

基于TCN的USRP调制信号识别算法

杨 宵¹, 姚爱琴¹, 石喜玲²

(1. 中北大学信息与通信工程学院, 太原 030051; 2. 中北大学电气与控制工程学院, 太原 030051)

摘要: 针对自动调制识别 (Automatic modulation recognition, AMR) 中未充分利用原始信号时序信息、识别率低的问题, 提出基于频域降噪和时序卷积网络 (Temporal convolutional network, TCN) 的信号模式识别算法。实验使用标准数据集 RML2016.10a, 引入频域去噪模块 (Frequency domain denoising module, FDDM) 有效抑制环境噪声, 将信号的 I/Q 分量转换为 A/P 分量, 并进行向量归一化处理提升稳定性。最后, 将预处理后的信号输入 TCN 网络进行分类识别。结果表明, 该算法在处理复杂调制方式时 (如 16 QAM 和 64 QAM), 平均识别率高于循环门控单元 (Gated recurrent unit, GRU)、长短期记忆网络 (Long short-term memory, LSTM)、经济高效的卷积神经网络 (Memory-cost-efficient convolutional neural network, MCNet)、经济高效的混合神经网络 (Cost-efficient hybrid deep learning network, CGDNet) 和去噪自动编码器 (Denoising auto-encoder, DAE) 等模型。此外, 通过通用软件无线电外设 (Universal software radio peripheral, USRP) 采集的实际 I/Q 数据验证, 该算法在加性高斯白噪声 (Additive white Gaussian noise, AWGN) 信道下表现出良好的鲁棒性和应用潜力。

关键词: 自动调制识别; 时序卷积网络; 频域去噪模块; 预处理

中图分类号: TN911.3 **文献标志码:** A

A TCN-Based Modulation Signal Recognition Algorithm for USRP

YANG Xiao¹, YAO Aiqin¹, SHI Xiling²

(1. School of Information and Communication Engineering, North University of China, Taiyuan 030051, China; 2. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China)

Abstract: To address the low recognition rates due to the insufficient utilization of original signal timing information in automatic modulation recognition (AMR), this paper proposes a signal pattern recognition algorithm based on frequency domain denoising and temporal convolutional networks (TCN). Experiments are conducted using the standard dataset RML2016.10a, and a frequency domain denoising module (FDDM) is introduced to effectively suppress environmental noise. The I/Q components of the signal are converted into A/P components, followed by vector normalization to enhance stability. Finally, the preprocessed signals are fed into the TCN network for classification recognition. Results indicate that this algorithm achieves an average recognition rate higher than those of models such as gated recurrent unit (GRU), convolutional long short-term memory (LSTM), memory-cost-efficient convolutional neural network (MCNet), cost-efficient hybrid deep learning network (CGDNet), and denoising auto-encoder

(DAE) when processing complex modulation schemes like 16 QAM and 64 QAM. Additionally, validation using actual I/Q data collected through the universal software radio peripheral (USRP) demonstrates that the algorithm exhibits good robustness and application potential under additive white Gaussian noise (AWGN) channels.

Key words: automatic modulation recognition (AMR); temporal convolutional network (TCN); frequency domain denoising module (FDDM); pretreatment

引 言

自动调制识别 (Automatic modulation recognition, AMR) 通过分析无线电信号的特征来确定其调制方式, 从而实现信号的有效解调, 是下变频和解调器之间的重要环节。在频谱监测中, AMR 有助于监管机构实时检测和分类非法或干扰信号; 在军事通信中, 则用于确保友军信号的可靠传输与接收, 同时有效定位、识别并干扰敌方信号; 对于民用通信系统, AMR 通过优化信号接收和解码过程, 提升用户的通信体验和服务质量^[1-4]。

传统的调制识别方法主要分为基于似然比 (Likelihood-based, LB) 和基于特征提取 (Feature-based, FB)^[5] 两类。LB 方法虽然能显著提高识别准确率, 但需要大量的先验知识和高计算复杂度, 尤其在判决阈值时需要大量数据。当缺乏信道状态信息和干扰等先验知识时, LB 方法难以获得准确结果。相比之下, FB 方法计算复杂度较低, 常用的特征提取方法包括瞬时特征^[6]、小波变换特征^[7]、短时傅里叶变换特征^[8]和高阶统计量^[9]等。然而, FB 方法需要精心设计特征参数、选择合适的分类器, 并考虑多种环境条件。因此, 这些方法在复杂电磁环境中的调制识别均存在局限性。

与传统方法相比, 基于深度学习 (Deep learning, DL) 的 AMR 在识别精度和处理复杂性方面表现更优。O'Shea 等^[10]首次将卷积神经网络 (Convolutional neural network, CNN) 应用于 AMR, 验证了其在处理复杂无线电信号时的高适应性。在低信噪比 (Signal-to-noise ratio, SNR) 条件下, CNN 能够对大型密集的编码时间序列进行自适应学习, 识别准确率达到 79.3%。张军等^[11]提出了基于卷积长短期深度神经网络 (Convolutional long short-term deep neural networks, CLDNN) 的方法, 通过 CNN 减少频域变化, 长短期记忆网络 (Long short-term memory, LSTM) 捕捉长时依赖, 深度神经网络 (Deep neural networks, DNN) 映射特征空间到输出层, 在 SNR 为 0 dB 时实现了 85% 的平均识别率。

