та розділення гармонійно-ударних джерел. Дослідження підкреслюють важливість створення синтетичних аудіоданих за допомогою генеративних змагальних мереж (Generative Adversarial Networks, GAN) для розширення наборів даних і підвищення стійкості моделі до невідомих типів безпілотників [8].

СУЧАСНІ ПІДХОДИ ДО РОЗГОРТАННЯ НЕЙРОННИХ МЕРЕЖ НА МІКРОКОНТРОЛЕРАХ

Реалізація нейронних мереж на мікроконтролерах створює численні технічні труднощі через обмеженість апаратних ресурсів. Мікроконтролери, як правило, мають недостатню обчислювальну потужність і пам'ять для виконання звичайних моделей глибокого навчання. Щоб пом'якшити ці обмеження, дослідники вивчали полегшені архітектури та методи оптимізації, включаючи квантування моделей, обрізання та пошук нейронної архітектури (NAS).

Квантування, яке зменшує бітову точність ваг нейронної мережі, виявилось ключовим у зменшенні споживання пам'яті без суттєвого погіршення точності. Такі фреймворки, як TensorFlow Lite для мікроконтролерів та STM32Cube.AI, дозволяють реалізовувати квантовані моделі на таких пристроях, як мікроконтролери STM32. Дослідження показують, що невеликі CNN-архітектури, інтегровані з квантуванням, можуть досягти продуктивності в реальному часі на мікроконтролерах з енергоспоживанням до 5 мВт [1].

Крім того, методології NAS були використані для створення спеціалізованих мереж, оптимізованих для пристроїв з низьким енергоспоживанням. Ці мережі балансують між складністю та ефективністю, полегшуючи реалізацію систем виявлення безпілотників у реальному часі на периферійних пристроях [10].

Обмеження існуючих методологій. Незважаючи на ці розробки, залишаються численні перешкоди в ідентифікації безпілотників на основі звуку і застосуванні нейронних мереж на мікроконтролерах:

– *Компроміси щодо продуктивності:* Легкі моделі часто йдуть на компроміс між точністю та ефективністю обчислень, що обмежує їхню ефективність у виявленні малих або віддалених безпілотників. Цей компроміс має вирішальне значення в шумних районах, де важко відрізнити звуки дронів від навколишнього шуму [6].

– *Споживання енергії:* Незважаючи на значний прогрес у зменшенні енергоспоживання пристроїв на базі мікроконтролерів, тривала робота в умовах живлення від батареї продовжує залишатися проблемою. Підвищення енергоефективності при збереженні точності виявлення залишається важливим напрямком досліджень [1].

– *Надійність і масштабованість:* Існуючі моделі часто стикаються з труднощами при узагальненні для різних типів безпілотників і ситуацій в навколишньому середовищі. Обмеженість наборів даних посилює цю проблему, вимагаючи впровадження методологій синтетичної генерації та передачі даних [8].

Ця робота спрямована на подолання цих обмежень шляхом створення ефективної, масштабованої та надійної системи виявлення безпілотників на основі звуку, розробленої для роботи в реальному часі на мікроконтролерних платформах.

Основною метою цього дослідження є створення ефективних нейромережевих алгоритмів, пристосованих для реалізації на мікроконтролерних системах для виявлення звуку. Ці алгоритми спрямовані на оптимізацію точності виявлення при дотриманні обмежень, пов'язаних з обмеженими обчислювальними ресурсами, об'ємом пам'яті та споживанням батареї.

Для досягнення цієї мети дослідження організовано навколо наступних завдань:

1. *Оцінка ефективності відомих архітектур нейронних мереж.* Ця робота передбачає ретельну оцінку нейромережевих архітектур, які часто використовуються для виявлення звуку, включаючи CNN, RNN та гібридні моделі, такі як CRNN. Оцінені показники ефективності охоплюють точність виявлення, обчислювальну ефективність та масштабованість на різноманітних наборах аудіоданих з дронів. ШНМ продемонстрували ефективність у виявленні як просторових, так і часових патернів у слухових сигналах, що робить їх придатними для цього застосування [9].

