

## Ước lượng hướng đến của tín hiệu vô tuyến sử dụng mạng nơ-ron tích chập cho mảng anten tuyến tính không đồng đều

Nguyễn Duy Thái\*

Viện Điện tử, Viện Khoa học và Công nghệ quân sự.

\*Email: ndthai03@gmail.com.

Nhận bài ngày 06/01/2022; Hoàn thiện ngày 16/02/2022; Chấp nhận đăng ngày 10/4/2022.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.78.2022.78-85>

### TÓM TẮT

Trong nghiên cứu này, mô hình mạng nơ-ron tích chập kết nối dư (đặt tên là DOA-ResNet) được đề xuất nhằm cải thiện độ chính xác ước lượng góc đến của nguồn tín hiệu vô tuyến. Mô hình DOA-ResNet đã được phân tích đánh giá bằng cách thay đổi số lượng và kích thước kênh lọc trong lớp tích chập nhằm tìm ra sự phụ thuộc giữa hiệu năng ước lượng góc và các tham số đó. Từ đó đưa ra mô hình phù hợp để cân bằng giữa các yếu tố về độ chính xác, độ lớn mô hình và thời gian thực thi khi áp dụng vào thực tế. Ngoài ra, mô hình đề xuất còn được xem xét so sánh với một số thuật toán học máy khác nhằm minh chứng cho hiệu năng vượt trội của nó cả về độ chính xác và thời gian xử lý.

**Từ khóa:** Ước lượng hướng đến; Mạng nơ-ron tích chập; Mảng anten không đồng nhất.

### 1. ĐẶT VẤN ĐỀ

Trong lĩnh vực giám sát và trinh sát tín hiệu vô tuyến, góc đến (DOA: Direction of Arrival) của nguồn tín hiệu là một trong những tham số đặc biệt quan trọng, vì nó cho phép xác định hướng/vị trí của nguồn phát trong phạm vi quan sát [1]. Mặc dù cho đến nay các phương pháp truyền thống xác định góc tới bằng cách so sánh các tham số của tín hiệu như biên độ, pha, thời gian vẫn đang được áp dụng, song những phương pháp này đang dần bộc lộ những nhược điểm khi môi trường sóng điện từ ngày càng dày đặc với các kênh truyền ngày càng phức tạp. Để khắc phục những hạn chế của phương pháp truyền thống, một số phương pháp hiện đại như Beamforming, MVDR, MUSIC và ESPRIT được đề xuất [2]. Đặc biệt, phương pháp MVDR, MUSIC và ESPRIT có khả năng xác định được nhiều nguồn tới với độ phân giải cao. Tuy nhiên, đây là những phương pháp dựa trên mô hình mảng anten dựng trước nên khi có bất kỳ thay đổi hoặc sai lệch nào từ thực tế lắp đặt hệ thống anten cũng như môi trường truyền sóng thì sai số lớn sẽ xảy ra.

Gần đây, các nghiên cứu áp dụng mạng nơ-ron nhân tạo cho bài toán ước lượng DOA của tín hiệu vô tuyến và âm thanh đang nhận được sự quan tâm từ cộng đồng nghiên cứu nhằm khắc phục những tồn tại của các phương pháp nêu trên [3, 4]. Thật vậy, ước lượng DOA dựa trên các thuật toán học sâu có thể cập nhật trọng số theo kênh truyền thực tế, tự động điều chỉnh sai số hệ thống. Tuy nhiên, mạng nơ-ron lại đòi hỏi một phần cứng tính toán đủ mạnh để thực thi. Những năm gần đây, sự phát triển vượt bậc về công nghệ sản xuất chip đã phần nào đáp ứng được các mô hình học sâu có số lượng trọng số lớn, cụ thể là khả năng tính toán song song của card đồ họa (GPU: Graphic Processing Unit). Do đó, trong nghiên cứu này, một mô hình mạng nơ-ron tích chập sâu dựa trên cấu trúc kết nối dư (residual), đặt tên là DOA-ResNet, được đề xuất để thực hiện bài toán ước lượng hướng đến của tín hiệu vô tuyến. Mô hình DOA-ResNet được phân tích đánh giá bằng việc thay đổi số lượng kênh lọc và kích thước của chúng để có thể lựa chọn mô hình phù hợp cho sự cân bằng giữa độ chính xác, độ lớn mô hình và thời gian thực thi. Bên cạnh đó, mô hình DOA-ResNet được xem xét so sánh với một số thuật toán học máy khác như SVM (Support Vector Machine) [5], KNN (k-Nearest Neighbors) [6], và DT (Decision Tree) [7] để minh chứng cho tính vượt trội của nó.


