

## Ứng dụng mô hình học sâu CNN và kỹ thuật lọc CFAR cho nhận dạng drone dựa trên dấu vết tín hiệu vô tuyến RF trong điều kiện nhiễu

Nguyễn Văn Bắc<sup>1\*</sup>, Hoàng Văn Phúc<sup>1</sup>, Đoàn Văn Sáng<sup>2</sup>,  
Hoàng Xuân Tĩnh<sup>1</sup>, Trịnh Đình Linh<sup>1</sup>

<sup>1</sup>Viện Tích hợp hệ thống, Học viện Kỹ thuật Quân sự, 236 Hoàng Quốc Việt, Bắc Từ Liêm, Hà Nội, Việt Nam;

<sup>2</sup>Học viện Hải quân, 30 Trần Phú, Nha Trang, Khánh Hòa, Việt Nam.

\*Email: bacnv.isi@lqdtu.edu.vn

Nhận bài: 26/3/2024; Hoàn thiện: 27/5/2024; Chấp nhận đăng: 12/6/2024; Xuất bản: 25/6/2024.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.96.2024.30-40>

### TÓM TẮT

Hiện nay, số lượng các thiết bị bay không người lái cỡ nhỏ (drone) đã gia tăng nhanh chóng do nhu cầu tương tác từ xa, không tiếp xúc và công nghệ tiên tiến ngày càng tăng. Tuy nhiên, cùng với nhu cầu ngày càng tăng về drone trên nhiều lĩnh vực, việc sử dụng chúng với mục đích xấu cũng tăng lên. Do đó, cần có hệ thống giám sát drone để phát hiện việc sử dụng drone trái phép. Trong nghiên cứu này, chúng tôi đề xuất giải pháp mới dựa vào dấu vết tín hiệu vô tuyến của drone (thu RF). Dữ liệu được sử dụng trong nghiên cứu được thu từ tín hiệu điều khiển của 17 loại drone đã được công bố. Phương pháp đề xuất giúp nâng cao độ chính xác phân loại khi tỉ số tín trên tạp (SNR) giảm do sự ảnh hưởng của nhiễu. Trong thử nghiệm, chúng tôi đã mở rộng bộ dữ liệu tín hiệu điều khiển drone bằng cách thêm nhiễu Gauss trắng vào để thay đổi giá trị SNR từ  $-15$  dB đến  $+15$  dB với bước nhảy  $+5$  dB. Chân dung công suất phổ sau tiền xử lý ngưỡng bằng phương pháp ổn định bảo động lamm (CFAR) được áp dụng để làm hình ảnh huấn luyện mạng nơ-ron tích chập (CNN). Mô hình đề xuất đạt được độ chính xác trên 96% ở mức SNR bằng  $-15$  dB và độ chính xác 99,82% vùng SNR cao. Những kết quả này cho thấy, phương pháp đề xuất có khả năng phân loại tốt trong điều kiện nhiễu cao.

**Từ khóa:** Phân loại drone; Mạng học sâu CNN; Chân dung phổ - thời gian; Spectrogram.

### 1. MỞ ĐẦU

Hiện nay, thiết bị bay không người lái (drone) đã trở nên quen thuộc và được nhắc đến nhiều trên các phương tiện thông tin đại chúng. Những lợi ích mà drone mang lại cho con người là rất lớn trong hầu hết các lĩnh vực [1]. Vì vậy, việc phát triển các thế hệ drone là mối quan tâm của nhiều quốc gia vì mục đích an ninh-quốc phòng, dân sự và phát triển công nghệ [2]. Tuy nhiên, các ứng dụng bất hợp pháp của drone như để do thám trái phép [3], buôn lậu ma túy [4] và khủng bố [5] cũng đang tăng lên. Mặc dù đã có các quy định và khu vực cấm hoạt động drone nhưng drone vẫn có thể dẫn đến nhiều rủi ro [6]. Do đó, các hệ thống giám sát, phòng chống drone là cần thiết để ngăn chặn việc sử dụng drone trái phép cho các mục đích xấu. Một trong những bài toán cần được giải quyết của các hệ thống này là phát hiện và phân loại drone. Đã có nhiều phương pháp phát hiện và phân loại drone được công bố. Các nguồn dữ liệu khác nhau như tín hiệu radar, âm thanh, hình ảnh camera và dấu vết tín hiệu vô tuyến (RF) hiện được sử dụng để phát hiện và phân loại drone [8]. Nhưng tất cả các phương pháp phát hiện và nhận dạng này đều đang đứng trước nhiều thách thức. Các phương pháp phát hiện dựa trên radar nổi tiếng gặp khó khăn trong việc phát hiện drone kích thước nhỏ và bay ở độ cao thấp. Trong khi đó, phát hiện dựa trên âm thanh lại có khoảng cách phát hiện rất ngắn và nhạy cảm với nhiễu [9]. Ngoài ra, phát hiện dựa trên hình ảnh camera có nhược điểm là bị giới hạn bởi sương mù, thời tiết và các chướng ngại vật khác nhau. Phát hiện dựa trên thu RF mang lại các lợi thế về độ tin cậy cao hơn và hiệu suất tốt hơn [10]. Bằng việc thu và phân tích các tín hiệu liên lạc của drone và trạm điều khiển (RC) có thể phát hiện, nhận dạng, và xác định được vị trí của chúng. Phương pháp dựa trên thu RF này khắc phục được vấn đề che khuất tầm nhìn quang học, hoạt động được cả ngày, đêm và điều kiện thời

tiết xấu. Cụ ly phát hiện của phương pháp dựa trên thu RF có thể vượt xa cụ ly liên lạc giữa drone và RC của nó. Tuy nhiên, phương pháp thu RF cũng gặp nhiều khó khăn khi thực hiện trong điều kiện nhiễu cao. Trong phần sau, chúng tôi tập trung trình bày về các công bố đã được nghiên cứu, những khó khăn gặp phải của các phương pháp và đề xuất phương pháp để cải thiện kết quả phân loại drone. Phương pháp đề xuất sử dụng kỹ thuật ổn định xác suất bảo động làm để hiệu chỉnh chân dung phổ - thời gian (spectrogram) tín hiệu vô tuyến thu được từ drone, kết hợp với mạng tích chập CNN để trích xuất đặc trưng từ chân dung phổ - thời gian đó phục vụ cho bài toán nhận dạng. Kết quả mô phỏng trên Matlab cho thấy phương pháp đề xuất giúp cải thiện rõ rệt bài toán nhận dạng drone trong điều kiện nhiễu cao.

