

BỘ QUỐC PHÒNG  
HỌC VIỆN KỸ THUẬT QUÂN SỰ

LÊ HÀ KHÁNH

NGHIÊN CỨU NÂNG CAO HIỆU NĂNG PHÂN LOẠI  
ĐIỀU CHẾ TỰ ĐỘNG ỨNG DỤNG MẠNG NƠ-RON

Chuyên ngành: KỸ THUẬT ĐIỆN TỬ  
Mã số: 9 52 02 03

TÓM TẮT LUẬN ÁN TIẾN SĨ KỸ THUẬT

Hà Nội - 2026

**CÔNG TRÌNH ĐƯỢC HOÀN THÀNH TẠI  
HỌC VIỆN KỸ THUẬT QUÂN SỰ - BỘ QUỐC PHÒNG**

**Phản biện 1: GS.TS Trần Đức Tân**

**Phản biện 2: PGS.TS Hán Trọng Thanh**

**Phản biện 3: PGS.TS Nguyễn Cảnh Minh**

Luận án sẽ được bảo vệ trước Hội đồng đánh giá luận án cấp Học viện theo Quyết định số ... ngày ... tháng ... năm ... của Giám đốc Học viện Kỹ thuật Quân sự, họp tại Học viện Kỹ thuật Quân sự vào hồi ... giờ ... ngày ... tháng ... năm ...

**Có thể tìm hiểu luận án tại:**

- Thư viện Quốc gia Việt Nam
- Thư viện Học viện Kỹ thuật Quân sự.

# DANH MỤC CÁC CÔNG TRÌNH SỬ DỤNG TRONG LUẬN ÁN

[C1.] “Tự động nhận dạng điều chế dưới tác động của nhiễu pha-dinh đa đường sử dụng kỹ thuật học sâu”, Hội nghị Khoa học Quốc Gia REV-ECIT 2021 (10/2021).

[C2.] “Performance Analysis of Convolutional Neural Networks with Different Window Functions for Automatic Modulation Classification,” *Proceedings of the 13th International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju Island, Republic of Korea, 2022, pp. 153–157, doi: 10.1109/ICTC55196.2022.9952750. (**Scopus Indexed**)

[C3.] “Improving Automatic Modulation Classification Accuracy Using Combination of Short-Time Fourier Transform and Radon Transform,” *2024 International Conference on Advanced Technologies for Communications (ATC)*, Ho Chi Minh City, Vietnam, 2024, pp. 493–498, doi: 10.1109/ATC63255.2024.10908305. (**Scopus Indexed**)

[J1.] "DFENet: A diverse feature extraction neural network for improving automatic modulation classification accuracy in wireless communication systems." *PLoS One*. 2026 Jan 21;doi: 10.1371/journal.pone.0341020. (**SCIE, Q1**)

[C4.] "AMC-CNN-BiLSTM: An Advanced Hybrid Model for Automatic Modulation Classification of Radio Signals," 2024 RIVF International Conference on Computing and Communication Technologies (RIVF), Danang, Vietnam, 2024, pp. 271-275, doi: 10.1109/RIVF64335.2024.11009112. (**Scopus Index**)

[J2.] “Ensemble of Convolution Neural Networks for Improving Automatic Modulation Classification Performance”. *Tạp Chí Khoa học Và Công nghệ - Đại học Đà Nẵng*, vol 20, số p.h 6.2, Tháng Sáu 2022, tr 25-32, doi:10.31130/ud-jst.2022.293E.

# MỞ ĐẦU

## 1. Động lực nghiên cứu:

Trong bối cảnh chiến tranh hiện đại chuyển mạnh sang không gian điện từ, *trình sát điện tử* đóng vai trò then chốt trong việc thu thập, phân tích và khai thác thông tin từ các nguồn phát xạ vô tuyến. Khả năng phát hiện, nhận dạng và phân loại tín hiệu một cách nhanh chóng, chính xác là nền tảng để xây dựng bức tranh tác chiến điện tử, hỗ trợ ra quyết định chiến thuật và đảm bảo ưu thế trên phổ tần. Đặc biệt, trong các hệ thống *tác chiến điện tử*, việc nhận dạng dạng điều chế của tín hiệu thu không chỉ phục vụ giám sát phổ mà còn trực tiếp liên quan đến phát hiện mục tiêu, phân tích ý đồ đối phương và triển khai các biện pháp đối kháng hiệu quả.

Song song với đó, phổ tần vô tuyến ngày càng trở nên phức tạp do sự gia tăng nhanh chóng của mật độ thiết bị phát xạ, sự đa dạng của các chuẩn truyền thông và tính động cao của môi trường truyền dẫn. Trong các kịch bản quân sự, tín hiệu thường được thiết kế theo hướng *khó bị phát hiện*, sử dụng các kỹ thuật điều chế thích nghi, nhảy tần hoặc trải phổ, đồng thời chịu tác động của gây nhiễu chủ động và các dạng can nhiễu Gauss. Những đặc điểm này làm gia tăng đáng kể độ khó của bài toán nhận dạng tín hiệu, đặc biệt trong điều kiện tỷ số tín hiệu trên nhiễu thấp.

Trong bối cảnh đó, bài toán *phân loại điều chế tự động* (Automatic Modulation Classification – AMC) không chỉ là một vấn đề kỹ thuật thuần túy mà còn là thành phần cốt lõi trong các hệ thống trình sát điện tử, giám sát phổ tần và thông tin vô tuyến thông minh. Tuy nhiên, trong thực tế, tín hiệu thu luôn chịu ảnh hưởng đồng thời của nhiễu Gauss trắng, fading đa đường, sai lệch tần số, dịch Doppler và các yếu tố phi tuyến của kênh truyền. Những tác động này làm biến dạng mạnh đặc trưng biên độ và pha của tín hiệu, khiến việc nhận dạng dựa trên đặc trưng trở nên khó khăn, đặc biệt trong các kịch bản tác chiến có cường độ nhiễu cao.

Các phương pháp AMC truyền thống, dựa trên lý thuyết quyết định hoặc trích xuất đặc trưng thủ công, thường yêu cầu các giả thiết chặt chẽ về mô hình kênh và phụ thuộc lớn vào kinh nghiệm chuyên gia. Khi môi trường thay đổi hoặc xuất hiện các dạng tín hiệu mới, các phương pháp này bộc lộ hạn chế về khả năng thích nghi và suy giảm hiệu năng đáng kể. Điều này đặt ra yêu

cầu cấp thiết đối với các phương pháp có khả năng tự động học đặc trưng, tổng quát hóa tốt và hoạt động ổn định trong môi trường vô tuyến phức tạp, đặc biệt là trong các hệ thống quân sự phi hợp tác.

