

Đề xuất mạng nơ-ron học sâu ARTRNet cho bài toán tự động nhận dạng mục tiêu ra đa FMCW

Nguyễn Văn Trà^{1*}, Nguyễn Trường Sơn¹, Nguyễn Hoàng Việt²

¹Viện Ra đa, Viện Khoa học và Công nghệ quân sự;

²Nhà máy Z181, Tổng cục Công nghiệp Quốc phòng.

*Email: sinhviennaolinh2000@gmail.com

Nhận bài: 02/8/2022; Hoàn thiện: 16/9/2022; Chấp nhận đăng: 12/12/2022; Xuất bản: 28/12/2022.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.84.2022.24-31>

TÓM TẮT

Trong bài báo này, chúng tôi đề xuất một mạng nơ-ron học sâu (đặt tên là ARTRNet) có chức năng tự động nhận dạng mục tiêu ra đa dựa trên dấu hiệu đặc trưng diện tích phản xạ hiệu dụng và tần số Doppler của mục tiêu trong tín hiệu phản xạ. Dữ liệu thô đầu vào mạng nơ-ron ARTRNet được định dạng 3D với các thông tin cự ly – phương vị – tần. Tác giả đề xuất một cải tiến hàm mất mát trong quá trình huấn luyện mạng nơ-ron giúp nâng cao hiệu năng nhận dạng mục tiêu của mô hình.

Từ khóa: FMCW; Radar; Range; Azimuth; Doppler; Object detection; Deep learning.

1. ĐẶT VẤN ĐỀ

Ra đa điều tần tuyến tính liên tục (FMCW: Frequency Modulated Continuous Wave) đang được sử dụng rộng rãi trong các ứng dụng dân sự cũng như lĩnh vực an ninh, quốc phòng [1]. Phát hiện và tự động nhận dạng mục tiêu ra đa (RATR: Radar Automatic Target Recognition) là hai lĩnh vực nghiên cứu chính trong lĩnh vực xử lý tín hiệu ra đa hiện đại [2]. Chức năng nhận dạng mục tiêu ra đa đóng vai trò quan trọng trong tác chiến thực tế. Thông qua chức năng này, kiểu loại mục tiêu được bổ sung vào thông tin mục tiêu bên cạnh các tham số cự ly, phương vị, tốc độ và hướng di chuyển góp phần hỗ trợ cho các hoạt động tác chiến.

Gần đây, các nghiên cứu áp dụng mạng nơ-ron nhân tạo cho bài toán nhận dạng mục tiêu ra đa đang thu hút được sự quan tâm từ cộng đồng nghiên cứu [2]. Với sự phát triển mạnh mẽ của các thuật toán trí tuệ nhân tạo (AI: Artificial Intelligence) và công nghệ sản xuất chip điện tử tạo điều kiện giải quyết các bài toán phức tạp mà trước đây không thể giải quyết được bằng các phương pháp truyền thống, trong đó có bài toán tự động nhận dạng mục tiêu ra đa. Việc áp dụng trí tuệ nhân tạo trong bài toán phát hiện và tự động nhận dạng mục tiêu ra đa là một hướng mới và phù hợp với xu hướng phát triển của khoa học công nghệ.

Nâng cao chất lượng mạng nơ-ron chính là quá trình giải quyết bài toán làm tăng chính xác, giảm thời gian tính toán và giảm số lượng tham số của mô hình. Để giải quyết vấn đề này, các nhà nghiên cứu tập trung vào một số hướng nghiên cứu như: lựa chọn tham số đặc trưng tín hiệu ra đa để tiến hành nhận dạng [4], tối ưu hóa mô đun trích xuất đặc trưng (backbone) [5, 6], tối ưu hóa mô đun phát hiện và phân vùng vật thể (detection head) [7], tối ưu hóa hàm mất mát [8, 9].

Trong bài báo này, chúng tôi tập trung nghiên cứu lý thuyết nhận dạng mục tiêu ra đa, đề xuất một mạng nơ-ron học sâu có chức năng tự động nhận dạng mục tiêu ra đa. Bên cạnh đó, chúng tôi cũng đề xuất cải tiến hàm mất mát sử dụng trong quá trình huấn luyện để nâng cao hiệu năng nhận dạng mục tiêu của mạng nơ-ron đề xuất.

