

基于双曲状态空间模型的无线电信号调制识别

王冠淳, 刘 淳, 张向荣*, 陈亦凡, 张天扬, 唐 旭

(西安电子科技大学人工智能学院, 陕西西安 710126)

摘要: 无线通信系统利用接收信号的数据特性进行自动调制识别(Automatic Modulation Recognition, AMR)是确保电磁频谱智能监测与管控的重要先导步骤。近年来,深度学习技术凭借其强大的隐式特征提取能力被广泛研究,国内外学者致力于探索深度学习技术在信号调制识别任务中的潜力,并已提出一系列AMR方法,依据其采用的网络架构可粗略划分为以下三种类型:基于卷积神经网络(Convolutional Neural Networks, CNN)、基于循环神经网络(Recurrent Neural Networks, RNN)以及基于Transformer网络的方法。然而,在动态复杂电磁环境中,现有AMR方法面临两大共性挑战:现有深度学习模型对时变信道噪声缺乏自适应感知能力,导致不同信噪比(Signal-to-Noise Ratio, SNR)条件下的不同调制类型之间易产生混淆;现有模型在长时序信号建模中的计算效率与特征提取能力难以兼顾,对长序列信号数据的判别精度受限。因此,针对现有调制识别方法缺乏电磁环境感知能力、长时序高效建模能力不足等问题,本文将状态空间模型(State Space Models, SSMs)的长序列建模能力与双曲几何空间的SNR感知特性相结合,提出一种基于双曲状态空间模型(Hyperbolic state space model, H-Mamba)的无线电信号调制识别方法。具体地,本文首先建立了一种基于状态空间模型的时频特征挖掘机制(Mamba-based Time-frequency Feature Mining, MTFM),联合提取时域与频域判别性表征以增强不同调制类型信号间可分性;其次,从双曲几何空间的角度提出了一种新颖的信号质量感知方法,依据所接收信号的双曲几何半径判断其SNR分布情况,并基于此设计了一种基于双曲SNR提示的特征调制模块(Hyperbolic SNR-aware Feature Modulation, HSFM),通过双曲几何引导动态调整信号表征,提升模型对不同SNR条件的适应能力;最后,提出了一种基于双曲SNR感知的课程学习策略(Hyperbolic SNR-aware Curriculum Learning, HSCL),通过双曲距离度量实现对样本质量差异的感知,从而动态调整模型训练过程以缓解低质数据干扰。实验结果表明:本文方法在RML2016A(RadioML2016.10A)、RML2016B(RadioML2016.10B)以及RML2018(RadioML2018)等多个公开信号调制识别数据集上均取得最优性能,较现有最优方法分别提高了4.09%、1.58%、1.21%,证明了其有效性。

关键词: 认知无线电;信号调制识别;状态空间模型(SSMs);双曲几何;信噪比(SNR)感知

基金项目: 国家自然科学基金(No.62506285, No.62501433, No.62571387, No.62276197);陕西省自然科学基金基础研究计划(No.2025JC-YBQN-795);中国博士后科学基金(No.2025T180431, No.2025M771550)

中图分类号: TN911.72; TP183

文献标识码: A

文章编号: 0372-2112(2026)02-0517-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20251225

Research on Radio Signal Modulation Recognition Based on Hyperbolic State Space Model

WANG Guanchun, LIU Chun, ZHANG Xiangrong*, CHEN Yifan, ZHANG Tianyang, TANG Xu

(School of Artificial Intelligence, Xidian University, Xi'an, Shaanxi 710126, China)

Abstract: In wireless communication systems, automatic modulation recognition (AMR) leveraging the intrinsic characteristics of received signals serves as a crucial prerequisite for intelligent electromagnetic spectrum monitoring and management. In recent years, deep learning technology has been widely studied due to its powerful implicit feature representation capabilities. Many scholars have explored the potential of deep learning technology in signal modulation recognition tasks and have proposed a series of AMR methods, which can be roughly divided into three types based on their network architecture: convolutional neural networks-based (CNN), recurrent neural networks-based (RNN), and Transformer-based methods. However, in dynamic and complex electromagnetic environments, existing AMR methods face two common challenges: existing models typically lack adaptive perception capabilities for time-varying channel noise, leading to confusion between different modulation types under varying signal-to-noise ratio (SNR) conditions; existing models struggle to balance computational efficiency and representation capabilities in long-term signal modeling, limiting the accuracy of discrimination for long-sequence signals. Considering existing modulation recognition methods typically lack the capabilities of electromagnetic environment perception and struggle to efficiently model long-term time sequences, this paper proposes a

novel hyperbolic state space model (H-Mamba) that integrates the long-sequence modeling capability of state space models (SSMs) with the SNR awareness inherent in hyperbolic geometry. Specifically, we first develop a Mamba-based time-frequency feature mining (MTFM) mechanism to jointly extract discriminative representations from both time and frequency domains, thereby enhancing inter-class separability among different modulation types. Next, we introduce a novel signal quality perception method from the perspective of hyperbolic geometry that correlates the hyperbolic radius of a received signal with its SNR distribution. Building upon this insight, we design a hyperbolic SNR-aware feature modulation (HSFM) module that dynamically adjusts signal representations under hyperbolic geometric guidance, improving model robustness across varying SNR conditions. Furthermore, we propose a hyperbolic SNR-aware curriculum learning (HSCL) strategy that leverages hyperbolic distance to perceive sample quality differences, enabling adaptive training dynamics that mitigate the adverse impact of low-quality data. Extensive experiments on multiple public AMR benchmarks, including RadioML2016.10A (RML2016A), RadioML2016.10B (RML2016B), RadioML2018 (RML2018), demonstrate that the proposed H-Mamba achieves state-of-the-art performance, outperforming current best baselines by 4.09%, 1.58%, and 1.21%, respectively, thereby validating its efficacy.

Keywords: cognitive radio; signal modulation recognition; state space models (SSMs); hyperbolic geometric perception; signal-to-noise ratio (SNR) perception

Foundation Item(s): National Natural Science Foundation of China (No.62506285, No.62501433, No.62571387, No.62276197); Natural Science Basic Research Program of Shaanxi (No.2025JC-YBQN-795); China Postdoctoral Science Foundation (No.2025T180431, No.2025M771550)

0 引言

无线电信号感知与解译是电磁频谱资源管理与监测中的关键任务,其旨在先验信息缺失条件下通过智能化手段对所接收电磁信号进行识别与分析,在电子对抗、无线电频谱管控等诸多领域具有广泛应用价值^[1-4]。随着无线通信、物联网、计算机等技术的高速发展,无线电用频设备数量快速增长,为高效、准确的无线电频谱资源管理与监测带来了严峻挑战。如何对海量、非合作无线电信号进行自动化、高精度解译与分析成为亟须解决的关键问题。电磁信号自动调制识别(Automatic Modulation Recognition, AMR)是无线电通信系统中的重要先导步骤,其主要目标是通过分析所接收信号的波形特征,自动推断其调制方式,从而在非合作条件下实现对所截获信号信息的有效提取,为后续的信号解调与分析提供基础支撑^[5-9]。

传统 AMR 方法可大体划分为基于最大似然技术的识别方法^[10]与基于特征工程的识别方法^[11]。前者依赖于对信号统计特性的精确建模,通过最大化观测信号在不同调制假设下的似然值来实现调制类型的识别。此类方法在信道条件良好、先验知识充分的简单场景下表现出较好的识别性能,然而其求解成本高,难以满足实时性或资源受限场景下的信号解译需求。基于特征工程的方法则依赖于手工设计的信号时频特征、统计特征或高阶累积量等判别性特征,结合机器学习分类器(如支持向量机、随机森林或 K 近邻等)进行调制类型识别。相较于基于最大似然技术的方法,此类方法识别效率高、部署资源要求低,但面对复杂电磁环境下信号形式多样、信道参数时变等

情况时性能受限、泛化性能不足。然而,由于电磁环境日趋复杂,所接收信号数据低质、特征畸变等问题愈发严重,传统基于专家经验或统计学习的方法难以应对精细化信号调制类型识别挑战。

近年来,深度学习技术^[12]在计算机视觉^[13]、自然语言处理^[14]等领域中展现出显著优势,深度神经网络避免了传统方法中的烦琐手工特征设计,凭借其强大的隐式判别性特征提取能力而被广泛关注。为此,许多学者致力于探索深度学习技术在信号调制识别任务中的潜力。现有基于深度学习的信号调制识别方法通常可依据其采用的网络架构而粗略划分为以下三种类型:基于卷积神经网络(Convolutional Neural Networks, CNN)^[15-18]、基于循环神经网络(Recurrent Neural Networks, RNN)^[19-22]以及基于Transformer网络^[23-26]的调制识别方法。

文献[15]首次提出了基于CNN的信号调制识别模型,其通过将卷积层与全连接层相级联的方式实现对信号调制类型的分类,取得了超越传统方法的性能。文献[18]在CNN基础上引入多层次小波分解策略,建立了一种自适应小波神经网络(Adaptive Wavelet Network, AWN),通过引入频域先验知识有效挖掘信号本征特征。考虑到同相/正交(In-phase/Quadrature, I/Q)信号的时间序列属性,文献[21]提出了基于多通道卷积与长短时序挖掘的深度网络(Multi-channel Convolutional Long short-term Deep Neural Network, MCLDNN),其首先通过多维度卷积操作提取I/Q维度判别特征,其次利用长短时记忆(Long Short-Term Memory, LSTM)模块层捕捉其时序特征,并在多个公开数据集上验证了该模型的判识优势。文献[24]借助

Transformer 网络优异的全局信息提取能力提出了一种基于复值神经网络的调制识别模型,通过单独挖掘 I、Q 维度数据高维特征并采用交叉注意力机制对其进行融合,有效提升了识别精度。为了协同利用 Transformer 网络的长程依赖信息提取能力与 CNN 良好的局部信息感知能力,文献[25]设计了一种卷积与 Transformer 模块的级联网络架构(Convolutional Dual-Attention Transformer, CDAT),利用卷积与 Transformer 机制联合提取数据局部细节与全局语义特征,提升模型的识别精度与泛化性。而文献[26]设计了一种基于时频信息联合挖掘的 CNN-Transformer 混合架构(Multi-channel Convolutional Distilled Transformer, MCDformer),其首先将 I/Q 信号投影至频域空间进行特征去噪,其次输入 CNN 进行时域特征提取,最后使用 Transformer 模块进行多模态信息整合,实现精准调制识别。