## 2. TỔNG QUAN VẤN ĐỀ NGHIÊN CỨU VÀ BỘ DỮ LIỆU

### 2.1. Các công bố liên quan

Trong phần này, các nghiên cứu liên quan phương pháp phân loại drone dựa trên thu RF sẽ được thảo luận chi tiết. Đối với phân loại drone dựa trên thu RF, đã có nhiều công bố được thực hiện. Các nghiên cứu liên quan được tóm tắt trong bảng 1.

**Bảng 1.** Bảng so sánh các công bố nhận dạng Drone sử dụng dấu vết tín hiệu vô tuyến.

Công bố	Dữ liệu	Trích xuất đặc trưng	Công cụ phân loại	Số loại Drone	Độ chính xác	Điều kiện nhiễu
[11]	[12]	Đặc trưng thống kê *	DA, SVM, k-NN	15	50 %	SNR= 0 dB
[13]	[12]	Đặc trưng thống kê *	k-NN	15	60 %	SNR= 0 dB
[14]	[15]	công suất phổ	DNN	3+1 (nền nhiễu)	85,4 %	
[16]	[15]	Đặc trưng thống kê *	1DCNN	3+1 (nền nhiễu)	85,8 %	
[17]	[15]	Đặc trưng thống kê *	1DCNN	3+1 (nền nhiễu)	92,02 %	
[18]	[15]	Đặc trưng thống kê *	1DCNN	3+1 (nền nhiễu)	92,5 %	
[19]	[22]	công suất phổ - thời gian	CNN	3+1 (nền nhiễu)	100 %	
[20]	[25]	công suất phổ - thời gian	DRNN	9+1 (nền nhiễu)	87,6 %	SNR= -10 dB
[21]	[15]	công suất phổ - thời gian	CNN đa kênh	3+1 (nền nhiễu)	95,6 %	
[26]	[12]	công suất phổ - thời gian	CNN	15	92 %	SNR= -10 dB
Bài báo này	[12]	công suất phổ - thời gian	CNN	17	>95 %	SNR= -15 dB

\* Các đặc trưng thống kê: độ nhọn, độ hỗn loạn, phương sai của tín hiệu.

Trong các nghiên cứu đã được công bố, việc trích xuất các đặc trưng khác nhau và sử dụng học máy (ML) và học sâu (DL) được thực hiện để phân loại drone. Trong nghiên cứu [11], tác giả đã trích xuất các đặc trưng thống kê của tín hiệu điều khiển drone (ví dụ: độ nhọn, độ hỗn loạn, phương sai,...) [12], sau đó phân loại được tiến hành thông qua các thuật toán học máy khác nhau, chẳng hạn như k-NN, DA, SVM. Độ chính xác phân loại cho 15 lớp drone là 96,3%, nhưng các thuật toán đều cho thấy độ chính xác dưới 50% ở mức SNR bằng 0 dB. Tương tự, trong [13], các tác giả đã đề xuất một phương pháp đạt độ chính xác phân loại 98,13% bằng cách sử dụng k-NN ở mức SNR bằng 25 dB. Tuy nhiên, Mô hình này cũng cho thấy một hạn chế là độ chính xác dưới 60% ở mức SNR bằng 0 dB.

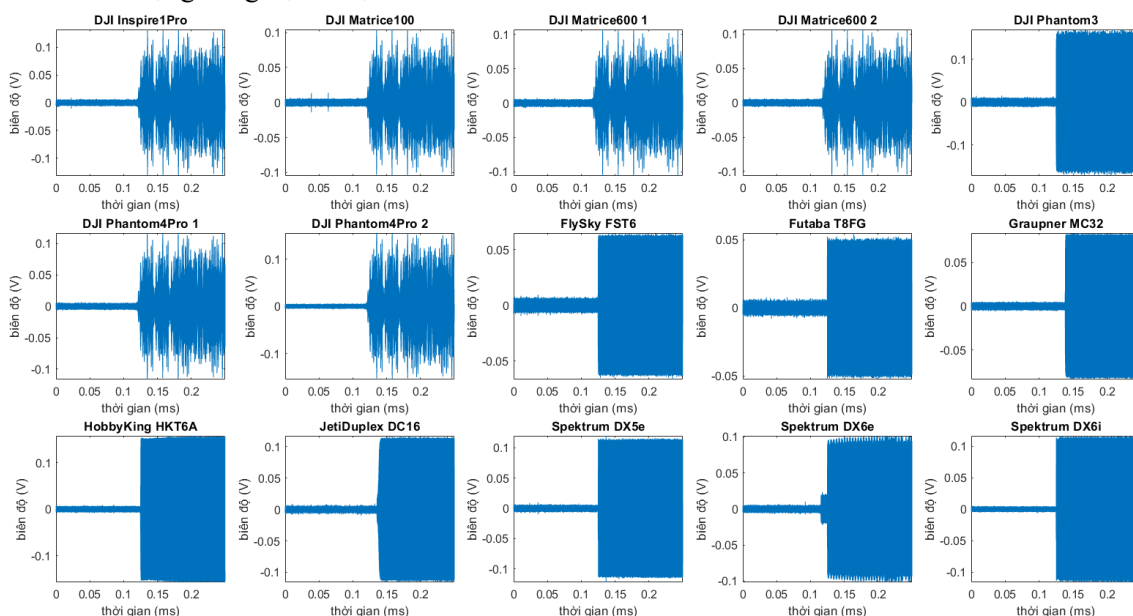
Trong [14], các tác giả đã xây dựng bộ dữ liệu về drone [15] và phân loại dữ liệu thành bốn lớp (ba lớp drone và một lớp nền). Bằng cách phân tích đặc trưng thống kê của tín hiệu RF từ drone và sử dụng mạng nơ-ron học sâu DNN, nhóm tác giả đã đạt được độ chính xác là 85,4%.

Hơn nữa, nhiều nghiên cứu [16-18] đã sử dụng mạng nơ-ron tích chập một chiều (1DCNN) để nhận dạng drone và đạt được kết quả độ chính xác tốt như 85,8% [16], 92,02% [17] và 92,5% [18], tương ứng.

Gần đây, các mạng nơ-ron tích chập (CNN) đã được sử dụng để phân tích các chân dung phổ tín hiệu để đạt được độ chính xác cao trong các nhiệm vụ phân loại drone dựa trên thu RF [19], [20]. Trong công bố [21], tác giả đạt được độ chính xác 95,6% bằng cách sử dụng mô hình CNN đa kênh làm bộ phân loại. Các tác giả của [19] và [22] đạt được độ chính xác xấp xỉ 100% bằng cách sử dụng hình ảnh chân dung phổ tín hiệu drone kết hợp với bộ phân loại CNN. Tuy nhiên, những nghiên cứu này không xem xét các trường hợp khi tỉ số tín trên tạp (SNR) thấp.