Dữ liệu ra đa được sử dụng để tiến hành huấn luyện và kiểm tra mạng nơ-ron là bộ dữ liệu thô sau tuyến xử lý số sơ bộ của ra đa FMCW. Dữ liệu ra đa này bao gồm các thông tin: cự ly, phương vị và tốc độ mục tiêu được đóng gói ở dạng 3D thể hiện trên hai trục tọa độ cự ly – phương vị và cự ly – tần số.

Trong nội dung bài báo, chúng tôi đề xuất một cải tiến hàm mất mát được sử dụng trong quá

trình huấn luyện mạng nơ-ron của bài toán phát hiện vật thể (Object Detection) nhằm nâng cao hiệu năng nhận dạng mục tiêu của mô hình đề xuất. Nội dung tiếp theo của bài báo được trình bày theo bố cục sau. Phần 2 mô tả lý thuyết nhận dạng mục tiêu ra đa, hàm mất mát và cơ sở đánh giá hiệu năng của mạng nơ-ron giải quyết bài toán nhận dạng mục tiêu. Phần 3 trình bày về cấu trúc mạng nơ-ron ARTRNet đề xuất. Nội dung kết quả nhận dạng và thảo luận được trình bày trong phần 4. Cuối cùng, phần 5 trình bày kết luận và hướng phát triển tiếp theo của bài báo.

2. CƠ SỞ LÝ THUYẾT

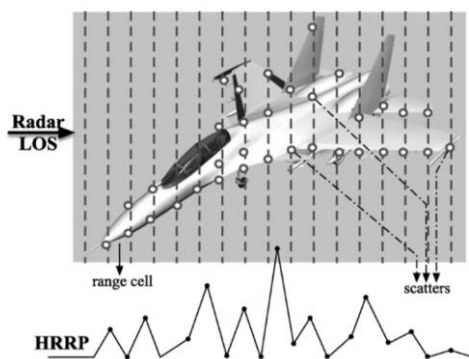
2.1. Lý thuyết nhận dạng mục tiêu ra đa

Mỗi kiểu loại mục tiêu ra đa thường có những đặc trưng riêng biệt, các đặc trưng này được thể hiện trong tín hiệu phản xạ về từ mục tiêu của ra đa. Dựa vào sự khác nhau trong tín hiệu phản xạ về của từng mục tiêu mà bộ nhận dạng mục tiêu sẽ tiến hành phân loại và nhận dạng. Các đặc trưng trong tín hiệu phản xạ như: diện tích phản xạ hiệu dụng (RCS: Radar Cross Section), tần số Doppler, micro-Doppler và thông tin về pha là những dấu hiệu thường được sử dụng để tiến hành nhận dạng mục tiêu [4].

Diện tích phản xạ hiệu dụng ra đa được định nghĩa là diện tích bức xạ tương đương, phản xạ tất cả năng lượng truyền đến nó và tạo nên tại điểm thu mật độ dòng công suất như đối với mục tiêu thực. RCS là một đặc tính đặc biệt quan trọng để xây dựng mô hình tín hiệu phản xạ từ mục tiêu, được mô tả khái quát ở công thức (1). Với những đài ra đa có độ phân giải cao về cự ly (HRRP: High Resolution Range Profile), thông tin tín hiệu phản xạ từ mục tiêu biểu diễn trên miền biên độ - thời gian hay đặc trưng phổ biểu diễn trên miền tần số - thời gian thông qua phép biến đổi STFT (Short-time Fourier Transform) mang đặc trưng diện tích phản xạ hiệu dụng của mục tiêu là cơ sở thực hiện bài toán phân loại mục tiêu [2, 10]. Trên hình 1 là ví dụ tín hiệu phản xạ về từ mục tiêu của một đài ra đa có độ phân giải cao về cự ly. Mỗi kiểu loại mục tiêu sẽ có ảnh chân dung biên độ - thời gian riêng, chính sự khác nhau về đặc trưng tín hiệu này là cơ sở để mạng nơ-ron tiến hành phân loại.

$$\sigma = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|E_s|^2}{|E_i|^2} \quad (1)$$

Trong đó: R là cự ly giữa ra đa và mục tiêu, E_s là độ lớn trường tán xạ điện từ tại ra đa, E_i là độ lớn trường chiếu xạ điện từ tại mục tiêu.