## 2. MÔ HÌNH TÍN HIỆU CỦA MẢNG ANTEN TUYẾN TÍNH

Phần này trình bày một mô hình thu tín hiệu của mảng Anten tuyến tính không đồng đều (NLA: Non-uniform Linear Array) làm cơ sở để tạo tập dữ liệu phù hợp cho mạng nơ-ron đề xuất. Mô hình thu tín hiệu của mảng Anten được minh họa như trong hình 1. Giả sử rằng, mảng NLA có  $M$  phần tử Anten đẳng hướng có chức năng thu tín hiệu để xác định hướng đến của chúng. Giả thiết rằng, có  $P$  nguồn tín hiệu truyền tới Anten trong mặt phẳng phương vị ở các góc lần lượt là  $\theta_1, \theta_2, \dots, \theta_P$ . Khi đó, tín hiệu tại đầu ra của mảng NLA là:

$$\mathbf{x}(t) = \mathbf{A}(\theta) \cdot \mathbf{s}(t) + \mathbf{n}(t) \quad (1)$$

trong đó,  $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_P(t)]^T$  là véc-tơ tín hiệu của  $P$  nguồn,  $\mathbf{n}(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T$  là véc-tơ của nhiễu tạp tương ứng với  $M$  kênh thu,  $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$  là véc-tơ tín hiệu tại đầu ra của mảng NLA với  $M$  phần tử,  $\mathbf{A}(\theta)$  là ma trận định hướng của mảng NLA, được biểu diễn như sau [8]:

$$\mathbf{A}(\theta) = \begin{bmatrix} 1 & 1 & \dots & 1 \\ e^{-j\frac{2\pi d_1 \sin \theta_1}{\lambda}} & e^{-j\frac{2\pi d_1 \sin \theta_2}{\lambda}} & \dots & e^{-j\frac{2\pi d_1 \sin \theta_P}{\lambda}} \\ \vdots & \vdots & \ddots & \vdots \\ e^{-j\frac{2\pi d_{M-1} \sin \theta_1}{\lambda}} & e^{-j\frac{2\pi d_{M-1} \sin \theta_2}{\lambda}} & \dots & e^{-j\frac{2\pi d_{M-1} \sin \theta_P}{\lambda}} \end{bmatrix} \quad (2)$$



Hình 1. Mô hình thu tín hiệu cho bài toán ước lượng hướng đến.

Tại máy thu, tín hiệu từ các phần tử Anten sẽ được chuyển từ tương tự sang số để xử lý. Gọi  $T_s$  là chu kỳ lấy mẫu của bộ biến đổi tương tự sang số (ADC: Analog to Digital Converter) thì đầu ra của của Anten có thể biểu diễn như sau [9]:

$$\mathbf{x} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_M \end{bmatrix}^T = \begin{bmatrix} x_1(T_s) & x_1(2T_s) & \dots & x_1(NT_s) \\ x_2(T_s) & x_2(2T_s) & \dots & x_2(NT_s) \\ \vdots & \vdots & \ddots & \vdots \\ x_M(T_s) & x_M(2T_s) & \dots & x_M(NT_s) \end{bmatrix}^T, \quad (3)$$

Ở đây,  $N$  là số lượng mẫu tín hiệu trong một cửa sổ tín hiệu. Có thể thấy rằng, tín hiệu thu  $\mathbf{x}$  là ma trận số có kích thước  $N \times M$ . Trong trường hợp máy thu sử dụng kênh cầu phương gồm tín hiệu đồng pha (I: In-phase) và vuông pha (Q: Quadratic-phase) thì  $\mathbf{x}$  là ma trận ba chiều có kích thước  $2 \times N \times M$ . Như vậy, ma trận  $\mathbf{x}$  sẽ được chỉ định là dữ liệu đầu vào cho mạng nơ-ron đề xuất trong nghiên cứu này.