Sự phát triển mạnh mẽ của trí tuệ nhân tạo và học sâu trong những năm gần đây đã mở ra một hướng tiếp cận đầy triển vọng cho bài toán AMC. Các mạng nơ-ron sâu có khả năng học trực tiếp từ dữ liệu tín hiệu thô, tự động trích xuất đặc trưng và mô hình hóa các quan hệ phi tuyến phức tạp mà không cần xây dựng mô hình toán học tường minh cho từng điều kiện kênh truyền. Đây là ưu thế đặc biệt quan trọng trong các hệ thống vô tuyến quân sự, nơi môi trường hoạt động có tính biến động cao và khó mô hình hóa chính xác trước.

Xuất phát từ những yêu cầu thực tiễn trên, với mục tiêu nghiên cứu chuyên sâu trong lĩnh vực xử lý tín hiệu và học máy đề xuất các giải pháp nâng cao hiệu năng nhận dạng tín hiệu vô tuyến trong các điều kiện bất lợi, nghiên cứu sinh đã lựa chọn đề tài **“Nghiên cứu nâng cao hiệu năng phân loại điều chế tự động ứng dụng mạng nơ-ron”** cho luận án tiến sĩ. Đề tài không chỉ có ý nghĩa khoa học trong việc phát triển các mô hình học sâu tiên tiến cho bài toán AMC, mà còn mang giá trị thực tiễn cao trong các ứng dụng trinh sát điện tử, tác chiến điện tử và đảm bảo an ninh – quốc phòng, góp phần nâng cao hiệu quả giám sát và khai thác phổ tần vô tuyến trong các kịch bản hiện đại.

## **2. Các đóng góp của luận án:**

1. Đề xuất kiến trúc trích xuất đặc trưng đa nhánh DFENet cho phân loại điều chế từ tín hiệu IQ nhằm tăng cường tính đa dạng trong không gian biểu diễn, đồng thời duy trì khả năng học đặc trưng cục bộ và toàn cục của tín hiệu.
2. Đề xuất mô hình dạng kiến trúc lai ghép CNN–BiLSTM nhằm mô hình hóa đồng thời đặc trưng không gian và phụ thuộc chuỗi theo thời gian của tín hiệu điều chế, cải thiện hiệu năng nhận dạng trên dải SNR rộng. Đề xuất phương pháp ensemble giữa các mô hình CNN, tận dụng tính bổ sung về đặc trưng của các kiến trúc mạng nhằm nâng cao độ chính xác phân loại.

## **3. Bố cục luận án:**

Luận án được trình bày trong 152 trang, bao gồm phần Mở đầu; 3 chương nội dung; Kết luận và hướng nghiên cứu tương lai; Danh mục các công trình đã công bố và Tài liệu tham khảo.

## Chương 1

# TỔNG QUAN VỀ BÀI TOÁN PHÂN LOẠI ĐIỀU CHẾ TỰ ĐỘNG ỨNG DỤNG MẠNG NƠ-RON HỌC SÂU

### 1.1 Tổng quan về phân loại điều chế tự động

Sự phát triển mạnh mẽ của các hệ thống thông tin vô tuyến thế hệ mới như 5G, 6G, Internet vạn vật (IoT), vô tuyến nhận thức (Cognitive Radio) và truy nhập phổ động (Dynamic Spectrum Access) đã làm gia tăng đáng kể nhu cầu sử dụng phổ tần vô tuyến. Trong bối cảnh đó, việc tự động nhận biết đặc tính của tín hiệu phát đóng vai trò quan trọng nhằm hỗ trợ quản lý phổ tần, điều khiển thích nghi và giám sát môi trường vô tuyến.

Nhận dạng điều chế tự động (Automatic Modulation Classification - AMC) là quá trình xác định dạng điều chế của tín hiệu thu mà không cần thông tin tiên nghiệm từ phía máy phát. AMC được xem là một chức năng cốt lõi tại lớp vật lý của các hệ thống vô tuyến thông minh, cho phép lựa chọn phương pháp giải điều chế phù hợp, nâng cao hiệu quả sử dụng phổ tần và đảm bảo chất lượng truyền thông.

Ngoài các ứng dụng dân sự, AMC còn có vai trò đặc biệt quan trọng trong các hệ thống quân sự và tác chiến điện tử. Thông qua việc nhận dạng tín hiệu của các nguồn phát không hợp tác, AMC hỗ trợ thu thập thông tin tình báo, nhận diện thiết bị phát sóng, giám sát phổ tần và thực hiện các biện pháp gây nhiễu có chọn lọc.

Tuy nhiên, trong môi trường thực tế, tín hiệu vô tuyến thường chịu ảnh hưởng của nhiều yếu tố như fading đa đường, nhiễu cộng Gaussian, sai lệch tần số sóng mang và sai lệch pha. Những tác động này làm biến dạng tín hiệu thu, khiến bài toán nhận dạng điều chế trở nên khó khăn, đặc biệt trong điều kiện tỷ số tín hiệu trên nhiễu thấp.

#### 1.1.1 Cơ sở lý thuyết bài toán phân loại điều chế tự động

Nhận dạng điều chế tự động (Automatic Modulation Classification – AMC) là quá trình xác định dạng điều chế của tín hiệu thu mà không cần thông tin

tiên nghiệm từ phía máy phát. Đây là một chức năng quan trọng trong các hệ thống vô tuyến thông minh, vô tuyến nhận thức và giám sát phổ tần.

Trong hệ thống thông tin vô tuyến, tín hiệu thu được tại máy thu có thể được biểu diễn bởi:

$$r(t) = s(t) * h(t) + n(t) \quad (1.1)$$

trong đó  $s(t)$  là tín hiệu phát,  $h(t)$  là đáp ứng kênh truyền và  $n(t)$  là nhiễu Gauss trắng cộng (AWGN).

Tín hiệu thu thường được biểu diễn dưới dạng tín hiệu IQ gồm hai thành phần trực giao:

$$r(t) = I(t) + jQ(t) \quad (1.2)$$

Biểu diễn IQ bảo toàn đầy đủ thông tin biên độ và pha của tín hiệu, do đó được sử dụng rộng rãi trong các hệ thống AMC hiện đại.