Hình 1. Tín hiệu phản xạ về từ mục tiêu của của ra đa có độ phân giải cao về cự ly.

Dấu hiệu độ dịch tần số Doppler, micro-Doppler trong tín hiệu phản xạ về từ mục tiêu cũng một nhân tố quan trọng được sử dụng để nhận dạng mục tiêu ra đa [11, 12]. Với một mục tiêu chuyển động, ngoài thành phần chuyển động tịnh tiến của cả mục tiêu, các thành phần chuyển động khác gây nên các thành phần micro-Doppler. Ví dụ, với mục tiêu người đi bộ, sự di chuyển

của các cánh tay, bước chân, lắc đầu sẽ hình thành tần số micro-Doppler. Trên hình 2 là mô tả kết quả phân tích dấu hiệu độ dịch tần micro-Doppler của 3 kiểu loại mục tiêu: người đi xe đạp, người đi bộ, xe ô tô thông qua phép biến đổi STFT. Giá trị tần số Doppler, micro-Doppler được tạo ra do sự chuyển động của mục tiêu được thể hiện qua công thức (2).

$$f = \frac{2v \cdot \cos(\theta)}{\lambda} \quad (2)$$

Trong đó: f là tần số Doppler, v là vận tốc của mục tiêu, θ là góc của hướng chuyển động mục tiêu và trục của bức sóng chính, λ là bước sóng của tín hiệu phát.



Hình 2. Phân tích dấu hiệu độ dịch tần số micro-Doppler qua phép biến đổi STFT (hình bên trái cùng là kết quả phân tích tín hiệu của mục tiêu người đi xe đạp, hình ở giữa là mục tiêu người đi bộ, hình bên phải là mục tiêu xe ô tô).

Thông tin về pha cũng là một tham số quan trọng được sử dụng để tiến hành nhận dạng mục tiêu. Trong công trình [13], nhóm tác giả đã tiến hành phân loại mục tiêu người đi bộ và phương tiện cơ giới trong ra đa điều tần tuyến tính liên tục dựa vào độ lệch pha tín hiệu nhận được giữa các chấn tử của anten thu.

2.2. Hàm mất mát

Mạng nơ-ron được huấn luyện thông qua sử dụng các thuật toán tối ưu để điều chỉnh các hệ số trọng lượng theo một quy luật điều chỉnh nhất định (thường là phương pháp Gradient Descent). Là một phần của thuật toán tối ưu, giá trị lỗi của trạng thái mô hình hiện tại phải được tính toán một cách liên tục. Hàm mất mát (loss function) chính là một hàm toán học để tính giá trị lỗi, từ giá trị lỗi này các thuật toán tối ưu sẽ tiến hành cập nhật lại các trọng số mạng nơ-ron để đảm bảo giá trị lỗi đó giảm dần trong các lần đánh giá tiếp theo. Lựa chọn hàm mất mát phù hợp trong quá trình huấn luyện sẽ góp phần nâng cao hiệu năng cho mô hình mạng nơ-ron học sâu.

Trong bài toán phát hiện vật thể, hàm mất mát thường được tạo thành từ hai thành phần chính: lỗi do phân loại (classification loss) và lỗi xác định vị trí (localization loss) [14]. Giá trị lỗi xác định vị trí L_{Box} được tính toán theo [16], hàm Cross Entropy được sử dụng để tính toán lỗi phân loại vật thể L_{Cls} .

$$L_{Total} = L_{Box} + L_{Cls} \quad (3)$$

Trong đó: L_{Total} : Lỗi tổng hợp của mô hình;

L_{Box} : Lỗi xác định vị trí;

L_{Cls} : Lỗi phân loại vật thể.