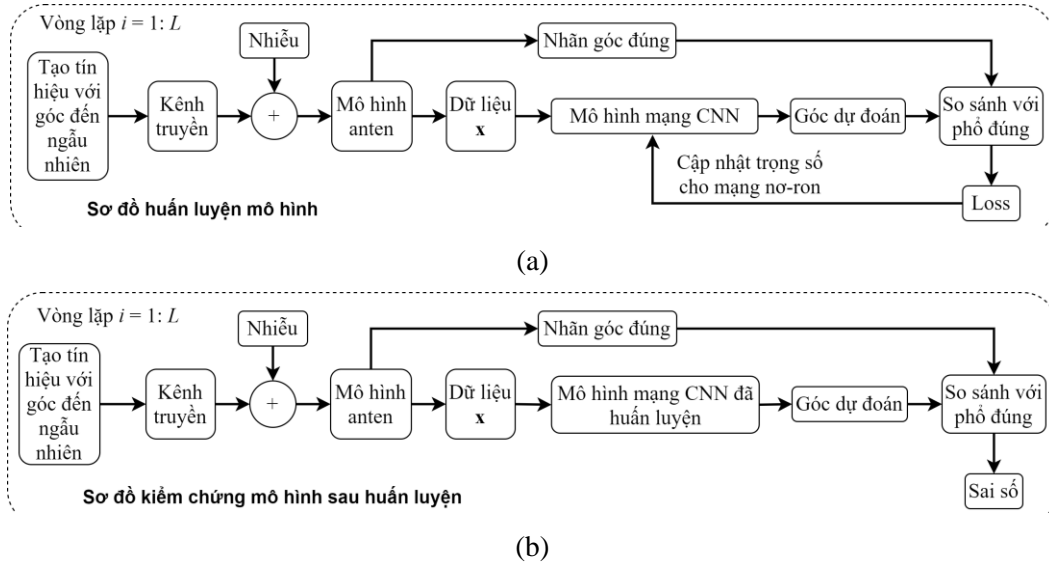
### 3. MÔ HÌNH MẠNG NƠ-RON ƯỚC LƯỢNG HƯỚNG ĐẾN CỦA TÍN HIỆU

#### 3.1. Huấn luyện và kiểm chứng

Trong nghiên cứu này, mô hình mạng nơ-ron được đề xuất để ước lượng hướng đến của tín hiệu vô tuyến. Trước khi mô hình được sử dụng để thực thi quá trình ước lượng hướng đến, nó phải được huấn luyện với tập dữ liệu. Thay vì tạo ra bộ dữ liệu cố định để huấn luyện mạng nơ-ron, tác giả thực hiện huấn luyện mô hình với dữ liệu được tạo ra liên tục bằng mô phỏng với góc phương vị ngẫu nhiên và các mức nhiễu/kênh truyền khác nhau. Quá trình huấn luyện được mô tả như trong hình 2(a), trong đó có thể thấy mỗi vòng lặp một tín hiệu có biên độ phức ngẫu nhiên được điều chế với tần số sóng mang 35 MHz và góc tới giả định được tạo ra. Để tạo dữ liệu quan sát cho mô hình mạng nơ-ron tích chập (CNN: Convolutional Neural Network) để xuất, tín hiệu này được đưa qua kênh truyền và thêm nhiễu, sau đó, nó được giả định thu bởi một mảng 5 phần tử anten có khoảng cách không đồng đều, trong đó  $d_1 = 3\lambda/2$ ,  $d_2 = 5\lambda/2$ ,  $d_3 = 7\lambda/2$  và  $d_4 = 10\lambda/2$ ; ở đây,  $d_i$  là khoảng cách giữa anten  $A_{i+1}$  và anten tham chiếu  $A_1$  (như biểu diễn trong hình 1). Bằng quá trình truyền thẳng, một góc dự đoán sẽ thu được ở đầu ra của mạng CNN. Góc dự đoán này được so sánh với nhãn góc đúng để tạo một giá trị mất mát. Giá trị mất mát là cơ sở để cập nhật lại trọng số của mô hình CNN theo một phương pháp nhất định, ví dụ như SGD (stochastic gradient descent) hoặc ADAM. Trong nghiên cứu này, tác giả lựa chọn phương pháp SGD để thực hiện cập nhật trọng số của CNN. Hàm cross-entropy được sử dụng để tính giá trị mất mát. Hàm cross-entropy được mô tả như trong biểu thức sau [10]:

$$L_{CE} = -\frac{1}{Q} \sum_{i=1}^Q y_i \log \hat{y}_i, \quad (4)$$

trong đó,  $y_i$  là nhãn góc đúng,  $\hat{y}_i$  là nhãn góc dự đoán và  $Q$  là số lượng nhãn góc.



**Hình 2.** Sơ đồ huấn luyện và kiểm chứng mô hình mạng CNN đề xuất.

Sau khi mạng CNN đạt được sự hội tụ nhất định với giá trị mất mát đủ nhỏ thì quá trình huấn luyện sẽ được dừng lại. Lúc này mạng CNN đã huấn luyện sẽ được kiểm chứng theo sơ đồ hình 2(b) để đánh giá hiệu năng của nó dựa trên các tham số đo đặc như sai số quân phương, thời gian thực thi. Trong đó, sai số quân phương được xác định theo công thức sau:

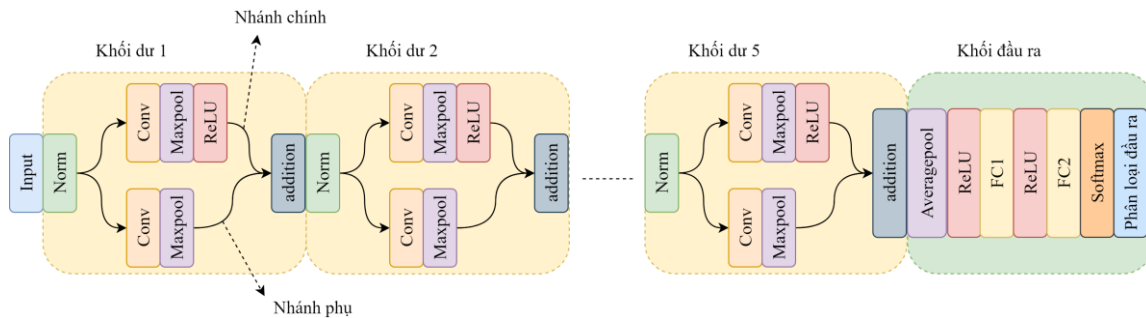
$$RMSE_{DOA} = \sqrt{\frac{1}{L} \sum_{i=1}^L (\hat{\theta}_i - \theta_i)^2} \quad (5)$$

trong đó,  $\theta_i$  và  $\hat{\theta}_i$  lần lượt là giá trị góc đúng và góc ước lượng được của mô hình mạng CNN, và  $L$  là số vòng lặp hay số phép thử.

**3.2. Mạng nơ-ron đề xuất**

Để thực hiện bài toán ước lượng hướng đến của tín hiệu vô tuyến, một mô hình mạng nơ-ron dựa trên cấu trúc kết nối dư (residual) được đề xuất trong bài báo này và được đặt tên là DOA-ResNet. Cấu trúc của DOA-ResNet được thể hiện như trong hình 3. Có thể thấy, mô hình DOA-ResNet được kết cấu bởi một dãy gồm 5 Khối dư 1÷5 (Residual block) và Khối đầu ra. Các Khối dư 1÷5 đóng vai trò như các khối trích chọn đặc trưng, còn Khối đầu ra đóng vai trò như bộ phân loại cuối. Mỗi Khối dư gồm hai nhánh: một Nhánh chính (Backbone flow) và một Nhánh phụ (Skip-connection flow). Nhánh chính đảm nhiệm chức năng trích chọn đặc trưng của luồng dữ liệu, còn Nhánh phụ đảm nhiệm chức năng truyền đặc trưng cũ từ lớp chuẩn hóa (Norm) đến kết hợp với đầu ra của Nhánh chính tại lớp cộng (addition). Vì lý do này, các lớp tích chập (Conv) trong các Nhánh chính được chỉ định với  $K$  bộ lọc với kích thước  $1 \times k$ , trong khi đó các lớp Conv trong Nhánh phụ chỉ có kích thước  $1 \times 1$  để đảm bảo đặc trưng từ lớp Norm truyền đến lớp addition không bị thay đổi. Để có thể thực hiện được phép cộng đặc tính tại lớp addition thì kích thước tại đầu ra của hai nhánh phải bằng nhau, vì vậy số lượng kênh lọc ở hai nhánh phải bằng nhau và lớp gộp cục đại (Maxpool) ở hai nhánh phải được chỉ định cùng tham số trượt. Cụ thể trong nghiên cứu này, lớp Maxpool được thiết kế với kích thước  $1 \times 5$  và bước trượt (1, 2). Theo sau lớp Maxpool ở Nhánh chính là lớp kích hoạt ReLU. Hàm kích hoạt ReLU được lựa chọn vì nó cho phép khả năng tính toán và hội tụ nhanh hơn hầu hết các hàm kích hoạt khác.

Tiếp theo sau Khối dư cuối cùng là Khối đầu ra. Khối này gồm lớp gộp trung bình (Averagepool), 2 lớp kích hoạt ReLU, 2 lớp kết nối đầy đủ (FC), lớp Softmax và lớp Phân loại đầu ra, như trong hình 3. Lớp Averagepool có kích thước  $1 \times 16$  và bước trượt (1, 8). Lớp FC1 và FC2 lần lượt có số lượng nơ-ron là 256 và 161, trong đó, số lượng nơ-ron của FC2 bằng với số lượng phân lớp góc ước lượng từ  $-80^\circ$  đến  $+80^\circ$  với bước nhảy  $1^\circ$ . Lớp Softmax được áp dụng để tính giá trị xác suất cho từng phân lớp đầu ra, từ đó đưa ra quyết định góc tại lớp Phân loại đầu ra.