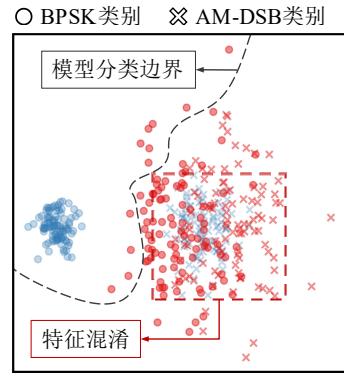
尽管上述深度模型在调制识别任务中展现出一定的有效性,但其网络架构设计仍然存在两个缺陷:

(1)缺乏电磁环境感知能力。现有深度模型设计通常仅聚焦于不同调制类型信号间的判别性特征学习与优化,忽视了对不同电磁环境下信号数据分布特性的感知与针对性处理。在实际应用中,信号数据质量常因电磁环境的动态变化而展现出显著差异,当面临强电磁干扰、邻近通信系统密集、非稳态传输信道等场景时,所接收的通信信号往往呈现出较低信噪比(Signal-to-Noise Ratio, SNR),导致信号主体信息被噪声成分淹没。相反地,当通信传播环境理想、通信干扰可控时,所截获的信号往往具备较高 SNR,呈现出清晰的信号主体特征。其中,低 SNR 信号数据中的噪声干扰会破坏深度学习模型对信号序列时空演变规律的挖掘能力,导致模型难以捕获不同调制类型信号的本征特征;另一方面,采用不同 SNR 水平的混杂数据进行联合训练将导致低质数据的模糊特征损坏不同调制类型信号的特征空间可分性,导致判别模型的决策边界混淆。如图 1(a)所示,在低 SNR 下二进制相移键控(Binary Phase Shift Keying, BPSK)调制信号的时频特征与高 SNR 下幅度调制单边带(Amplitude Modulation Single SideBand, AM-SSB)信号高度重叠,导致深度模型难以准确挖掘各类型信号间的本征差异。


(2)长时序高效建模能力不足。现有深度学习模型在表征 I/Q 信号序列数据时受其架构固有特性影响,难以高效挖掘时序信号的全局判别性时频表征。基于 CNN 的模型虽具备局部判别信息提取能力,但难以对具有周期性或非平稳调制特征的长序列数据建模,RNN 则在捕捉长距离依赖时效率低下且性能不佳。基于 Transformer 网络的模型利用自注意力机制可实现全局序列建模,但其计算复杂度随序列长度

呈二次方增长,计算代价高、效率低。因此,亟须建立一种兼具长序列建模能力、低计算复杂度的新型调制识别网络。

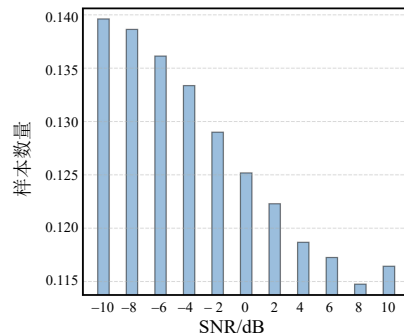
为解决上述问题,本文构建了一种新颖的基于双曲几何空间的信号质量感知方法,揭示了电磁信号



(a) 不同 SNR 下信号特征可视化对比
(a) Visualization comparison of signal features under different SNRs



(b) 不同 SNR 下信号样本的双曲半径可视化对比(AM-DSB 类别)
(b) Visualization comparison of hyperbolic radii of signal samples under different SNRs (AM-DSB category)



(c) 不同 SNR 样本的双曲半径分布统计图(RML2016A 数据集)
(c) Statistical plot of hyperbolic radius distribution of samples under different SNRs (RML2016A dataset)

图 1 本文研究动机

Figure 1 Motivation of H-Mamba

SNR与双曲空间几何半径间的关联,依据所接收信号的双曲几何半径判断其SNR分布情况。本文观察到不同SNR下的信号样本在双曲空间中呈现出显著分布规律。具体地,图1(b)展示了不同SNR下的AM-DSB调制类别样本的双曲半径分布,可以看出低SNR样本具有更大的双曲半径,分布于双曲空间外围且远离庞加莱球球心,特征表达模糊且受复杂噪声干扰;高SNR样本则具有较小的双曲半径,聚集于庞加莱球中心区域,具有更显著的共性特征与类别可分性。图1(c)展示了RML2016A数据集上样本在不同SNR条件下的双曲半径均值统计结果,进一步验证了此现象。基于此,提出了一种基于双曲状态空间模型(Hyperbolic state space model, H-Mamba)的无线电调制识别网络,该网络将状态空间模型(State Space Models, SSMs)的长序列建模能力与双曲空间的SNR感知能力相结合,可有效提升模型在不同电磁环境下的识别稳定性与准确性。

具体地,首先建立基于状态空间模型的时频特征挖掘机制(Mamba-based Time-frequency Feature Mining, MTFM),从时域、频域角度联合抽取信号序列的判别性表征,有效提升不同调制类型信号间的特征可分性。其次,设计了一种基于双曲SNR提示的特征调制模块(Hyperbolic SNR-aware Feature Modulation, HSFM),通过在双曲空间中引导模型感知样本SNR分布差异,动态调整模型对不同SNR条件下的信号表征,增强其在复杂电磁环境下的鲁棒性。再次,提出了一种基于双曲SNR感知的课程学习策略(Hyperbolic SNR-aware Curriculum Learning, HSCL),将信号样本特征映射至双曲几何空间中,通过双曲距离度量实现对样本质量差异的感知,从而动态调整模型训练过程以缓解低质数据干扰。最后,在包括RML2016A(RadioML2016.10A)、RML2016B(RadioML2016.10B)以及RML2018(RadioML2018)等多个公开的信号调制识别任务数据集上的实验结果表明:本文所提出的H-Mamba模型的调制识别准确率相较于现有最优模型分别提升了4.09%、1.58%、1.21%,证明了其有效性。本文的主要贡献如下:

(1)提出了一种基于H-Mamba的无线电调制识别网络,其协同利用SSMs的长序列建模能力与双曲空间的信号质量感知能力,实现了对复杂电磁环境下调制信号的高效识别,在多个公开无线电调制识别数据集上的实验结果表明:所提方法表现出了最佳识别性能。

(2)提出了一种MTFM,通过局部信息感知单元与全局语义整合单元,协同挖掘无线电数据序列的时频判别性表征,助力目标调制类型判别。

(3)设计了一种HSFM,通过动态调整模型实现对不同SNR条件下信号的鲁棒表征,增强其在复杂电磁环境下的判别能力。

(4)建立了一种基于HSCL,在双曲几何空间下感知各信号样本SNR差异,从而有效降低低质信号对模型训练的影响。

1 预备知识

1.1 SSMs

SSMs利用一组状态变量对动态时序系统进行建模,近年来已成为分析序列数据的有效工具,其建模过程可表述为一系列常微分方程,用于实现序列到序列的投影^[27-30]。该过程可简化表示为

$$\begin{cases} \mathbf{h}'(t) = \mathbf{A}\mathbf{h}(t) + \mathbf{B}\mathbf{x}(t) \\ \mathbf{y}(t) = \mathbf{C}\mathbf{h}(t) + \mathbf{D}\mathbf{x}(t) \end{cases} \quad (1)$$

其中: $\mathbf{h}(t) \in \mathbb{R}^N$ 表示隐状态; $\mathbf{x}(t) \in \mathbb{R}^L$ 表示输入序列; $\mathbf{y}(t) \in \mathbb{R}^L$ 表示输出序列; N 和 L 分别表示隐空间和序列的规模。SSMs的核心在于通过状态转移矩阵 $\mathbf{A} \in \mathbb{R}^{N \times N}$ 、状态控制矩阵 $\mathbf{B} \in \mathbb{R}^{N \times L}$ 以及输出矩阵 $\mathbf{C} \in \mathbb{R}^{L \times N}$ 来建模所输入数据的长距离依赖关系。 $\mathbf{D} \in \mathbb{R}^1$ 通常被设置为1,用于实现残差连接操作。Mamba模型^[27]通过零阶保持法将连续SSMs离散化,使其满足离散数据序列处理需求,具体转换为

$$\begin{cases} \bar{\mathbf{A}} = \exp(\Delta\mathbf{A}) \\ \bar{\mathbf{B}} = (\Delta\mathbf{A})^{-1}(\exp(\Delta\mathbf{A}) - \mathbf{I}) \cdot \Delta\mathbf{B} \end{cases} \quad (2)$$

采用步长 Δ 对式(1)进行离散化,状态空间变换方式可重新表述为

$$\begin{cases} \mathbf{h}_t = \bar{\mathbf{A}}\mathbf{h}_{t-1} + \bar{\mathbf{B}}\mathbf{x}_t \\ \mathbf{y}_t = \mathbf{C}\mathbf{h}_t + \mathbf{D}\mathbf{x}_t \end{cases} \quad (3)$$

为进一步增强模型对长距离依赖关系的建模能力,Mamba模型^[27]在SSMs的基础上引入了选择性扫描机制,该机制将可学习的变换矩阵调整为与输入数据相关的形式,即 $\mathbf{B} \in \mathbb{R}^{P \times L \times N}$, $\mathbf{C} \in \mathbb{R}^{P \times L \times N}$ 以及 $\Delta \in \mathbb{R}^{P \times L \times M}$,这些参数与 M 维输入数据 $\mathbf{X} \in \mathbb{R}^{P \times L \times M}$ 相关联。通过引入选择性扫描机制,Mamba模型可根据输入数据动态调整状态转移矩阵权重,从而更高效地捕捉数据序列中的关键信息。