在调制识别研究中, 单一模态特征往往难以满足复杂的任务要求。Wang 等^[12]提出基于数据驱动的融合模型, 通过两个独立的 CNN 网络分别在 I/Q 信号和星座图数据集上进行训练, 提升识别性能。杨小蒙等^[13]提出了特征融合的方法, 利用 LSTM 提取调制信号的时序特征, 并通过复数密集残差卷积提取空间特征, 在 SNR > 5 dB 时实现了 93.25% 的识别准确率。Xu 等^[14]采用时空多通道网络 (Multi-channel convolutional long short-term deep neural network, MCLDNN), 结合一维和二维 CNN 与 LSTM, 充分利用时域特征的互补性, 提升识别精度。

尽管多路输入的并行网络能够增强特征提取能力, 但其高计算复杂度不利于在计算资源有限的平台上实现高效部署。为降低训练成本, 本文使用基于频域降噪的时序卷积网络 (Temporal convolutional network, TCN) 算法, 通过多层感知器 (Multilayer perceptron, MLP) 提取频域特征进行降噪处理, 随后将信号还原至时域并输入 TCN 进行分类。实验结果表明, 该方法有效增强了信号质量, 提高了低 SNR 条件下的平均识别准确率。由于 TCN 能够快速提取特征并更适合处理时间序列数据, 本文提出的方法在实际应用中表现出色。

1 接收机系统与信号模型

1.1 无线电智能接收机系统

正交采样是常见的接收机架构之一^[15],其通过采样I/Q信号来获取数据流。本文基于零中频(ZIF)接收机进行网络设计,如图1所示。每个样本维度为 $N \times 2$,其中 N 表示信号的时间长度,2表示I/Q分量。智能卫星通信接收机的工作流程如下:射频信号经过带通滤波器和低噪声放大器进行频率选择和放大,随后与本振信号在混频器中混频生成I/Q信号,接着对I/Q信号进行放大、滤波、采样和提取,形成数字基带信号,最后将采集到的I/Q基带信号输入AMR模型,完成信号调制类型的识别。

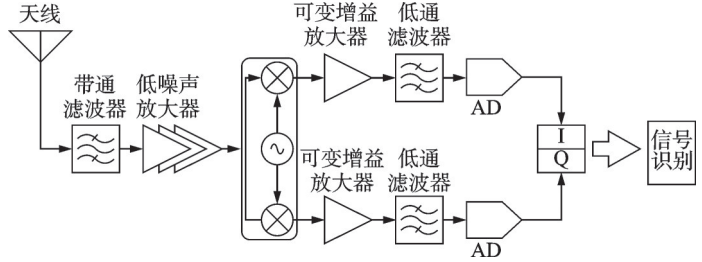


图1 正交采样 ZIF 智能接收机

Fig.1 Orthogonal sampling ZIF intelligent receiver

1.2 信号模型

与图像分类任务类似,AMR本质上是一个多分类问题。接收到的无线电信号以复基带时间序列的形式表示,输出则是各调制类型的概率分布。接收信号可以表示为

$$x(t) = s(t) * h(t) + n(t) \quad (1)$$

式中: $s(t)$ 表示发送的复基带信号, $h(t)$ 为信道脉冲响应, $n(t)$ 为加性高斯白噪声。在该模型中,接收的无线电信号可以通过以下表达式来近似真实的无线电传输信号

$$x(t) = x_i(t) + j \cdot x_q(t) \quad (2)$$

式中: $x_i(t)$ 和 $x_q(t)$ 分别代表同相分量I和正交分量Q, x_i 和 x_q 为其离散形式。因此,每个长度为 N 的信号样本都可以表示为矩阵 $X \in \mathbf{R}^{2 \times N}$,即

$$X = \begin{bmatrix} x_i \\ x_q \end{bmatrix} = \begin{bmatrix} x_i(1), x_i(2), \dots, x_i(N) \\ x_q(1), x_q(2), \dots, x_q(N) \end{bmatrix} \quad (3)$$

2 算法模型

2.1 AMR 模型

本文提出了一种基于频域去噪的TCN模型,其结构如图2所示。该模型由频域降噪模块、空间特征提取模块、时域特征提取模块以及分类识别模块组成。输入信号首先经过频域降噪模块处理,有效降低噪声干扰,确保后续特征提取过程的可靠性。接着,信号通过4层CNN网络提取关键的空间特征,利用TCN提取时序动态特征和长期依赖关系。最后,将空间特征与时域特征融合,输入分类识别模块完成最终的分类任务。各模块相互协作,显著提升了模型的性能和分类准确率。




