

NÂNG CAO ĐỘ CHÍNH XÁC PHÂN LOẠI CÁC HOẠT ĐỘNG CỦA CON NGƯỜI DỰA TRÊN ẢNH PHỔ CÓ DẤU HIỆU MICRO-DOPPLER VỚI SỰ TÁC ĐỘNG CỦA NHIỄU

Nguyễn Ngọc Bình, Nguyễn Thạc Dũng*
Trường Đại học thông tin liên lạc

Thông tin chung:

Ngày nhận bài: 07/10/2025

Ngày phân biện: 09/10/2025

Ngày duyệt đăng: 02/12/2025

*Tác giả chính:

dnthacdung4@gmail.com

DOI:

<https://doi.org/10.70879/e8LoeQEPS>

Title:

Enhance the classification accuracy of human activities based on micro-doppler signatures with the impact of noise.

Từ khóa:

micro-Doppler (m-D), DCNNs, nhiễu Gauss trắng, radar FMCW, entropy cực tiểu, phân loại hoạt động người.

Keywords: *micro-Doppler (m-D), DCNNs, white Gauss noise, FMCW radar, entropy minimization, Human Activity Recognition (HAR).*

TÓM TẮT: *Các mạng nơ-ron chập sâu (Deep Convolutional Neural Networks – DCNNs) ngày càng được sử dụng rộng rãi để phân loại các hoạt động của con người dựa trên ảnh phổ có dấu hiệu micro-Doppler (m-D) thu được từ radar. Tuy nhiên, hiệu suất phân loại của các mô hình thường bị giảm đáng kể khi tín hiệu m-D bị ảnh hưởng bởi nhiễu. Nghiên cứu này đề xuất một phương pháp mới nhằm cải thiện độ chính xác phân loại của DCNNs trong môi trường có sự tác động bởi nhiễu Gauss trắng. Phương pháp đề xuất giới thiệu một kỹ thuật lựa chọn ô cự ly (range bin) tối ưu dựa trên tiêu chí giá trị entropy cực tiểu (minimum entropy) của tín hiệu, nhằm tăng cường chất lượng tín hiệu đầu vào cho DCNN mà không cần thay đổi kiến trúc mạng. Kỹ thuật đề xuất được kiểm chứng thực nghiệm bởi 4 mô hình DCNNs hiện có trên tập dữ liệu mô phỏng (với 6 mức nhiễu khác nhau), cho thấy sự cải thiện đáng kể về độ chính xác phân loại.*

ABSTRACT: *Deep Convolutional Neural Networks (DCNNs) are increasingly being utilized for the classification of human activities based on micro-Doppler (m-D) signatures obtained from radar. However, the classification performance of these models typically degrades significantly when the m-D signal is affected by noise. This study proposes a novel method to improve the classification accuracy of DCNNs in environments impacted by white Gaussian noise. The proposed method introduces an optimal range-bin selection technique based on the minimum entropy criterion of the signal. This approach aims to enhance the input signal quality for the DCNN without requiring modifications to the network architecture. The proposed technique is experimentally validated by four existing DCNN models on a simulated dataset (with six different noise levels), demonstrating a significant improvement in classification accuracy.*

1. Giới thiệu vấn đề nghiên cứu

Trong những năm gần đây, việc phát hiện và phân loại chính xác hoạt động của con người đang nhận được nhiều sự quan tâm, đặc biệt trong các ứng dụng chăm sóc sức khỏe nhằm giám sát và cảnh báo kịp thời các hoạt động bất thường, tiềm ẩn nguy hiểm như té ngã do đột quỵ, nhồi máu cơ tim, đặc biệt đối với người cao tuổi và những người có nhu cầu

đặc biệt [1]. Các công nghệ truyền thống như thiết bị đeo (wearables) hoặc hệ thống camera gặp phải những hạn chế nhất định: thiết bị đeo gây bất tiện khi sử dụng liên tục, trong khi camera xâm phạm quyền riêng tư và hoạt động kém trong điều kiện thiếu sáng hoặc sương mù [2]. Do đó, các hệ thống dựa trên cảm biến radar, với khả năng hoạt động không tiếp xúc, bảo vệ quyền riêng tư và xuyên qua chướng

ngại vật, đang là một giải pháp thay thế hiệu quả.