**Hình 3.** Cấu trúc của mạng nơ-ron DOA-ResNet.

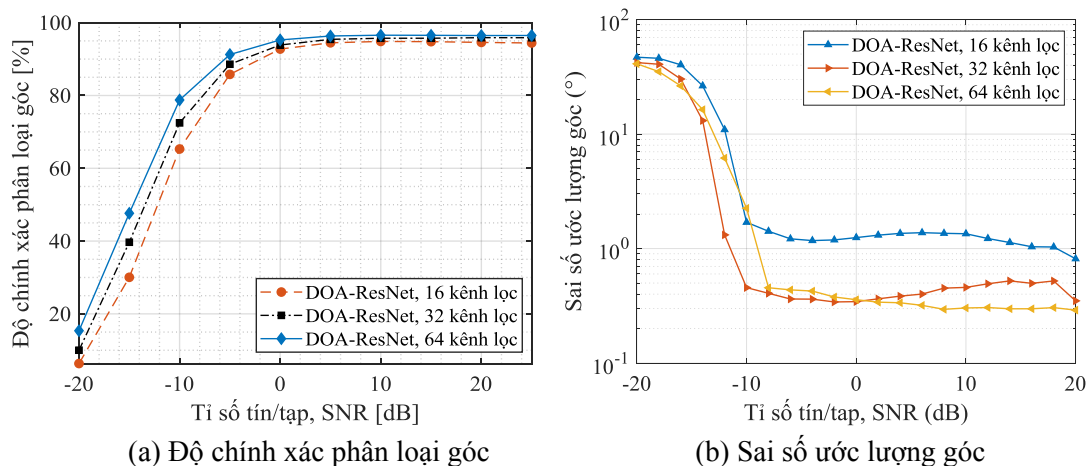
**4. KẾT QUẢ MÔ PHỎNG VÀ THẢO LUẬN**

Mô hình DOA-ResNet đề xuất được mô phỏng bằng Matlab và đánh giá thông qua việc thay đổi các tham số của mạng nơ-ron như số lượng và kích thước kênh lọc, cũng như so sánh hiệu năng của nó với một số mô hình học máy khác. Tín hiệu mô phỏng được giả định với các tham số như sau: tần số sóng mang: 35 MHz, tỉ số SNR: từ -20 dB đến 25 dB, góc tới giả định: từ  $-80^\circ$  đến  $+80^\circ$  trong mặt phẳng phương vị, tần số lấy mẫu: 350 MHz, số lượng mẫu cho một cửa sổ tín hiệu: 1024. Các tham số huấn luyện được thiết lập như sau: tốc độ học khởi tạo là 0.01 và sẽ giảm 10 lần sau 10000 vòng lặp; bộ tối ưu là SGDM với hệ số moment = 0.9, chương trình huấn luyện sẽ dừng lại nếu sau 3 lần cập nhật độ chính xác phân loại góc không tăng. Mô hình sau huấn luyện sẽ được kiểm chứng với tín hiệu mới với 10000 vòng lặp. Mô hình DOA-ResNet được huấn luyện và kiểm

tra trên nền tảng phần cứng GPU của Laptop với cấu hình CPU Intel Core i5 9300H, RAM 16 GB và GPU GTX 1660ti. Sau đây là các kết quả mô phỏng và thảo luận.

