



研究与开发

一种复数域轻量化知识蒸馏驱动的调制识别模型

王子恒, 张徐, 高硕, 周金
(天津财经大学理工学院, 天津 300222)

摘要: 深度学习模型在调制识别任务中依赖大量训练样本, 但实际场景中信号样本有限, 尤其在复杂噪声环境下, 模型性能受限。为此, 提出了一种基于局部特征引导的轻量化调制识别方法。首先, 构建轻量化教师网络以提取含噪调制信号的局部特征, 并设计局部语义特征优化算法将局部知识蒸馏给学生网络; 其次, 针对调制信号频谱的复数域特性, 设计复数域 Transformer 作为学生网络进行全局特征提取, 并最终完成识别任务。实验结果表明, 所提模型在小样本场景下相比其他深度学习模型具有更高的识别效率, 在计算复杂度和实时性等方面较现有方法表现出明显优势。

关键词: 调制识别; 知识蒸馏; 小样本数据集; Transformer; 轻量化网络

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025173

A modulation recognition model driven by lightweight knowledge distillation in the complex number domain

WANG Ziheng, ZHANG Xu, GAO Shuo, ZHOU Jin

School of Information Science and Technology, Tianjin University of Finance and Economics, Tianjin 300222, China

Abstract: Deep learning models rely on a large number of training samples in the modulation recognition task. However, in actual scenarios, the signal samples are limited, especially in complex noise environments, where the model performance is restricted. Therefore, a lightweight modulation recognition method based on local feature guidance was proposed. Firstly, a lightweight teacher network was constructed to extract local features from noisy modulated signals, and a local semantic feature optimization algorithm was designed to distill local knowledge into the student network. Secondly, aiming at the complex-domain characteristics of the modulated signal spectrum, a complex-domain Transformer was designed as the student network for global feature extraction, ultimately completing the recognition task. Experimental results show that the proposed model demonstrates higher recognition efficiency in small-sample scenarios compared with other deep learning models, and exhibits significant advantages in terms of computational complexity and real-time performance compared with existing methods.

Key words: modulation recognition, knowledge distillation, small-sample dataset, Transformer, lightweight network

收稿日期: 2024-12-01; 修回日期: 2025-01-06

通信作者: 周金, zhoujin@tjufe.edu.cn

基金项目: 天津自然科学基金面上项目 (No.22JCYBJC01550)

Foundation Item: The Natural Science Foundation of Tianjin (No.22JCYBJC01550)



0 引言

自动调制识别 (automatic modulation recognition, AMR) 是一项介于信号检测和信号解调之间的技术。AMC 仅依靠接收信号即可确定调制方式类别, 在通信、电子信息对抗等领域有着重要的研究意义, 同时也是保障无线网络物理层安全的关键技术之一^[1]。传统的 AMR 方法严重依赖人工经验, 且有关特征提取的信号处理过程非常复杂, 难以适应现有的复杂电磁环境^[2-3]。

近年来, 随着深度学习理论的发展, AMR 性能获得较大提升。深度神经网络 (deep neural network, DNN) 由于具备强大的特征提取能力和便捷、独有的端到端结构, 在无线电信号的分类任务中成为常见和有力的解决方案^[4-6]。卷积神经网络 (convolutional neural network, CNN) 擅长数据的局部特征提取^[7], Transformer 网络则擅长获取特征的长距离依赖关系, 克服了 CNN 无法获取全局特征的弊端。自 2022 年开始, 众多学者将 Transformer 引入无线通信物理层研究, 如文献[8]将 Transformer 引入 AMR, 该模型利用 Transformer 捕获同相正交 (in-phase quadrature, IQ) 序列的全局语义特征, 并证明了该模型相较 CNN 和长短期记忆 (long short-term memory, LSTM) 神经网络在识别效率方面的优越性。同年, 文献[9]提出基于 IQ 信号的多模态特征和多尺度特征融合的 Transformer 网络实现调制识别, 并验证了该方法在计算复杂度等方面的优异性能。在文献[8-9]的基础上, 文献[10]发现局部特征的缺失对调制信号识别的抗噪性能有重要影响, 基于该发现, 提出了同时捕获信号的局部特征和长距离依赖特征的并行 CNN-Transformer 网络。

上述网络在高识别精度的要求下, 需要大量有标签的训练样本。然而, 由于信道和噪声的时变性, 获取充足的调制信号样本极具挑战。为解决

小样本场景下的 AMR 难题, 2024 年, 文献[11]提出一种基于卷积相关的信号 Transformer 和知识蒸馏融合的调制识别模型, 该模型在小样本识别性能方面较现有方法获得了显著提升。

尽管上述方法获得了优异的性能, 但仍存在以下问题。

(1) 以文献[11]为代表的知识蒸馏模型虽然解决了小样本环境下识别性能下降的问题, 但是该模型采用具有较强能力的网络作为教师网络, 采用较弱能力的网络作为学生网络, 将教师提取的全局特征蒸馏给学生。因此, 教师网络往往成为学生网络识别能力提升的瓶颈。