Khi con người di chuyển và thực hiện các hoạt động hàng ngày, các chuyển động đồng thời của các bộ phận khác nhau, như: vung tay, xoay, cúi, gập người được định nghĩa là chuyển động vi mô so với chuyển động tịnh tiến của cơ thể. Các chuyển động vi mô này tạo ra các biến điệu tần số đặc trưng, được thể hiện dưới dạng các ảnh phổ thời gian-tần số [3]. Những ảnh phổ này, chứa các dấu hiệu đặc trưng duy nhất cho từng hoạt động và được sử dụng làm đầu vào cho các hệ thống phân loại [4].

Trong vài năm trở lại đây, DCNNs đã cho thấy hiệu quả vượt trội trong việc tự động trích xuất đặc trưng và phân loại các ảnh phổ m-D. Nhiều nghiên cứu đã chuyển từ các phương pháp trích xuất đặc trưng thủ công [5, 6] sang các mô hình học sâu. Các kiến trúc phức tạp và các kỹ thuật học chuyển giao (transfer learning) sử dụng các mạng nổi tiếng như ResNet, Alex-Net, và VGG-Net đã đạt được độ chính xác phân loại cao, trên 90% đối với các bộ dữ liệu tiêu chuẩn [8, 9]. Tuy nhiên, một hạn chế của các công trình hiện tại là hiệu suất của chúng thường được đánh giá trong điều kiện lý tưởng, với dữ liệu đầu vào có tỷ lệ tín trên tạp (SNR) cao. Trong các ứng dụng thực tế, tín hiệu radar thu về không thể tránh khỏi việc bị ảnh hưởng bởi nhiễu, chẳng hạn như nhiễu Gauss trắng. Khi nhiễu nền tăng, các dấu hiệu m-D đặc trưng được trích xuất trên ảnh phổ trở nên mờ nhạt và bị chìm dưới nền nhiễu, điều này làm giảm độ chính xác phân loại của các mô hình. Mặc dù việc sử dụng các mạng DCNN sâu hơn có thể duy trì độ chính xác phân loại ổn định cho các hành động bị ảnh hưởng bởi các mức nhiễu khác nhau, nhưng chúng sẽ cần một lượng lớn dữ liệu và chi phí xử lý đáng kể.

Xuất phát từ các kết quả nghiên cứu trên, có thể thấy, việc quá tập trung vào tối ưu hóa kiến trúc mô hình mà bỏ qua chất lượng dữ liệu đầu vào sẽ không đạt được độ chính xác cao. Do đó, một hướng tiếp cận hiệu quả hơn

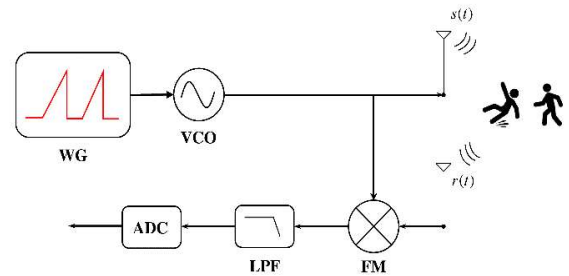
là tiền xử lý tín hiệu để nâng cao chất lượng ảnh phổ trước khi đưa vào bộ phân loại.

Để giải quyết vấn đề này, nghiên cứu tập trung đề xuất một thuật toán tiền xử lý dữ liệu nhằm lựa chọn chỉ số ô cự ly (range-bin) tối ưu dựa trên tiêu chí giá trị entropy cực tiểu [10] để nâng cao chất lượng phân loại các hoạt động của con người dưới sự tác động của nhiễu Gauss trắng. Hiệu quả của phương pháp đề xuất được đánh giá bằng bốn mô hình DCNNs hiện có, qua đó chứng minh khả năng cải thiện chất lượng phân loại một cách nhất quán dưới sáu mức nhiễu Gauss trắng khác nhau.

Cấu trúc của bài báo như sau: Mục 2 mô tả phương pháp thu thập và quy trình xử lý dữ liệu. Mục 3 giới thiệu thuật toán đề xuất. Các kết quả thực nghiệm và thảo luận được trình bày trong Mục 4. Kết luận được tóm tắt tại Mục 5.