图2 AMR模型结构示意图

Fig.2 Schematic diagram of AMR model structure

2.2 频域降噪模块

频域降噪模块的核心在于利用频域学习全局滤波器,该方法源于卷积定理 $F\{f*g\}=F\{f\}\cdot F\{g\}$,用于提高信号处理的质量和效果。图3展示了频域去噪模块(Frequency domain denoising module, FDDM),该模块通过频域处理技术对输入的I/Q信号进行降噪,详细过程如下。

时域信号 $x(t)$,其离散形式为 $x(n)$,通过快速傅里叶变换(Fast Fourier transform, FFT)信号转换为复值序列 $X(k)$,即

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi}{N}nk} \quad (4)$$

式中 $X(k)$ 由 $\mathbf{X} = [X^{\text{Re}}, X^{\text{Im}}] \in \mathbf{R}^{2 \times N}$ 两部分组成,应用MLP学习全局滤波器能有效处理整个频谱范围内的信号特征,从而提升降噪效果。经过降噪处理后的频域信号表示为

$$\hat{X}^{\text{Re}} = \tanh(\sigma_{\text{Re}}(X^{\text{Re}})) \odot X^{\text{Re}} \quad (5)$$

$$\hat{X}^{\text{Im}} = \tanh(\sigma_{\text{Im}}(X^{\text{Im}})) \odot X^{\text{Im}} \quad (6)$$

在频域中 σ_{Re} 和 σ_{Im} 作为MLP的映射函数,分别对频域信号的实部和虚部进行降噪处理。该处理将实部和虚部的变化相互独立,从而增强了频谱在幅值和相位上的可调性。为了保持网络训练的稳定性,使用 \tanh 函数将输出范围限制在 $[-1, 1]$ 。降噪处理后的实部和虚部重新组合为

$$\hat{X}(k) = \hat{X}^{\text{Re}} + j \cdot \hat{X}^{\text{Im}} \quad (7)$$

随后,将滤波处理后的频域信号 $\hat{X}(k)$ 通过逆傅里叶变换(Inverse fast Fourier transform, IFFT)转换回时域信号 $\hat{x}(k)$,即

$$\hat{x}(k) = \frac{1}{N} \sum_{k=0}^{N-1} \hat{X}(k) e^{j\frac{2\pi}{N}nk} \quad (8)$$

最后,使用残差连接将处理后的信号与初始输入信号相加,确保在去噪过程中不丢失有用信息,同时有效缓解梯度消失问题,从而使网络在处理复杂信号时更有效和稳定。

2.3 空间特征提取模块

该模型由4个CNN组成,前两层各使用256个大小为3的卷积核,后两层各采用80个大小为3的卷积核,并应用填充操作来保持输入和输出维度的一致性。在每个CNN层后均引入了30%的Dropout正则化。该深层网络结构能有效细化和处理前一层提取的I/Q数据,提升了模型在多样信号环境中的性能,同时增强了不同调制方式的区分能力,为应对复杂的调制识别任务提供了强大的数据表征能力。

2.4 时域特征提取模块

TCN网络^[16]通过因果卷积、膨胀卷积和残差连接等机制,实现对时序数据的并行处理,从而加速训练过程。TCN不仅能够捕捉长时间依赖关系,还具有计算效率高和稳定性好的特征。此外,通过调整卷积核大小和层数,TCN能适应不同长度的输入序列,并对输入序列长度变化表现出较强的适应能力,使其在时序任务中表现出色。

在TCN中,因果卷积可以处理任意长度的序列,并且能生成与输入序列长度相同的输出序列。该序列问题定义为:根据 x_1, x_2, \dots, x_t 去预测 y_1, y_2, \dots, y_t 。因果卷积中,滤波器表示为 $F = (f_1, f_2, \dots, f_K)$,序列为 $S = (s_1, s_2, \dots, s_T)$,在 x_t 处的因果卷积为

$$(F*S)_{(s_t)} = \sum_{k=1}^K f_k \cdot s_{t-K+k} \quad (9)$$

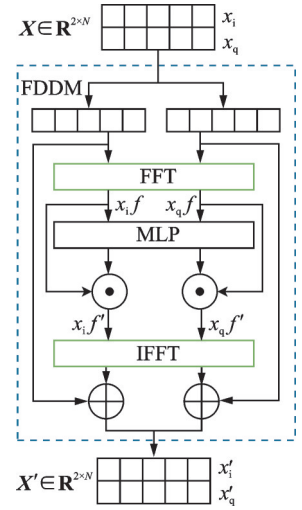


图3 FDDM结构示意图

Fig.3 Schematic diagram of FDDM structure

当卷积核大小为3时,因果卷积结构如图4所示。在因果卷积层中,预测 y_t 时,只能使用已经观测到的序列 s_1, s_2, \dots, s_t ,而无法使用该时间点之后的数据 s_{t+1}, s_{t+2}, \dots 。为了确保输出与输入数据长度相同,需要在输入序列的左侧进行0填充,数量为 $K-1$ 。在需要追溯的历史信息增加时,隐藏层数量也会随之增加,该过程会加剧梯度消失的问题,并增加训练过程的复杂性。