1.2 双曲几何空间

双曲几何空间是一种典型的非欧几里得几何空间,具有恒定负曲率特性^[31]。双曲空间的周长和面积随半径指数增长,使得双曲空间能够在有限的空间内更高效地描述复杂语义的层级拓扑结构,即层次化关系中的上层节点靠近中心、子节点沿半径向外扩散。庞加莱球模型(Poincaré ball model)是双曲空间的一种常用的具体表现形式,该模型将双曲空间投影

至高维欧几里得球体中,通过球面上的测地线来计算任意两点之间的距离,以半径为 $1/\sqrt{c}$ 、曲率为 $-c$ 的庞加莱球模型为例

$$\mathcal{Q}_c^n = \{X \in \mathbb{R}^n : c \|X\|^2 < 1\} \quad (4)$$

该模型从欧氏几何空间投影到双曲空间的转换方程为 $g^{0c} = \lambda_{c,X}^2 g^{En}$, $\lambda_{c,X} = 2/(1 - c \|X\|^2)$ 为共形因子。在庞加莱球模型中,两点间距离计算式定义为

$$d_c^0(X_1, X_2) = (2/\sqrt{c}) \operatorname{artanh}^{-1}(\sqrt{c} \| -X_1 \oplus_c X_2 \|) \quad (5)$$

一般地,庞加莱球模型先采用指数映射将欧氏空间下的输入数据 Z 投影至双曲空间,在双曲空间进行系列运算后,再通过对数映射操作将相关向量投影回欧氏空间,具体指数映射与对数映射操作如式(6)所示:

$$\begin{cases} \exp_{X_0}^0(Z) = X_0 \oplus_c \left(\frac{\tanh(\sqrt{c} \frac{\lambda_{c,X_0} \|Z\|}{2})}{\sqrt{c} \|Z\|} Z \right) \\ \ln_{X_0}^{D,c}(Z) = \frac{2}{\sqrt{c} \lambda_{c,X_0}} \operatorname{artanh}(\sqrt{c} \| -X_0 \oplus_c Z \|) \frac{-X_0 \oplus_c Z}{\| -X_0 \oplus_c Z \|} \end{cases} \quad (6)$$

其中: X_0 为双曲空间的中心原点, \oplus_c 为莫比乌斯加法,即

$$\begin{aligned} X_1 \oplus_c X_2 &= \frac{(1 + 2c \langle X_1, X_2 \rangle + c \|X_2\|^2) X_1 + (1 - c \|X_1\|^2) X_2}{1 + 2c \langle X_1, X_2 \rangle + c^2 \|X_1\|^2 \|X_2\|^2} \end{aligned} \quad (7)$$

此外,给定参数矩阵为 W , 庞加莱球模型下的莫比乌斯矩阵乘法操作为

$$W \otimes_c X = \left(\frac{1}{\sqrt{c}} \right) \tanh \left(\frac{\|WX\|}{\|X\|} \operatorname{artanh}(\sqrt{c} \|X\|) \right) \frac{WX}{\|WX\|} \quad (8)$$

2 基于 H-Mamba 的无线电信号调制识别网络

2.1 总体框架

针对现有深度调制识别模型易受低质数据干扰、难以处理 SNR 各异的混杂数据等问题,本文提出了一种基于 H-Mamba 的无线电信号调制识别网络,图 2 展示了该网络的整体结构框架。给定输入 I/Q 信号 $X \in \mathbb{R}^{P \times 2 \times M}$, 该网络首先对其进行批归一化操作,随后对其 I、Q 以及 IQ 维度进行卷积编码后进行拼接,将输入数据投影至高维特征空间,表示为

$$Z = \psi(H_{2 \times k}(\operatorname{Norm}(X)), H_{1 \times k}(\operatorname{Norm}(X^I)), H_{1 \times k}(\operatorname{Norm}(X^Q))) \quad (9)$$

其中: ψ 表示特征拼接操作; $H_{2 \times k}$ 表示卷积核大小为 $2 \times k$; 以 GELU 为非线性激活函数的卷积层操作。其次,将投影得到的特征 $Z \in \mathbb{R}^{P \times K \times M}$ 输入首个 MTFM 进行时频特征提取,以挖掘 I/Q 信号的时频判别性表征 $Z^{\text{Time-Freq}} \in \mathbb{R}^{P \times K \times M}$ 。再次,将特征 $Z^{\text{Time-Freq}}$ 输入 HSFM 进行 SNR 分布感知,提取 SNR 相关特征 $S \in \mathbb{R}^{P \times K \times M}$, 并以此作为提示信息引导模型对不同 SNR 条件下的数据进行动态自适应。最后,联合时频表征 $Z^{\text{Time-Freq}}$ 与 SNR 相关特征 S 输入 MTFM 模块实现进一步的特征提取,并通过线性层实现调制类型分类。在训练阶段中,利用 HSCL 度量各样本 SNR 分布,并以此改进模型目标函数,缓解低质样本对模型的干扰,提升无线电信号调制识别精度与鲁棒性。

2.2 MTFM

MTFM 旨在从不同数据域视角下协同挖掘 I/Q 信号的判别性表征,该模块由局部信息感知单元与全局语义整合单元组成。局部信息感知单元通过级联残差卷积操作提取 I/Q 时序数据的局部细节特征,增强模型对细微信号差异的感知能力,随后者采用具有线

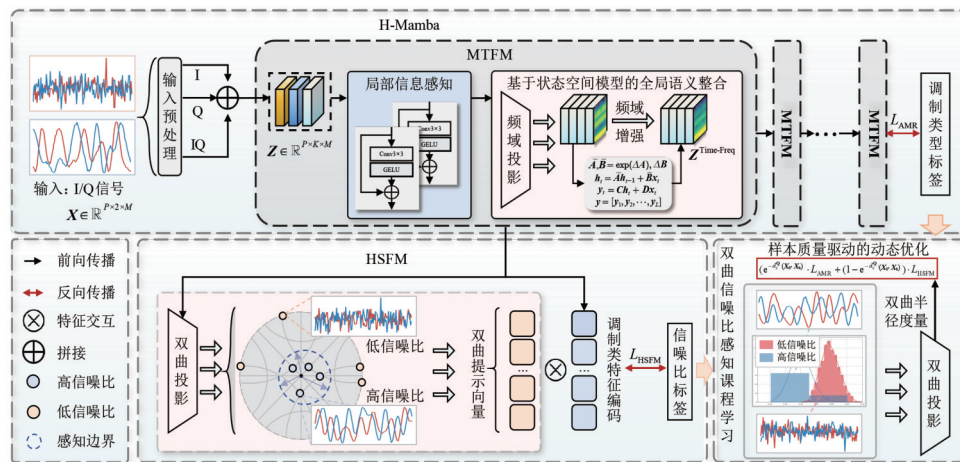


图 2 基于 H-Mamba 的无线电信号调制识别网络框架图

Figure 2 Overall framework of H-Mamba

性复杂度的 SSMs 对信号全局特征进行整合,实现时信号长时序规律的高效建模。

具体地,给定输入序列 $\mathbf{Z} \in \mathbb{R}^{P \times K \times M}$,局部信息感知单元采用一组堆叠的残差卷积块对其进行特征计算,每组残差卷积块由 3×3 卷积层、GELU 激活函数以及残差连接分支组成。通过这种方式,局部信息感知单元能够有效捕捉信号在短时窗口内的变化规律,增强模型对信号序列瞬态特性的表征。随后,将特征序列 $\mathbf{Z}^{\text{Local}} \in \mathbb{R}^{P \times K \times M}$ 输入至全局语义整合单元。

为提取信号序列本征信息并降低噪声干扰,该单元滤除其低频分量后仅保留关键主频特征,对其进行快速傅里叶变换投影至频域提取幅度谱 $\mathbf{A} \in \mathbb{R}^{P \times \lfloor K/2+1 \rfloor \times M}$ 与相位谱 $\mathbf{P} \in \mathbb{R}^{P \times \lfloor K/2+1 \rfloor \times M}$ 信息。接着,将二者分别送入线性层进行特征计算后经逆傅里叶变换重构时域特征序列 $\mathbf{Z}^{\text{Freq}} \in \mathbb{R}^{P \times K \times M}$ 。随后,将重构后的特征序列输入至 SSMs 中,通过一系列状态转移矩阵捕获信号特征序列 $\mathbf{Z}^{\text{Freq}} = \{\mathbf{Z}_0^{\text{Freq}}, \mathbf{Z}_1^{\text{Freq}}, \dots, \mathbf{Z}_{K-1}^{\text{Freq}} | \mathbf{Z}_k^{\text{Freq}} \in \mathbb{R}^{P \times M}, k=[1, K]\}$ 的长时序周期性规律,以提取全局语义信息,表示为

$$\begin{cases} \mathbf{h}_k^{\text{Freq}} = \bar{\mathbf{A}}_{\text{MTFM}} \mathbf{h}_{k-1}^{\text{Freq}} + \bar{\mathbf{B}}_{\text{MTFM}} \mathbf{Z}_k^{\text{Freq}} \\ \mathbf{Z}_k^{\text{Time-Freq}} = \mathbf{C}_{\text{MTFM}} \mathbf{h}_k^{\text{Freq}} + \mathbf{Z}_k^{\text{Freq}} \end{cases} \quad (10)$$

其中: $\bar{\mathbf{A}}_{\text{MTFM}}$ 、 $\bar{\mathbf{B}}_{\text{MTFM}}$ 、 \mathbf{C}_{MTFM} 分别表示 MTFM 模块中的状态转移矩阵、状态控制矩阵以及输出矩阵。通过 SSMs 进行时序推理,可获得融合了频域、时序特性后的特征序列 $\mathbf{Z}_k^{\text{Time-Freq}}$,该特征序列不仅保留了信号的局部细节信息,同时还融合了全局语义特征,从而有效提升模型对 I/Q 数据中关键判别性特征的提取能力。

2.3 HFSM

针对不同 SNR 混杂数据联合训练中存在的同类异谱、同谱异类现象,本文提出了 HFSM,其旨在双曲几何空间中引导模型感知样本 SNR 分布,并动态调整模型使其适应不同 SNR 条件下的信号数据,缓解判别模型决策边界混淆现象。