Trong công bố [26], nhóm tác giả đã sử dụng bộ phân loại CNN để thực hiện phân loại drone dựa trên đặc trưng chân dung phổ. Đồng thời, nhóm tác giả cũng đã có những khảo sát hiệu suất của bộ phân loại tại các SNR khác nhau từ 30 dB tới -10 dB. Hiệu suất của bộ phân loại đã giảm rõ rệt khi SNR giảm tới -10dB. Để đạt được hiệu quả phân loại tốt trên vùng SNR thử nghiệm, nhóm tác giả đã đề xuất phương pháp sử dụng ngưỡng cứng để lọc các thành phần nhiễu gây ảnh hưởng đến độ chính xác phân loại.

Phương pháp được đề xuất tại công bố [26] đã chứng minh được hiệu quả của quá trình tiền xử lý dữ liệu trong mô hình phân loại. Tuy nhiên, khi sử dụng duy nhất một ngưỡng dùng cho tất cả các SNR khác nhau là chưa tối ưu. Nếu sử dụng ngưỡng quá thấp, hiệu quả lọc sẽ không đảm bảo tại vùng SNR thấp. Nếu sử dụng ngưỡng quá cao, hiệu quả tốt tại vùng SNR thấp nhưng sẽ dẫn tới việc mất mát đặc trưng của tín hiệu. Chính vì vậy, trong nghiên cứu này, nhóm tác giả đề xuất phương pháp tiền xử lý dữ liệu dựa trên kỹ thuật ổn định xác suất báo động lầm (CFAR) cho hình ảnh chân dung phổ. Phương pháp tiền xử lý dữ liệu này giúp cải thiện độ chính xác phân loại của mô hình học sâu CNN tại vùng SNR khác nhau. Bộ dữ liệu được sử dụng là tín hiệu RF điều khiển từ xa drone [12] được công bố trên IEEE Dataport. Sự vượt trội của phương pháp đề xuất được xác định bằng độ chính xác phân loại 17 drone khác nhau và so sánh kết quả với các nghiên cứu khác đã sử dụng cùng bộ dữ liệu.



Hình 1. Biểu đồ thời gian biên độ các dạng tín hiệu điều khiển drone.

## 2.2. Dữ liệu và mở rộng dữ liệu theo tỉ số tín trên tạp SNR khác nhau

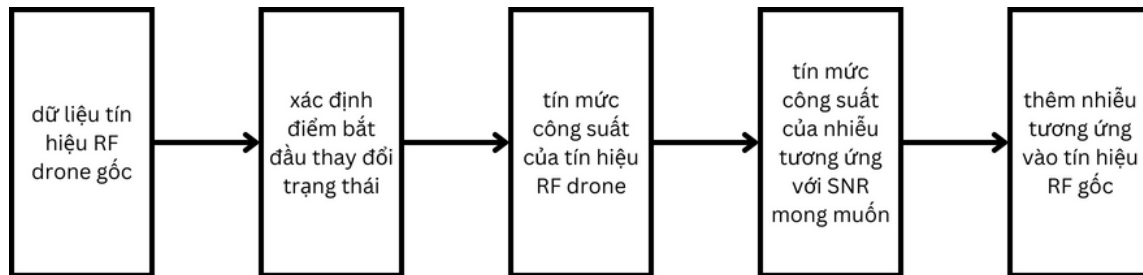
### 2.2.1. Quy trình thu thập bộ dữ liệu

Nghiên cứu này sử dụng tín hiệu RF từ bộ điều khiển drone [12] trong bộ dữ liệu IEEE Dataport. Bộ dữ liệu được thu thập bao gồm tín hiệu điều khiển 17 loại drone của 8 nhà sản xuất khác nhau. Hệ thống giám sát vô tuyến liên tục nhận tín hiệu và ghi lại khi tín hiệu điều khiển từ xa (RC) của drone. Hệ thống thu thập dữ liệu gồm một máy hiện sóng (KEYSIGHT Technologies, Infiniium S-Series) với tần số lấy mẫu tối đa là 20 GHz, một ăng-ten parabolic lưới 2,4 GHz 24 dBi (Tp-link, TL-ANT2424B), và một khuếch đại tín hiệu tạp âm thấp (Fairview Microwave, 0,85 dB NF Input Protected Low Noise Amplifier) hoạt động ở dải 2,0–2,6 GHz. Biểu đồ thời gian – biên độ các loại tín hiệu RF của drone được thể hiện trên hình 1.

**2.2.2. Kích bản thêm nhiễu để mở rộng tập dữ liệu huấn luyện**

Như thể hiện trong hình 1, giá trị SNR của tín hiệu RF từ drone thu được là tương đối lớn. Chính vì thế, sử dụng tập dữ liệu này sẽ không thể tổng quát hoá được các trường hợp với SNR thấp. Do đó, trong nghiên cứu này, tín hiệu điều khiển drone được mở rộng bằng cách thêm nhiễu tạp Gauss trắng vào tín hiệu thu thập được. Để thay đổi SNR, cần phải tạo ra và thêm nhiễu phù hợp với mức công suất của tín hiệu RF từ drone.

Nhiễu được thêm vào tín hiệu điều khiển drone thông qua quá trình thể hiện trên hình 2. Các thành phần nhiễu và tín hiệu trong tín hiệu được tách ra nhằm đảm bảo tính toán mức công suất tín hiệu điều khiển drone được chính xác. Để thực hiện tách nhiễu, chúng ta cần xác định được điểm bắt đầu quá trình điều khiển drone. Có nhiều phương pháp xác định điểm bắt đầu của trạng thái chuyển tiếp đã được công bố [24]. Nghiên cứu này sử dụng phương pháp phát hiện điểm thay đổi trung bình (mean change point detection) [24].



**Hình 2.** Quá trình thêm nhiễu nhằm mở rộng tập dữ liệu huấn luyện.

Khi tín hiệu thu thập được là  $x[n] = x_1, x_2, \dots, x_N$ , một điểm ngẫu nhiên  $k$  được chọn từ  $k = 2, 3, \dots, N$ , sẽ chia tín hiệu  $x$  thành 2 phần  $x_1, x_2, \dots, x_{k-1}$  và  $x_k, x_{k+1}, \dots, x_N$ , (với  $N$  là độ dài của tín hiệu thu thập  $x$ ). Khi đó, ta sẽ thu được giá trị tổng phương sai của từng phần  $S_k$

$$S_k = \sum_{t=1}^{k-1} (x_t - \bar{X}_{t1})^2 + \sum_{t=k}^N (x_t - \bar{X}_{t2})^2$$

Trong đó:  $\bar{X}_{t1}$  là giá trị trung bình của phần tín hiệu  $x_1, x_2, \dots, x_{k-1}$ ;

$\bar{X}_{t2}$  là giá trị trung bình của phần tín hiệu  $x_k, x_{k+1}, \dots, x_N$ .