标准的CNN通过增加池化层来扩展感受野,但这会导致信息的不可逆损失。为了解决这一问题,膨胀卷积引入了空洞卷积技术,通过在卷积核中加入跳跃的感受野,从而在保持网络深度相对稳定的情况下扩展感受野范围。该方法有效提升了网络处理大范围输入数据的能力^[17-18]。

膨胀卷积中,滤波器表示为 $F=(f_1, f_2, \dots, f_K)$,序列为 $S=(s_1, s_2, \dots, s_T)$,在 x_i 处的膨胀卷积为

$$(F*S)_{(s_i)} = \sum_{k=1}^K f_k \cdot s_{i-(K-k)d} \quad (10)$$

式中 d 为膨胀系数,膨胀卷积的感受野大小为 $(K-1)d+1$,故增大 K 或 d 都可以增加感受野。在实际应用中,随着网络层数的增加, d 以2的指数增长。膨胀卷积通过在卷积核内部相邻值之间使用0填充,既不增加计算量,又扩大了卷积核的有效尺寸和内部相邻值之间的距离。这种方法能够有效增大感受野,使每个卷积输出能够捕捉到更广泛的信息。在TCN中,膨胀卷积结构如图5所示,卷积核大小为3,膨胀系数为2。

在AMR模型中,尽管采用了膨胀因果卷积,深层网络结构仍可能面临梯度消失等问题。为解决这些问题,引入残差模块,通过跳跃连接将输入直接添加到卷积层输出中,有效缓解了梯度消失的影响。该设计提升了模型的表达能力和学习效果,有助于捕捉复杂数据中的特征和模式。

本文中的TCN模型结构如图6所示,输入数据经过6层膨胀因果卷积处理,每层卷积核大小为3,通道数为6,膨胀系数 d 依次为1、2、4、6、8、32。为防止模型过拟合,在输入单元和TCN模块中分别应




图4 因果卷积结构示意图

Fig.4 Schematic diagram of causal convolution structure




图5 膨胀卷积结构示意图

Fig.5 Schematic diagram of the dilated convolution structure




图6 TCN网络结构示意图

Fig.6 Schematic diagram of TCN network structure

用 20% 的 Dropout。卷积层的权重矩阵采用 He 正态分布进行初始化,以优化模型的初始化过程。此外,还在残差层中应用批处理规范化,进一步提高训练效率和模型稳定性。

2.5 分类识别模块

在分类识别模块中,使用包含 64 个神经元的线性修正单元(Rectified linear unit,ReLU)激活函数全连接层,并加入 30% 的 Dropout 正则化以减轻过拟合现象。最终的输出层由 11 个节点组成,采用 Softmax 激活函数实现信号调制识别的分类,输出类别的概率分布。损失函数使用分类交叉熵,用于衡量模型预测结果与实际类别之间的差异,其公式为

$$\text{Loss} = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \ln \hat{y}_i$$

(11)

式中: y_i 表示实际标签; \hat{y}_i 表示预测输出; N 表示样本总数量。

3 实验结果及分析

3.1 数据集与实验参数

本文使用开源数据集 RML2016.10a,该数据集通过 GNU Radio 仿真软件生成,模拟了复杂通信环境的多种因素,包括频率偏移、信号衰落和多径效应等^[10]。数据集包含 22 万个调制信号,涵盖 11 种常用调制方式,具体信息详见表 1。

表 1 数据集参数
Table 1 Dataset parameters

数据集	RML2016.10 a
调制类型	数字调制: BPSK, QPSK, 8 PSK, 16 QAM, 64 QAM, CPFSK, GFSK, 4PAM 模拟调制: WBFM, 双边带调幅(Amplitude modulation-double sideband, AM-DSB), 单边带调幅(Amplitude modulation-single sideband, AM-SSB)
样本总数/ 10^3	220
采样率/kHz	200
采样率偏移标准偏差/Hz	0.01
最大采样率偏移/Hz	50
载波频率偏移标准差/Hz	0.01
最大载波频率偏移/Hz	500
信号格式	同相分量正交分量(I/Q)[128, 2]
信噪比范围/dB	[−20, −18, ⋯, 18]
信道环境	加性高斯白噪声(Additive white Gaussian noise, AWGN), 莱斯衰落(Rician), 瑞利衰落(Rayleigh)

本文所有实验参数设置相同。数据集按 6:2:2 的比例划分为训练集、测试集和验证集。训练轮数(Epoch)为 150, 批量大小(Batch size)为 400。采用基于随机梯度下降的 Adam 优化器, 并使用交叉熵损失函数。初始学习率设为 0.001, 每训练 20 个周期, 学习率减半。具体的训练参数见表 2。