Dưới góc độ học máy, AMC được xem là bài toán phân loại đa lớp, trong đó mô hình cần xây dựng hàm ánh xạ từ tín hiệu thu đến nhãn điều chế:

$$\hat{y} = f(\mathbf{R}; \theta) \quad (1.3)$$

với  $\mathbf{R}$  là tín hiệu đầu vào và  $\theta$  là tập tham số của mô hình. Quá trình huấn luyện nhằm tìm bộ tham số tối ưu để cực tiểu hóa xác suất phân loại sai:

$$P(\hat{y} \neq y) \quad (1.4)$$

trong các điều kiện kênh truyền khác nhau. Trong luận án này, các mô hình học sâu được nghiên cứu nhằm tự động học đặc trưng từ tín hiệu IQ, từ đó nâng cao độ chính xác và khả năng hoạt động của hệ thống AMC trong môi trường vô tuyến phức tạp.

### 1.1.2 Tổng quan về các phương pháp nhận dạng điều chế tự động

Các phương pháp nhận dạng điều chế tự động (AMC) có thể được chia thành hai nhóm chính gồm các phương pháp cổ điển và các phương pháp dựa trên học máy, học sâu.

## Các phương pháp AMC cổ điển

Các phương pháp AMC cổ điển bao gồm hai hướng tiếp cận chủ yếu là phương pháp dựa trên hàm hợp lý (Likelihood-Based - LB) và phương pháp dựa trên trích chọn đặc trưng (Feature-Based - FB).

Phương pháp LB xây dựng hàm xác suất của tín hiệu thu đối với từng giả thuyết điều chế và lựa chọn kiểu điều chế có giá trị hàm hợp lý lớn nhất. Trong điều kiện lý tưởng, phương pháp này đạt hiệu năng tối ưu theo tiêu chuẩn Bayes. Tuy nhiên, độ phức tạp tính toán rất cao và đòi hỏi thông tin chính xác về kênh truyền, khiến việc triển khai trong các hệ thống thời gian thực gặp nhiều khó khăn.

Để giảm độ phức tạp, các phương pháp FB thực hiện trích xuất các đặc trưng tín hiệu như mô-men bậc cao, đặc trưng biên độ, pha tức thời, đặc trưng chu kỳ dừng hoặc đặc trưng thời gian–tần số, sau đó sử dụng các bộ phân loại như KNN, SVM hoặc Decision Tree để nhận dạng điều chế. Mặc dù có chi phí tính toán thấp hơn, hiệu năng của các phương pháp này phụ thuộc mạnh vào chất lượng đặc trưng được thiết kế thủ công và thường suy giảm đáng kể trong điều kiện SNR thấp hoặc fading phức tạp.

Nhìn chung, các phương pháp AMC cổ điển còn hạn chế về khả năng thích nghi, khó mở rộng đối với các hệ thống vô tuyến hiện đại và các dạng điều chế bậc cao.

## AMC dựa trên học máy và học sâu

Sự phát triển của học máy (Machine Learning) và học sâu (Deep Learning) đã tạo ra bước tiến quan trọng cho bài toán AMC. Khác với các phương pháp truyền thống, các mô hình học sâu có khả năng tự động học đặc trưng trực tiếp từ dữ liệu tín hiệu mà không cần thiết kế đặc trưng thủ công.

Các mô hình được sử dụng phổ biến bao gồm mạng nơ-ron tích chập (CNN), mạng hồi tiếp (RNN, LSTM), các mô hình lai CNN–LSTM, mạng Residual, DenseNet, Attention và Transformer. Trong đó, CNN cho khả năng trích xuất đặc trưng hiệu quả từ tín hiệu IQ hoặc ảnh thời gian–tần số, trong khi LSTM và BiLSTM có khả năng khai thác mối quan hệ phụ thuộc theo thời gian của tín hiệu.

Bên cạnh kiến trúc mạng, biểu diễn tín hiệu đầu vào cũng đóng vai trò quan trọng. Các nghiên cứu hiện nay thường sử dụng tín hiệu IQ trực tiếp hoặc các biểu diễn thời gian–tần số như STFT, WVD và SPWVD nhằm tăng cường khả



năng phân biệt giữa các dạng điều chế.

Mặc dù đạt hiệu năng vượt trội so với các phương pháp truyền thống, các mô hình học sâu hiện nay vẫn tồn tại một số hạn chế như độ phức tạp tính toán lớn, số lượng tham số cao, hiệu năng chưa ổn định trong điều kiện SNR thấp và khả năng tổng quát hóa còn hạn chế đối với dữ liệu thực tế.

### 1.1.3 Khoảng trống nghiên cứu

Qua khảo sát các công trình liên quan có thể nhận thấy rằng hiệu năng của AMC phụ thuộc đáng kể vào cả mô hình mạng và không gian biểu diễn tín hiệu. Tuy nhiên, nhiều mô hình hiện nay vẫn được kế thừa từ thị giác máy tính và chưa được thiết kế chuyên biệt cho tín hiệu vô tuyến. Bên cạnh đó, việc kết hợp hiệu quả giữa đặc trưng miền thời gian, miền thời gian–tần số và thông tin điều kiện kênh vẫn chưa được khai thác đầy đủ. Đây chính là động lực để luận án đề xuất các mô hình học sâu mới nhằm nâng cao độ chính xác, tăng khả năng chống nhiễu và giảm độ phức tạp tính toán cho bài toán nhận dạng điều chế tự động.

## 1.2 Kết luận chương 1

Chương 1 đã trình bày tổng quan về bài toán phân loại điều chế tự động trong các hệ thống thông tin vô tuyến hiện đại, đồng thời phân tích các phương pháp AMC cổ điển, các hướng tiếp cận dựa trên học máy và học sâu, cũng như những ưu điểm và hạn chế của từng nhóm phương pháp. Thông qua khảo sát các công trình nghiên cứu liên quan, một số khoảng trống nghiên cứu đã được xác định, bao gồm khả năng khai thác đặc trưng tín hiệu chưa hiệu quả, hạn chế trong việc mô hình hóa quan hệ thời gian và yêu cầu cân bằng giữa độ chính xác với độ phức tạp tính toán.

Trên cơ sở đó, luận án đề xuất ba hướng nghiên cứu chính gồm: xây dựng mô hình học sâu chuyên biệt cho tín hiệu vô tuyến, phát triển mô hình lai CNN–BiLSTM và nghiên cứu phương pháp học kết hợp cho AMC. Những nội dung này sẽ được trình bày chi tiết trong các chương tiếp theo của luận án.