2.3. Cơ sở đánh giá hiệu năng của mạng nơ-ron

Chỉ số độ chính xác trung bình của tất cả class mAP (Mean Average Precision) được sử dụng để đánh giá hiệu năng của các mô hình phát hiện vật thể như: Fast R-CNN, YOLO (You Only Look One), Mask R-CNN,... Trong công trình nghiên cứu này, chúng tôi cũng sử dụng giá trị

mAP là cơ sở để đánh giá hiệu năng nhận dạng mục tiêu của mạng nơ-ron đề xuất. Giá trị mAP được tính theo công thức (4).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{4}$$

Trong đó, giá trị độ chính xác trung bình (AP: Average Precision) được tính toán thông qua tham số độ chính xác (precision) và độ bao phủ (recall) như thể hiện ở công thức (5)

$$AP = \sum_{k=0}^{k=n-1} (\text{Recall}_{(k)} - \text{Recall}_{(k+1)}) * \text{Precision}_{(k)} \tag{5}$$

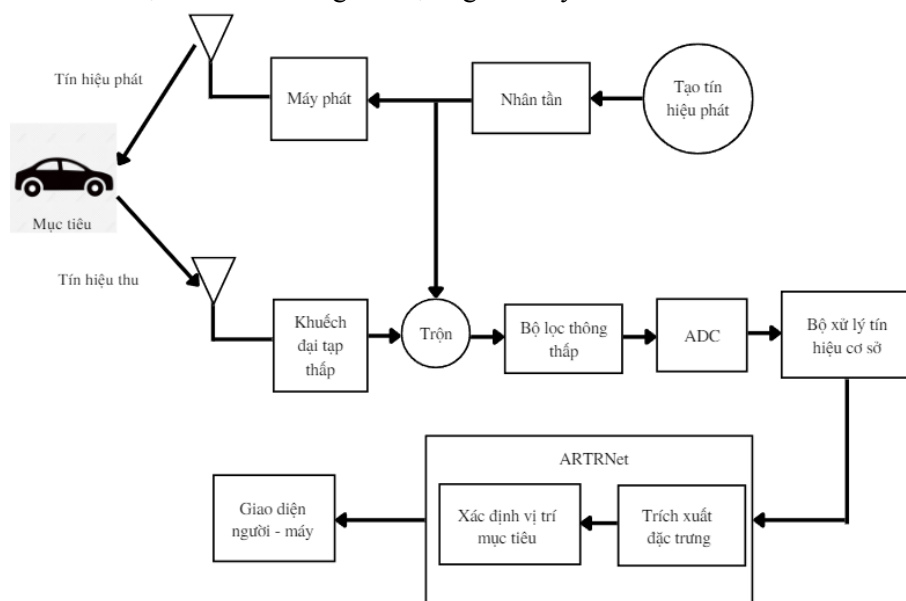
Các tham số precision và recall được tính thông qua ma trận xáo trộn (confusion matrix) và chỉ số IoU (Intersection Over Union). Trong quá trình đánh giá hiệu năng mạng nơ-ron đề xuất của bài báo, tác giả sử dụng giá trị ngưỡng IoU để tính toán giá trị Recall và Precision là 0.3.

3. MÔ HÌNH MẠNG NƠ-RON NHẬN DẠNG MỤC TIÊU RA ĐA

3.1. Vị trí vai trò mạng nơ-ron trong tuyến xử lý tín hiệu ra đa FMCW

Vị trí của mạng nơ-ron học sâu ARTRNet trong tuyến xử lý tín hiệu ra đa FMCW được mô tả trên hình 3. Tín hiệu đầu ra máy thu qua bộ lọc thông thấp và bộ biến đổi tín hiệu tương tự sang số (ADC: Analog Digital Converter) sẽ được đưa đến bộ xử lý sơ bộ. Tại đây, thông qua các thuật toán tính cự ly và phương vị, dữ liệu đầu ra được đóng gói ở dạng ba chiều cự ly – phương vị – tần số và tiếp tục được đưa đến mạng nơ-ron ARTRNet để tiến hành nhận dạng.