表 2 实验训练参数
Table 2 Experimental training parameters

训练参数	FDDM-TCN
数据集划分比例	6:2:2
Batch size	400
Epoch	150
优化器	Adam
初始学习率	0.001
分类函数	Softmax

3.2 对比实验分析

将本文所提算法与经典算法进行比较,选择循环门控单元(Gated recurrent unit,GRU)^[19]、LSTM^[20]、经济高效的卷积神经网络(Memory-cost-efficient convolutional neural network,MCNet)^[21]、经济高效的混合神经网络(Cost-efficient hybrid deep learning network,CGDNet)^[22]和去噪自动编码器(Denoising auto-encoder,DAE)^[23]进行对比实验。各模型的网络结构见表3。

图7展示了各模型的识别率曲线。本文提出的算法在中高 SNR 条件下表现尤为突出。实验结果显示,GRU 模型的最高识别率为 87.81%,LSTM 为 90.13%,MCNet 为 85.59%,CGDNet 为 87.45%,DAE 为 89.45%,而 TCN 模型的最高识别率达到 92.88%。当 SNR 大于 0 dB 时,TCN 模型的平均识别准确率为 92.10%。总体而言,本文算法在识别准确率上明显优于其他模型,特别是在高 SNR 条件下。

表4给出了各模型在不同 SNR 范围内的参数量、计算量(FLOPs/MB)、训练时间(s/Epoch)、以及其平均识别率。低 SNR 的范围是 $[-20, 0)$ dB,记作 Acc_low,高 SNR 范围是 $[0, 18]$ dB,记作 Acc_high,Acc_all 表示网络在所有 SNR 范围内的总体平均识别准确率。

表 3 各模型的网络结构

Table 3 Network structure of each model

模型结构	输入数据	主要结构
GRU	I/Q	2层128神经元的GRU
LSTM	A/P	2层128神经元的LSTM
MCNet	I/Q	CNN
CGNDet	I/Q	CNN+GRU+DNN
DAE	A/P	2层32神经元的LSTM

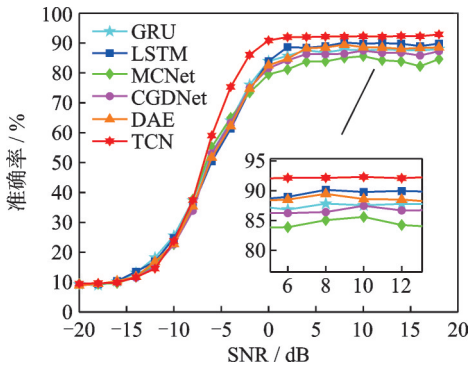


图7 各模型在不同 SNR 下的识别率曲线

Fig.7 Recognition rate curves for each model at different SNRs

表 4 各模型参数和实验结果

Table 4 Parameters and experimental results of each model

模型	参数量/ (FLOPs·Mb ⁻¹)	计算量/ (s·Epoch ⁻¹)	训练 时间/s	Acc_low 的 平均识别率/%	Acc_high 的 平均识别率/%	Acc_all/%
GRU	151 179	38.02	9	31.59	87.03	59.31
LSTM	201 099	25.62	11	30.54	88.84	59.69
MCNet	121 611	1.11	8	30.98	83.39	57.19
CGNDet	124 676	213.5	11	30.35	85.87	58.11
DAE	15 085	1.76	7	30.40	87.55	58.98
TCN	457 707	7.83	21	33.68	92.10	62.89

尽管 TCN 模型的参数量高于其他模型,但其计算复杂度为 7.83 FLOPs/MB,处于中等水平,表明该模型在维持较大参数数量的同时仍保持较低的计算负担。此外,TCN 模型的每周训练时间为 21 s,表明其计算效率与卓越识别性能的良好平衡,适合高效信号处理任务。

进一步分析显示,TCN 模型在低 SNR 范围内的平均识别率显著高于其他模型,分别提高了

2.09%、3.14%、2.70%、3.33% 和 3.28%。在高 SNR 范围内,其识别率达到 92.10%,超出其他模型 5.07%、3.26%、8.71%、6.23% 和 4.55%。总体而言,TCN 模型在各 SNR 范围内的平均识别率均优于其他模型,提升幅度分别为 3.58%、3.20%、5.70%、4.78% 和 3.91%。这些结果表明,本文提出的算法在各 SNR 范围内的平均识别率显著提高,且其 FDDM 在处理噪声信号时具有卓越的鲁棒性。

为了进一步评估基于频域降噪的 TCN 模型在分类识别方面的性能,图 8 为 GRU、LSTM、MCNet、CGDNet、DAE 和 TCN 模型的混淆矩阵(SNR=8 dB)。由图 8 可得,TCN 模型的混淆矩阵呈现出一条明显且颜色较深的对角线,表明其预测标签与实际标签高度一致。尽管在识别宽带调频(Wide-band frequency modulation, WBFM)和 AM-DSB 信号时存在轻微混淆,TCN 算法在其他信号类型的识别上表现出更高的准确率。相比之下,其他 5 种算法在识别 16 QAM 和 64 QAM 信号类型时易发生混淆,而 TCN 算法则展现出了更强的识别能力。