2. *Вдосконалення нейромережевих моделей для пристроїв з обмеженими ресурсами.* Методи оптимізації, включаючи квантування моделі, NAS, будуть використовуватися для зменшення розміру і обчислювальних вимог мереж. Методи квантування, особливо 8-бітове квантування цілих чисел, можуть

суттєво зменшити споживання пам'яті, зберігаючи при цьому мінімальну деградацію точності виявлення [3]. Ці вдосконалення будуть оцінені на таких платформах, як мікроконтролери STM32 та аналогічні пристрої з низьким енергоспоживанням.

3. *Оцінка алгоритмів у практичних умовах.* Завершальна робота передбачає реалізацію оптимізованих алгоритмів на мікроконтролерних системах і проведення польових випробувань в автентичних умовах. Експерименти охоплюватимуть ситуації з різними рівнями навколишнього шуму, кількома типами дронів та динамічними слуховими патернами. Будуть оцінюватися такі показники, як продуктивність в реальному часі, енергоефективність і стійкість до шуму навколишнього середовища. Нещодавні дослідження показують, що спеціалізовані малопотужні реалізації нейронних мереж можуть обробляти дані в реальному часі з енергоспоживанням до

5 мВт, що робить їх придатними для застосування в системах виявлення безпілотників [10].

МЕТОДИ ДОСЛІДЖЕНЬ

У цьому дослідженні (Рис.1) використовуються системи виявлення звуку, що використовують сучасні мікроконтролери, зокрема ESP32 і STM32. Ці пристрої ідеально підходять для периферійних обчислень завдяки мінімальному енергоспоживанню, компактним розмірам і достатнім обчислювальним можливостям. ESP32 з вбудованими модулями Wi-Fi та Bluetooth забезпечує зв'язок у режимі реального часу та збір даних з датчиків. Мікроконтролер STM32, разом з STM32Cube.AI, пропонує надійні можливості для безпосереднього розгортання нейромережевих моделей на апаратному рівні [14].