如上文所述,不同 SNR 条件下的无线电信号样本于双曲空间内展现出显著差异。低 SNR 样本因其特征表达不清晰、包含复杂噪声,故缺乏类别共有属性,导致其通常位于双曲空间的外侧,即具有较大双曲半径的;相反地,高 SNR 样本具备更突出的共性特征与类别可分性的,使其集中于庞加莱球的中心区域,即双曲半径较小。基于此特性,HFSM 模块旨在双曲空间中对不同 SNR 信号样本进行鉴别,并生成 SNR 相关的提示向量以动态调整模型参数空间,助力网络对不同噪比样本实现隐式特征隔离,降低类别混淆。

具体而言,HFSM 模块首先将输入特征映射至庞

加莱球模型下的双曲空间,利用其层次化特性促进模型感知不同 SNR 下的信号分布差异。对于输入样本特征 $\mathbf{Z}^{\text{Time-Freq}}$,HSFM 机制采用指数映射的方式将其投影至庞加莱球模型中:

$$\begin{aligned} & \exp_{X_0}^{\mathcal{O}}(\mathbf{Z}^{\text{Time-Freq}}) \\ &= \mathbf{X}_0 \oplus_c \left(\tanh \left(\sqrt{c} \frac{\lambda_{c, X_0} \|\mathbf{Z}^{\text{Time-Freq}}\|}{2} \right) \frac{\mathbf{Z}^{\text{Time-Freq}}}{\sqrt{c} \|\mathbf{Z}^{\text{Time-Freq}}\|} \right) \end{aligned} \quad (11)$$

其次,通过全连接层 \mathbf{W} 与上述特征进行莫比乌斯矩阵乘法操作,在双曲空间中进行编码以提取双曲特征 \mathbf{H} :

$$\mathbf{H} = \mathbf{W} \otimes_c \exp_{X_0}^{\mathcal{O}}(\mathbf{Z}^{\text{Time-Freq}}) \quad (12)$$

再次,利用对数映射方式将其投影至欧氏空间 $\mathbf{S} = \ln_{X_0}^{\mathcal{D}, c}(\mathbf{H})$

$$= \frac{2}{\sqrt{c} \lambda_{c, X_0}} \operatorname{artanh} \left(\sqrt{c} \frac{\|\mathbf{H}\|}{\|\mathbf{H} + \mathbf{X}_0\|} \right) \frac{-\mathbf{X}_0 \oplus_c \mathbf{H}}{\|\mathbf{H} + \mathbf{X}_0\|} \quad (13)$$

其中:特征 \mathbf{S} 表示双曲提示向量,将其作为 SNR 感知信息与主干网络特征相融合,通过门控机制动态调节主干网络特征响应,即 $\mathbf{Z}^{\text{Time-Freq}} \circ \zeta(\mathbf{S})$ 。其中, $\zeta(\cdot)$ 表示 Sigmoid 激活函数, \circ 表示逐元素乘法操作。至此,HSFM 模块通过双曲提示向量实现了对主干特征网络的自适应调制,助力模型对不同 SNR 样本进行差异化表征,提升模型在复杂 SNR 环境下的判别能力。

在训练阶段,建立 SNR 判识辅助任务引导 HFSM 模块学习 SNR 感知能力。由图 1(b)可知,双曲空间中极低 SNR 样本与其余样本可通过双曲半径显著区分。为此,将混杂数据划分为低 SNR (SNR 小于 0 dB)、常规 SNR (SNR 大于等于 0 dB) 两类,并在 HFSM 模块构建后引入一个轻量级的二分类头 $H_{\text{HSFM}}(\cdot)$ 用于预测输入样本所属的 SNR 类别,构建 SNR 交叉熵分类损失函数对其进行优化:

$$L_{\text{HSFM}} = -\frac{1}{P} \sum_{p=1}^P \left[\mathbf{Y}_p^{\text{SNR}} \ln H_{\text{HSFM}}(\mathbf{S}) + (1 - \mathbf{Y}_p^{\text{SNR}}) \ln (1 - H_{\text{HSFM}}(\mathbf{S})) \right] \quad (14)$$

其中: $\mathbf{Y}_p^{\text{SNR}} \in \{0, 1\}$ 表示第 p 个样本的真实 SNR 类别标签 (0 表示低 SNR, 1 表示常规 SNR)。在推理阶段,HSFM 模块可根据输入信号的 SNR 自适应调整特征表示,为主干网络提供 SNR 提示信息,从而缓解不同 SNR 数据间类别混淆问题。

2.4 HSCL

针对不同 SNR 信号样本在双曲空间中呈现出的层次化分布特性,高 SNR 信号样本具有更小的双曲半径,趋近于庞加莱球球心,即高 SNR 样本所传递的信息更具共性且特征稳定。相反地,低 SNR 样本则

距离庞加莱球中心点的距离更远,该类样本受噪声干扰,其所蕴含的调制类别相关信息稀疏且模糊,数据分布多样性强。为此,在模型训练早期应重点关注高 SNR 样本的学习,促使模型拟合不同调制类型的正确、共性语义信息,之后逐渐引入较难区分的低 SNR 样本,提升模型鲁棒泛化性能。

基于此,本文提出了一种 HSCL,通过度量各样本距离庞加莱球心的双曲距离量化估计其易分程度,并设计了一种课程学习方式动态调整模型训练策略,促使模型在训练初期聚焦于高 SNR 样本的调制类型识别任务以及低 SNR 样本的 SNR 判识任务,优先拟合高 SNR 样本以建立清晰的类别边界。随着模型判识能力的逐步提升,HSCL 机制逐渐加强对低 SNR 样本的调制类型识别训练,渐进式地提升模型综合性能。该过程可表述为

$$L_{\text{HSCL}} = \lambda_{\text{HSCL}} \cdot L_{\text{AMR}} + (1 - \lambda_{\text{HSCL}}) \cdot L_{\text{HSFM}}$$

$$= \frac{1}{P} \sum_{p=1}^P \left(e^{-d_c^Q(\mathbf{X}_p, \mathbf{X}_p)} \cdot \Omega(\mathbf{Y}_{\text{pred}}^{\text{AMR}}, \mathbf{Y}_p^{\text{AMR}}) + (1 - e^{-d_c^Q(\mathbf{X}_p, \mathbf{X}_p)}) \cdot L_{\text{HSFM}} \right) \quad (15)$$

其中: L_{AMR} 表示调制识别分类任务; $\Omega(\cdot)$ 表示交叉熵分类损失函数; $\mathbf{Y}_p^{\text{AMR}} \in \{0, 1, \dots, C\}$ 表示第 p 个样本的真实调制类型标签。具体地,对于输入样本特征 $\mathbf{Z}^{\text{Time-Freq}}$,将其转化为双曲空间中的庞加莱球坐标表示,即 $g^{Q_c} = \lambda_{c,X}^2 g^E$ 。接着,计算其与庞加莱球中心之间的双曲距离,记为

$$d_c^Q(\mathbf{X}_0, \mathbf{Z}^{\text{Time-Freq}}) = (2/\sqrt{c}) \operatorname{artanh} \left(\sqrt{c} \left\| -\mathbf{X}_0 \oplus_c \mathbf{Z}^{\text{Time-Freq}} \right\| \right) \quad (16)$$

依据该距离值评估各样本训练优先级,对于特征稳定且共性信息丰富的高 SNR 样本,即 $d_c^Q(\mathbf{X}_0, \mathbf{Z}^{\text{Time-Freq}})$ 较小,在训练初期赋予其较大的调制识别任务权重,促使模型优先拟合此类样本以快速建立准确的类别边界。反之,对于特征稀疏且模糊的低 SNR 样本,即 $d_c^Q(\mathbf{X}_0, \mathbf{Z}^{\text{Time-Freq}})$ 较大,在训练初期赋予其较大的 SNR 判识任务权重,促使模型提升对其感知能力,避免其干扰模型对类别边界的准确构建。随着训练轮次的增加,模型对高 SNR 样本的调制类型识别能力逐渐提升,此时逐渐增大低 SNR 样本的调制识别任务权重,逐步提升模型的泛化鲁棒性能,提升多样化 SNR 环境下的模型综合判识性能。

3 实验设置与结果分析

3.1 数据集介绍

为全面评估所提 H-Mamba 模型在不同电磁环境下的调制识别性能,本文在三个公开基准数据集上对其进行实验验证,包括 RML2016A^[32]、RML2016B^[32]

以及 RML2018^[33]。

RML2016A 数据集^[32]包含 11 种调制类型,涵盖 3 类模拟调制类别[AM-DSB、AM-SSB、宽带调频(Wide-Band Frequency Modulation, WBFM)]与 8 类数字调制类别[BPSK、正交相移键控(Quadrature Phase Shift Keying, QPSK)、八进制相移键控(8 Phase Shift Keying, 8PSK)、十六进制正交幅度调制(16-ary Quadrature Amplitude Modulation, 16QAM)、六十四进制正交幅度调制(64-ary Quadrature Amplitude Modulation, 64QAM)、高斯频移键控(Gaussian Frequency Shift Keying, GFSK)、连续相位频移键控(Continuous Phase Frequency Shift Keying, CPFSK)、四电平脉冲幅度调制(4-level Pulse Amplitude Modulation, PAM4)]。所有信号均基于美国信息交换标准代码(American Standard Code for Information Interchange, ASCII)编码的文本源生成,具有真实通信语义。该数据集模拟了 11 种不同的 SNR 环境,SNR 分布范围为 -10~10 dB,以 2 dB 为间隔。不同调制类型在各 SNR 水平下分别包含 1 000 个信号样本,共构成 121 000 个信号样本,其中各样本由 I 与 Q 两路信号组成,数据维度为 2×128 的复值序列。