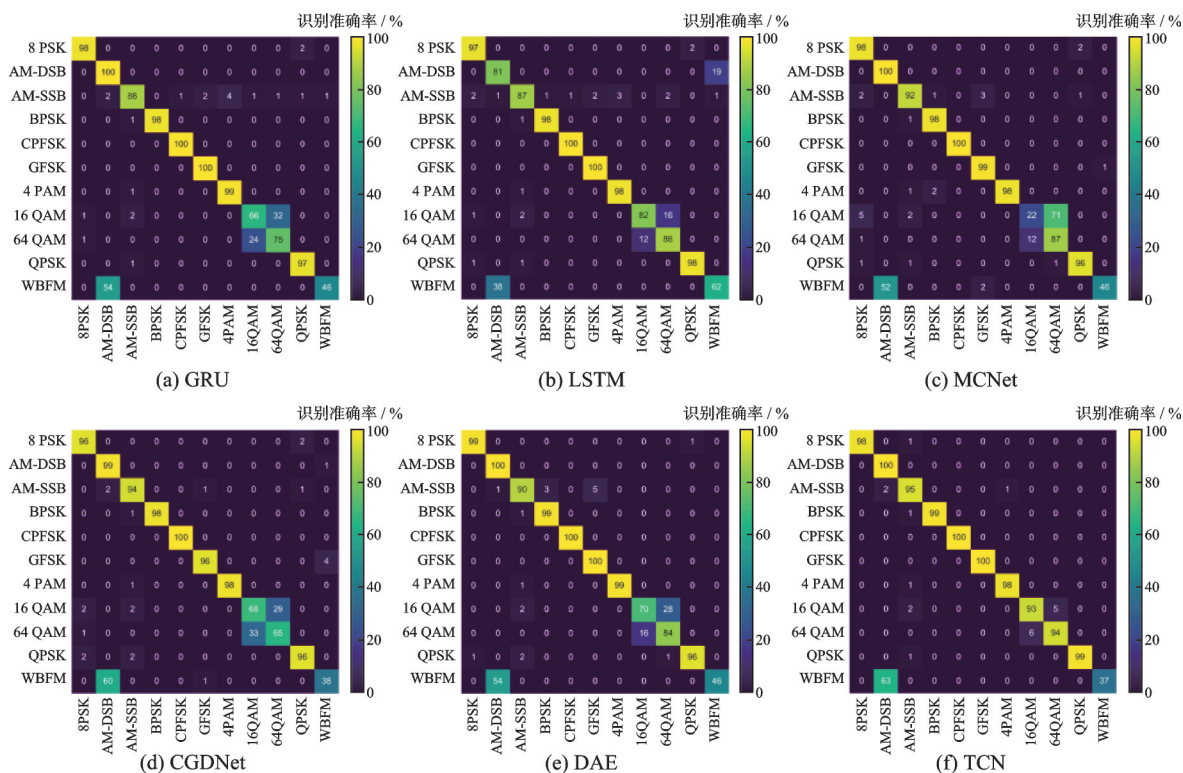


图8 各算法混淆矩阵

Fig.8 Confusion matrix of each algorithm

3.3 消融实验分析

为验证 FDDM 对 TCN 模型性能的影响,本节将原始 TCN 模型与集成降噪模块的 TCN 模型进行了比较实验。表 5 展示了这两种网络模型在数据集上的识别准确率。消融实验结果显示, FDDM-TCN 算法在各项测试中均优于原始 TCN

表 5 消融实验数据对比

Table 5 Comparison of ablation experimental data

模型	Acc_low	Acc_high	Acc_all/%
	平均识别率/%	平均识别率/%	
TCN	31.23	85.77	58.50
FDDM-TCN	33.68	92.10	62.89

模型。在低 SNR 环境下,FDDM-TCN 模型的识别准确率提高了 2.45%,体现了 FDDM 的有效性。在高 SNR 条件下,FDDM-TCN 模型的识别准确率提高了 6.33%,表明其不同 SNR 环境中的广泛适应性和鲁棒性。该项实验结果证明了 FDDM 的有效性,提高了 TCN 模型在处理复杂信号任务中的性能。图 9 为消融实验在不同 SNR 条件下模型的识别率曲线,进一步验证了本文算法的优越性以及其在实际应用中的潜力与价值。

3.4 实测数据分析

AMR 是认知无线电、智能解调器以及电子侦察等多种民用和军事应用的基本要求^[24]。在本节中,使用通用软件无线电外设(Universal software radio peripheral,USRP)设备对实际信号进行采集与分析。具体实验环境如下:发射端设备为左侧的华硕笔记本,使用 USRP N210 型号;接收端设备为右侧的微星台式机,搭载 USRP 2922 型号。采样率设定为 3 MHz,对应的采样周期为 25 ns。详细数据如表 6 所示。