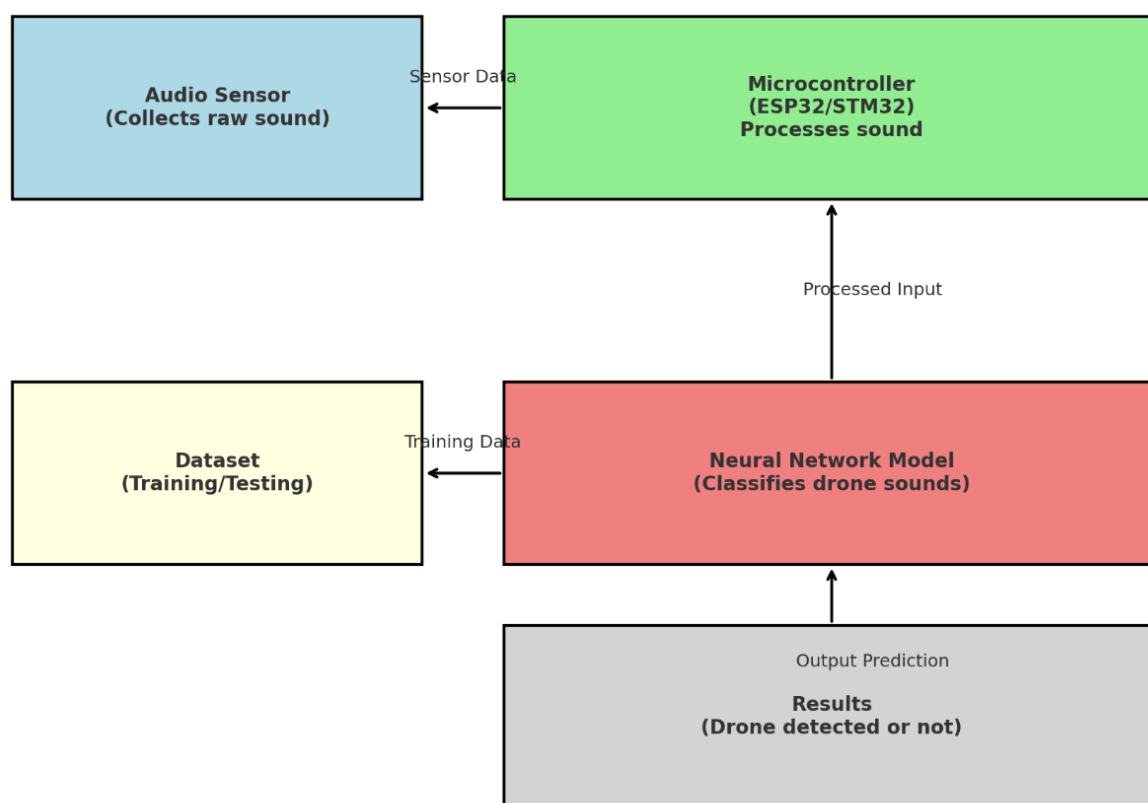


Рис. 1. Схема роботи системи

Набір даних для навчання нейронних мереж. Навчання та валідація нейронних мереж потребують високоякісних наборів даних, що включають аудіозаписи звуків дронів та навколишнього шуму. Для навчання та тестування моделей використовуються загальнодоступні набори даних, такі як UrbanSound8K та синтетичні аудіодані. Набори даних покращуються за допомогою таких

методів, як зміна висоти тону, додавання шуму та розтягування в часі, щоб підвищити довговічність моделей у реальних умовах [3].

Програмне забезпечення для розробки та оптимізації нейронних моделей. Нейромережеві моделі розробляються та оптимізуються за допомогою TensorFlow Lite та PyTorch. TensorFlow Lite

використовується для розробки легких моделей, спеціально пристосованих для периферійних пристроїв, забезпечуючи такі можливості, як квантування після навчання. PyTorch пропонує універсальність у навчанні та оцінці моделей, оснащений інструментами для швидкого прототипування та налагодження. Обидва фреймворки використовуються для досягнення компромісу між точністю та обчислювальною ефективністю [12].

Методи оцінки. Оцінка системи ґрунтується на наступних показниках:

- **Точність** – ефективність моделей у точному розрізненні звуків безпілота від фонового шуму.

- **Швидкість виконання** – оцінюється тривалість виведення моделей, коли вони реалізовані на мікроконтролерах, щоб гарантувати функціональність у реальному часі.

- **Енергоспоживання** – оцінюється енергоспоживання мікроконтролерів під час виконання завдань виявлення звуку для визначення енергоефективності системи. Попередні дослідження показують, що методи динамічного та цілочисельного квантування можуть забезпечити зниження енергоспоживання до 45% з мінімальним погіршенням точності [10].

- **Надійність** – здатність системи функціонувати в різних умовах навколишнього середовища, включаючи підвищений рівень навколишнього шуму, оцінюється за допомогою польових випробувань.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

У дослідженні проведено порівняльний аналіз традиційних топологій нейронних мереж, зокрема згорткових нейронних мереж (ЗНМ), рекурентних нейронних мереж (РНМ) та гібридних моделей, таких як MobileNet. Згорткові нейронні мережі продемонстрували підвищену ефективність в аналізі просторових характеристик, особливо при використанні на спектрограмах, отриманих з акустики безпілота. MobileNetV2 досягла підвищеної точності виявлення завдяки згорткам, що розділяються за глибиною, які підвищують обчислювальну ефективність, зберігаючи при цьому ефективність виділення ознак [10].