## Chương 2

# NÂNG CAO HIỆU NĂNG PHÂN LOẠI ĐIỀU CHẾ TỰ ĐỘNG SỬ DỤNG MẠNG NƠ-RON TÍCH CHẬP

### 2.1 Phân tích ảnh hưởng của cấu trúc thời gian, đặc trưng phổ và nhiễu cộng

Trong hệ thống thông tin vô tuyến, tín hiệu thu chịu tác động đồng thời của cấu trúc thời gian do kênh đa đường, đặc trưng phổ và nhiễu cộng. Đây là các yếu tố chính ảnh hưởng trực tiếp đến hiệu năng của bài toán phân loại điều chế tự động (AMC).

#### 2.1.1 Ảnh hưởng của cấu trúc thời gian

Tín hiệu thu trong môi trường đa đường được mô hình hóa bởi:

$$r[n] = \sum_{i=1}^P a_i s[n - \tau_i] + n[n] \quad (2.1)$$

Các thành phần trễ làm xuất hiện phụ thuộc theo thời gian giữa các mẫu tín hiệu. Do đó, mô hình học sâu cần có khả năng khai thác quan hệ dài hạn trong miền thời gian để giảm ảnh hưởng của fading đa đường.

#### 2.1.2 Ảnh hưởng của đặc trưng phổ

Đặc trưng điều chế thể hiện rõ trong miền tần số và có thể bị biến dạng bởi lệch tần số giữa máy phát và máy thu. Điều này làm dịch chuyển phổ tín hiệu và gây thay đổi đặc trưng giữa các lớp điều chế, đòi hỏi mô hình phải học được biểu diễn phổ đa thang và ổn định trước biến động kênh.

#### 2.1.3 Ảnh hưởng của nhiễu cộng

Tín hiệu thu thường chịu nhiễu Gaussian cộng:

$$r[n] = s[n] + n[n] \quad (2.2)$$

Khi SNR giảm, ranh giới giữa các lớp điều chế trở nên mờ, làm suy giảm độ chính xác phân loại. Do đó, mô hình AMC cần học các đặc trưng bền vững và giảm nhạy với nhiễu. Tổng hợp lại, cấu trúc thời gian, đặc trưng phổ và nhiễu cộng là ba yếu tố chính quyết định hiệu năng của hệ thống AMC, và là cơ sở quan trọng cho thiết kế các kiến trúc học sâu trong môi trường vô tuyến phức tạp.

## 2.2 Biểu diễn tín hiệu trong miền tần số và thời gian–tần số

Trong bài toán phân loại điều chế tự động, không gian biểu diễn tín hiệu đóng vai trò quan trọng đối với khả năng trích xuất đặc trưng của mô hình. Hai phương pháp biểu diễn phổ biến là FFT và STFT.

Đối với tín hiệu rời rạc  $x[n]$ , phổ tần số được xác định bởi:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi kn/N} \quad (2.3)$$


Trong khi FFT chỉ cung cấp thông tin miền tần số, STFT cho phép biểu diễn đồng thời đặc trưng thời gian và tần số:

$$\text{STFT}\{x[n]\}(m, \omega) = \sum_{n=-\infty}^{+\infty} x[n] w[n-m] e^{-j\omega n} \quad (2.4)$$

Kết quả thực nghiệm trên các kiến trúc CNN khác nhau (Hình 2.1) cho thấy các mô hình sử dụng STFT luôn đạt độ chính xác cao hơn FFT trên toàn bộ dải SNR. Đặc biệt, ResNet18-STFT đạt độ chính xác cao nhất khoảng 95,5% tại SNR = 8 dB. Kết quả này chứng minh rằng biểu diễn thời gian–tần số bảo toàn thông tin đặc trưng của tín hiệu hiệu quả hơn biểu diễn phổ thuần túy, từ đó nâng cao hiệu năng phân loại điều chế.

### *Kết hợp STFT và Radon Transform để tăng cường đặc trưng*

Để tăng cường khả năng biểu diễn của ảnh thời gian–tần số, luận án kết hợp STFT với biến đổi Radon (STFT-Radon), nhằm làm nổi bật các cấu trúc năng lượng đặc trưng và giảm ảnh hưởng của nhiễu. Kết quả thực nghiệm ở Hình 2.2 cho thấy STFT-Radon luôn đạt độ chính xác cao hơn STFT trên các kiến trúc ResNet18, GoogleNet và MobileNet. Trong đó, ResNet18-STFT-Radon đạt độ chính xác cao nhất khoảng 97,6%, còn GoogleNet và MobileNet được cải thiện trung bình từ 2% đến 3,5%.




Hình 2.1: So sánh độ chính xác phân loại các CNN khác nhau sử dụng STFT và FFT.

Tuy nhiên, khi so sánh với các mô hình sử dụng trực tiếp tín hiệu IQ (Hình 2.3), biểu diễn IQ vẫn cho hiệu năng cao hơn trên toàn bộ dải SNR, với mức chênh lệch trung bình khoảng 10–15%. Kết quả này cho thấy các phép biến đổi STFT và Radon có thể làm mất một phần thông tin đặc trưng của tín hiệu.

Từ các kết quả trên có thể kết luận rằng STFT cho hiệu năng cao hơn FFT, STFT-Radon tiếp tục cải thiện khả năng phân tách đặc trưng, nhưng tín hiệu IQ nguyên thủy vẫn là biểu diễn hiệu quả nhất cho bài toán AMC. Vì vậy, luận án lựa chọn tín hiệu IQ làm đầu vào chính cho các mô hình học sâu được đề xuất ở các phần tiếp theo.

## 2.3 Đề xuất mô hình DFENet

Luận án đề xuất mô hình DFENet (Diverse Feature Extraction Network) cho bài toán nhận dạng điều chế tự động từ tín hiệu IQ nguyên thủy. DFENet kết hợp cơ chế trích xuất đặc trưng đa tỉ lệ (DFE) và tăng cường đặc trưng (FEN) nhằm khai thác hiệu quả thông tin cục bộ và toàn cục của tín hiệu. Cấu trúc mạng gồm ba thành phần chính: tầng khởi tạo, các khối trích xuất



Hình 2.2: So sánh độ chính xác phân loại của các CNN khác nhau sử dụng STFT và STFT-Radon.

đặc trưng và tăng phân loại (Hình 2.4a). Với khoảng 2 triệu tham số, DFENet đạt hiệu năng phân loại cao trong khi vẫn duy trì độ phức tạp tính toán thấp.


### Thiết kế khối DFE và FEN

DFENet được xây dựng từ hai thành phần chính là khối DFE (Diverse Feature Extraction) và khối FEN (Feature Enhancement and Normalization).