2. Cơ sở lý thuyết và phương pháp nghiên cứu

2.1. Thu thập dữ liệu của radar FMCW



Hình 1. Sơ đồ khối của radar FMCW

Tổng quan sơ đồ khối của radar điều tần liên tục (Frequency modulated continuous wave - FMCW) được mô tả ở Hình 1. Bộ tạo dạng sóng (waveform-generator-WG) tạo tín hiệu điều khiển cho bộ dao động điều khiển điện áp (voltage-controlled oscillator-VCO) để phát ra tín hiệu radar FMCW radar có tần số thay đổi theo thời gian. Sau đó, tín hiệu được chia thành hai nhánh, nhánh thứ nhất đi đến anten phát (TX) để phát đến mục tiêu, nhánh còn lại được đưa đến bộ trộn ở máy thu.

Tín hiệu phát của radar FMCW có thể được biểu diễn như sau [11]:

$$S(t) = A_t \cos\left(2\pi\left(f_0 t + \frac{\Delta B}{2\tau} t^2\right)\right) \quad (1)$$

trong đó, ΔB là băng thông, τ là thời lượng mỗi chirp, A_t và f_0 lần lượt là biên độ

và tần số sóng mang của tín hiệu phát. Khi tín hiệu $S(t)$ được phát vào không gian, gặp mục tiêu sẽ có tín hiệu phản xạ về lại anten thu của radar. Lúc này, tín hiệu nhận được ở máy thu được biểu diễn như sau:

$$R(t) = A_r \cos(2\pi(f_0(t-t_d) + \frac{\Delta B}{2\tau}(t-t_d)^2)) \quad (2)$$

trong đó, $t_d = \frac{2(D_0 + vt)}{c}$ là thời gian trễ

của tín hiệu thu. D_0 là khoảng cách từ mục tiêu đến anten thu tại thời điểm $t=0$, v là vận vận tốc di chuyển của mục tiêu và c vận tốc ánh sáng.

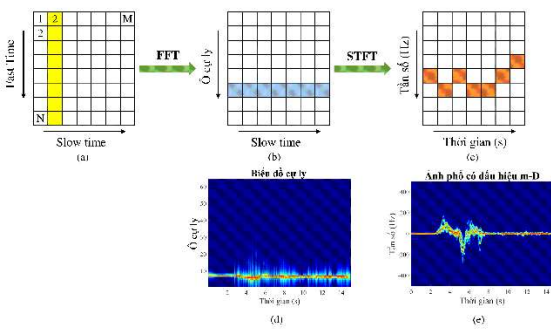
Tại máy thu, tín hiệu $R(t)$ được trộn với tín hiệu phát $S(t)$ tại bộ trộn tần số FM (frequency mixed-FM) và thông qua một bộ lọc thông thấp (low pass filter-LPF) để thu được tín hiệu IQ cho các bước xử lý tiếp theo

$$R_{IQ}(t) = A_m \exp\{2\pi(\frac{2f_0 D_0}{c} + (\frac{2f_0 \cdot v}{c} + \frac{2\Delta B \cdot D_0}{\tau})t)\} \quad (3)$$

trong đó, $A_m = \frac{A_r A_t}{2}$ là biên độ của tín hiệu

IQ thu được sau bộ lọc thông thấp. Bằng cách phân tích phổ m-D của IF signal, ta có thể phân loại được các hoạt động của con người dựa vào các dấu hiệu m-D.

2.2. Quy trình xử lý dữ liệu



Hình 2 Quy trình xử lý dữ liệu

Hình 2 trình bày chi tiết quy trình xử lý từ tín hiệu IF đến kết quả thu được là các range-Doppler hoặc m-D frames [12] của mục tiêu. Tín hiệu IF (raw data), theo dạng sóng răng cưa điển hình, bao gồm các chirps, trong đó một frame được xác định là tập hợp của M chirps. Đối với mỗi chirp, dữ liệu được lấy mẫu với số lượng các ô tần số (frequency bin)