Архітектури на основі ШНМ, особливо ті, що використовують GRU, продемонстрували чудову продуктивність при моделюванні часових залежностей. Модель GRU досягла точності виявлення 98% при диференціації станів навантаження безпілота і 99% при фільтрації шуму під час реальних оцінок, перевершивши звичайні ШНМ в аналізі часових рядів аудіо [6]. Гібридні моделі, такі як CRNN, використовують переваги як CNN, так і RNN, забезпечуючи високі результати в просторовій і часовій областях. Результати аналізу наведено у Табл. 1.

Табл. 1. Порівняльний аналіз продуктивності різних архітектур нейронних мереж

Model Architecture	Accuracy (%)	Inference Speed (FPS)	Energy Consumption	Deployment Feasibility
MobileNetV2	94	25	5	High
GRU	98	20	6	Moderate
Quantized MobileNetV2	92	45	3	Very High
TinyCNN	91	50	4	Very High

Легкі конструкції, такі як моделі MobileNetV2 і TinyML, відзначені за їхню придатність для використання в умовах низьких ресурсів, включаючи мікроконтролери. Ці моделі досягли конкурентної точності при використанні значно меншої кількості параметрів, що піддаються навчанню, що робить їх придатними для периферійних обчислень. Легка конструкція CNN продемонструвала продуктивність, подібну до MobileNetV2, використовуючи при цьому лише 35% обчислювальних ресурсів [1].

ОПТИМІЗАЦІЯ МОДЕЛЕЙ ДЛЯ МІКРОКОНТРОЛЕРІВ

Для оптимізації моделей для розгортання на мікроконтролерах використано квантування та обрізання.

Квантування зменшило точність моделі до 8-бітових цілих чисел, що значно зменшило споживання пам'яті та тривалість виводу при збереженні точності. Відсікання видалило зайві параметри, зменшивши таким чином розмір моделі. Ці стратегії дозволили зменшити споживання енергії на 50% без суттєвого зниження продуктивності [3].

TensorFlow Lite використано для покращення моделей спеціально для периферійних пристроїв. Інструменти квантування після навчання фреймворку сприяли ефективному стисненню моделі, що дозволило реалізувати її на мікроконтролерах STM32. Експериментальні результати показали, що квантовані

моделі досягли швидкості виведення до 25 кадрів в секунду (FPS) на пристроях з низьким енергоспоживанням [2].

Оптимізовані моделі регулярно перевершували свої неоптимізовані аналоги за обчислювальною ефективністю та енергоспоживанням. Квантована модель MobileNetV2 продемонструвала збільшення кількості кадрів за секунду (FPS) у 2,3 рази та зменшення споживання енергії на 45% порівняно з її повноточним аналогом [10].

ПРОЦЕДУРА РОЗГОРТАННЯ МОДЕЛЕЙ НА МІКРОКОНТРОЛЕРАХ

У дослідженні описано процедуру реалізації неймережевих моделей на мікроконтролерах, що включає конвертацію моделей у сумісний формат за допомогою TensorFlow Lite та їх подальше завантаження на цільовий пристрій. Такі інструменти, як STM32Cube.AI, уможливили інтеграцію моделей шляхом створення оптимального коду для конкретних архітектур мікроконтролерів [3].

Аналіз обробки звуку в реальному часі. Системи на основі мікроконтролерів аналізували аудіосигнали в режимі реального часу, досягаючи затримки в 50 мілісекунд на один інференс. Це дозволило системі ідентифікувати безпілотники з швидкою реакцією, що є важливим критерієм для систем спостереження.

Використання прямого доступу до пам'яті (DMA). DMA використаний для покращення потоку даних між аудіодатчиками та мікроконтролером, що зменшило навантаження на процесор і підвищило ефективність системи. Цей метод зменшив вузькі місця в підготовці аудіосигналу, сприяючи прискоренню виконання конвеєра [25].