Khối DFE có nhiệm vụ trích xuất đặc trưng đa tỉ lệ từ tín hiệu IQ thông qua các nhánh tích chập song song với kích thước bộ lọc khác nhau. Các bộ lọc kích thước nhỏ giúp khai thác các biến đổi cục bộ của biên độ và pha, trong khi các bộ lọc kích thước lớn học các đặc trưng toàn cục và các quan hệ phụ thuộc dài hạn của tín hiệu. Nhờ đó, DFE có khả năng thu nhận đồng thời các đặc trưng ở nhiều thang thời gian khác nhau, góp phần nâng cao khả năng phân biệt giữa các dạng điều chế. Đầu ra của khối DFE được xác định bởi:

$$Y_{DFE} = Y_1 + Y_2 \quad (2.5)$$

trong đó  $Y_1$  và  $Y_2$  là các đặc trưng thu được từ hai nhánh xử lý.




Hình 2.3: So sánh độ chính xác phân loại của các CNN khác nhau sử dụng STFT-Radon và IQ.

Sau quá trình trích xuất đặc trưng, khối FEN thực hiện nhiệm vụ tăng cường và chuẩn hóa đặc trưng nhằm giảm ảnh hưởng của nhiễu và fading. Đồng thời, FEN giảm kích thước không gian đặc trưng để hạn chế độ phức tạp tính toán và tạo ra các biểu diễn ổn định hơn cho các tầng phía sau. Vai trò của FEN tương tự như một cơ chế tinh lọc đặc trưng, giúp giữ lại các thành phần mang thông tin điều chế và loại bỏ các thành phần ít hữu ích. Đầu ra của khối FEN được xác định bởi:

$$F_{FEN} = F_1 + F_2 \quad (2.6)$$

trong đó  $F_1$  và  $F_2$  là các đặc trưng thu được từ hai nhánh xử lý song song.

Sự kết hợp giữa DFE và FEN giúp DFENet đồng thời thực hiện hai nhiệm vụ quan trọng: khai thác đặc trưng đa mức từ tín hiệu IQ và tạo ra các biểu diễn đặc trưng ổn định trước nhiễu. Đây là cơ sở giúp mô hình đạt hiệu năng phân loại cao trong các điều kiện SNR thấp và môi trường fading phức tạp.



Hình 2.4: Cấu trúc tổng thể của DFENet và các khối thành phần.

## 2.4 Kết quả thực nghiệm và thảo luận

### *So sánh với các mô hình hiện có*

So với các kiến trúc CNN phổ biến như Inception, ResNet và MCNet, DFENet được thiết kế chuyên biệt cho tín hiệu vô tuyến thông qua cơ chế trích xuất đặc trưng đa tỉ lệ và khối tăng cường, chuẩn hóa đặc trưng FEN thể hiện trong Bảng 2.1. Thiết kế này cho phép khai thác hiệu quả các đặc trưng của tín hiệu IQ, nâng cao khả năng chống nhiễu và duy trì độ phức tạp tính toán thấp. Nhờ đó, DFENet đạt được sự cân bằng tốt giữa hiệu năng và chi phí tính toán trong bài toán nhận dạng điều chế tự động.

Bảng 2.1: So sánh mô hình mạng DFE với các mô hình đa nhánh và đa quy mô

| Mô hình       | Tích chập đa tỉ lệ                                           | kết nối dư | Chuẩn hóa đặc trưng      |
|---------------|--------------------------------------------------------------|------------|--------------------------|
| Inception     | Có ( $1\times 1$ , $3\times 3$ , $5\times 5$ )               | Không      | BN                       |
| ResNet        | Không (Chỉ $3\times 3$ )                                     | Có         | BN+ReLU                  |
| MCNet         | Có (đa quy mô)                                               | Có         | Không FEN                |
| <b>DFENet</b> | Có ( $1\times 1$ , $3\times 3$ , $5\times 5$ , $7\times 7$ ) | Không      | <b>Khối FEN (Chỉ BN)</b> |

### Nghiên cứu cắt bỏ kiến trúc

Để đánh giá đóng góp của từng thành phần trong DFENet được mô tả ở Bảng 2.2 cho thấy DFENet đầy đủ đạt độ chính xác trung bình cao nhất (80.8%). Việc loại bỏ DFE, FEN hoặc cơ chế tích chập đa tỉ lệ đều làm hiệu năng suy giảm đáng kể, trong khi ShallowNet chỉ đạt 14.95%. Kết quả này khẳng định vai trò quan trọng của cơ chế trích xuất đặc trưng đa tỉ lệ và tăng cường đặc trưng trong việc nâng cao hiệu năng của DFENet.

Bảng 2.2: Nghiên cứu cắt bỏ trên bộ dữ liệu HisarMod2019


| Mô hình                | Khối |     | Bộ lọc đa quy mô (%) | Độ chính xác trung bình (%) |
|------------------------|------|-----|----------------------|-----------------------------|
|                        | DFE  | FEN |                      |                             |
| DFENet- đầy đủ         | ✓    | ✓   | ✓                    | <b>80.8</b>                 |
| Không-FEN              | ✓    | □   | ✓                    | 70.31                       |
| Không-DFE              | □    | ✓   | ✓                    | 70.59                       |
| Không bộ lọc đa quy mô | ✓    | ✓   | $3\times 3$          | 71.25                       |
| ShallowNet             | □    | □   | □                    | 14.95                       |

### So sánh DFENet với các mô hình hiện có

DFENet được đánh giá trên hai bộ dữ liệu HisarMod2019 và RadioML2018 nhằm kiểm chứng khả năng phân loại trong các điều kiện kênh khác nhau và so sánh với các kiến trúc học sâu phổ biến. Kết quả trên HisarMod2019 (Hình 2.5) cho thấy LSTM đạt hiệu năng thấp nhất do khả năng khai thác đặc trưng từ tín hiệu IQ còn hạn chế. Các mô hình CNN như MobileNet, GoogLeNet, Inception,



RepVGG, SqueezeNet, ResNet và MCNet đều cải thiện đáng kể độ chính xác nhờ khả năng học đặc trưng phân cấp. Tuy nhiên, hiệu năng của các mô hình này vẫn suy giảm đáng kể trong vùng SNR thấp.




Hình 2.5: So sánh độ chính xác phân loại của các mô hình CNN đơn lẻ khác nhau đối với tập dữ liệu HisarMod2019.

DFENet đạt kết quả tốt nhất trong số các mô hình được khảo sát với độ chính xác trung bình 78.2%. Đặc biệt, mô hình vẫn duy trì độ chính xác trên 51.2% tại SNR = -20 dB và vượt 90% từ SNR = +2 dB, cho thấy khả năng thích nghi tốt trong môi trường nhiễu và fading mạnh. Hiệu năng này đến từ cơ chế trích xuất đặc trưng đa tỉ lệ của khối DFE, cho phép khai thác đồng thời các đặc trưng cục bộ và dài hạn của tín hiệu IQ.