RML2016B 数据集^[32]是一个更大规模的无线电信号调制识别数据集,整体数据集结构与 RML2016A 相似,共包含 10 种调制方式:AM-DSB、WBFM、BPSK、QPSK、8PSK、16QAM、64QAM、GFSK、CPFSK、PAM4。该数据集模拟了 11 种不同的 SNR 环境,SNR 分布范围为 -10~10 dB,以 2 dB 为间隔。不同调制类型在各 SNR 水平下分别包含 6 000 个信号样本,共构成 660 000 个信号样本。该数据集可用于验证模型在大规模数据场景下的泛化能力。

RML2018 数据集^[33]是当下最具挑战性的 AMR 基准之一,该数据集不仅涵盖更多的调制类型,还引入了更复杂的模拟信道效应,包括载波频偏、采样率偏移、热噪声以及信号时延等,更贴近真实无线电通信场景。RML2018 数据集共包含 24 种调制方式,涵盖通断键控(On-Off Keying, OOK)、四进制幅移键控(4-level Amplitude Shift Keying, 4ASK)、八进制幅移键控(8-level Amplitude Shift Keying, 8ASK)、BPSK、QPSK、8PSK、16PSK、32PSK、十六进制幅度相位键控(16-ary Amplitude and Phase Shift Keying, 16APSK)、32APSK、64APSK、128APSK、16QAM、32QAM、64QAM、128QAM、256QAM、带载波的单边带幅度调制(Amplitude Modulation Single-SideBand With Carrier, AM-SSB-WC)、抑制载波的单边带幅度调制(Amplitude Modulation Single-SideBand Suppressed Carrier, AM-SSB-SC)、带载波的双边带幅度调制(Amplitude Modulation Double-SideBand With Carrier, AM-DSB-WC)、抑制载波的双边带幅度调制(Amplitude Modulation

Double-SideBand Suppressed Carrier, AM-DSB-SC)、频率调制(Frequency Modulation, FM)、高斯最小频移键控(Gaussian Minimum Shift Keying, GMSK)和偏移正交相移键控(Offset Quadrature Phase Shift Keying, OQPSK)。该数据集模拟了11种不同的SNR环境,SNR分布范围为-10~10 dB,以2 dB为间隔。数据集共包含1 081 080个信号样本,其中各样本由I与Q两路信号组成,数据维度为 2×1024 的复值序列。该数据集对模型的鲁棒性、长序列建模能力及抗信道失真能力提出了更高要求。

3.2 实验设置

为确保对比实验的公平性,本文所有实验均在统一的软硬件环境下完成,实验平台基于Ubuntu 16.04操作系统,采用Python编程语言与PyTorch1.10.0深度学习框架,中央处理器(Central Processing Unit, CPU)型号为Intel Xeon(R) E5-2680v4@2.40 GHz,内存大小256 GB, GPU加速设备为NVIDIA GeForce RTX 2080Ti。数据集划分方面,所有数据集均按6:2:2的比例划分为训练集、验证集和测试集,训练过程中随机种子统一固定为0,以保证实验结果的可复现性。

在训练策略方面,所有模型均采用AdamW优化器^[34],并使用余弦退火策略进行学习率的动态调整,余弦函数周期设置为5,训练轮次数量为50,训练批量大小设为512,在序列更长、规模更大的RML2018数据集上,训练批量大小设为256以适配显存限制。为了确保各模型均达到自身最佳性能,将门控循环单元(Gated Recurrent Unit, GRU)、基于改进CNN的自动调制分类网络(Improved Convolutional neural network-based Automatic Modulation Classification network, ICAMC)、卷积门控循环单元深度神经网络(Convolutional Gated recurrent units Deep Neural Networks, CGDNN)模型的初始学习率设置为0.000 3,其余模型的初始学习率设置为0.001。为确保实验结果的稳定性,所有报告的数据均为3次独立运行结果的平均值。在模型初始化阶段,所有模型的权重均采用Xavier均匀分布进行初始化。在超参数设置方面,双曲空间负曲率 c 设置为1.0,MTFM模块中局部信息感知单元的隐含层特征维度设置为[32, 64, 128],全局语义整合单元隐含层特征维度设置为128,HSCL策略的预热步长为30。依据MTFM模块数量设置不同,将拥有3个MTFM模块的轻量化模型记为H-Mamba(Tiny),拥有6个MTFM模块的模型记为H-Mamba。上述设置在所有数据集上保持一致,充分验证了所提方法的鲁棒性与通用性。

3.3 对比实验

本文选取了近年来AMR领域具有代表性的10种深度学习模型作为基线方法进行对比,包括基于CNN架构的ICAMC^[16]、复数值深度可分离CNN(Complex-

valued Depthwise Separable CNN, CDSCNN)^[17]、AWN^[18],基于RNN架构的GRU^[19]、CGDNN^[20]、MCLDNN^[21]、基于参数估计与变换的卷积门控循环单元深度神经网络(Parameter Estimation and Transformation based Convolutional Gated recurrent unit Deep Neural Network, PET-CGDNN)^[22]以及近期基于Transformer网络架构的自动调制分类网络(Automatic Modulation Classification Network, AMC-Net)^[23]、CDAT^[25]、MCDformer^[26]。所有基线模型均在其原始配置基础上进行复现。

RML2016A数据集上,如表1所示,本文提出的H-Mamba模型取得了0.771 1的平均准确率,显著优于其余对比方法。此外,本文方法的轻量化版本H-Mamba(Tiny)以0.752 7的总体准确率仍显著优于其余基线模型,为资源受限的边缘端部署任务提供了可行方案。具体地,与基于CNN架构的方法相比,H-Mamba的整体准确率分别以0.226 6、0.096 9、0.034 0的优势领先于ICAMC、CDSCNN、AWN方法,有效缓解了卷积架构对局部噪声的敏感性。与基于RNN架构的方法相比,H-Mamba在长序列建模能力上展现出更强的稳定性,相较于GRU、CGDNN、MCLDNN和PET-CGDNN,准确率分别提升0.098 5、0.243 5、0.068 1和0.100 0,验证了其在全局时序特征提取方面的优越性。与近期基于Transformer架构的AMC-Net、CDAT和MCDformer相比,H-Mamba仍分别提升0.081 8、0.054 8和0.040 9的平均准确率,表明本文所提出的MTFM模块相较Multi-head Self-Attention机制在捕获调制信号时频特征方面更具优势。在低SNR场景下(-10~0 dB),H-Mamba展现出更显著的判别优势,相较于现有先进的Transformer模型MCDformer,准确率分别提升0.015 5、0.030 0、0.059 1、0.059 1、0.062 3、0.054 1,证明了其有效性。

为了更清晰地对比各方法在不同SNR下的识别性能,本文对RML2016A数据集上不同SNR下的各方法识别精度进行了可视化分析,如图3所示。由图3可知,本文所提出的H-Mamba方法及其轻量化版本H-Mamba(Tiny)在几乎所有SNR条件下均优于现有方法,进一步证明了其优越性。此外,本文对各方法在RML2016A数据集上的混淆矩阵进行了可视化分析。如图4所示,本文所提出方法具有更少的类别错分,尤其是具有相似特性的类别,例如,QAM64和QAM16,证明了其有效性。

在模型部署效率方面,本文对比了各方法识别精度随训练轮次的变化趋势,曲线截止于各方法取得最优性能所需的轮次,如图5所示。由图5可知,本文所提出的H-Mamba在第10训练轮次即可达到0.75的识别精度,超越其余方法最优性能,之后在第30轮附

表 1 RML2016A 数据集上的对比试验结果

Table 1 Comparison with the other methods on the RML2016A dataset

方法	模型	准确率											整体准确率
		-10 dB	-8 dB	-6 dB	-4 dB	-2 dB	0 dB	2 dB	4 dB	6 dB	8 dB	10 dB	
CNN-based Method	ICAMC	0.130 0	0.259 5	0.418 2	0.505 5	0.577 7	0.639 1	0.679 1	0.697 7	0.689 5	0.690 0	0.702 7	0.544 5
	CDSCNN	0.235 5	0.370 5	0.518 6	0.622 3	0.736 8	0.787 7	0.808 6	0.828 6	0.833 2	0.833 2	0.840 9	0.674 2
	AWN	0.229 5	0.426 4	0.560 0	0.703 2	0.805 9	0.880 0	0.887 7	0.897 7	0.909 1	0.900 9	0.907 7	0.737 1
RNN-based Method	GRU	0.228 2	0.395 0	0.549 5	0.637 7	0.733 6	0.779 5	0.798 6	0.817 3	0.820 5	0.816 8	0.821 4	0.672 6
	CGDNN	0.134 1	0.278 6	0.372 3	0.468 6	0.557 7	0.631 4	0.649 1	0.667 7	0.686 4	0.656 4	0.701 8	0.527 6
	MCLDNN	0.210 0	0.386 8	0.561 8	0.658 2	0.777 3	0.835 0	0.851 8	0.856 8	0.867 7	0.863 6	0.864 0	0.703 0
Transformer-based Method	PET-CGDNN	0.202 3	0.393 6	0.539 1	0.640 0	0.727 3	0.780 9	0.804 5	0.820 0	0.829 1	0.818 6	0.826 8	0.671 1
	AMC-Net	0.220 0	0.390 9	0.571 8	0.648 6	0.753 6	0.827 7	0.831 8	0.826 4	0.840 0	0.838 2	0.833 2	0.689 3
	CDAT	0.269 1	0.425 5	0.544 1	0.661 4	0.775 5	0.840 9	0.865 9	0.866 4	0.882 7	0.876 4	0.871 4	0.716 3
Our proposed Method	MCDformer	0.225 9	0.414 1	0.570 9	0.686 8	0.799 1	0.866 4	0.882 7	0.891 4	0.895 5	0.901 4	0.897 7	0.730 2
	H-Mamba(Tiny)	0.265 0	0.445 0	0.593 6	0.707 7	0.830 0	0.890 0	0.905 0	0.906 4	0.915 9	0.910 5	0.910 9	0.752 7
	H-Mamba	0.241 4	0.444 1	0.630 0	0.745 9	0.861 4	0.920 5	0.926 8	0.922 3	0.932 7	0.926 8	0.930 0	0.771 1