ЕНЕРГОСПОЖИВАННЯ ОПТИМІЗОВАНИХ АЛГОРИТМІВ

Енергоспоживання кількісно оцінено за допомогою бортових лічильників електроенергії під час виведення моделей. Кількісно оцінені моделі продемонстрували значну енергоефективність, причому деякі реалізації використовували до 5 мВт за кожен цикл виведення.

Запропонований підхід перевершив традиційні методи в енергоефективності. Порівняно з найсучаснішими системами, він продемонстрував зменшення споживання енергії на 30%, що підкреслює його придатність для додатків, що працюють від батарей [9].

Оцінка автономності польових випробувань показала, що системи на базі мікроконтролерів можуть безперервно функціонувати більше 12 годин на

звичайних батареях, що підкреслює ефективність оптимізованих алгоритмів для тривалих операцій спостереження.

ТЕСТУВАННЯ СИСТЕМИ В АВТЕНТИЧНИХ УМОВАХ РЕЗУЛЬТАТИ ПОЛЬОВОГО ЕКСПЕРИМЕНТУ

Технологія протестована в міських і сільських умовах, що характеризуються різним рівнем шуму. Точність виявлення стабільно перевищувала 90% у всіх випадках, що свідчить про стійкість до шумів навколишнього середовища. Дальність виявлення збільшилася до 100 метрів, залежно від акустичної сигнатури дрона.

Експерименти показали, що точність виявлення знижується зі збільшенням відстані та інтерференції сигналу. Пристрій ідеально працював у радіусі 50 метрів, демонструючи деяке погіршення роботи за межами цієї відстані.

Пристрій ефективно працював у несприятливих умовах, включаючи підвищену швидкість вітру і значний міський шум, проте з незначним зниженням точності виявлення.

Запропоновану методологію оцінено порівняно з існуючими методами за показниками точності, ефективності та енергоспоживання. Вона регулярно перевершувала попередні системи, досягаючи вищих показників виявлення та зменшуючи енергоспоживання.

Основними перевагами є можливість миттєвої обробки даних, сумісність з технологіями з обмеженими ресурсами та підвищена енергоефективність. Ці характеристики роблять систему реальним рішенням для автономного виявлення безпілотників.

ОБГОВОРЕННЯ РЕЗУЛЬТАТІВ

Дослідження показало, що оптимальні неймережеві методи можуть бути ефективно реалізовані на мікроконтролерних платформах для виявлення звуку безпілотників у реальному часі. Такі моделі, як MobileNetV2 та GRU, продемонстрували високі показники продуктивності з точністю виявлення 94% та 98% відповідно. Кількісні ітерації MobileNetV2 досягли аналогічної точності (92%) при значному зниженні енергоспоживання до 3 мВт на один інференс, що підкреслює доцільність використання легких архітектур в умовах обмежених ресурсів. Ці результати підтверджують актуальність методів оптимізації нейронних мереж для додатків периферійного ШІ.

Оцінка ефективності покращених алгоритмів. Стратегії квантування та обрізання є важливими для зменшення обчислювальної складності при збереженні коректності моделі. Використання TensorFlow Lite та

STM32Cube, квантування після навчання зі штучним інтелектом полегшило розпізнавання безпілотників у реальному часі з затримкою 50 мілісекунд на один висновок, що робить систему придатною для реалістичних додатків спостереження. Використання DMA значно підвищило ефективність обробки даних, усунувши вузькі місця і підвищивши загальну продуктивність конвеєра. У порівнянні зі звичайними методами, модифіковані алгоритми забезпечили до 45% економії енергії і підвищили швидкість виведення на 80%.

Перспективні вдосконалення для подальших досліджень. Це дослідження ефективно продемонструвало реалізацію оптимальних нейронних мереж на мікроконтролерах, проте залишається кілька можливостей для вдосконалення. По-перше, додаткове дослідження методів динамічного квантування може забезпечити ще більш значне зниження енергоспоживання при збереженні ефективності обробки в реальному часі. По-друге, використання методів навчання з передачею даних може підвищити стійкість системи до різних умов навколишнього середовища і моделей безпілотників. Зрештою, доповнення набору даних ширшим набором аудіо-зразків, що охоплює низькочастотні та зашумлені ситуації, може покращити узагальнюваність моделей.