使用实测信号评估各模型识别性能,图 10 展示了各模型总体识别精度和 TCN 模型的混淆矩阵(SNR=8 dB)。实验结果表明,TCN 模型在各 SNR 条件下仍能保持较高的识别准确率,尤其在中高 SNR 情况下($SNR \geq 4$ dB)。与传统的 GRU、LSTM、MCNet、CGDNet 和 DAE 模型相比,TCN 模型在大多数 SNR 条件下表现更佳,最高准确率达到 91.16%。通过分析真实环境中采集的 I/Q 数据,进一步验证了基于频域降噪的 TCN 网络在实际信号分类中的有效性。

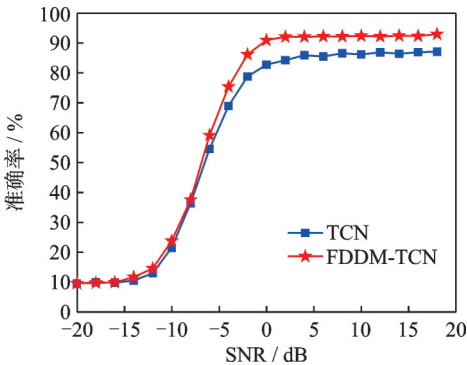


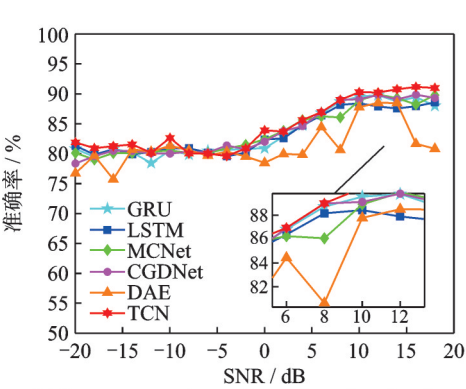
图 9 消融实验在各 SNR 条件下的识别率曲线

Fig.9 Recognition rate curves of ablation experiments under different SNR conditions

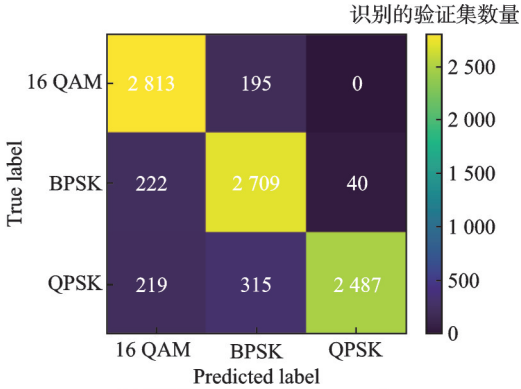
表 6 实测数据集参数

Table 6 Measured dataset parameters

数据集	实测数据
调制类型	数字调制:16 QAM,BPSK,QPSK
信号格式	同相分量正交分量(I/Q)[1 024,2]
信噪比范围/dB	$[-20,-18,\cdots,18]$
信道环境	AWGN
样本总数	900 000



(a) Parameters and experimental results of each model



(b) TCN model confusion matrix

图 10 模型性能比较和分类有效性验证

Fig.10 Analysis of model performance and classification effectiveness

4 结束语

本文使用TCN网络进行信号模式识别,并引入自适应校正去噪模块应对传输过程中的噪声和偏移干扰。实验结果表明,该模型在中高SNR范围(0~18 dB)内表现出优异的识别性能,但在极低SNR(如-20~-10 dB)条件下仍面临一定的挑战。同时,利用GNU Radio软件无线电平台对实测数据进行传输和接收,进一步验证了算法在实际信号分类中的适应性与高效性。综上所述,基于频域降噪的TCN模型拥有显著的优势和广泛的应用前景。未来研究可进一步优化降噪算法和TCN结构,应对更为复杂的信号环境和多样化的应用需求。

参考文献:

- [1] WANG Y, LIU M, YANG J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(4): 4074-4077.
- [2] JI Mingrui, HUANG Chenzhao, LUO Ruisen. Automatic modulation recognition based on spatio-temporal features fusion [C]//*Proceedings of the 2022 IEEE 12th International Conference on Electronics Information and Emergency Communication (ICEIEC)*. Piscataway, USA: IEEE, 2022: 89-93.
- [3] SHAH M H, DANG X. Robust approach for AMC in frequency selective fading scenarios using unsupervised sparse autoencoder based deep neural network (SAE-DNN)[J]. *IET Communications*, 2018, 13(4): 423-432.
- [4] 江汉, 胡林, 李文, 等. 信号调制识别的对抗样本攻防技术研究进展[J]. *数据采集与处理*, 2023, 38(6): 1235-1256.
JIANG Han, HU Lin, LI Wen, et al. Research progress of adversarial attack and defense for signal modulation recognition[J]. *Journal of Data Acquisition and Processing*, 2023, 38(6): 1235-1256.
- [5] 张海燕, 闫文君, 张立民, 等. 通信信号调制识别综述[J]. *海军航空大学学报*, 2022, 37(1): 126-132.
ZHANG Haiyan, YAN Wenjun, ZHANG Limin, et al. An overview of communication signal modulation recognition[J]. *Journal of Naval Aviation University*, 2022, 37(1): 126-132.
- [6] 王海滨, 周正, 李炳荣, 等. 基于数字通信信号瞬时特性的调制方式识别方法[J]. *现代电子技术*, 2019, 42(16): 22-25.
WANG Haibin, ZHOU Zheng, LI Bingrong, et al. Method of modulation mode recognition based on instantaneous characteristic of digital communication signal[J]. *Modern Electronics Technique*, 2019, 42(16): 22-25.
- [7] CHAVALI V G, DA SILVA C R C M. Maximum-likelihood classification of digital amplitude-phase modulated signals in flat fading non-gaussian channels[J]. *IEEE Transactions on Communications*, 2021, 59(8): 2051-2056.
- [8] MENG F, CHEN P, WU L, et al. Automatic modulation classification: A deep learning enabled approach[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(11): 10760-10772.
- [9] CHANG D C, SHIH P K. Cumulants-based modulation classification technique in multipath fading channels[J]. *IET Communication*, 2015, 9(6): 828-835.
- [10] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//*Proceedings of Engineering Applications of Neural Networks: The 17th International Conference*. Aberdeen, UK: Springer, 2016: 213-226.
- [11] 张军, 符杰林, 林基明. 基于CLDNN的调制信号识别方法[J]. *计算机应用与软件*, 2021, 38(10): 216-220, 277.
ZHANG Jun, FU Jieli, LIN Jiming. Modulation signal recognition method based on CLDNN[J]. *Computer Applications and Software*, 2021, 38(10): 216-220, 277.
- [12] WANG Y, LIU M, YANG J, et al. Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(4): 4074-4077.
- [13] 杨小蒙, 张涛, 庄建军, 等. 基于多模态融合和深度学习的调制信号识别[J]. *计算机科学*, 2023, 50(11A): 220900007-7.
YANG Xiaomeng, ZHANG Tao, ZHUANG Jianjun, et al. Modulation signal recognition based on multimodal fusion and deep learning[J]. *Computer Science*, 2023, 50(11A): 220900007-7.
- [14] XU J, LUO C, PARR G, et al. A spatiotemporal multi-channel learning framework for automatic modulation recognition[J]. *IEEE Wireless Communication Letters*, 2020, 9(10): 1629-1632.
- [15] YAO T, CHAI Y, WANG S, et al. Radio signal automatic modulation classification based on deep learning and expert features

- [C]//Proceedings of the 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Chongqing, China: IEEE, 2020: 1225-1230.
- [16] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-03-01). <https://doi.org/10.48550/arXiv.1803.01271>.
- [17] INGOLFSSON T M, HERSCHE M, WANG X, et al. EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces[C]//Proceedings of the 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). [S.l.]: IEEE, 2020: 2958-2965.
- [18] MUSALLAM Y K, ALFASSAM N I, MUHAMMAD G, et al. Electroencephalography-based motor imagery classification using temporal convolutional network fusion[J]. Biomedical Signal Processing and Control, 2021, 69: 102826.
- [19] HONG D, ZHANG Z, XU X. Automatic modulation classification using recurrent neural networks[C]//Proceedings of the 2017 3rd IEEE International Conference on Computer and Communications (ICCC). Chengdu, China: IEEE, 2017: 695-700.
- [20] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 433-445.
- [21] HUYNH-THE T, HUA C H, PHAM Q V, et al. MCNet: An efficient CNN architecture for robust automatic modulation classification[J]. IEEE Communications Letters, 2020, 24(4): 811-815.
- [22] 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.
- [23] KE Z, VIKALO H. Real-time radio technology and modulation classification via an LSTM auto-encoder[J]. IEEE Transactions on Wireless Communications, 2022, 21(1): 370-382.
- [24] 刘桥平,高兴宇,邱昕,等.基于 USRP 的自动调制识别[J].计算机应用与软件,2020,37(8):110-114,121.
LIU Qiaoping, GAO Xingyu, QIU Xin, et al. Automatic modulation recognition based on USRP[J]. Computer Applications and Software, 2020, 37(8): 110-114, 121.

作者简介:



杨宵(1999-),女,硕士研究生,研究方向:无线通信、模式识别、软件无线电,
E-mail: yx6666cc@163.com。



姚爱琴(1969-),通信作者,女,副教授,研究方向:信息探测与信号处理、无线电频谱感知与智能识别、图像识别处理、现代通信技术,
E-mail: yaaoaiqin@nuc.edu.cn。



石喜玲(1980-),女,副教授,研究方向:多传感器信息融合、智能控制、深度学习、步态识别, E-mail: shixl@nuc.edu.cn。

(编辑:陈琨)