Luận án tiếp tục đánh giá DFENet trên bộ dữ liệu RadioML2018 và so sánh với các mô hình MCNet, Inception và ResNet như trong Hình 2.6. Kết quả cho thấy Inception đạt hiệu năng thấp nhất, với độ chính xác tối đa khoảng 73% tại SNR = +18 dB. Điều này cho thấy kiến trúc được thiết kế cho thị giác máy tính chưa thực sự phù hợp để khai thác đặc trưng của tín hiệu IQ.

Trong khi đó, ResNet và MCNet đạt hiệu năng tốt hơn nhờ khả năng học đặc trưng sâu và khai thác hiệu quả các liên kết dư. Tại SNR = +18 dB, ResNet



Hình 2.6: So sánh độ chính xác phân loại của các mô hình CNN đơn lẻ khác nhau đối với tập dữ liệu RadioML2018.

và MCNet lần lượt đạt độ chính xác khoảng 81% và 83%. DFENet đạt kết quả cao nhất trên toàn bộ dải SNR khảo sát. Độ chính xác của mô hình vượt 93% tại các mức SNR từ +6 dB trở lên, đồng thời vẫn duy trì trên 60% tại SNR = -20 dB và trên 90% tại SNR = -2 dB. Kết quả này khẳng định khả năng trích xuất đặc trưng hiệu quả và tính bền vững của DFENet trong môi trường nhiễu mạnh, đồng thời cho thấy ưu thế rõ rệt so với các kiến trúc CNN hiện có trên bộ dữ liệu RadioML2018.

## 2.5 Kết luận chương 2

Chương 2 đã khảo sát các phương pháp biểu diễn tín hiệu cho bài toán AMC. Kết quả cho thấy STFT cho hiệu năng cao hơn FFT, trong khi STFT kết hợp Radon giúp tăng cường khả năng phân tách đặc trưng. Tuy nhiên, tín hiệu IQ nguyên thủy vẫn đạt độ chính xác cao nhất nhờ bảo toàn đầy đủ thông tin biên độ và pha. Trên cơ sở đó, luận án đề xuất mô hình DFENet nhằm khai thác trực tiếp tín hiệu IQ thông qua cơ chế trích xuất đặc trưng đa tỉ lệ và chuẩn hóa đặc trưng. Kết quả thực nghiệm trên các bộ dữ liệu chuẩn cho thấy DFENet đạt độ chính xác vượt trội so với nhiều kiến trúc CNN phổ biến, đồng thời duy trì độ phức tạp tính toán thấp.

## Chương 3

# GIẢI PHÁP KẾT HỢP KIẾN TRÚC CÁC MẠNG NƠ-RON CHO NÂNG CAO HIỆU NĂNG PHÂN LOẠI ĐIỀU CHẾ TỰ ĐỘNG

### 3.1 Thiết kế mô hình lai ghép AMC-CNN-BiLSTM

#### 3.1.1 Xây dựng mô hình lai ghép

Mặc dù DFENet đã chứng minh hiệu quả trong việc khai thác các đặc trưng không gian từ tín hiệu IQ thông qua cơ chế tích chập đa tỉ lệ, mô hình vẫn chủ yếu tập trung vào các đặc trưng cục bộ và chưa khai thác đầy đủ mối quan hệ phụ thuộc theo thời gian của tín hiệu vô tuyến.

Về bản chất, tín hiệu điều chế là dữ liệu chuỗi thời gian, trong đó thông tin không chỉ nằm ở từng mẫu riêng lẻ mà còn được thể hiện thông qua sự biến thiên của chuỗi tín hiệu theo thời gian. Đặc biệt trong môi trường fading đa đường, các đặc trưng cục bộ có thể bị suy giảm hoặc che lấp bởi nhiễu, làm giảm hiệu quả của các mô hình CNN thuần túy.

Để khắc phục hạn chế này, luận án đề xuất mô hình lai ghép AMC-CNN-BiLSTM nhằm kết hợp khả năng trích xuất đặc trưng không gian của CNN với khả năng mô hình hóa quan hệ thời gian của mạng hồi quy.


Trong mô hình đề xuất: CNN đóng vai trò trích xuất và nén các đặc trưng quan trọng từ tín hiệu IQ, đồng thời giảm nhiễu và giảm chiều dữ liệu. BiLSTM khai thác đồng thời thông tin quá khứ và tương lai của chuỗi đặc trưng, giúp học được các phụ thuộc thời gian dài hạn và tăng khả năng phân biệt giữa các dạng điều chế.

Nhờ sự kết hợp giữa học đặc trưng không gian và thời gian, mô hình AMC-CNN-BiLSTM được kỳ vọng cải thiện độ chính xác phân loại, đặc biệt trong điều kiện SNR thấp và môi trường kênh truyền phức tạp.

#### Mô hình tổng quan

Mô hình AMC-CNN-BiLSTM nhận đầu vào là tín hiệu IQ kích thước  $1024 \times 2$  và gồm ba thành phần chính: tầng CNN đa nhánh, tầng BiLSTM và tầng phân

loại, như minh họa trong Hình 3.1.



Hình 3.1: Mô hình đề xuất của mô hình AMC-CNN-BiLSTM.

**Tầng CNN đa nhánh** có nhiệm vụ trích xuất đặc trưng không gian từ tín hiệu IQ. Các lớp tích chập ban đầu được sử dụng để học các đặc trưng sơ cấp về biên độ và pha của tín hiệu. Sau đó, dữ liệu được đưa qua các nhánh tích chập song song nhằm khai thác đặc trưng ở nhiều mức độ khác nhau. Các nhánh nông tập trung vào đặc trưng cục bộ, trong khi các nhánh sâu hơn học các đặc trưng trừu tượng và quan hệ phi tuyến phức tạp. Đầu ra của các nhánh được hợp nhất để tạo thành biểu diễn đặc trưng giàu thông tin:

$$Y_{CNN} = f_{CNN}(X) \quad (3.1)$$

Trong đó  $X$  là tín hiệu IQ đầu vào và  $Y_{CNN}$  là đặc trưng sau khối CNN.

Để tăng tính ổn định và khả năng chống nhiễu, các lớp Batch Normalization được sử dụng sau các lớp tích chập nhằm chuẩn hóa phân bố đặc trưng và cải thiện quá trình huấn luyện.