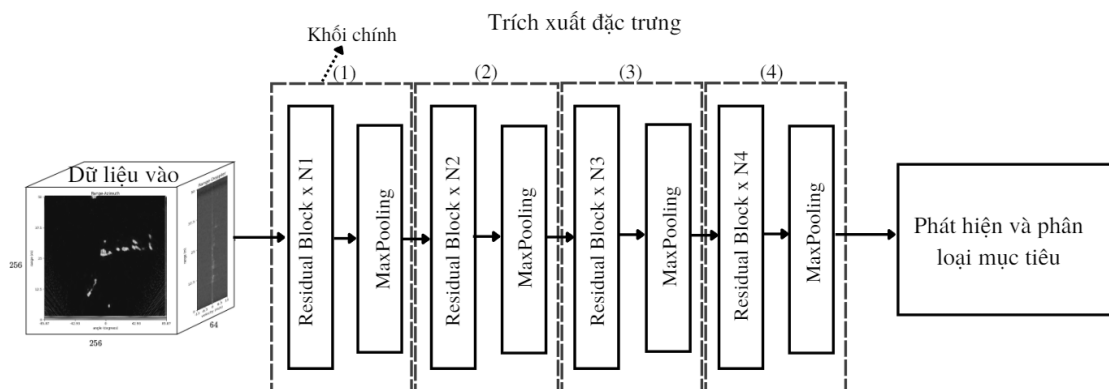
Mạng nơ-ron học sâu ARTRNet đề xuất bao gồm hai phần chính: backbone có nhiệm vụ trích xuất đặc trưng và detection head có nhiệm vụ phát hiện, xác định vị trí và phân loại mục tiêu. Mô đun backbone là một mạng nơ-ron tích chập (CNN: Convolutional Neural Network) được xây dựng tương tự như mạng CNN ResNet [15]. Bản đồ đặc trưng (feature map) trích xuất từ backbone được đưa đến mô đun detection head để phát hiện, xác định vị trí và phân loại mục tiêu. Detection head được xây dựng theo nguyên lý bộ phát hiện vật thể một bước (one-stage Detectors) theo cấu trúc mạng YOLO. Tín hiệu giả video cùng thông tin kiểu loại mục tiêu được chuyển đến và hiển thị trên màn hình giao diện người máy.



Hình 3. Minh họa vị trí mô đun tự động nhận dạng mục tiêu ARTRNet trong tuyến xử lý tín hiệu ra đa FMCW.

3.2. Mạng nơ-ron đề xuất

Trong nghiên cứu này, nhóm tác giả xây dựng một mạng nơ-ron học sâu có chức năng tự động nhận dạng mục tiêu ra đa và được đặt tên là ARTRNet, sơ đồ chức năng mạng nơ-ron ARTRNet thể hiện trên hình 4. Dữ liệu đầu vào mạng nơ-ron là thông tin đầu ra bộ xử lý tín hiệu cơ sở ở dạng 3D cụ lý – phương vị – tần số. Thông qua các phép tính tích chập (Convolutional) và lấy giá trị cực đại (Maxpooling) dữ liệu đầu vào sẽ được biến đổi để tạo ra bản đồ đặc trưng (Feature map). Thông tin bản đồ đặc trưng được đưa đến mô đun phát hiện và phân loại mục tiêu, từ đây, các mục tiêu ra đa được tiến hành nhận dạng.



Hình 4. Cấu trúc mạng nơ-ron đề xuất cho bài toán nhận dạng mục tiêu ra đa ARTRNet.

Có thể thấy, mô hình ARTRNet được kết cấu bởi một dãy gồm 4 khối chính 1÷4 và mô đun detection head thực hiện chức năng phát hiện và phân loại mục tiêu. Các khối chính 1÷4 đóng vai trò như các khối trích chọn đặc trưng. Mỗi khối chính được tạo thành từ nhiều khối dư (Residual block) kết nối liên tiếp nhau và kết thúc là lớp gộp cực đại (Maxpooling). Số lần lặp lại của các khối dư trong 4 khối chính tạo nên tham số kích thước khối dư [N1, N2, N3, N4] của mạng nơ-ron ARTRNet. Mỗi khối dư được xây dựng theo nguyên lý của CNN ResNet [15] gồm hai nhánh: một nhánh chính (Backbone flow) và một nhánh phụ (Skip-connection flow). Nhánh chính đảm nhiệm chức năng trích xuất đặc trưng dữ liệu, nhánh phụ có nhiệm vụ truyền đặc trưng cũ từ lớp chuẩn hóa đến kết hợp với đầu ra của nhánh chính tại lớp cộng.