注:加粗字体为最优结果,下同。

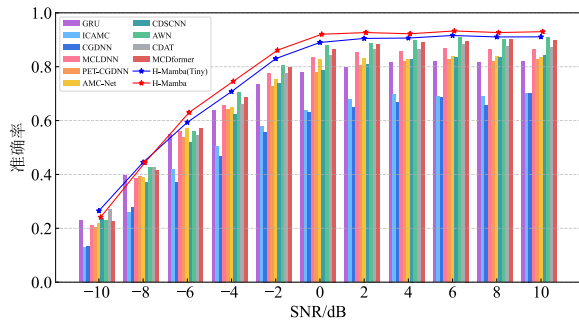


图 3 RML2016A 数据集上不同 SNR 下的各方法识别精度对比
Figure 3 Comparison across different SNRs on RML2016A

近达到最优性能。相比之下,大部分对比方法需要在第 80 轮次后才能逐步逼近其最佳性能,证明 H-Mamba 具有更快的收敛速度与更高的部署效率。图 6 展示了各对比方法的模型参数量与识别精度对比。

由图 6 可知, H-Mamba 在参数量仅为 0.32×10^6 的条件下,实现了 0.771 1 的整体准确率,显著优于需要更大规模参数数量的 Transformer 方法(AMC-Net、MCDformer),证明了本文所提出的 MTFM 模块在调制识别任务上具有更高的参数利用效率。此外,本文方法的轻量化版本 H-Mamba(Tiny) 仅需 0.12×10^6 参数量即可实现 0.752 7 的识别准确率,在最优识别性能的条件下在参数量方面优于大多数对比方法,进一步验证了 H-Mamba 在资源受限场景下的部署优势。

为了进一步验证本文方法的有效性,在 RML2016B 和更大规模的 RML2018 数据集上对本文所提出的 H-Mamba 与现有方法进行了全面对比评估。如表 2 所示,本文提出的 H-Mamba 模型在 RML2016B 上取得了 0.790 4 的平均准确率,显著优于所有基线方法。此

外,本文方法的轻量版本 H-Mamba(Tiny) 以 0.782 6 的整体准确率仍全面超越现有最优模型(0.782 6 vs. 0.774 6),证明了其高效性。与基于 CNN 架构的方法相比, H-Mamba 的整体准确率分别以 0.111 2、0.071 1、0.034 5 的优势领先于 ICAMC、CDSCNN 和 AWN。与基于 RNN 架构的方法相比, H-Mamba 在序列化数据建模中展现出更强的稳定性,相较于 GRU、CGDNN、MCLDNN 和 PET-CGDNN, 准确率分别提升 0.024 7、0.222 2、0.036 0 和 0.034 9。与基于 Transformer 架构的 AMC-Net、CDAT 和 MCDformer 相比, H-Mamba 仍可取得 0.027 8、0.026 9 和 0.015 8 的平均准确率提升,表明 H-Mamba 能更高效地融合调制信号的局部细节与全局上下文特征。

表 3 展示了 RML2018 数据集上的识别结果,本文提出的 H-Mamba 模型取得了 0.580 2 的平均准确率,显著超越所有基线方法,证明了其在复杂大规模场景下的有效性。本文轻量化版本 H-Mamba(Tiny) 以 0.560 7 的总体准确率,仍领先于现有架构模型。与现有最优的基于 Transformer 架构的方法 CDAT 相比, H-Mamba 取得了 0.015 9 的性能优势。具体地,与基于 CNN 架构的方法相比, H-Mamba 的整体准确率分别以 0.095 3、0.089 5 和 0.035 7 的优势领先于 ICAMC、CDSCNN 和 AWN。由于 RML2018 数据集具有更大的序列长度, H-Mamba 与基于 RNN 架构的方法相比取得了更明显的优势,准确率分别提升 0.121 0、0.195 4、0.012 1 和 0.167 7,证明了其在长序列依赖建模中的有效性。图 7 可视化展示了不同 SNR 下各方法更具体的识别准确率,可以看出 H-Mamba 和 H-Mamba(Tiny) 始终可取得最优性能。图 8 进一步验证了本文方法在不同 SNR 下的识别优势。



图4 RML2016A数据集上各方法混淆矩阵对比

Figure 4 Comparison of confusion matrix on RML2016A

3.4 消融实验及参数分析

本节对H-Mamba模型进行了全面的消融实验分析,以评估各组件对检测性能的贡献。基线模型设置

如下:以传统的Mamba模块^[27]替代MTFM模块,不使用HSFM机制与HSCL策略。所有消融实验均在RML2016A数据集上进行,且采用相同的训练设置。

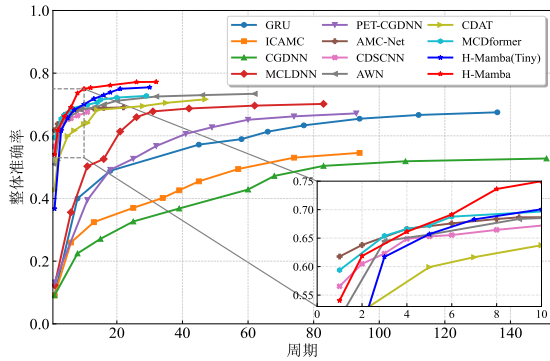


图5 RML2016A数据集上不同方法训练轮次与识别精度对比
Figure 5 Overall accuracy at different training epochs

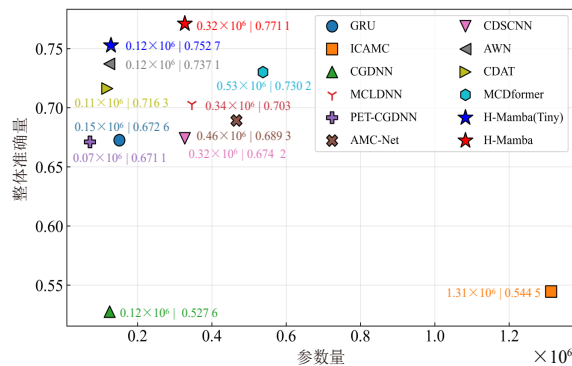


图6 不同方法模型参数数量与识别精度对比
Figure 6 Comparison of model parameters and overall accuracy

消融实验结果如表4所示,基线模型在不同SNR下的平均准确率为0.6863,证明了SSMs在AMR任务上具有一定的潜力。在Mamba基线模型的基础上引入HSFM机制后,模型平均准确率提升至0.7154,表明HSFM通过动态调整模型使其适应不同SNR条件

下的信号数据,有效增强了模型对不同识别场景的鲁棒性。在其基础上进一步引入HSCL策略后,模型性能进一步提升至0.7315,结果表明HSCL有效引导模型由易到难地学习调制识别任务,缓解了SNR差异带来的训练不稳定性,提升了泛化能力。

同时,将MTFM模块引入模型后,平均准确率达到0.7304,显著高于基线模型,验证了基于SSMs的时频特征挖掘模块在捕捉局部与全局信号特征方面的有效性。此外,本文探索了频域处理机制[快速傅里叶变换(Fast Fourier Transform, FFT)]对MTFM模块的影响,移除掉MTFM模块中的FFT路径后,模型平均识别准确率从0.7304下降至0.7139,这表明频域处理机制对信号特征增强具有显著作用。同时引入MTFM模块与HSFM机制,模型识别准确率达到0.7484,较基线模型提升显著。最终,同时引入MTFM模块、HSFM机制与HSCL策略的完整模型在RML2016A数据集上取得0.7711的平均准确率,较基线模型提升0.0848,充分验证了各模块协同作用的有效性。此外,对消融实验进行了特征空间可视化分析,如图9所示。由图9可知,引入HSFM机制与HSCL策略后,不同调制类型类内特征分布更加紧凑且类间分离度显著提升,易混淆的QAM16和QAM64类别的离散度由18.51提升至39.10,特征空间判别性显著提升,表明模型在双曲空间中通过SNR感知的特征调制与课程学习策略,有效克服了低SNR样本对分类边界的干扰,提升了易混淆类别可分性。

首先,本文对各模块内部进行消融实验分析,包括MTFM模块中的时频域分支、HSFM机制中的SNR预测分支以及HSCL策略中的双曲空间负曲率。首先,对MTFM模块中的时频域分支进行消融实验分

表2 RML2016B数据集上的对比试验结果

Table 2 Comparison with the other methods on the RML2016B dataset

方法	模型	准确率										整体准确率	
		-10 dB	-8 dB	-6 dB	-4 dB	-2 dB	0 dB	2 dB	4 dB	6 dB	8 dB		10 dB
CNN-based Method	ICAMC	0.199 1	0.354 9	0.521 6	0.646 5	0.759 8	0.818 9	0.830 6	0.831 9	0.833 5	0.838 8	0.836 2	0.679 2
	CDSCNN	0.257 1	0.409 0	0.527 4	0.661 0	0.774 8	0.854 5	0.869 8	0.883 8	0.890 8	0.895 9	0.888 3	0.719 3
	AWN	0.296 9	0.436 3	0.546 7	0.686 3	0.822 2	0.896 4	0.917 3	0.923 3	0.930 1	0.930 7	0.929 1	0.755 9
RNN-based Method	GRU	0.291 4	0.451 2	0.573 7	0.729 6	0.842 2	0.904 2	0.919 0	0.924 0	0.927 7	0.930 1	0.929 7	0.765 7
	CGDNN	0.169 7	0.275 9	0.406 2	0.528 3	0.626 8	0.684 6	0.696 9	0.711 6	0.710 6	0.722 2	0.717 8	0.568 2
	MCLDNN	0.291 8	0.436 8	0.551 5	0.679 1	0.821 1	0.896 3	0.914 8	0.921 6	0.926 9	0.929 1	0.929 8	0.754 4
	PET-CGDNN	0.285 9	0.453 2	0.570 7	0.684 6	0.814 2	0.885 6	0.905 8	0.915 6	0.919 1	0.920 0	0.922 3	0.755 5
Transformer-based Method	AMC-Net	0.282 8	0.433 9	0.551 7	0.717 6	0.853 8	0.909 3	0.924 3	0.925 4	0.929 2	0.931 2	0.930 3	0.762 6
	CDAT	0.261 7	0.437 3	0.579 3	0.737 9	0.846 1	0.900 5	0.920 0	0.925 6	0.929 3	0.931 6	0.929 8	0.763 5
	MCDformer	0.292 4	0.433 1	0.591 3	0.757 2	0.870 3	0.916 7	0.927 1	0.929 7	0.934 4	0.935 0	0.934 1	0.774 6
Our proposed Method	H-Mamba(Tiny)	0.303 7	0.471 1	0.618 2	0.764 7	0.869 5	0.918 4	0.927 8	0.930 7	0.935 1	0.935 0	0.934 8	0.782 6
	H-Mamba	0.307 8	0.480 5	0.638 3	0.785 8	0.883 7	0.923 2	0.930 6	0.932 2	0.937 5	0.937 0	0.937 3	0.790 4