#### 4.1. Hiệu năng ước lượng góc của mô hình khi thay đổi số lượng kênh lọc

Để đánh giá ảnh hưởng của số lượng kênh lọc trong các lớp Conv của mô hình DOA-ResNet lên hiệu năng ước lượng góc đến của tín hiệu vô tuyến, tác giả giữ cố định kích thước kênh lọc  $1 \times 7$  và thay đổi số lượng kênh lọc trong các lớp Conv lần lượt là 16, 32 và 64. Giả thiết góc đến của tín hiệu là  $10^\circ \pm 0.5^\circ$ . Kết quả mô phỏng thể hiện trong hình 4 cho thấy, việc tăng số lượng kênh lọc có thể cải thiện độ chính xác phân loại góc và sự khác biệt này có thể nhận thấy rõ rệt với SNR thấp ( $< -5$  dB). Xét về độ chính xác phân loại góc, mô hình DOA-ResNet với 16, 32 và 64 kênh lọc lần lượt đạt độ chính xác phân loại góc là 85,8%, 88,59%, và 91,25% tại SNR = -5 dB. Khi quan sát độ chính xác phân loại ở mức SNR cao, có thể nhận thấy rằng, mô hình với 32 và 64 kênh lọc không có sự khác biệt đáng kể và tốt hơn mô hình với 16 kênh lọc. Xét về sai số ước lượng góc, mô hình DOA-ResNet với 32 kênh lọc cho sai số ước lượng góc thấp hơn mô hình 64 kênh lọc khi SNR  $< 0$  dB do ảnh hưởng của nhiễu mạnh, cường độ tín hiệu thấp hơn nên nhiễu. Tuy nhiên, khi SNR  $> 0$  dB thì mô hình 64 kênh lọc lại cho sai số ước lượng góc thấp hơn mô hình 32 kênh lọc. Chú ý rằng, với SNR  $\leq -12$  dB sai số ước lượng của mô hình 16 và 64 kênh tương đối lớn (sai số quân phương  $> 6^\circ$ ), trong khi đó, mô hình 32 kênh lọc cho sai số ước lượng góc thấp hơn đáng kể (khoảng xấp xỉ  $1^\circ$ ). Khi SNR  $> -8$  dB các mô hình 32 và 64 kênh lọc đều cho độ chính xác ước lượng góc tốt ( $< 0.5^\circ$ ) và tốt hơn đáng kể so với mô hình 16 kênh lọc. Bên cạnh việc đánh giá độ chính xác phân loại và sai số ước lượng góc, việc so sánh số lượng trọng số và thời gian xử lý của mô hình cũng rất quan trọng để đưa ra sự lựa chọn phù hợp với phần cứng khi áp dụng vào thực tế hoạt động. Hai tham số này được báo cáo trong bảng 1 cho thấy, khi tăng số lượng kênh lọc từ 32 lên 64 thì số lượng trọng số cũng tăng lên hơn 2 lần, điều này dẫn đến thời gian thực thi bị chậm đi đáng kể. Cụ thể, thời gian thực thi của mô hình 16 và 32 không có sự khác biệt nhiều và chúng nhanh hơn mô hình 64 kênh lọc đến hơn 1 ms. Vì vậy, cần phải cân nhắc sự đánh đổi giữa độ chính xác với độ lớn mô hình và thời gian xử lý của nó.



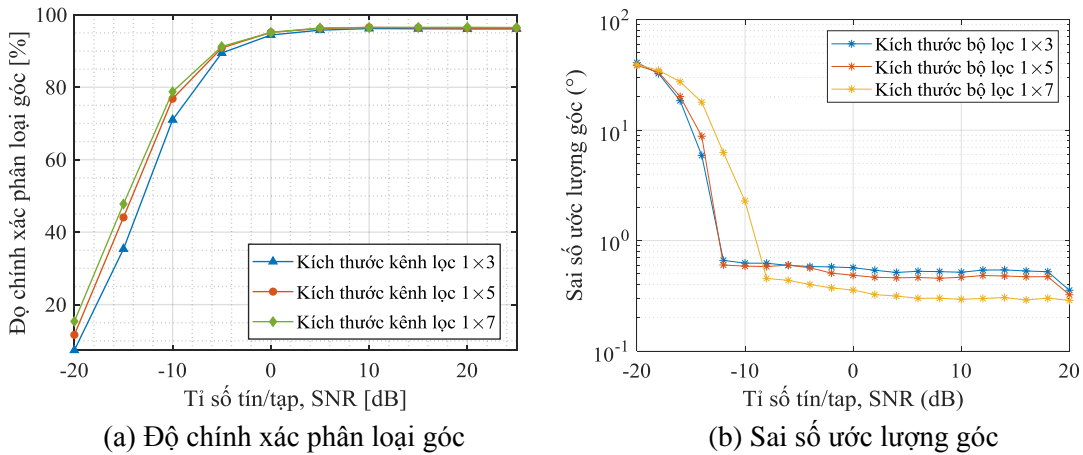
**Hình 4.** Hiệu năng ước lượng góc của mô hình DOA-ResNet với số lượng kênh lọc khác nhau.

**Bảng 1.** So sánh độ lớn và thời gian thực thi của DOA-ResNet với số lượng kênh lọc khác nhau.

Số lượng kênh lọc	Số lượng trọng số của mô hình	Thời gian thực thi
16 kênh lọc	83531	(6,8 ± 0,5) ms
32 kênh lọc	141803	(6,9 ± 0,5) ms
64 kênh lọc	307499	(8.1 ± 0,5) ms