Trong ra đa cỡ nhỏ tầm gần FMCW, tốc độ cập nhật dữ liệu mỗi vòng quét thường lớn do tốc độ quay anten (hoặc quét búp sóng số) nhanh hơn so với các đài ra đa cảnh giới tầm xa. Vì vậy, yêu cầu tốc độ xử lý và cập nhật thông tin nhận dạng mục tiêu phải cao để đồng bộ hóa toàn bộ chuỗi xử lý tín hiệu. Vì lý do đó, nhóm tác giả lựa chọn xây dựng mô đun phát hiện và phân loại mục tiêu detection head theo nguyên lý làm việc của lớp mô hình họ YOLO. Đây là một cấu trúc có ưu điểm về tốc độ xử lý so với các mô hình khác. Mô hình này trực tiếp huấn luyện một mạng với các bounding box và tiến hành phát hiện và phân loại tất cả đối tượng trên một ảnh đặc trưng (feature map).

Dữ liệu đầu vào mạng nơ-ron học sâu ARTRNet là sự kết hợp của cả thông tin diện tích phản xạ hiệu dụng và thông tin tần số Doppler của mục tiêu ra đa. Bộ dữ liệu dùng cho quá trình huấn luyện, kiểm tra và đánh giá mạng nơ-ron đề xuất là dữ liệu ra đa và thông tin gán nhãn của hơn 10000 vòng quét với dung lượng hơn 300 GB. Việc sử dụng cả hai đặc trưng quan trọng của mục tiêu sẽ nâng cao độ chính xác nhận dạng của mạng nơ-ron. Thông tin diện tích phản xạ hiệu dụng của mục tiêu thể hiện qua ma trận tín hiệu theo trục cụ lý-phương vị, thông tin tần số Doppler thể hiện qua ma trận tín hiệu cụ lý-tần số. Kích thước dữ liệu ra đa đầu vào mạng nơ-ron là 256*256*64. Tập dữ liệu sẽ được chia thành các tập huấn luyện và kiểm tra với tỷ lệ tương ứng là 80% và 20%.

4. KẾT QUẢ NHẬN DẠNG VÀ THẢO LUẬN

Mạng nơ-ron học sâu ARTRNet được xây dựng và tiến hành huấn luyện kiểm tra bằng ngôn ngữ lập trình Python sử dụng framework Tensorflow. Bài báo tiến hành thay đổi kích thước các khối dư backbone và điều chỉnh hàm mất mát trong quá trình huấn luyện. Từ đó lựa chọn bộ tham số giúp cho mạng nơ-ron có hiệu năng nhận dạng mục tiêu cao nhất. Các tham số được thiết lập cho quá trình huấn luyện, kiểm tra như sau: Batch size được thiết lập là 4, tốc độ học (learning rate) khởi tạo là 0.0001 và giảm dần 96% sau mỗi 10.000 vòng lặp, sử dụng thuật toán tối ưu Adam để cập nhật trọng số. Mô hình được huấn luyện và kiểm tra trên nền tảng phần cứng GPU của máy tính với cấu hình: chip xử lý Intel Xeon E5-2678 v3 CPU, card màn hình RTX 3060 GPU, Ram 32GB.

4.1. Hiệu năng nhận dạng mục tiêu của mô hình khi điều chỉnh hàm mất mát

Hàm mất mát sử dụng trong quá trình huấn luyện mạng nơ-ron học sâu ARTRNet như thể hiện ở công thức (3). Trong quá trình huấn luyện, chúng tôi nhận thấy rằng, ảnh hưởng của thành phần L_{Box} lên hàm mất mát tổng là rất lớn so với thành phần L_{Cls} dẫn đến hiện tượng suy giảm độ chính xác phân loại mục tiêu của mạng nơ-ron. Vì vậy, chúng tôi đề xuất điều chỉnh hàm mất mát bằng cách nhân thêm một hệ số điều chỉnh β vào thành phần L_{Box} trong hàm mất mát. Hàm mất mát mới được đề xuất trong quá trình huấn luyện mạng nơ-ron là:

$$L_{Total} = \beta * L_{Box} + L_{Cls} \quad (8)$$


Qua quá trình chạy thực nghiệm và so sánh kết quả nhận dạng của mạng nơ-ron với hàm mất mát chưa nhân hệ số [16] và hàm mất mát được nhân các hệ số điều chỉnh β khác nhau, chúng tôi nhận thấy, với hệ số nhân $\beta = 0.1$ mô hình mạng nơ-ron đề xuất có hiệu năng nhận dạng cao nhất.