Tương tự, ta có giá trị  $S$  đối với toàn bộ tín hiệu  $x[n] = x_1, x_2, \dots, x_N$

$$S = \sum_{t=1}^N (x_t - \bar{X})^2$$

Với  $\bar{X}$  là giá trị trung bình của toàn bộ tín hiệu.

Điểm  $k$  là điểm bắt đầu của trạng thái chuyển tiếp của  $x[n]$  nếu giá trị  $S - S_k$  đạt giá trị cực đại.

Bằng cách phương pháp trên, chúng ta có thể tiến hành tách phần tín hiệu của drone ra khỏi nền nhiễu, qua đó tính được mức công suất của tín hiệu:

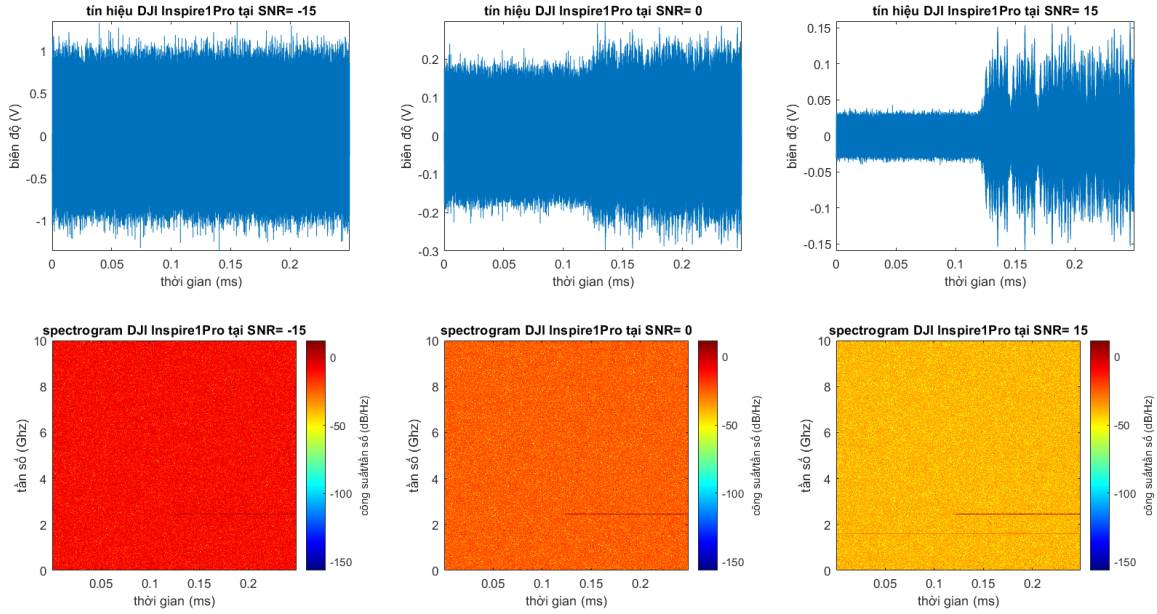
$$P_S = \frac{1}{N - k + 1} \sum_{i=k}^N (x[i])^2$$

Nếu SNR mong muốn là  $\gamma$  [dB] và công suất tín hiệu là  $P_S$ , thì công suất nhiễu có thể thu được bằng biểu thức SNR:

$$P_n(W) = \frac{P_S}{10^{\frac{\gamma}{10}}}$$

Cuối cùng, tín hiệu nhiễu Gauss trắng được thêm vào chuỗi tín hiệu RF của drone thu được  $n[i] = \sqrt{P_n} \cdot \mathcal{N}(0,1)$ , trong đó,  $i = 1, 2, 3, \dots, N$ , và  $\mathcal{N}(0,1)$  là phân phối chuẩn Gaussian, kỳ vọng bằng 0, phương sai là 1.

Một tín hiệu thu RF của drone có SNR mong muốn được tạo ra bằng cách cộng thêm tín hiệu nhiễu với mức công suất tương ứng vào tín hiệu gốc  $y[i] = x[i] + n[i]$ . Dạng sóng của tín hiệu drone với mức SNR khác nhau được minh họa trong hình 3.




Hình 3. Biểu đồ biên độ- thời gian và biểu đồ spectrogram của tín hiệu RF drone tại các SNR khác nhau.

### 3. MÔ HÌNH ĐỀ XUẤT PHÂN LOẠI DRONE, KẾT QUẢ VÀ THẢO LUẬN

#### 3.1. Mô hình hệ thống phân loại drone

Mô hình hệ thống phân loại drone dựa trên thu RF được thể hiện trong hình 4. Tín hiệu drone bao gồm các thành phần nhiễu và tín hiệu, được biến đổi sang chân dung công suất phổ - thời gian. Hình ảnh chân dung công suất phổ - thời gian sau khi được tiền xử lý CFAR để loại bỏ bớt ảnh hưởng của nhiễu, được đưa vào một mạng nơ-ron tích chập CNN. Lớp cuối của mạng CNN là lớp phân loại của 17 loại drone.

Như vậy, hình ảnh chân dung công suất phổ - thời gian sử dụng cho mô hình huấn luyện CNN từ tín hiệu có SNR khác nhau bao gồm hai bước. Bước đầu tiên là thông qua biến đổi Fourier thời gian ngắn (STFT) để thu được chân dung mật độ công suất phổ (power spectral density PSD) của tín hiệu RF theo thời gian, và bước thứ hai là áp dụng kỹ thuật CFAR nhằm cân bằng nhiễu nền của ảnh.