ВИСНОВКИ

Це дослідження ефективно довело життєздатність реалізації оптимальних нейромережевих алгоритмів для ідентифікації безпілотників за аудіосигналами на обмежених за ресурсами мікроконтролерних платформах. Такі моделі, як MobileNetV2 та GRU, досягли точності виявлення 94% та 98% відповідно, тоді як квантовані реалізації зменшили використання енергії до 3 мВт на один інференс. Застосування методів оптимізації, таких як квантування і обрізання, продемонструвало ефективність у виконанні вимог до обробки даних у реальному часі при збереженні точності. Ці вдосконалення роблять запропоновану систему привабливим кандидатом для малопотужних периферійних додатків.

ЛІТЕРАТУРА

- [1] E. Ragusa, T. Taccioli, A. Canepa, R. Zunino, and P. Gastaldo, "Design and Implementation of Tiny Deep Neural Networks for Landing Pad Detection on UAVs," *IEEE Access*, vol. 12, pp. 124009–124020, 2024. DOI: 10.1109/ACCESS.2024.3454363.
- [2] Z. Zhang, M. A. P. Mahmud, and A. Kouzani, "FitNN: A Low-Resource FPGA-Based CNN Accelerator for Drones," *IEEE Internet of Things Journal*, vol. 9, pp. 21357–21369, 2022. DOI: 10.1109/JIOT.2022.3179016.
- [3] P.-E. Novac, G. B. Hacene, A. Pegatoquet, B. Miramond, and V. Gripon, "Quantization and Deployment of Deep Neural Networks on Microcontrollers," *Sensors*, vol. 21, 2021. DOI: 10.3390/s21092984.
- [4] H. Sun, J. Yang, J. Shen, D. Liang, L. Ning-zhong, and H. Zhou, "TIB-Net: Drone Detection Network With Tiny Iterative Backbone," *IEEE Access*, vol. 8, pp. 130697–130707, 2020. DOI: 10.1109/ACCESS.2020.3009518.
- [5] D. Utebayeva, L. Ilipbayeva, and E. Matson, "Practical Study of Recurrent Neural Networks for Efficient Real-Time Drone Sound Detection: A Review," *Drones*, vol. 7, no. 1, 2022. DOI: 10.3390/drones7010026.
- [6] S. Jeon, J. Shin, Y.-J. Lee, W.-H. Kim, Y. Kwon, and H.-Y. Yang, "Empirical Study of Drone Sound Detection in Real-Life Environment with Deep Neural Networks," in *Proc. 25th European Signal Processing Conf. (EUSIPCO)*, 2017, pp. 1858–1862. DOI: 10.23919/eusipco.2017.8081531.
- [7] S. Al-Emadi, A. Al-Ali, and A. Al-Ali, "Audio-Based Drone Detection and Identification Using Deep Learning Techniques with Dataset Enhancement Through Generative Adversarial Networks," *Sensors*, vol. 21, 2021. DOI: 10.3390/s21154953.
- [8] C. Dumitrescu, M. Minea, and I. Costea, "Development of an Acoustic System for UAV Detection," *Sensors*, vol. 20, 2020. DOI: 10.3390/s20174870.
- [9] M. Meyer, L. Cavigelli, and L. Thiele, "Efficient Convolutional Neural Network for Audio Event Detection," *ArXiv*, 2017. [Онлайн]. URL: <https://arxiv.org/abs/1709.09888>. Дата звернення: 22.12.2024.
- [10] G. Cerutti, R. Prasad, A. Brutti, and E. Farella, "Compact Recurrent Neural Networks for Acoustic Event Detection on Low-Energy Low-Complexity Platforms," *IEEE J. Sel. Topics Signal Process.*, vol. 14, pp. 654–664, 2020. DOI: 10.1109/JSTSP.2020.2969775.
- [11] A. Diouani, R. E. Hamdi, and M. Njah, "Assessing the Efficacy of TinyML Implementations on STM32 Microcontrollers: A Performance Evaluation Study," in *Proc. 7th Int. Conf. Advanced Technologies, Signal and Image Processing (ATSIP)*, 2024, pp. 267–271. DOI: 10.1109/ATSIP62566.2024.10638900.
- [12] C. Contoli and E. Lattanzi, "A Study on the Application of TensorFlow Compression Techniques to Human Activity Recognition," *IEEE Access*, vol. 11, pp. 48046–48058, 2023. DOI: 10.1109/ACCESS.2023.3276438.
- [13] J. Rai, P. Carniglia, A. Dey, B. Balaji, S. Rajan, and S. Pant, "Lightweight Convolutional Neural Network-based Drone Detection Using Radar Spectrograms," in *Proc. Int. Symp. Sensing and Instrumentation in 5G and IoT Era (ISSI)*, 2024, pp. 1–6. DOI: 10.1109/ISSI63632.2024.10720508.
- [14] Z. Zhang, M. A. P. Mahmud, and A. Kouzani, "FitNN: A Low-Resource FPGA-Based CNN Accelerator for Drones," *IEEE Internet of Things Journal*, vol. 9, pp. 21357–21369, 2022. DOI: 10.1109/JIOT.2022.3179016.