Bảng 1. So sánh hiệu năng nhận dạng mạng nơ-ron khi thay đổi hệ số điều chỉnh hàm mất mát.

Hệ số β	0 [16]	0.01	0.05	0.1	0.15	0.2	0.25	0.3
mAP _{0.3}	0.2036	0.3287	0.3463	0.3559	0.3482	0.3391	0.2847	0.2480

4.2. Kết quả nhận dạng mục tiêu của mô hình mạng nơ-ron đề xuất ARTRNet


Sau khi xây dựng mô hình mạng nơ-ron với số lần lặp lại các khối dư trong cấu trúc backbone lần lượt là [2, 4, 8, 16] và hàm mất mát trong quá trình huấn luyện như công thức (8), chúng tôi tiến hành huấn luyện mạng nơ-ron trên toàn bộ tập dữ liệu, số vòng lặp huấn luyện là 200.000. Kết quả huấn luyện được thể hiện trên hình 5 với các giá trị: sai số huấn luyện (training loss) thể hiện ở hình bên trái cùng, sai số xác thực (validation loss) thể hiện ở hình ở giữa và độ chính xác trung bình mAP thể hiện ở hình bên phải cùng lần lượt có giá trị là 1.673, 0.3039 và 56.5%.



Hình 5. Kết quả huấn luyện và kiểm tra mạng nơ-ron ARTRNet.

Hình 6 thể hiện kết quả nhận dạng mục tiêu ra đa mạng nơ-ron ARTRNet hiển thị trên màn hình giao diện người – máy. Hai hình bên trái cùng lần lượt biểu diễn tín hiệu đầu vào mạng nơ-ron trên trục cự ly – tần số và trục cự ly – phương vị, hình bên phải cùng là tín hiệu video cùng

với thông tin nhận dạng mục tiêu của mạng nơ-ron đề xuất ARTRNet. Thông tin về vị trí và kiểu loại mục tiêu từ mạng nơ-ron được thể hiện bởi bounding box và thông tin nhãn mục tiêu.



Hình 6. Kết quả nhận dạng mục tiêu ra đa mạng nơ-ron ARTRNet hiển thị trên màn hình giao diện người – máy.

5. KẾT LUẬN

Bài báo đã đề xuất một mô hình mạng nơ-ron học sâu, đặt tên là ARTRNet cho bài toán tự động nhận dạng mục tiêu ra đa FMCW. Bên cạnh đó, tác giả đề xuất một cải tiến hàm mất mát trong quá trình huấn luyện mạng nơ-ron giúp nâng cao chất lượng nhận dạng mục tiêu. Mô hình mạng nơ-ron học sâu ARTRNet cho kết quả nhận dạng mục tiêu ra đa với dữ liệu đầu vào mang thông tin cự ly – phương vị – tần số của mục tiêu với độ chính xác trung bình mAP = 56.5%. Kết quả nghiên cứu của bài báo là tiền đề tác giả tiếp tục nghiên cứu, phát triển các nội dung khác trong việc sử dụng mạng nơ-ron nhân tạo giải quyết các bài toán trong lĩnh vực xử lý tín hiệu ra đa.