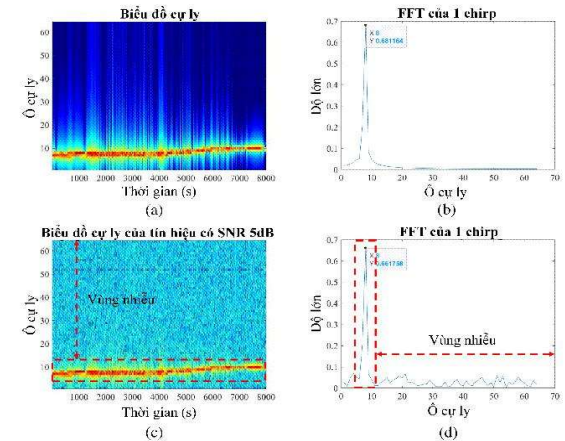
là N (Hình 2a). FFT lần thứ nhất được áp dụng trực tiếp cho mỗi chirp theo chiều fast-time, các ô cự ly tương ứng từng chirp sẽ được lưu trữ trong ma trận range-time (Hình 2b). Quá trình xử lý biến đổi Fourier này sẽ biểu thị cho sự hiện diện của các mục tiêu tại các khoảng cách khác nhau. Quá trình xử lý này được gọi là range-FFT và kết quả là ta sẽ thu được biểu đồ cự ly của mục tiêu tương ứng (Hình 2d).

Tiếp theo, các dấu hiệu m-D của mục tiêu thu được bằng cách sử dụng biến đổi Fourier thời gian ngắn (STFT) các ô cự ly theo chiều slow-time (Hình 2c). Kết quả sẽ thu được ảnh phổ có chứa các dấu hiệu m-D tương ứng với các hoạt động khác nhau của mục tiêu (Hình 2e).

Trong nội dung nghiên cứu, thay vì áp dụng STFT trên tất cả các ô cự ly hay với bất kỳ một giá trị chỉ số ô cự ly cụ thể nào; chúng tôi sẽ lựa chọn ra một vùng lân cận các chỉ số ô cự ly có giá trị cao nhất tập trung tối ưu vào đối tượng để tạo ra ảnh phổ m-D theo thời gian làm đầu vào phân loại của các DCNN.

2.3. Lựa chọn vùng ô cự ly tối ưu dựa vào giá trị entropy cục bộ


Như đã trình bày trong phần 2, các dấu hiệu m-D của mục tiêu được thu thập bằng cách sử dụng STFT trên tất cả các ô cự ly theo chiều slow-time. Tuy nhiên, đối với trường hợp tín hiệu có nhiễu thì việc lựa chọn các vùng ô cự ly tối ưu để trích xuất các dấu hiệu m-D là một trong những phương pháp giảm nhiễu hiệu quả.



Hình 3. Biểu đồ cự ly và FFT của một chirp cụ thể

Hình 3a,c biểu diễn biểu đồ cực ly của hoạt động đi bộ với dữ liệu sạch và dữ liệu có mức nhiễu là 5dB. Trong cả hai trường hợp, mục tiêu được phát hiện tại khoảng ô cực ly thứ 8 và dao động trong khoảng từ ô cực ly thứ 6 đến ô cực ly thứ 10 trong suốt quá trình chuyển động.

Hình 3b,d lần lượt biểu diễn kết quả FFT của 1 chỉ số ô cực ly cụ thể tương ứng với dữ liệu sạch và dữ liệu có mức nhiễu 5dB. Quan sát chi tiết, Hình 3d cho thấy mức năng lượng tập trung lớn nhất đại diện cho mục tiêu cũng xuất hiện ở ô cực ly thứ 8 (trùng tự Hình 3b), các đỉnh năng lượng ngoài vùng nẻđứt màu đỏ được xem là nhiễu. Do đó, trong nội dung tiếp theo, nhóm tác giả sẽ sử dụng giá trị entropy cực tiểu để xác định khoảng chỉ số ô cực ly tối ưu nhằm loại bỏ các thành phần nhiễu không mong muốn. Hình 4 trình bày sơ đồ tóm tắt quy trình thuật toán đề xuất.



Hình 4. Sơ đồ tóm tắt quy trình thuật toán

2.3.1. Thông tin entropy

a. Định nghĩa

Cho dãy phân bố xác suất rời rạc $p = (p_1, p_2, \dots, p_n)$, theo định nghĩa entropy thông tin, entropy thông tin của nó có thể viết là $H(p) = -\sum_i p_i \ln p_i$, trong đó $i = 1, 2, \dots, n$ đại

diện cho tất cả các giá trị có thể có của biến ngẫu nhiên đầu ra và p_i biểu thị xác suất của từng giá trị. Bằng cách tương tự, trong phân bố tần số thời gian của tín hiệu, nếu phân bố tần số của tín hiệu tại một thời điểm nhất định, $p = (p_1, p_2, \dots, p_F)$ được coi là một chuỗi phân bố xác suất, khi đó phân bố xác suất tần số của tín hiệu tại thời điểm t có thể thu được là