**4.2. Hiệu năng ước lượng góc của mô hình khi thay đổi kích thước kênh lọc trong lớp tích chập**

Từ kết quả mô phỏng, đánh giá theo số lượng kênh lọc bên trên, tác giả lựa chọn cố định 64 kênh lọc cho việc mô phỏng, đánh giá theo kích thước kênh lọc này. Kích thước kênh lọc sẽ thay đổi bởi các thông số lần lượt là 1×3, 1×5 và 1×7. Kết quả so sánh hiệu năng phân loại góc cho các kích thước kênh lọc khác nhau được thể hiện trong hình 5. Có thể thấy rằng, khi kích thước kênh lọc càng lớn thì càng nhiều tính năng đại diện sẽ được học bởi mô hình CNN và do đó độ chính xác phân loại góc sẽ tăng lên. Cụ thể, xét về độ chính xác phân loại góc, mô hình có kích thước bộ lọc 1×7 cho độ chính xác cao nhất, và độ chính xác thấp nhất xuất hiện ở mô hình có kích thước bộ lọc 1×3. Nếu xét về sai số ước lượng góc, mô hình 1×7 có sai số lớn hơn hai mô hình còn lại khi SNR ≤ -10 dB, và sai số này thấp hơn đáng kể so với mô hình 1×3 và 1×5 khi SNR ≥ -8 dB. Tương tự như mô phỏng trước, số lượng trọng số của các mô hình và thời gian thực thi cho một dự đoán góc cũng được đo đạc. Kết quả đo hai tham số này thể hiện trong bảng 2 cho thấy, khi kích thước kênh lọc tăng cũng làm cho số lượng trọng số của mô hình tăng, nhưng không có sự khác biệt lớn về thời gian thực thi giữa các mô hình.



**Hình 5.** Hiệu năng ước lượng góc của mô hình DOA-ResNet với kích thước bộ lọc khác nhau.

**Bảng 2.** So sánh độ lớn và thời gian thực thi của DOA-ResNet với kích thước bộ lọc khác nhau.

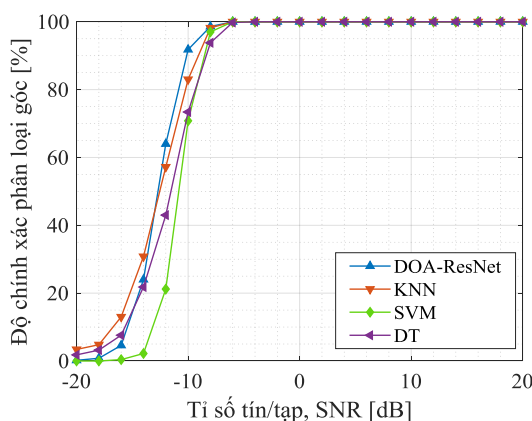
Kích thước kênh lọc	Số lượng trọng số của mô hình	Thời gian thực thi
1×3	240683	(8.0 ± 0,5) ms
1×5	274091	(8.0 ± 0,5) ms
1×7	307499	(8.1 ± 0,5) ms

**4.3. So sánh DOA-ResNet với các mô hình học máy khác**

Trong phần này, mô hình DOA-ResNet với 64 kênh lọc kích thước 1×7 được xem xét so sánh với một số thuật toán học máy khác như SVM, KNN với hệ số k = 5, và DT. Đây là ba thuật toán học máy phổ biến được sử dụng rộng rãi trong nhiều lĩnh vực, trong đó có bài toán ước lượng hướng đến của tín hiệu. Đầu vào của các mô hình cũng là dữ liệu thô có kích thước 2×1024×5 như đối với mô hình DOA-ResNet. Kết quả so sánh về độ chính xác phân loại góc được thể hiện như trong hình 6. Có thể nhận thấy rằng, DOA-ResNet cho độ chính xác phân loại góc trung bình cao hơn các mô hình còn lại, đặc biệt là khi SNR > -12 dB.

Bên cạnh đó, thời gian xử lý của các mô hình SVM, KNN và DT cũng được đo đạc và nhận được các giá trị lần lượt như sau: 3,3 s đối với SVM, 38,3 ms đối với KNN và 14,4 ms đối với DT. Mô hình SVM vốn được sử dụng cho bài toán phân loại nhị phân và có khả năng mở rộng cho đa phân lớp. Tuy nhiên, với số lượng phân lớp góc là 161 và kích thước dữ liệu đầu vào lớn nên mô hình SVM xử lý rất chậm, đây là nhược điểm cố hữu của SVM, và cũng là nhược điểm

chung của các mô hình học máy truyền thống khác. Mô hình KNN do phải thực hiện phép toán so sánh khoảng cách giữa các điểm dữ liệu nên thời gian xử lý cũng tương đối chậm. Mô hình DT cho hiệu quả nhanh hơn hai mô hình vừa nêu, nhưng do luồng dữ liệu đặc trưng lớn nên chỉ đạt tốc độ xử lý 14,4 ms. Lưu ý rằng, dữ liệu càng lớn thì các mô hình SVM, KNN và DT xử lý càng chậm. Ngược lại, mô hình DOA-ResNet do chỉ cập nhật trọng số theo dữ liệu nên tốc độ xử lý vẫn đảm bảo nhanh khi sử dụng dữ liệu lớn. Hơn thế nữa, dữ liệu càng lớn và càng đa dạng thì mô hình DOA-ResNet càng cho độ chính xác cao mà vẫn đảm bảo tốc độ xử lý. Như vậy, có thể thấy rằng, mô hình DOA-ResNet mà tác giả đề xuất trong nghiên cứu này vượt trội hơn các thuật toán học máy cả về độ chính xác và thời gian xử lý.