Lời cảm ơn: Nghiên cứu thiết kế từ máy tính trung tâm 394IB01-M trên cơ sở linh kiện mới cho đài ra đa KASTA-2E2

TÀI LIỆU THAM KHẢO

- [1]. Jędrzej Drozdowicz, Maciej Wielgo, Piotr Samczynski, Krzysztof Kulpa, Jaroslaw Krzonkalla, Maj Mordzonek, Marcin Bryl, Zbigniew Jakielaszek “35 GHz FMCW Drone Detection System”.
- [2]. Jinwei Wan, Bo Chen¹, Bin Xu, Hongwei Liu and Lin Jin. “Convolutional neural networks for radar HRRP target recognition and rejection”. EURASIP Journal on Advances in Signal, 2019:5, (2019).
- [3]. Nguyễn Văn Trà, Đoàn Văn Sáng, Vũ Chí Thanh, Trần Công Tráng, “Đánh giá hiệu năng tự động phân loại mục tiêu radar của một số mạng nơ-ron hiện đại”. Tạp chí Nghiên cứu KH&CN quân sự, số 74. (2021).
- [4]. Woosuk Kim 1, Hyunwoong Cho 1, Jongseok Kim 1, Byungkwan Kim 2 and Seongwook Lee “YOLO-Based Simultaneous Target Detection and Classification in Automotive FMCW Radar Systems”. MDPI, 20 May, (2020).
- [5]. Long, X., Deng, K., Wang, G., Zhang, Y., Dang, Q., Gao, Y.,... & Wen, S., “PP-YOLO: An Effective and Efficient Implementation of Object Detector”. arXiv preprint arXiv:2007.12099, (2020).
- [6]. Liu, Y., Wang, Y., Wang, S., Liang, T., Zhao, Q., Tang, Z., & Ling, H., CBNet: “A Novel Composite Backbone Network Architecture for Object Detection”. In AAAI, pp. 11653-1660, (2020).
- [7]. A. Bochkovskiy, C. Y. Wang, and H. M. Liao, “Yolov4: Optimal speed and accuracy of object detection,” arXiv preprint arXiv:2004.10934, (2020).
- [8]. Yu, J., Jiang, Y., Wang, Z., Cao, Z., & Huang, T., “Unitbox: An advanced object detection network”. In Proceedings of the 24th 15 ACM international conference on Multimedia, pp. 516-520, (2016).
- [9]. Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. “Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression”. In AAAI, pp. 12993-13000, (2020).
- [10]. Tomasz Jasinski, Irina Antipov, Sildomar T. Monteiro, Graham Brooker “W-Band Maritime Target Classification using HighResolution Range Profiles”. The University of Sydney NSW, Australia, (2006).

- [11]. Villeval, S.; Bilik, I.; Gurbuz, S.Z. “Application of a 24 GHz FMCW automotive radar for urban target classification”. In Proceedings of the IEEE Radar Conference, Cincinnati, OH, USA, 19–23, (2014).
- [12]. Rytel-Andrianik, R.; Samczynski, P.; Gromek, D.; Weilgo, J.; Drozdowicz, J.; Malanowski, M. “Micro-range, micro-Doppler joint analysis of pedestrian radar echo”. In Proceedings of the IEEE Signal Processing Symposium (SPSymo), Debe, Poland, 10–12 June, (2015).
- [13]. Lim, S.; Lee, S.; Yoon, J.; Kim, S.-C. “Phase-based target classification using neural network in automotive radar systems”. In Proceedings of the IEEE Radar Conference (RadarConf), Boston, MA, USA, 22–26 April, (2019).
- [14]. Shang Jiang, Haoran Qin, Bingli Zhang, Jieyu Zheng. “Optimized Loss Functions for Object detection: A Case Study on Nighttime Vehicle Detection”, Computer Vision and Pattern Recognition, (2020).
- [15]. K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in IEEE conference on computer vision and pattern recognition, pp. 770–778, (2016).
- [16]. J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in IEEE conference on Computer Vision and Pattern Recognition, pp. 779–788, (2016).

ABSTRACT

Proposed deep neural network ARTRNet for automatic target recognition for FMCW radar

In this paper, we propose a deep learning neural network (named ARTRNet) that automatically recognizes radar targets based on the characteristic signature of radar cross section and Doppler frequency of target in the reflected signal. The raw data input to ARTRNet is 3D formatted with distance - azimuth - frequency information. The author proposes an improvement of the loss function in the neural network training process to improve the target recognition performance of the model.

Keywords: FMCW; Radar; Range; Azimuth; Doppler; Object detection; Deep learning.