**Hình 4.** Hệ thống phân loại drone dựa vào dấu vết tín hiệu vô tuyến drone.

**A. Xây dựng chân dung công suất phổ - thời gian**

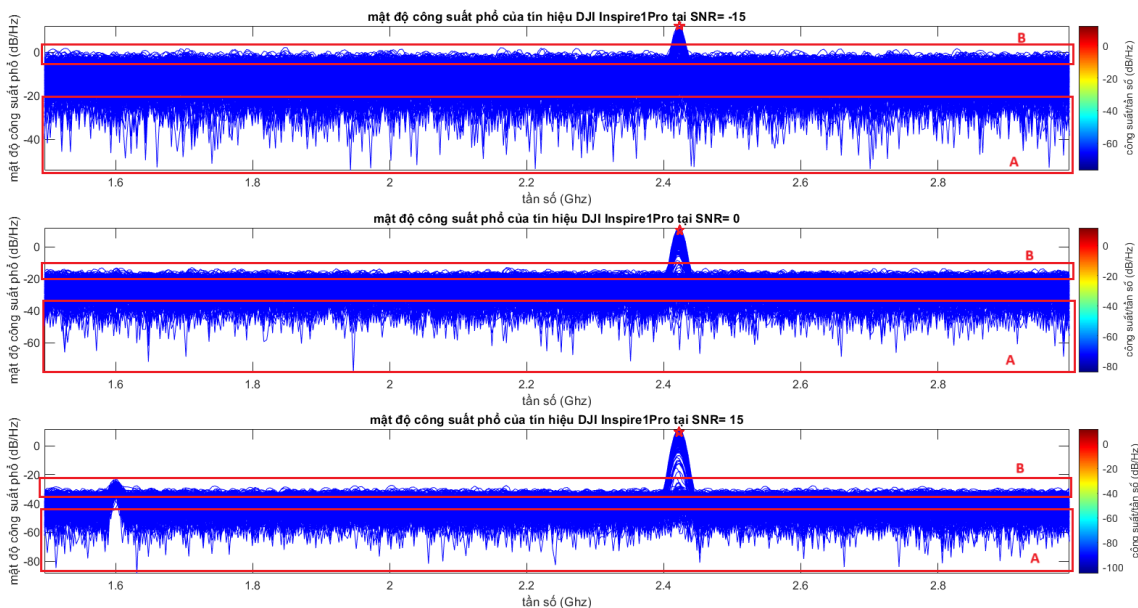
Fourier thời gian ngắn (STFT) của một tín hiệu được thực hiện bằng cách trượt một cửa sổ phân tích có độ dài  $M$  qua tín hiệu và tính biến đổi Fourier rời rạc của từng đoạn dữ liệu được lấy mẫu bằng cửa sổ. Hầu hết các hàm cửa sổ giảm dần ở các cạnh để tránh hiện tượng rung phổ. Cửa sổ di chuyển qua tín hiệu gốc với khoảng cách là  $R$  và số chồng lấn  $L = M - R$ . Biến đổi Fourier rời rạc của từng đoạn dữ liệu được lấy mẫu bằng cửa sổ được thêm vào ma trận chứa độ lớn và pha cho mỗi điểm trong thời gian và tần số. Số hàng trong ma trận STFT bằng số điểm biến đổi Fourier rời rạc và số cột được xác định bởi  $k = \lfloor \frac{N_x - L}{M - L} \rfloor$ , trong đó,  $N_x$  là độ dài của tín hiệu gốc.

Ma trận STFT nhận được  $X(f) = [X_1(f) X_2(f) X_3(f) \dots X_k(f)]$ , trong đó, thành phần  $X_m(f)$  được xác định bằng

$$X_m(f) = \sum_{n=-\infty}^{\infty} x(n)g(n - mR)e^{-j2\pi fn}$$

Trong đó:  $g(n)$  là hàm cửa sổ áp dụng vào đoạn FFT có độ dài  $M$ .

Trong nghiên cứu này, để giảm số lượng tính toán, đồng thời giữ được mối tương quan thời gian giữa các lần lấy mẫu, kích thước nháy cửa sổ FFT được đặt bằng một nửa độ dài của hàm cửa sổ. Hàm cửa sổ  $g(n)$  được sử dụng là hàm Kaiser nhằm đảm bảo hiệu suất tính toán và đáp ứng chất lượng phân tích tần số mong muốn. Kết quả của STFT này được biểu diễn bằng hình ảnh Spectrogram biểu thị theo thời gian, tần số và mật độ công suất phổ (PSD) bằng cách ánh xạ bình phương tuyệt đối của STFT vào một thanh màu (hình 5).



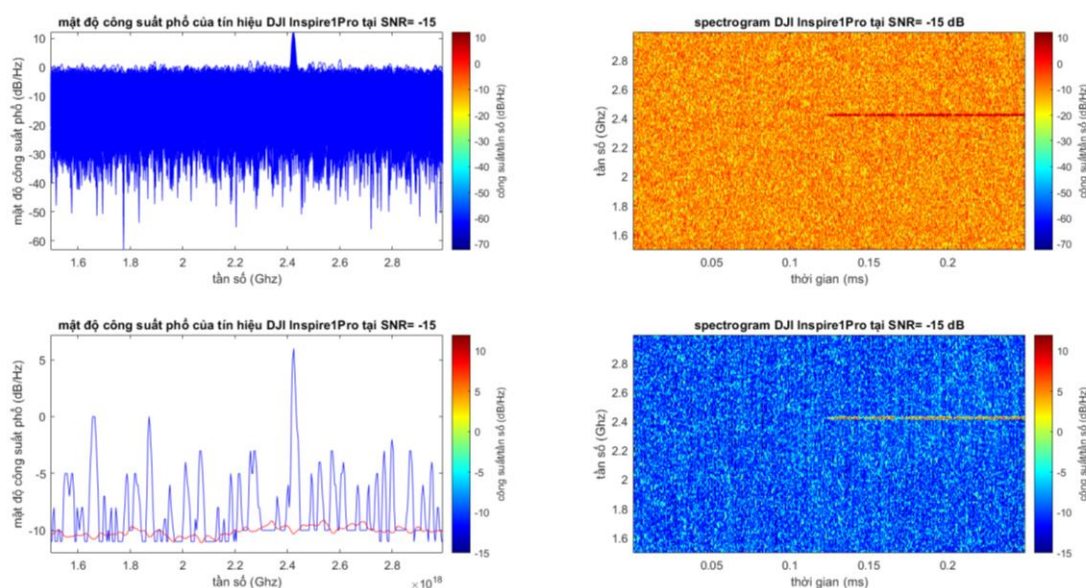
**Hình 5.** Công suất phổ của tín hiệu trong các SNR khác nhau.

B. CFAR trong xử lý chân dung ảnh phổ - thời gian

CNN là một loại kiến trúc học sâu (DL) và là một công cụ mạnh mẽ được sử dụng cho phân loại ảnh. Dữ liệu ảnh được sử dụng cho việc huấn luyện CNN có thể được hiểu là một ma trận ba chiều với các hàng, cột và kênh RGB. Trong một CNN thực tế, giá trị màu RGB, vị trí và các yếu tố ảnh khác ảnh hưởng lớn đến kết quả huấn luyện. Hình ảnh chân dung công suất phổ - thời gian sử dụng một bản đồ màu để biểu diễn mức công suất của tín hiệu drone theo tần số và thời gian, như được thể hiện trong hình 3. Trong đó, chúng ta có thể quan sát thấy vùng đặc trưng của tín hiệu RF drone có độ lớn xấp xỉ nhau, nên được biểu diễn bằng cùng một thang màu ở các mức SNR khác nhau. Tuy nhiên, độ lớn nền nhiễu ở các mức SNR khác nhau lại thay đổi rõ rệt. Khi SNR càng thấp, thang màu nền nhiễu càng gần giống với vùng đặc trưng của tín hiệu drone (hình 5). Đây là nguyên nhân lớn làm giảm độ chính xác trong phân loại của một CNN, việc áp dụng bước tiền xử lý là cần thiết để làm giảm ảnh hưởng của nền nhiễu.