$$p_t(f) = \frac{|X(t, f)|^2}{\int_{-\infty}^{\infty} |X(t, f)|^2 df} \quad (4)$$

trong đó $X(t, f)$ là mức năng lượng của tín hiệu tại thời điểm (t, f) . Khi đó tại thời điểm t , entropy thông tin của tần số chứa trong tín hiệu có thể được viết là

$$H_t(p_t) = -\sum_F p_t \ln p_t \quad (5)$$

trong đó, $H_t(p_t)$ được gọi là hàm entropy, dùng để đo và biểu thị entropy thông tin. F là đơn vị của độ phân giải tần số và giá trị của nó liên quan đến độ dài thời gian của tín hiệu và thuật toán phân tích tần số thời gian.

b. Tiêu chí entropy cực tiểu

Phân phối tần số thời gian từ STFT của tín hiệu có thể được hiểu là chuỗi phân phối xác suất. Và phân bố xác suất của đơn vị phân giải tần số tại thời điểm t có thể được định nghĩa là:

$$p_t(u) = \frac{|X_{\text{STFT},r}(t, u)|^2}{\int_{-\infty}^{\infty} |X_{\text{STFT},r}(t, u)|^2 du} \quad (6)$$

trong đó, $X_{\text{STFT},r}(t, u)$ là STFT của tín hiệu đầu vào, $x(t)$, với khoảng chỉ số ô cực ly được chọn là r . Do đó, entropy thông tin có thể được biểu diễn dưới dạng:

$$H_t(p_t) = -\int_{-\infty}^{\infty} p_t(u) \cdot \ln p_t(u) du \quad (7)$$

Để thuận tiện cho việc tính toán, (6) và (7) có thể được chuyển đổi thành dạng rời rạc dưới dạng:

$$p_m(k) = \frac{|X_{\text{STFT},r}(m, k)|^2}{\sum_{k=1}^M |X_{\text{STFT},r}(m, k)|^2} \quad (8)$$

$$H_m = -\sum_{k=1}^M p_m(k) \cdot \ln p_m(k) \quad (9)$$

Trong trường hợp này, H_m là entropy thông tin của phân bố tần số tại thời điểm t sau STFT. Giá trị entropy thông tin trung bình thu được tại tất cả các thời điểm của tín hiệu được biểu diễn

$$H_{avg} = \frac{\sum_{m=1}^M H_m}{M} \quad (10)$$

Vì giá trị của H_{avg} có thể phản ánh sự tổng hợp năng lượng của phân bố tần số thời gian của tín hiệu, bằng cách tìm kiếm entropy thông tin cực tiểu, có thể xác định vùng chỉ số ô cụ lý tối ưu để đạt được mức tổng hợp năng lượng cao nhất. Do đó, để có được sự tổng hợp tần số thời gian tốt nhất, tiêu chí về entropy thông tin cực tiểu được sử dụng cho STFT bằng cách tìm giá trị H_{avg} nhỏ nhất trong phương trình (10).

2.3.2. Lựa chọn khoảng ô cụ lý tối ưu

Tại mỗi chirp, sau khi thực hiện FFT lần thứ nhất, chúng tôi sẽ xác định chỉ số ô cụ lý có giá trị cao nhất (idx_m). Tiếp theo, $r = \{0, 1, 2, 3\}$ là một chuỗi giá trị các khoảng chỉ số ô cụ lý được lựa chọn để xét (các giá trị này được lựa chọn dựa vào thực nghiệm). Sau đó, r trở thành thư viện hàm chỉ số ô cụ lý cho phép biến đổi STFT và mỗi phần tử trong thư viện được lựa chọn lần lượt để thực hiện STFT. Tương ứng với các giá trị của r , giá trị chỉ số ô cụ lý được lựa chọn là: $[idx_m - i, idx_m, idx_m + i]$ với $i = 1:r$.