**Tầng BiLSTM** tiếp nhận chuỗi đặc trưng từ CNN và thực hiện mô hình hóa các phụ thuộc theo thời gian của tín hiệu. Khác với LSTM một chiều, BiLSTM khai thác đồng thời thông tin từ quá khứ và tương lai của chuỗi đặc trưng:

$$h_t = [\vec{h}_t, \overleftarrow{h}_t] \quad (3.2)$$

trong đó  $\vec{h}_t$  và  $\overleftarrow{h}_t$  lần lượt là trạng thái ẩn theo hướng tiến và hướng lùi. Cơ chế này giúp mô hình nắm bắt đầy đủ ngữ cảnh thời gian và tăng khả năng phân biệt giữa các dạng điều chế có đặc trưng tương đồng.

**Tầng phân loại** bao gồm lớp kết nối đầy đủ và hàm Softmax để ánh xạ đặc

trung học được vào không gian nhãn điều chế:

$$P(y = i|X) = \frac{\exp(z_i)}{\sum_{k=1}^C \exp(z_k)} \quad (3.3)$$


trong đó  $C$  là số lớp điều chế và  $z_i$  là đầu ra của lớp kết nối đầy đủ.

Nhờ kết hợp khả năng trích xuất đặc trưng không gian của CNN và khả năng học quan hệ thời gian của BiLSTM, mô hình AMC-CNN-BiLSTM có thể khai thác hiệu quả cả đặc trưng cục bộ lẫn phụ thuộc dài hạn của tín hiệu IQ, từ đó nâng cao độ chính xác phân loại trong các điều kiện nhiễu và fading.

### 3.1.2 Kết quả thực nghiệm và thảo luận

#### Đánh giá hiệu năng mô hình khi thay đổi số lượng bộ lọc

Hình 3.2 cho thấy độ chính xác phân loại tăng khi số lượng bộ lọc tích chập được mở rộng. Điều này cho thấy AMC đòi hỏi không gian đặc trưng đủ lớn để mô hình hóa các khác biệt tinh vi giữa các dạng điều chế.




Hình 3.2: Độ chính xác phân loại với số lượng bộ lọc khác nhau.

Tuy nhiên, việc tăng trực tiếp số lượng bộ lọc làm gia tăng đáng kể số tham số và chi phí tính toán. Do đó, thay vì mở rộng mạng theo chiều rộng, mô hình AMC-CNN-BiLSTM sử dụng kiến trúc CNN đa nhánh nhằm khai thác đặc trưng đa tỉ lệ hiệu quả hơn trong khi vẫn duy trì độ phức tạp ở mức hợp lý.

## Ảnh hưởng của độ dài tín hiệu

Kết quả trong Hình 3.3 cho thấy độ chính xác phân loại tăng theo độ dài tín hiệu đầu vào. Khi số lượng mẫu lớn hơn, mô hình có khả năng quan sát đầy đủ hơn cấu trúc điều chế và các quan hệ phụ thuộc theo thời gian của tín hiệu.




Hình 3.3: Độ chính xác phân loại với các độ dài tín hiệu khác nhau.

Kết quả này là cơ sở cho việc tích hợp lớp BiLSTM vào kiến trúc đề xuất. Thông qua cơ chế xử lý hai chiều, BiLSTM cho phép khai thác hiệu quả thông tin ngữ cảnh dài hạn, góp phần cải thiện độ chính xác phân loại, đặc biệt trong môi trường nhiễu và fading.

## So sánh mô hình với các mô hình hiện có

Để đánh giá hiệu quả của mô hình đề xuất, AMC-CNN-BiLSTM được so sánh với các mô hình học sâu phổ biến như ResNet18, GoogleNet, MobileNet, SqueezeNet, RepVGG, LSTM và CLDNN. Kết quả trong Hình 3.4 cho thấy AMC-CNN-BiLSTM đạt độ chính xác cao nhất trên toàn bộ dải SNR khảo sát.

Đặc biệt, mô hình duy trì hiệu năng vượt trội trong điều kiện SNR thấp, đồng thời tiếp tục đạt kết quả tốt ở các mức SNR trung bình và cao. Kết quả



Hình 3.4: So sánh độ chính xác phân loại của các mô hình CNN khác nhau.

này cho thấy việc kết hợp CNN đa nhánh và BiLSTM hai chiều giúp khai thác hiệu quả cả đặc trưng không gian và quan hệ phụ thuộc theo thời gian của tín hiệu IQ. Nhìn chung, AMC-CNN-BiLSTM cải thiện đáng kể độ chính xác phân loại và khả năng tổng quát hóa so với các mô hình hiện có, khẳng định hiệu quả của kiến trúc lai ghép trong bài toán nhận dạng điều chế tự động.

## 3.2 Phương pháp học kết hợp để cải thiện hiệu suất AMC

### 3.2.1 Mô hình học kết hợp CNN

Trong bài toán AMC, mỗi kiến trúc CNN có khả năng khai thác các đặc trưng khác nhau của tín hiệu vô tuyến. Do đó, việc sử dụng một mô hình đơn lẻ có thể dẫn đến khả năng tổng quát hóa hạn chế, đặc biệt trong điều kiện SNR thấp. Để khắc phục vấn đề này, luận án áp dụng phương pháp học kết hợp nhằm tận dụng tính bổ sung giữa nhiều mô hình CNN khác nhau.

Trong nghiên cứu này, các mô hình ResNet18, MobileNet và GoogleNet được huấn luyện độc lập trên cùng tập dữ liệu đầu vào. Mỗi mô hình tạo ra một vector xác suất dự đoán cho các lớp điều chế. Quyết định cuối cùng được xác

định thông qua cơ chế hợp nhất xác suất:

$$\hat{y} = \arg \max_c \left( \frac{1}{K} \sum_{k=1}^K p_k(c|\mathbf{x}) \right), \quad (3.4)$$

trong đó  $p_k(c|\mathbf{x})$  là xác suất dự đoán của mô hình thứ  $k$  đối với lớp  $c$ .

Phương pháp này cho phép khai thác ưu điểm của từng kiến trúc CNN, đồng thời giảm ảnh hưởng của các dự đoán sai từ từng mô hình riêng lẻ. Nhờ đó, hệ thống đạt độ ổn định và khả năng tổng quát hóa tốt hơn trong các điều kiện nhiễu và fading khác nhau.

Mục tiêu của học kết hợp trong nghiên cứu này là đánh giá tác động của tính đa dạng kiến trúc và biểu diễn đầu vào đến hiệu năng phân loại điều chế. Các kết quả thu được cũng tạo cơ sở cho các hướng phát triển tiếp theo của luận án theo hướng đa đầu vào và nhận biết SNR.