Như thể hiện trên hình 5, mức công suất nhiễu tại các tần số là ngẫu nhiên, nên sự chênh lệch giữa mức công suất của phổ tín hiệu drone và các tần số nhiễu cực đoan (vùng A) là rất lớn. Sự chênh lệch này càng lớn, thang màu vùng đặc trưng (đấu ☆) của tín hiệu RF drone càng gần với thang màu của nền nhiễu trung bình (vùng B). Khi thang màu giữa vùng đặc trưng của tín hiệu càng gần với thang màu của nền nhiễu, phát hiện và phân loại tín hiệu càng khó khăn. Tương ứng, chất lượng chân dung ảnh phổ - thời gian càng kém cho mô hình CNN huấn luyện.

Để cải thiện chất lượng chân dung ảnh phổ - thời gian, phương pháp đơn giản nhất là sử dụng một mức ngưỡng để lọc. Nếu mức công suất của tín hiệu và nhiễu cao hơn thì được giữ, ngược lại thì bị loại bỏ [26]. Thao tác này giúp loại bỏ đi những tần số nhiễu cực đoan, và giúp thang màu hiển thị chân dung phổ tốt hơn. Tuy nhiên, dùng một ngưỡng cố định áp dụng cho toàn bộ nền nhiễu và tại các SNR, dẫn tới việc làm mất đặc trưng của tín hiệu RF từ drone, tương ứng, độ chính xác phân loại giảm. Trong nghiên cứu này, chúng tôi đề xuất sử dụng ngưỡng thích nghi, ứng dụng kỹ thuật CFAR.



Hình 6. Chân dung phổ - thời gian của tín hiệu trước và sau CFAR tại SNR = -15 dB.


CFAR (Constant False-Alarm Rate) là một công cụ mạnh mẽ để xác định ngưỡng phát hiện. Trong CFAR, khi cần phát hiện cho một ô kiểm tra  $n$  (CUT), ngưỡng phát hiện  $T$  được ước tính từ các ô lân cận theo công thức  $T = \alpha \cdot P_n$ , trong đó,  $P_n$  là ước tính công suất nhiễu và  $\alpha$  là hệ số ngưỡng. Trong nghiên cứu này, chúng tôi sử dụng bộ trung bình CFAR (CA-CFAR). Ước tính công

suất nhiễu được trích xuất từ xung quanh CUT (gọi là ô huấn luyện) và được tính toán bằng trung bình công suất nhiễu tại các ô đào tạo. Hệ số ngưỡng được tính toán dựa trên tỷ lệ báo động sai mong muốn  $\alpha = N \cdot (P_{fa}^{-\frac{1}{N}} - 1)$  với  $P_{fa}$  là tỷ lệ báo động lầm mong muốn,  $N$  là số các ô huấn luyện.

Trong nghiên cứu này, chân dung phổ - thời gian của tín hiệu drone có đặc trưng di chuyển dọc theo thời gian, nên CA-CFAR được thực hiện một chiều theo miền tần số. Trên miền thời gian, tùy thuộc vào từng loại drone, các loại điều chế tín hiệu khác nhau, độ dài các gói dữ liệu khác nhau nên có sự gián đoạn khác nhau. Việc áp dụng CFAR trên miền thời gian có thể làm mất đặc trưng của tín hiệu. Các tham số của bộ lọc CA-CFAR được lựa chọn thông qua các phân tích đặc trưng phổ tín hiệu và thực nghiệm. Số ô bảo vệ được lựa chọn dựa vào độ rộng của vùng đặc trưng phổ tín hiệu điều khiển. Độ rộng ô bảo vệ được chọn bằng độ rộng phổ lớn nhất của các loại drone. Trong nghiên cứu này, số ô bảo vệ được chọn bằng 4. Số ô huấn luyện  $N$  được chọn bằng 32, tương đối lớn so với độ rộng phổ vùng đặc trưng của mục tiêu nhằm giảm sự ảnh hưởng đến ngưỡng tại vùng gần phổ mục tiêu. Đồng thời, nhóm tác giả chọn tỷ lệ báo động lầm  $P_{fa} = 0,36$ , tỷ lệ báo động lầm cao để tránh sự mất mát đặc trưng tín hiệu. Chân dung phổ - thời gian của tín hiệu drone trước và sau xử lý CFAR được thể hiện trên hình 6. Thang màu chân dung phổ - thời gian sau xử lý CFAR đã được rút gọn từ khoảng  $(-60 \div 10)$  dB thành  $(-15 \div 10)$  dB. Như vậy, độ phân giải của thang màu tốt hơn, đồng thời vùng đặc trưng của phổ tín hiệu drone có thể được phân biệt rõ hơn so với nền nhiễu.

**3.2. Mô hình CNN phân loại drone**

Trong phần này, một mô hình CNN hiệu quả và chính xác cao được trình bày để phân loại các tín hiệu RF của 17 bộ điều khiển drone khác nhau. Mô hình CNN đề xuất bao gồm ba lớp tích chập hai chiều (conv2D) và ba lớp lấy mẫu cực đại (maxpool). Kiến trúc tổng thể của mô hình CNN được minh họa trong hình 7. Chân dung ảnh phổ - thời gian có kích thước  $356 \times 452 \times 3$  được tiền xử lý như trên sử dụng làm lớp đầu vào của mô hình CNN.