Thuật toán STFT cho tín hiệu đầu vào tại idx_m có thể được viết là:

$$STFT_{idx_m}(t, f) = \int_{-\infty}^{+\infty} x(t)w(t - \tau) \exp(-j\omega\tau) dt \quad (11)$$

trong đó, $x(t)$ là tín hiệu đầu vào và $w(t - \tau)$ là hàm cửa sổ. Giá trị STFT thu được đối với vùng ô cụ lý được lựa chọn tương ứng với hàm r được xác định:

$$STFT_r(t, f) = \sum_{idx_m-i}^{idx_m+i} STFT_{idx_m}(t, f) \quad (12)$$


Giá trị $STFT_r(t, f)$ thu được sẽ được tính toán mức entropy theo phương trình (10) để lựa chọn ra vùng chỉ số ô cụ lý tối ưu nhất.

3. Kết quả thực nghiệm và thảo luận

3.1. Mô tả tập dữ liệu

Tập dữ liệu nhiễu được mô phỏng bởi phần mềm Simalator [13], bao gồm 11 hoạt động hàng ngày của con người: đi bộ, xoay tại chỗ, đứng, đá, cúi xuống nhặt 1 vật, đứng lên khi đang ngồi trên ghế, ngồi xuống ghế khi đang đứng, đang ngồi ghế đứng dậy, đi bộ đến ghế và ngồi xuống, ngã khi đang đi bộ và từ vị trí ngã đứng dậy để đi bộ; được thu thập bằng cách sử dụng radar FMCW; với tần số sóng mang là 24GHz (K-Band), băng thông và thời lượng mỗi chirp lần lượt là 400MHz và 1ms. Tín hiệu thô được lấy mẫu với tần số lấy mẫu trên 1 chirp là 128 mẫu. Radar được bố trí cách mặt đất 1m, vị trí từ radar đến đến tượng là 3m. 11 hành động khác nhau được thực hiện và lặp lại 60 lần với các góc lệch khác nhau lần lượt $[-90^0, -45^0, 0^0, 45^0, 90^0]$. Thời gian cho mỗi lần thực hiện là từ 8s đến 15s đối với từng loại hành động cụ thể. Ngoài ra, để sát với điều kiện thực tế và tăng tính thử thách cho mô hình, nhiễu Gauss trắng (white Gauss Noise) được thêm vào tập dữ liệu thu được với các mức SNR (signal-to-noise-ratio) khác nhau trong khoảng từ -15dB đến 10dB. Kết quả thu được, tập dữ liệu tín hiệu thô bao gồm 19800 mẫu (11 hoạt động x 5 góc lệch x 60 lần lặp x 6 mức nhiễu).

3.2. Kết quả lựa chọn vùng ô cụ lý tối ưu



Hình 5. Ảnh phổ với các khoảng ô cụ lý khác nhau tại mức SNR là 5 dB

Thư viện khoảng ô cự ly có giá trị $r = \{0, 1, 2\}$ được lựa chọn dựa trên thực nghiệm. Hình 5 biểu diễn ảnh phổ tương ứng với các khoảng ô cự ly được chọn khác nhau ở mức SNR 5 dB. Hình 5a biểu diễn ảnh phổ của hoạt động ngã ở mức SNR 5 dB khi áp dụng STFT trên toàn bộ các ô cự ly của range-FFT. Hình 5(b-d) thể hiện ảnh phổ của cùng hoạt động ngã nhưng với các lựa chọn khoảng ô cự ly khác nhau, lần lượt là $r = 0$, $r = 1$ và $r = 2$. Quan sát Hình 5b, với $r = 0$ (tương ứng với chỉ chọn 1 giá trị ô cự ly cực đại), nhiễu đã được loại bỏ và các dấu hiệu m-D cũng trở nên rõ ràng hơn so với ảnh phổ ban đầu ở mức SNR là 5dB (Hình 5a). Tuy nhiên, một số dấu hiệu m-D nhỏ và chi tiết hơn vẫn chưa được thể hiện rõ ràng như trong Hình 5c (vùng nét đứt được khoanh tròn màu đỏ). Đối với Hình 5d, với $r = 2$, các dấu hiệu m-D cũng được cải thiện rõ ràng nhưng vẫn bị ảnh hưởng bởi nhiễu. Với $r = 1$ (Hình 5c), mức năng lượng và các dấu hiệu m-D được thể hiện rõ ràng và đầy đủ nhất, đặc biệt là ở các thành phần thân và chi trên ảnh phổ thu được.