Hình 6. So sánh DOA-ResNet với các thuật toán học máy khác.

## 5. KẾT LUẬN

Bài báo đã đề xuất và đánh giá một mô hình mạng nơ-ron tích chập học sâu theo cấu trúc residual, đặt tên là DOA-ResNet cho bài toán ước lượng hướng đến tín hiệu vô tuyến. Mô hình này đã cho thấy sự vượt trội so với các thuật toán SVM, KN và DT khi so sánh về độ chính xác phân loại góc và thời gian xử lý. Mặc dù DOA-ResNet chưa phải là mô hình tối ưu nhất, nhưng nó sẽ là tiền đề để tác giả tiếp tục nghiên cứu, phát triển các nội dung khác trong việc sử dụng mạng nơ-ron nhân tạo giải quyết bài toán định hướng nguồn tín hiệu vô tuyến. Những định hướng nghiên cứu tiếp theo: (1) tối ưu mạng nơ-ron cho cho bài toán ước lượng hướng đến; (2) thực hiện ước lượng nhiều nguồn tín hiệu tương quan và không tương quan; (3) thực nghiệm đo đạc, kiểm chứng và đưa mô hình vào ứng dụng trong thực tiễn.

## TÀI LIỆU THAM KHẢO

- [1]. R. Wiley, "ELINT: The Interception and Analysis of Radar Signals", Artech House, 2006.
- [2]. S. Chandran, "Advances in Direction-of-Arrival Estimation", Artech House, 2006.
- [3]. L. Wu, Z.-M. Liu, and Z.-T. Huang, "Deep convolution network for direction of arrival estimation with sparse prior", IEEE Signal Processing Letters, vol. 26, no. 11, pp. 1688–1692, Nov. 2019.
- [4]. Z. Liu, C. Zhang and P. S. Yu, "Direction-of-Arrival Estimation Based on Deep Neural Networks With Robustness to Array Imperfections", IEEE Transactions on Antennas and Propagation, vol. 66, no. 12, pp. 7315-7327, Dec. 2018.
- [5]. A. Faye, J. D. Ndaw and M. Sène, "SVM-Based DOA Estimation with Classification Optimization," 2018 26th Telecommunications Forum (TELFOR), 2018, pp. 1-4.
- [6]. Y. Liu, H. Chen and B. Wang, "DOA Estimation of Underwater Acoustic Signals Based on PCA-kNN Algorithm," 2020 International Conference on Computer Information and Big Data Applications (CIBDA), 2020, pp. 486-490.
- [7]. Y. Miao, Y. Lv, J. Zhen, and B. Guo, "Accessorial Locating for Internet of Vehicles Based on DOA Estimation in Industrial Transportation," Wireless Communications and Mobile Computing, vol. 2021, p. 8241773, 2021.

- [8]. V.-S. Doan and D.-S. Kim, "DOA estimation of multiple non-coherent and coherent signals using element transposition of covariance matrix," *ICT Express*, vol. 6, no. 2, pp. 67–75, 2020.
- [9]. V. -S. Doan, T. Huynh-The, V. -P. Hoang and D. -T. Nguyen, "MoDANet: Multi-task Deep Network for Joint Automatic Modulation Classification and Direction of Arrival Estimation," *IEEE Communications Letters*, Early Access, pp. 1-1, Dec. 2021.
- [10]. S. Skansi, "Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence (1st. ed.)", Springer Publishing Company, 2018.

### **ABSTRACT**

#### **The direction of arrival estimation of radio signal sources using convolutional neural network model for non-uniform anten array**

*In this study, a Residual convolutional neural network model, named DOA-ResNet, is proposed to improve the direction of arrival (DOA) estimation accuracy of radio signal sources. The DOA-ResNet model is analyzed by changing the number and size of filter channels in the convolutional layer to find the dependence between the angular estimation performance and those parameters. Based on the evaluation, a suitable model is proposed for a trade-off between accuracy, model size, and execution time when it is applied in practice. In addition, the proposed model is compared with some other machine learning algorithms to demonstrate its remarkable performance in both accuracy and processing time.*

**Keywords:** Direction of Arrival; Convolutional Neural Network; Non-uniform Linear Array.