**Hình 7. Kiến trúc CNN được đề xuất.**

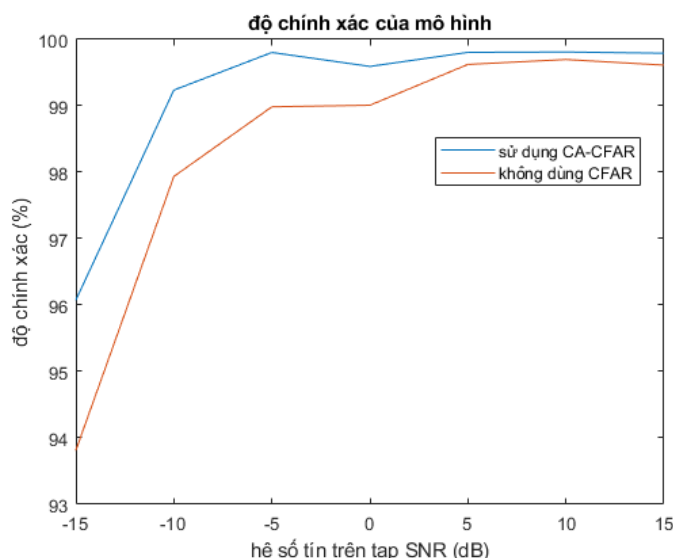
Lớp conv2D đầu tiên là một bộ lọc 64 kênh với kích thước là (2, 2) và bước là (2, 2). Sau đó, thông tin đi qua một lớp chuẩn hóa (batchnorm) và lớp tuyến tính hóa (ReLU), đó là một lớp kích hoạt. Dữ liệu sau đó đi qua lớp maxpool để giảm kích thước ảnh. Tiếp theo, thông tin được thông qua các lớp conv2D và maxpool với 128 và 256 kênh tương ứng. Lớp cuối cùng của mô hình CNN là lớp phân loại, trong đó, mô hình sử dụng hàm softmax.

**3.3. Kết quả mô phỏng và bình luận**

Trong phần này, các mô phỏng trên phần mềm Matlab được thực hiện để đánh giá hiệu suất của mô hình đề xuất. Nhóm đã thực hiện hai mô phỏng thực hiện để kiểm tra độ chính xác phân loại của mô hình đề xuất trong điều kiện mức SNR thấp. Đầu tiên, mô phỏng được thực hiện để kiểm chứng hiệu quả của mô hình CNN được đề xuất khi chưa sử dụng CA-CFAR. Độ chính xác phân loại của mô hình được so sánh với kết quả của các nghiên cứu khác sử dụng cùng một bộ dữ liệu. Thứ hai, mô phỏng thực hiện kiểm tra hiệu quả của mô hình khi áp dụng CA-CFAR trong môi trường nhiễu. Nhiễu Gauss trắng được thêm vào theo bước 5 dB của giá trị SNR từ -15 dB đến +15 dB.

Thuật toán tối ưu hóa của kiến trúc đề xuất là thuật toán suy giảm độ dốc ngẫu nhiên với động lượng (SGDM), hệ số động lượng là 0,9, hệ số chuẩn hoá L2 regularization là 0,0001, số epoch tối đa cho quá trình huấn luyện là 100, tỷ lệ học ban đầu là 0,01 (sau 30 epoch giảm xuống 0,001 để đạt được sự hội tụ huấn luyện tốt hơn), và kích thước mini-batch là 16.

Tập dữ liệu dùng cho huấn luyện gồm 119 lớp được tạo ra bằng cách kết hợp 17 tín hiệu điều khiển drone với 7 vùng SNR khác nhau. Chân dung ảnh phổ - thời gian dựa trên công suất phổ được sử dụng trong mô phỏng chứa 300 hình ảnh cho mỗi lớp, tổng cộng 35.700 hình ảnh. Tất cả các thiết lập mô phỏng đều giống như mô hình và các tùy chọn được mô tả ở trên. Ở đây, 80% bộ dữ liệu được sử dụng để huấn luyện, và 20% còn lại được sử dụng làm tập kiểm tra để xác minh.



**Hình 6.** Biểu đồ độ chính xác của mô hình tại các SNR khác nhau của mô hình đề xuất.

Độ chính xác phân loại được sử dụng là một chỉ số để đánh giá hiệu năng của hệ thống. Kết quả của mô hình đề xuất được so sánh với kết quả của các mô hình đã nghiên cứu trước đó như thể hiện ở bảng 1. Kết quả hai thí nghiệm được thể hiện trong hình 8. Kết quả cho thấy khi SNR giảm mạnh từ +15 dB tới -15 dB, độ chính xác phân loại cũng giảm, tuy nhiên, không dưới mức 94%. Đặc biệt, khi áp dụng bộ lọc CA-CFAR cho dữ liệu chân dung phổ - thời gian của tín hiệu, độ chính xác của mô hình vẫn giữ ở mức trên 96%. Từ kết quả thử nghiệm này, chúng ta có thể xác nhận rằng độ chính xác phân loại của phương pháp đề xuất là đáng tin cậy, kể cả ở các mức SNR rất thấp.

#### 4. KẾT LUẬN

Trong nghiên cứu này, chúng tôi đã đề xuất một kỹ thuật tiền xử lý dữ liệu kết hợp với mô hình học sâu CNN để phân loại tín hiệu RF của bộ điều khiển drone. Tỷ số tín trên tạp (SNR) đã thay đổi bằng cách thêm nhiễu tạp trắng. Phương pháp đề xuất sử dụng chân dung ảnh phổ - thời gian đã xử lý bằng CA-CFAR để huấn luyện. Việc áp dụng CA-CFAR để giảm ảnh hưởng của nhiễu, tăng độ chính xác phân loại tại điều kiện nhiễu cao. Phương pháp đề xuất có thể phân loại tín hiệu điều khiển drone với độ chính xác vượt quá 96%, ngay cả ở mức SNR cực thấp là -15 dB. Từ kết quả của phương pháp đề xuất, ta kỳ vọng rằng việc phân loại dựa trên chân dung ảnh phổ - thời gian có thể phân loại drone với độ chính xác cao hơn. Tuy nhiên, trong nội dung nghiên cứu chưa bao quát được các trường hợp nhiễu khác như nhiễu Wi-Fi, nhiễu sóng điện thoại,... Những nội dung này, nhóm tác giả dự kiến sẽ tiếp tục nghiên cứu trong tương lai.

*Lời cảm ơn:* Bài báo này được tài trợ trong khuôn khổ đề tài Nghị định thư với CH Séc mã số NĐT/CZ/22/12