Ngoài ra, các kết quả được thể hiện trong Bảng 1 cũng cho ta thấy giá trị entropy thông tin đạt cực tiểu tại $r = 1$, tương ứng với vùng ô cự ly được xác định là 3. Do đó, khoảng ô cự ly tối ưu được xác định là 3. Một kết quả tương tự với mức nhiễu 0dB cũng được thể hiện trong Bảng 1.

Bảng 1. Thông tin entropy với các khoảng ô cự ly được chọn khác nhau

	Ảnh nhiễu	r = 0	r = 1	r = 2	r = 3
Ngã (5dB)	3.77	2.46	2.34	2.5	2.63
Đi bộ (5dB)	4.2	3.03	2.88	2.94	3.06
Ngã (0dB)	5.37	3.46	2.96	3.22	3.42
Đi bộ (0dB)	5.4	3.61	3.3	3.37	3.66

3.3. Kết quả phân loại các hoạt động với hai tập dữ liệu

Trong phần này, bốn mạng DCNNs, bao gồm RepVGG [14], MobileNet [15], ResNet [16] và DopDense [17] được sử dụng để phân loại các hành vi của con người trên cả hai tập dữ liệu (tập dữ liệu nhiễu và tập dữ liệu khử nhiễu). Quá trình huấn luyện được thực hiện bởi một máy tính có cấu hình phần cứng Intel (R) Core™ i5-12400F 2.5Ghz, RAM 32 GB và GPU RTX 3060Ti. Kích thước batch size sử dụng là 16 với tốc độ huấn luyện là 0.0001 trong 20 lần lặp (epoch). Phương pháp xác thực chéo năm lần được sử dụng để đánh giá sự cải thiện về độ chính xác phân loại.

Các kết quả phân loại được thực hiện trên hai bộ dữ liệu (tập dữ liệu nhiễu và tập dữ liệu khử nhiễu) bởi bốn mạng DCNNs được thể hiện trong Bảng 2. Tỷ lệ phân loại chính xác của cả bốn mạng đã được cải thiện đáng kể đối với tập dữ liệu đã được khử nhiễu, chứng minh rằng thuật toán đề xuất thực sự góp phần nâng cao độ chính xác nhận dạng các hoạt động của con người. Cụ thể, độ chính xác phân loại của tất cả các mô hình được cải thiện khoảng trên 4% đối với tập dữ liệu đã được khử nhiễu, đặc biệt là RepVGG với độ chính xác tăng gần 10%.

Bảng 2. Kết quả độ chính xác phân loại

	Tập dữ liệu có nhiễu	Tập dữ liệu đã được khử nhiễu
RepVGG	80.9	90.53
MobileNet	90.61	95.37
ResNet	91.94	96
DopDenseNet	88.83	96.65

Kết quả phân tích cho thấy RepVGG đặc biệt nhạy cảm với nhiễu Gauss (80.9%), trái ngược với ResNet, MobileNet và DopDenseNet (88% - 91%). Nguyên nhân cốt lõi nằm ở kiến trúc mô hình: RepVGG, sau tái tham số hóa, có cấu trúc suy luận "trơn" (plain) thiếu kết nối tắt (skip connection), khiến nhiễu bị khuếch đại và làm suy giảm đặc trưng. Ngược lại, ba mô hình còn lại sở

hữu cơ chế kết nối tất/dày đặc, giúp bảo toàn thông tin và tăng cường khả năng kháng nhiễu nội tại. Do đó, khi thuật toán đề xuất loại bỏ nhiễu, RepVGG cho thấy sự "phục hồi" hiệu suất ấn tượng nhất (tăng lên 90.53%). Dữ liệu sạch cho phép mô hình phát huy tối đa lợi thế của bộ trọng số học được (từ huấn luyện đa nhánh) trên cấu trúc suy luận VGG-like hiệu quả. Trong khi đó, các mô hình vốn đã mạnh mẽ chỉ cho thấy sự tinh chỉnh hiệu suất biên (ví dụ: ResNet đạt 96%), minh chứng cho khả năng xử lý nhiễu nội tại của chúng.