表3 RML2018数据集上的对比试验结果
Table 3 Comparison with the other methods on the RML2018 dataset

方法	模型	准确率											整体准确率
		-10 dB	-8 dB	-6 dB	-4 dB	-2 dB	0 dB	2 dB	4 dB	6 dB	8 dB	10 dB	
CNN-based Method	ICAMC	0.107 4	0.151 9	0.220 0	0.305 2	0.399 3	0.499 5	0.597 3	0.700 7	0.767 0	0.791 9	0.794 1	0.484 9
	CDSCNN	0.140 6	0.192 9	0.261 7	0.325 3	0.420 5	0.521 1	0.596 5	0.673 6	0.734 0	0.762 9	0.768 4	0.490 7
	AWN	0.138 1	0.197 7	0.263 2	0.344 3	0.445 1	0.557 6	0.649 4	0.749 1	0.846 6	0.890 7	0.908 1	0.544 5
RNN-based Method	GRU	0.136 9	0.191 8	0.251 0	0.317 2	0.420 3	0.519 2	0.585 1	0.623 4	0.656 0	0.671 4	0.679 3	0.459 2
	CGDNN	0.111 0	0.165 0	0.217 7	0.260 9	0.342 6	0.438 1	0.493 2	0.536 7	0.552 4	0.559 2	0.555 6	0.384 8
	MCLDNN	0.138 6	0.201 6	0.272 9	0.351 6	0.462 5	0.572 9	0.686 2	0.794 4	0.889 0	0.931 4	0.948 1	0.568 1
Transformer-based Method	PET-CGDNN	0.121 6	0.176 5	0.242 0	0.300 4	0.367 3	0.440 0	0.501 6	0.530 2	0.546 3	0.548 6	0.548 3	0.393 0
	AMC-Net	0.108 5	0.130 8	0.169 6	0.254 0	0.316 8	0.364 5	0.395 2	0.409 5	0.414 6	0.410 2	0.414 5	0.308 0
	CDAT	0.156 1	0.210 8	0.279 2	0.361 1	0.468 6	0.578 9	0.689 2	0.799 1	0.865 3	0.893 4	0.905 5	0.564 3
Our proposed Method	MCDformer	0.125 4	0.145 3	0.154 1	0.185 9	0.227 5	0.253 5	0.273 4	0.273 5	0.281 0	0.282 5	0.286 3	0.226 2
	H-Mamba(Tiny)	0.149 2	0.205 6	0.270 7	0.349 5	0.462 0	0.574 3	0.678 7	0.792 1	0.870 3	0.903 8	0.911 7	0.560 7
	H-Mamba	0.140 1	0.207 9	0.278 8	0.358 8	0.493 7	0.596 0	0.713 3	0.823 7	0.899 9	0.930 1	0.940 3	0.580 2




图7 RML2016B数据集上不同SNR下的各方法识别精度对比
Figure 7 Comparison across different SNRs on RML2016B




图8 RML2018数据集上不同SNR下的各方法识别精度对比
Figure 8 Comparison across different SNRs on RML2018

析。对 MTFM 模块进行时域、频域分支移除操作，分别记为 MTFM (w/o Time)、MTFM (w/o Freq)。表 5 展示了不同设置下的 MTFM 平均识别性能，移除时域分支后模型平均准确率下降至 0.640 2，而移除频域分支后性能降低至 0.735 5，表明时域建模对 MTFM 模块性能影响至关重要，而引入频域分支亦能获得 0.035 6 的判识增益，证明了时频双域特征协同提取的互补性。将 MTFM 模块中的 SSMs 替换为 Transformer 结构后，平均准确率下降至 0.722 5，验证了 SSMs 在捕捉长

表4 消融实验结果

Table 4 Ablation study of H-Mamba

Mamba	MTFM	FFT	HSFM	HSCL	整体准确率
✓					0.686 3
✓			✓		0.715 4
✓			✓	✓	0.731 5
	✓				0.713 9
	✓		✓		0.727 3
	✓		✓	✓	0.735 5
	✓	✓			0.730 4
	✓	✓	✓		0.748 4
	✓	✓	✓	✓	0.771 1

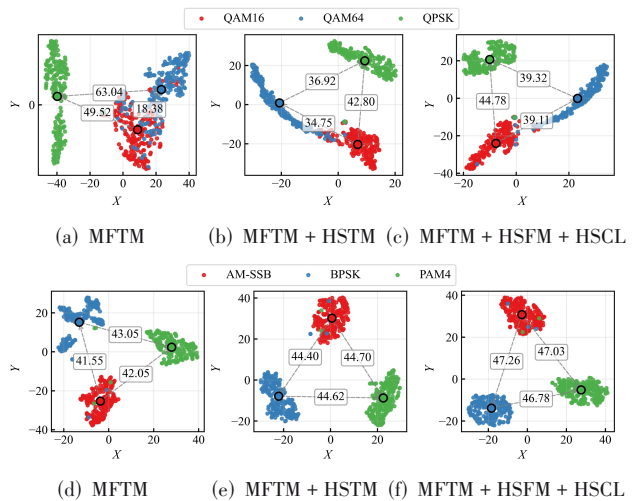


图9 消融实验特征空间可视化分析

Figure 9 Feature visualization of different model settings

时依赖与局部特征方面的优势。

其次，对 HSFM 机制中的 SNR 预测分支进行消融实验，如表 6 所示。本文所提出的 HSFM 机制在具有

天然层次化特性的双曲空间中对 SNR 进行感知建模,取得了 0.771 1 的平均准确率,显著优于传统欧氏空间中的 SNR 建模方式,证明了双曲空间对不同 SNR 样本的感知能力更强,与本文图 1 中的动机相符。

表 5 MTFM 模块中不同特征提取分支消融对比

Table 5 Comparison of different feature extraction branches in MTFM

特征提取模块	整体准确率	最高准确率	参数量($\times 10^6$)
MTFM	0.771 1	0.932 7	0.327
MTFM(w/o Time)	0.640 2	0.780 5	0.279
MTFM(w/o Freq)	0.735 5	0.913 2	0.277
Transformer	0.722 5	0.905 0	0.294
CNN	0.726 0	0.886 8	0.271

表 6 HSFM 机制中 SNR 预测分支消融对比

Table 6 Comparison of SNR prediction branches in HSFM

SNR 预测分支结构	整体准确率	最高准确率	参数量($\times 10^6$)
双曲空间	0.771 1	0.932 7	0.32
欧氏空间	0.758 2	0.925 9	0.36

再次,本文对双曲空间与欧氏空间下的 SNR 预测分支进行了性能可视化对比,如图 10 所示。实验结果表明:双曲空间下的 SNR 预测分支几乎在所有 SNR 条件下均优于基于欧氏空间的 SNR 预测分支,验证了其性能提升的普适性。此外,本文进一步记录了 SNR 预测分支分别采用双曲空间与欧氏空间下每一训练轮次的验证集损失函数值以及识别准确率,如图 11 所示。从验证准确率和损失曲线来看,采用双曲运算的模型在训练过程中损失值下降平稳且识别准确率稳步上升,自第 8 训练轮次后其识别准确率始终优于欧氏运算,证明了使用双曲空间进行 SNR 建模与感知的优越性。最后,对 HSCL 策略中的双曲空间负曲率进行参数实验分析,如图 12 所示。随着负曲率绝对值增大,模型性能先升后降,在负曲率为 1.0 时模型达到最优性能,此时双曲空间的几何特性更适配信号特征的层次分布结构。整体上,不同负曲率设置对模型性能影响较小,表明所提方法对曲率参数具有较好的鲁棒性。

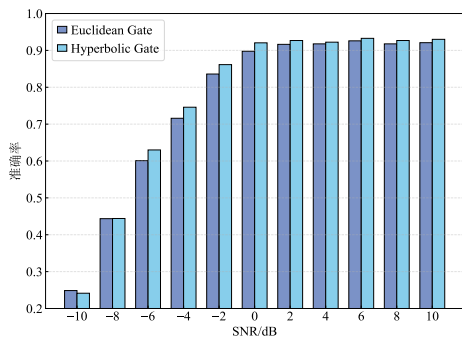



图 10 HSFM 中 SNR 预测分支采用双曲门控与欧氏门控性能对比
Figure 10 Comparison of Hyperbolic and Euclidean gate in HSFM



(a) 验证集损失值 (b) 验证集准确率

图 11 SNR 预测分支使用双曲空间运算与欧氏空间运算的验证集损失值与准确率对比

Figure 11 Loss and accuracy comparison of Hyperbolic and Euclidean operations




图 12 参数分析可视化:双曲空间负曲率大小对比

Figure 12 Parameter analysis of negative curvature magnitude in Hyperbolic space

4 结论

本文针对现有调制识别方法缺乏电磁环境感知能力、长时序高效建模能力不足等问题,提出了一种基于 H-Mamba 的无线电信号调制识别模型,联合应用 SSMs 的长序列建模能力与双曲几何空间的 SNR 感知特性,有效提升 AMR 性能。首先,建立了一种 MTFM,分别从时域、频域挖掘各调制类型的局部、全局判别性表征。其次,提出了一种 HSFM,从双曲几何空间感知信号样本质量并动态调整模型,使其适配不同应用场景。再次,提出了一种 HSCL,通过双曲距离度量实现对样本质量差异的感知,缓解低质数据干扰。最后,在 RML2016A、RML2016B 和 RML2018 等多个公开信号调制识别数据集上的大量实验结果验证了其有效性。