### TÀI LIỆU THAM KHẢO

- [1]. <https://www.dedrone.com/>
- [2]. <https://www.baogiaothong.vn/thu-tuong-chi-dao-cam-thiet-bi-bay-khong-nguoi-lai-hoat-dong-gan-san-bay-d442178.html>
- [3]. <https://tuoitre.vn/bao-cao-pho-thu-tuong-hai-vu-may-bay-mop-mui-vi-vat-the-bay-chua-xac-dinh-20191025120213955.htm>
- [4]. D. Krijnen, C. Dekker, “AR Drone 2.0 with Subsumption Architecture”, In Artificial intelligence research seminar, (2014).
- [5]. R.J. Bachmann, F.J. Boria, R. Vaidyanathan, P.G. Ifju, R.D. Quinn, “A biologically inspired micro-vehicle capable of aerial and terrestrial locomotion”, Mach. Theory 44, 513–526, (2009).
- [6]. M. Hassanalian, A. Abdelkefi, M. Wei, S. Ziaei-Rad, “A novel methodology for wing sizing of bio-inspired flapping wing micro air vehicles: theory and prototype”, Acta Mech. (2016). <http://dx.doi.org/10.1007/s00707-016-1757-4v>.
- [7]. D. Floreano, R.J. Wood, “Science, technology and the future of small autonomous drones”, Nature 521 (7553), 460–466, (2015).
- [8]. P. Cisar, R. Pinter, S. M. Cisar, and M. Gligorićević, “Principles of antidrone defense,” in Proc. 11th IEEE Int. Conf. Cognit. Infocommunications (CogInfoCom), pp. 000019–000026, (2020).
- [9]. 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, no. 15, p. 4953, (2021).
- [10]. G. Ding, Q. Wu, L. Zhang, Y. Lin, T. A. Tsiftsis, and Y.-D. Yao, “An amateur drone surveillance system based on the cognitive Internet of Things,” IEEE Commun. Mag., vol. 56, no. 1, pp. 29–35, (2018).
- [11]. M. Ezuma, F. Erden, C. K. Anjinappa, O. Ozdemir, and I. Guvenc, “MicroUAV detection and classification from RF fingerprints using machine learning techniques,” in Proc. IEEE Aerosp. Conf., pp. 1–13, (2019).
- [12]. M. Ezuma, F. Erden, C. K. Anjinappa, O. Ozdemir, and I. Guvenc, “Drone remote controller RF signal dataset,” Tech. Rep., (2020), doi: 10.21227/ss99-8d56.
- [13]. M. Ezuma, F. Erden, C. K. Anjinappa, O. Ozdemir, and I. Guvenc, “Detection and classification of UAVs using RF fingerprints in the presence of Wi-Fi and Bluetooth interference,” IEEE Open J. Commun. Soc., vol. 1, pp. 60–76, (2020)
- [14]. M. F. Al-Sa’ad, A. Al-Ali, A. Mohamed, T. Khattab, and A. Erbad, “RFbased drone detection and identification using deep learning approaches: An initiative towards a large open source drone database,” Future Gener. Comput. Syst., vol. 100, pp. 86–97, (2019).
- [15]. M. S. Allahham, M. F. Al-Sa’ad, A. Al-Ali, A. Mohamed, T. Khattab, and A. Erbad, “DroneRF dataset: A dataset of drones for RFbased detection, classification and identification,” Data Brief, vol. 26, Art. no. 104313, (2019). [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S235234091930667>.
- [16]. S. Al-Emadi and F. Al-Senaid, “Drone detection approach based on radiofrequency using convolutional neural network,” in Proc. IEEE Int. Conf. Informat., IoT, Enabling Technol. (ICIoT), pp. 29–34, (2020).
- [17]. E. S. Basan, M. D. Tregubenko, N. N. Mudruk, and E. S. Abramov, “Analysis of artificial intelligence methods for detecting drones based on radio frequency activity,” in Proc. 15th Int. Sci.-Tech. Conf. Actual Problems Electron. Instrum. Eng. (APEIE), pp. 238–242, (2021).
- [18]. R. Akter, V.-S. Doan, G. B. Tunze, J.-M. Lee, and D.-S. Kim, “RFbased UAV surveillance system: A sequential convolution neural networks approach,” in Proc. Int. Conf. Inf. Commun. Technol. Converg. (ICTC), pp. 555–558, (2020).
- [19]. S. Basak, S. Rajendran, S. Pollin, and B. Scheers, “Drone classification from RF fingerprints using deep residual nets,” in Proc. Int. Conf. Commun. Syst. Netw. (COMSNETS), pp. 548–555, (2021).
- [20]. M. Mokhtari, J. Bajcetic, B. Sazdic-Jotic, and B. Pavlovic, “RF-based drone detection and classification system using convolutional neural network,” in Proc. 29th Telecommun. Forum (TELFOR), pp. 1–4, (2021).
- [21]. D. K. Behera and A. Bazil Raj, “Drone detection and classification using deep learning,” in Proc. 4th Int. Conf. Intell. Comput. Control Syst. (ICICCS), pp. 1012–1016, (2020).

- 
- [22]. M. S. Allahham, T. Khattab, and A. Mohamed, "Deep learning for RFbased drone detection and identification: A multi-channel 1-D convolutional neural networks approach," in Proc. IEEE Int. Conf. Informat., IoT, Enabling Technol. (ICIOT), pp. 112–117, (2020).
- [23]. B. Sazdic-Jotic, I. Pokrajac, J. Bajcetic, and B. Bondzulich. VTI\_Droneset. Mendeley Data. [Online], (2020). Available: <https://data.mendeley.com/datasets/s6tggnp5n2/1>.
- [24]. L. Huang, M. Gao, C. Zhao, and X. Wu, "Detection of Wi-Fi transmitter transients using statistical method," in Proc. IEEE Int. Conf. Signal Process., Commun. Comput. (ICSPCC), pp. 1–5, (2013).
- [25]. S. Basak. Drone Signals. GitHub. [Online] (2021). Available: <https://github.com/sanjoy-basak/dronesignals>.
- [26]. Ender Ozturk, Fatih Erden, Ismail Guvenc, "RF-Based Low-SNR Classification of UAVs Using Convolutional Neural Networks," in ITU Journal on Future and Evolving Technologies, Issue 5 - Internet of Everything, pp 39-52, (2021).

### ABSTRACT

#### Application of CNN deep learning model and CFAR filtering technique for RF-based drone signal classification in noisy conditions

Currently, the use of small scale unmanned aerial vehicles, commonly known as drones, has increased due to the growing demand for remote interaction, contactless operations, and advanced technology. However, alongside the rising demand for drones across various sectors, their misuse for nefarious purposes has also escalated. Therefore, there is a need for drone monitoring systems to detect unauthorized drone usage. In this work, we propose a solution based on the radio frequency (RF) signature of drones. The data used in the research are control signals from 17 types of publicly disclosed drones. The proposed method addresses the issue of drone classification based on RF signatures; it maintains classification accuracy when the signal-to-noise ratio (SNR) decreases due to the presence of significant noise. In the experiments, we expanded the control signal data by adding white Gaussian noise to alter the SNR from  $-15$  dB to  $15$  dB with  $5$  dB increments. Power spectral density with threshold values were applied to create training images for the convolutional neural network (CNN). The proposed model achieved  $96\%$  accuracy at an SNR of  $-15$  dB and  $99.82\%$  accuracy in the high SNR region. From these results, we have confirmed that the proposed method not only has good classification capabilities but also high noise immunity.

**Keywords:** Drone classification; Convolutional neural networks; Spectrogram; Constant false alarm rate CFAR.