4. Kết luận

Bài báo này đã trình bày một thuật toán tiền xử lý dữ liệu, sử dụng phương pháp lựa chọn ô cụ lý tối ưu dựa trên tiêu chí entropy cực tiểu, để khử nhiễu tín hiệu m-D thu được từ radar FMCW. Phương pháp này được thiết kế nhằm nâng cao hiệu suất phân loại các hoạt động hàng ngày của con người. Kết quả thực nghiệm đã chứng minh tính hiệu quả của thuật toán đề xuất. Khi áp dụng trên tập dữ liệu mô phỏng, phương pháp tiền xử lý đề xuất giúp cải thiện độ chính xác phân loại lên tới gần 10% so với việc sử dụng dữ liệu gốc (tập dữ liệu chưa khử nhiễu). Thuật toán đề xuất sẽ được tối ưu hóa và kiểm chứng trong các nghiên cứu tiếp theo đối với các loại nhiễu thực tế trong quá trình thu thập dữ liệu từ radar.

Tài liệu tham khảo

1. W. Li, T. H. M. Keegan, B. Sternfeld, S. Sidney, C.P. Quesenberry, and J. L. Kelsey, "Outdoor falls among middle-aged and older adults: a neglected public health problem," *American Journal of Public Health*, vol. 96, no. 7, pp. 1192-1200, July 2006.
2. R. Igual, C. Medrano, and I. Plaza, "Challenges, issues and trends in fall detection systems," *BioMedical Engineering OnLine*, vol. 12, no.1, p.66, 2013.

3. V. Chen, F. Li, S.-S. Ho, and H. Wechsler, "Micro-doppler effect in radar: phenomenon, model, and simulation study," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 42, no. 1, pp. 2–21, Jan 2006.
4. Y. Kim and H. Ling, "Human activity classification based on microdoppler signatures using a support vector machine," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 5, pp.1328–1337, May 2009.
5. Z. Sun, J. Wang, J. Sun, and P. Lei, "Parameter estimation method of walking human based on radar micro-Doppler," in *2017 IEEE Radar Conference (RadarConf)*, 2017.
6. F. Fioranelli, M. Ritchie, S. Z. Gurbuz, and H. Griffiths, "Feature Diversity for Optimized Human Micro-Doppler Classification Using Multistatic Radar," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 53, pp. 640–654, April 2017.
7. Y. Kim and T. Moon, "Human Detection and Activity Classification Based on Micro-Doppler Signatures Using Deep Convolutional Neural Networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, pp.8–12, January 2016.
8. H. Du, Y. He, and T. Jin, "Transfer Learning for Human Activities Classification Using Micro-Doppler Spectrograms," in *2018 IEEE International Conference on Computational Electromagnetics (ICCEM)*, 2018.
9. F. A. Jibrin, A. Abdulaziz, A. S. Muhammad, A. D. Usman, and Y. Jibril, "Indoor Human Activity Classification Based on FMCW Radar Micro-Doppler Signatures and Deep-Learning Networks," in *2021 1st International*

- Conference on Multidisciplinary Engineering and Applied Science (ICMEAS), 2021.
10. Bing Deng, Dan Jin, Junbao Luan, "Adaptive Short-Time Fractional Fourier Transform Based on Minimum Information Entropy," in *Journal of Beijing Institute of Technology*, 30(3): pp.265-273, 2021.
 11. V. Winkler, "Range doppler detection for automotive FMCW radars," in *2007 European Microwave Conference. IEEE*, 2007.
 12. Fioranelli, H.F.; Griffiths, M.R.; Balleri, "A. Micro-Doppler Radar and Its Applications; The Institution of Engineering and Technology", Stevenage, UK, 2020
 13. S. Vishwakarma, W. Li, C. Tang, K. Woodbridge, R. Adve, and K. Chetty, "SimHumalator: An Open-Source End-to-End Radar Simulator for Human Activity Recognition," *IEEE Aerospace and Electronic Systems Magazine*, vol. 37, pp. 6–22, March 2022.
 14. X. Ding, X. Zhang, N. Ma, J. Han, G. Ding, and J. Sun, "Repvgg: making vgg-style convnets great again," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 13733-13742, 2021.
 15. M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," 2018.
 16. K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," 2015.
 17. Le, Hai & Hoang, Van-Phuc & Doan, Sang & Le, Dai, "Dop-DenseNet: Densely Convolutional Neural Network-Based Gesture Recognition Using a Micro-Doppler Radar", *Journal of Electromagnetic Engineering and Science*. 22. 335-343. 10.26866/jees.2022.3.r.95.