EFFICIENT NEURAL NETWORK ALGORITHMS FOR MICROCONTROLLERS IN AUDIO DETECTION SYSTEMS

Serhii Kolesnyk, Serhii Kovalev

This study focuses on the development and deployment of optimized neural network algorithms for real-time audio-based drone detection on resource-constrained microcontroller systems. Addressing the growing need for efficient drone detection, the research aims to design lightweight models that balance accuracy, low latency, and energy efficiency for edge devices such as STM32 and ESP32 microcontrollers.

The study evaluates neural network architectures, including Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and lightweight models like MobileNetV2 and TinyCNN. GRU-based RNNs achieved the highest accuracy of 98%, while MobileNetV2 offered a balance between performance and efficiency. Optimization techniques such as quantization and pruning were applied, enabling quantized MobileNetV2 to achieve inference speeds of 45 FPS and energy consumption of just 3 mW per inference. These results underscore the practicality of deploying such models in real-world scenarios.

Integration of these models onto microcontrollers was facilitated by frameworks like TensorFlow Lite and STM32Cube.AI. Field tests demonstrated the system's robustness in diverse environments, including noisy urban areas. Detection accuracy exceeded 90% within a 100-meter range, even under adverse conditions. The results highlight the system's potential for low-power, autonomous surveillance applications.

Key contributions include demonstrating the effectiveness of neural network optimization for edge systems, creating a scalable framework for audio-based detection, and advancing lightweight models for energy-efficient tasks. Future research will focus on advanced optimizations, expanding datasets, and integrating multi-modal detection.

This study lays a foundation for practical, efficient, and scalable drone detection technologies, addressing key challenges in energy use, accuracy, and real-world deployment.

Keywords: *drone detection, neural networks, microcontrollers, audio processing, real-time systems, edge computing, model optimization, quantization, energy efficiency, lightweight architectures.*