### 3.2.2 Phương pháp học kết hợp CNN cho phân loại điều chế

Luận án nghiên cứu phương pháp học kết hợp nhằm nâng cao hiệu năng phân loại điều chế. Với  $n$  mô hình CNN độc lập, xác suất dự đoán cuối cùng được xác định bởi:

$$\mathbf{p} = \sum_{i=1}^n \alpha_i \mathbf{y}_i, \quad \sum_{i=1}^n \alpha_i = 1. \quad (3.5)$$

Trong đó,  $\mathbf{y}_i$  là xác suất dự đoán của mô hình thứ  $i$  và  $\alpha_i$  là trọng số kết hợp. Các mô hình cơ sở gồm ResNet18, MobileNet và GoogleNet được huấn luyện độc lập, sau đó kết hợp bằng các chiến lược trung bình xác suất, bỏ phiếu đa số và trung bình có trọng số. Kết quả cho phép đánh giá khả năng cải thiện độ chính xác của học kết hợp so với từng mô hình đơn lẻ.


### 3.2.3 Kết quả thực nghiệm và phân tích hiệu năng học kết hợp

#### So sánh mô hình học kết hợp với các CNN đơn

Hiệu năng của phương pháp học kết hợp được đánh giá bằng cách so sánh với các mô hình CNN đơn phổ biến gồm ResNet18, SqueezeNet, MobileNet, GoogleNet và RepVGG. Kết quả trong Hình 3.5 cho thấy không có mô hình đơn nào duy trì hiệu năng tốt nhất trên toàn bộ dải SNR.

GoogleNet cho kết quả thấp nhất, với độ chính xác cực đại khoảng 56.76% tại  $\text{SNR} = +18$  dB. MobileNet và RepVGG cải thiện đáng kể hiệu năng, trong






Hình 3.5: So sánh độ chính xác phân loại của các CNN đơn.

khi ResNet18 và SqueezeNet đạt độ chính xác cao ở vùng SNR trung bình và cao. Tuy nhiên, các mô hình này đều suy giảm đáng kể khi SNR thấp.

Để khai thác tính bổ sung giữa các kiến trúc CNN, luận án xây dựng các mô hình học kết hợp EnCNN2, EnCNN3 và EnCNN5 sử dụng các chiến lược trung bình không trọng số và trung bình có trọng số. Kết quả trong Hình 3.6 cho thấy các mô hình học kết hợp đều đạt độ chính xác cao hơn so với các CNN đơn trên toàn bộ dải SNR khảo sát.

Đặc biệt, trong vùng SNR thấp ( $-20$  dB đến  $+2$  dB), các mô hình học kết hợp cải thiện khoảng 10% so với ResNet18 và khoảng 4% so với RepVGG. Ở vùng SNR trung bình và cao, độ chính xác tiếp tục được cải thiện, cho thấy khả năng chống nhiễu và tổng quát hóa tốt hơn của phương pháp học kết hợp. Trong số các cấu hình khảo sát, EnCNN3w đạt kết quả tốt nhất. Mô hình đạt độ chính xác 52.76% tại  $\text{SNR} = -20$  dB và gần 99% tại  $\text{SNR} = +18$  dB. Kết quả này chứng minh rằng việc kết hợp các mô hình có đặc tính bổ sung cùng với cơ chế gán trọng số phù hợp giúp nâng cao đáng kể hiệu năng phân loại điều chế.



Hình 3.6: So sánh độ chính xác giữa các mô hình CNN đơn và các mô hình học kết hợp.

### 3.3 Kết luận chương 3

Chương 3 đã mở rộng hướng nghiên cứu từ khai thác đặc trưng không gian sang mô hình hóa đồng thời đặc trưng không gian và thời gian của tín hiệu điều chế. Trên cơ sở đó, luận án đề xuất mô hình AMC-CNN-BiLSTM nhằm kết hợp khả năng trích xuất đặc trưng của CNN với năng lực học phụ thuộc chuỗi của BiLSTM. Kết quả thực nghiệm cho thấy AMC-CNN-BiLSTM đạt độ chính xác cao hơn các mô hình CNN và LSTM đơn lẻ, đặc biệt trong điều kiện SNR thấp và fading mạnh. Điều này khẳng định vai trò quan trọng của thông tin phụ thuộc thời gian trong bài toán AMC. Bên cạnh đó, phương pháp học kết hợp CNN được đề xuất đã khai thác hiệu quả tính bổ sung giữa các kiến trúc khác nhau, giúp nâng cao độ chính xác và độ ổn định so với từng mô hình riêng lẻ.

# KẾT LUẬN VÀ HƯỚNG PHÁT TRIỂN

## Kết quả đóng góp chính của luận án

1. Đề xuất mô hình trích xuất đặc trưng đa nhánh DFENet cho phân loại điều chế từ tín hiệu IQ nhằm tăng cường tính đa dạng trong không gian biểu diễn, đồng thời duy trì khả năng học đặc trưng cục bộ và toàn cục của tín hiệu.
2. Đề xuất mô hình dạng kiến trúc lai ghép CNN-BiLSTM nhằm mô hình hóa đồng thời đặc trưng không gian và phụ thuộc chuỗi theo thời gian của tín hiệu điều chế, cải thiện hiệu năng nhận dạng trên dải SNR rộng.
3. Đề xuất phương pháp ensemble giữa các mô hình CNN, tận dụng tính bổ sung về đặc trưng của các kiến trúc mạng nhằm nâng cao độ chính xác phân loại.

## HƯỚNG NGHIÊN CỨU TIẾP THEO

Trên cơ sở các kết quả đã đạt được, luận án có thể tiếp tục được phát triển theo hướng xây dựng các mô hình AMC có khả năng nhận biết điều kiện kênh truyền thông qua việc khai thác thông tin SNR và các tham số môi trường vô tuyến. Bên cạnh đó, hướng nghiên cứu trọng tâm là phát triển các kiến trúc đa đầu vào – đa đầu ra (Multi-In-Multi-Out), cho phép đồng thời thực hiện nhận dạng điều chế và ước lượng các tham số không gian như DOA trong một khuôn khổ học sâu thống nhất. Ngoài ra, việc áp dụng các phương pháp học bán giám sát, học tự giám sát, cùng với tối ưu hóa mô hình để triển khai trên phần cứng thời gian thực và đánh giá trên dữ liệu thu thực sẽ góp phần nâng cao khả năng ứng dụng của các hệ thống vô tuyến thông minh trong thực tế.