参考文献

[1] 徐冬月,田蕴哲,陈康,等. 面向信号调制识别的对抗攻击与防御综述[J]. 计算机研究与发展, 2025, 62(7): 1713-1737.
Xu Dongyue, Tian Yunzhe, Chen Kang, et al. Survey on adversarial attack and defense for signal modulation recognition[J]. Journal of Computer Research and Development, 2025, 62(7): 1713-1737. (in Chinese)

[2] 杨伟超,杜宇,文伟,等. 基于多重分形谱智能分析的卫星

- 信号调制识别研究[J]. 电子学报, 2022, 50(6): 1336-1343.
- Yang Weichao, Du Yu, Wen Wei, et al. Modulation recognition of satellite communication signal based on intelligent analysis of multi-fractal spectrum[J]. Acta Electronica Sinica, 2022, 50(6): 1336-1343. (in Chinese)
- [3] 李钦, 刘伟, 牛朝阳, 等. 低 SNR 下基于分裂 EfficientNet 网络的雷达信号调制方式识别[J]. 电子学报, 2023, 51(3): 675-686.
- Li Qin, Liu Wei, Niu Chaoyang, et al. Radar signal modulation recognition based on split EfficientNet under low signal-to-noise ratio[J]. Acta Electronica Sinica, 2023, 51(3): 675-686. (in Chinese)
- [4] 李昱, 石晓然, 苗昊倩, 等. 基于 DETR_S 的卫星信号智能检测方法[J]. 电子学报, 2025, 53(5): 1365-1378.
- Li Yi, Shi Xiaoran, Miao Haoqian, et al. Intelligent detection method of satellite signal based on DETR_S[J]. Acta Electronica Sinica, 2025, 53(5): 1365-1378. (in Chinese)
- [5] 张俊林, 王彬, 汪洋, 等. 一种 α 稳定分布噪声下 OFDM 信号调制识别与参数估计算法[J]. 电子学报, 2018, 46(6): 1390-1396.
- Zhang Junlin, Wang Bin, Wang Yang, et al. An algorithm for recognition and parameters estimation of OFDM in alpha stable distribution noise[J]. Acta Electronica Sinica, 2018, 46(6): 1390-1396. (in Chinese)
- [6] 查雄, 彭华, 秦鑫, 等. 基于循环神经网络的卫星幅相信号调制识别与解调算法[J]. 电子学报, 2019, 47(11): 2443-2448.
- Zha Xiong, Peng Hua, Qin Xin, et al. Satellite amplitude-phase signals modulation identification and demodulation algorithm based on the cyclic neural network[J]. Acta Electronica Sinica, 2019, 47(11): 2443-2448. (in Chinese)
- [7] 李东瑾, 杨瑞娟, 李晓柏, 等. 基于核协同表示与鉴别投影的辐射源调制识别[J]. 电子学报, 2020, 48(9): 1695-1702.
- Li Dongjin, Yang Ruijuan, Li Xiaobai, et al. Emitter signal modulation recognition based on kernel collaborative representation and discriminative projection[J]. Acta Electronica Sinica, 2020, 48(9): 1695-1702. (in Chinese)
- [8] Wang G C, Liu Z Y, Zhang X R, et al. PID: A parameter-efficient isolation domain-incremental learning framework for signal modulation classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2026, 37(3): 1449-1462.
- [9] Zhang X R, Chen Y F, Wang G C, et al. EDDA: An efficient divide-and-conquer domain adapter for automatic modulation recognition[J]. IEEE Journal of Selected Topics in Signal Processing, 2025, 19(1): 140-153.
- [10] Zhu D M, Mathews V J, Detienne D H. A likelihood-based algorithm for blind identification of QAM and PSK signals[J]. IEEE Transactions on Wireless Communications, 2018, 17(5): 3417-3430.
- [11] Hazza A, Shoaib M, Alshebeili S A, et al. An overview of feature-based methods for digital modulation classification[C]//2013 1st International Conference on Communications, Signal Processing, and their Applications (ICCS-PA). Piscataway: IEEE, 2013: 1-6.
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [13] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [14] Hirschberg J, Manning C D. Advances in natural language processing[J]. Science, 2015, 349(6245): 261-266.
- [15] O'Shea T J, Corgan J, Clancy T C. Convolutional radio modulation recognition networks[M]//Engineering applications of neural networks. Cham: Springer, 2016: 213-226.
- [16] Hermawan A P, Ginanjar R R, Kim D S, et al. CNN-based automatic modulation classification for beyond 5G communications[J]. IEEE Communications Letters, 2020, 24(5): 1038-1041.
- [17] Xiao C H, Yang S Y, Feng Z X. Complex-valued depth-wise separable convolutional neural network for automatic modulation classification[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2522310.
- [18] Zhang J W, Wang T T, Feng Z X, et al. Toward the automatic modulation classification with adaptive wavelet network[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(3): 549-563.
- [19] Hong D H, Zhang Z L, Xu X D. Automatic modulation classification using recurrent neural networks[C]//2017 3rd IEEE International Conference on Computer and Communications. Piscataway: IEEE, 2017: 695-700.
- [20] Njoku J N, Morocho-Cayamcela M E, Lim W. CGDNet: Efficient hybrid deep learning model for robust automatic modulation recognition[J]. IEEE Networking Letters, 2021, 3(2): 47-51.
- [21] Xu J L, Luo C B, Parr G, et al. A spatiotemporal multi-channel learning framework for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1629-1632.
- [22] Zhang F X, Luo C B, Xu J L, et al. An efficient deep

- learning model for automatic modulation recognition based on parameter estimation and transformation[J]. IEEE Communications Letters, 2021, 25(10): 3287-3290.
- [23] Zhang J W, Wang T T, Feng Z X, et al. AMC-net: An effective network for automatic modulation classification[C]// ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2023: 1-5.
- [24] Li W H, Deng W, Wang K R, et al. A complex-valued transformer for automatic modulation recognition[J]. IEEE Internet of Things Journal, 2024, 11(12): 22197-22207.
- [25] Yi Z R, Meng H, Gao L, et al. Efficient convolutional dual-attention transformer for automatic modulation recognition[J]. Applied Intelligence, 2025, 55(3): 231.
- [26] Chen Z H, Zhang X Z, He K. Multi-channel convolutional distilled transformer for automatic modulation classification[C]//2024 International Joint Conference on Neural Networks. Piscataway: IEEE, 2024: 1-8.
- [27] GU A, DAO T. Mamba: Linear-time sequence modeling with selective state spaces[C]//First Conference on Language Modeling, Philadelphia: OpenReview.net, 2024: 1-32.
- [28] GU A, GOEL K, RE C. Efficiently modeling long sequences with structured state spaces[C]//International Conference on Learning Representations, Virtual Event: OpenReview.net, 2022: 1-27.
- [29] GU A, JOHNSON I, GOEL K, et al. Combining recurrent, convolutional, and continuous-time models with linear state space layers[J]. Advances in neural information processing systems, 2021, 34: 572-585.
- [30] 杜文亮, 许晓宇, 赵佳琦, 等. 基于共享提示与Mamba适配器的遥感图像文本检索方法[J]. 电子学报, 2025, 53(9): 3358-3370.
- Du Wenliang, Xu Xiaoyu, Zhao Jiaqi, et al. A remote sensing image text retrieval method based on the shared prompt and mamba adapter[J]. Acta Electronica Sinica, 2025, 53(9): 3358-3370. (in Chinese)
- [31] Cannon J W, Floyd W J, Kenyon R, et al. Hyperbolic geometry[J]. Flavors of Geometry, 1997, 31(59-115): 2.
- [32] O'shea T J, West N. Radio machine learning dataset generation with gnu radio[C]//Proceedings of the GNU Radio Conference. Boulder: GNU Radio, 2016, 1(1): 12-17.
- [33] O'Shea T J, Roy T, Clancy T C. Over-the-air deep learning based radio signal classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 168-179.
- [34] Loshchilov I, Hutter F. Decoupled weight decay regularization[C]//International Conference on Learning Representations, Vancouver: OpenReview.net, 2018: 1-18.

作者简介



王冠淳 男,1997年12月出生于陕西省咸阳市。分别于2019年和2024年获西安电子科技大学学士、博士学位。现为西安电子科技大学助理研究员。主要研究方向为目标智能解译。中国电子学会会员编号:E190186536M。
E-mail: wangguanchun@xidian.edu.cn



刘淳 男,2002年6月出生于陕西省西安市。2024年毕业于西安邮电大学数据科学与大数据技术系,现为西安电子科技大学硕士研究生。主要研究方向为信号智能处理。
E-mail: 24181214479@stu.xidian.edu.cn



张向荣 女,1978年3月出生于陕西省宝鸡市。分别于1999年、2003年和2006年获西安电子科技大学学士、硕士、博士学位。现为西安电子科技大学教授。主要研究方向为机器学习。
E-mail: xrzhang@mail.xidian.edu.cn



陈亦凡 男,2001年4月出生于浙江省金华市。2023年毕业于浙江师范大学智能科学与技术专业,现为西安电子科技大学博士研究生。主要研究方向为信号智能解译。中国电子学会会员编号:E190186539A。
E-mail: yifanchen@stu.xidian.edu.cn



张天扬 男,1996年1月出生于河南省洛阳市。分别于2018年和2023年获西安电子科技大学学士、博士学位,现为西安电子科技大学讲师。主要研究方向为场景分类、目标解译等。中国电子学会会员编号:E190186530M。
E-mail: zhangtianyang@xidian.edu.cn



唐旭 男,1985年1月出生于陕西省西安市。分别于2007年、2010年和2017年获得西安电子科技大学学士、硕士、博士学位,现为西安电子科技大学教授。主要研究方向为目标智能解译。中国电子学会会员编号:E190160631M。
E-mail: tangxu128@gmail.com