REFERENCES

- [1] E. Ragusa, T. Taccioli, A. Canepa, R. Zunino, and P. Gastaldo, "Design and Implementation of Tiny Deep Neural Networks for Landing Pad Detection on UAVs," *IEEE Access*, vol. 12, pp. 124009–124020, 2024. DOI: 10.1109/ACCESS.2024.3454363.
- [2] Z. Zhang, M. A. P. Mahmud, and A. Kouzani, "FitNN: A Low-Resource FPGA-Based CNN Accelerator for Drones," *IEEE Internet of Things Journal*, vol. 9, pp. 21357–21369, 2022. DOI: 10.1109/JIOT.2022.3179016.
- [3] P.-E. Novac, G. B. Hacene, A. Pegatoquet, B. Miramond, and V. Gripon, "Quantization and Deployment of Deep Neural Networks on Microcontrollers," *Sensors*, vol. 21, 2021. DOI: 10.3390/s21092984.
- [4] H. Sun, J. Yang, J. Shen, D. Liang, L. Ning-zhong, and H. Zhou, "TIB-Net: Drone Detection Network With Tiny Iterative Backbone," *IEEE Access*, vol. 8, pp. 130697–130707, 2020. DOI: 10.1109/ACCESS.2020.3009518.
- [5] D. Utebayeva, L. Ilipbayeva, and E. Matson, "Practical Study of Recurrent Neural Networks for Efficient Real-Time Drone Sound Detection: A Review," *Drones*, vol. 7, no. 1, 2022. DOI: 10.3390/drones7010026.
- [6] S. Jeon, J. Shin, Y.-J. Lee, W.-H. Kim, Y. Kwon, and H.-Y. Yang, "Empirical Study of Drone Sound Detection in Real-Life Environment with Deep Neural Networks," in *Proc. 25th European Signal Processing Conf. (EUSIPCO)*, 2017, pp. 1858–1862. DOI: 10.23919/eusipco.2017.8081531.
- [7] S. Al-Emadi, A. Al-Ali, and A. Al-Ali, "Audio-Based Drone Detection and Identification Using Deep Learning Techniques with Dataset Enhancement Through Generative Adversarial Networks," *Sensors*, vol. 21, 2021. DOI: 10.3390/s21154953.
- [8] C. Dumitrescu, M. Minea, and I. Costea, "Development of an Acoustic System for UAV Detection," *Sensors*, vol. 20, 2020. DOI: 10.3390/s20174870.
- [9] M. Meyer, L. Cavigelli, and L. Thiele, "Efficient Convolutional Neural Network for Audio Event Detection," *ArXiv*, 2017. [Online]. URL: <https://arxiv.org/abs/1709.09888>. Accessed: 22 Dec, 2024.
- [10] G. Cerutti, R. Prasad, A. Brutti, and E. Farella, "Compact Recurrent Neural Networks for Acoustic Event Detection on Low-Energy Low-Complexity Platforms," *IEEE J. Sel. Topics Signal Process.*, vol. 14, pp. 654–664, 2020. DOI: 10.1109/JSTSP.2020.2969775.
- [11] A. Diouani, R. E. Hamdi, and M. Njah, "Assessing the Efficacy of TinyML Implementations on STM32 Microcontrollers: A Performance Evaluation Study," in *Proc. 7th Int. Conf. Advanced Technologies, Signal and Image Processing (ATSIP)*, 2024, pp. 267–271. DOI: 10.1109/ATSIP62566.2024.10638900.
- [12] C. Contoli and E. Lattanzi, "A Study on the Application of TensorFlow Compression Techniques to Human Activity Recognition," *IEEE Access*, vol. 11, pp. 48046–48058, 2023. DOI: 10.1109/ACCESS.2023.3276438.
- [13] J. Rai, P. Carniglia, A. Dey, B. Balaji, S. Rajan, and S. Pant, "Lightweight Convolutional Neural Network-based Drone Detection Using Radar Spectrograms," in *Proc. Int. Symp. Sensing and Instrumentation in 5G and IoT Era (ISSI)*, 2024, pp. 1–6. DOI: 10.1109/ISSI63632.2024.10720508.
- [14] Z. Zhang, M. A. P. Mahmud, and A. Kouzani, "FitNN: A Low-Resource FPGA-Based CNN Accelerator for Drones," *IEEE Internet of Things Journal*, vol. 9, pp. 21357–21369, 2022. DOI: 10.1109/JIOT.2022.3179016.