(2) 现有网络通常将序列转换为频谱数据或离散化 IQ 时序序列, 这两者均为复数域信号。训练网络通常采用实值网络, 训练时对实部和虚部信号分别并行处理, 使算法效率较低, 且忽略了实部和虚部之间的相关性, 同时特征提取过程可能产生冗余特征, 增加了网络的推演时间, 使网络无法适应具有较高实时性要求的应用场景。

鉴于此, 本文提出一种用于 AMR 的轻量化知识蒸馏网络 (lightweight knowledge distillation network, LKDN) 模型。该模型由轻量化教师网络获取调制信号的局部特征, 并将该局部知识引导蒸馏给学生网络, 设计引导局部特征的语义特征优化算法; 设计具有复数域全局特征提取能力的学生网络; 通过局部特征引导至全局特征, 使得学生网络在不影响自学习的前提下获取必要的局部特征, 由学生网络完成推演、识别等任务。

1 本文方法

基于 LKDN 的 AMR 模型总体结构如图 1 所示。该模型由基于全局特征提取的学生网络模块、基于局部特征提取的教师网络模块, 以及局部特征向全局特征引导模块组成。

基于全局特征提取的学生网络模块由 Transformer 模块构成, 其目的是提取输入样本块间的




图1 基于LKDN的AMR模型总体结构

远距离上下文信息之间的联系，捕获调制信号的全局特征，并通过类别标签的监督实现网络训练。基于局部特征提取的教师网络模块由轻量级残差网络（ResNet）设计而成，其目的是学习无线信号的多尺度局部细节特征，并将局部特征补偿给学生网络模块，使得学生网络模块获取强大的小样本数据集下的识别能力。局部特征向全局特征引导模块则通过将教师和学生网络的特征在空间和通道维度上对齐，以实现局部特征对全局特征的补偿，从而实现教师网络的知识向学生网络进行蒸馏。针对训练阶段和测试阶段损失函数的特定构造，两个网络模型在训练阶段可进行协同优化，以保证轻量级教师模型将所学习的判别信息有效转移到学生模型中，在测试阶段，将已完成知识蒸馏的学生网络执行调制信号的识别与分类等下游任务。

1.1 基于全局特征提取的学生网络模块

视觉 Transformer（vision Transformer, ViT）网络^[12-13]在图像分类任务上展现了出色的性能，该网络可以利用多头注意力机制来提取序列之间的远距离上下文关系。因此，本文引入 ViT 网络作为学生网络模块。在此基础上，为充分捕获 IQ 路信号的全局特征，本文设计并提出适用于无线信号频谱复数域的 Transformer 网络，即 WST

（wireless signal Transformer）网络。与 ViT 网络结构类似，WST 网络由嵌入层、Transformer 编码器以及多层感知机（multi-layer perception, MLP）头部这 3 个模块组成，不同之处在于，WST 网络的输入信号为 IQ 复数域序列频谱，针对复数域信号特点，设计了复数域特征提取层和复多头注意力（complex multi-head attention, C-MHA）机制。WST 网络结构如图 2 所示。其中，图 2（a）为编码器结构，Transformer 编码器由 L 个相同的模块组成，本文通过实验测试选定 $L=12$ ，每个编码器由批处理层、复多头注意力层和 MLP 构成。每个模块均需要进行层标准化，输入信号通过 C-MHA 模块后，调制信号特征向量的远距离上下文权重会增加。图 2（b）为本文提出的 C-MHA 结构，主要由 MHA 和复数前馈序列记忆网络（complex feedback sequential memory network, C-FSMN）构成，其信号处理原理如下。

首先，将 IQ 信号进行短时傅里叶变换（short-time Fourier transform, STFT），获得复数矩阵的实部和虚部，经过层归一化后使用 C-MHA 中的复 Conv2d 代替 Transformer 注意力机制中的线性投影来计算 Q 、 K 、 V ，并使用复数矩阵乘法和复激活函数 softmax 计算注意力权重，以更好地保持输入数据空间结构和维度的一致性，减少模




图2 WST网络结构

型的计算复杂度，提高计算效率，从而提取出更加丰富和多样的空间特征。其次，使用门控机制和复Conv2d代替Transformer中的前馈网络来捕获输入数据的局部特征，并适应复数数据的处理需求，进一步提升模型的表达能力，增强模型对复杂特征的提取能力。复Conv2d网络结构如图3所示。该网络的具体数据处理过程如下。

设IQ序列复数或其频谱复数形式的输入特征矩阵为 $\mathbf{X}=\mathbf{X}_R+j\mathbf{X}_I$ ，维度为 $B\times C\times T\times F\times 2$ ，其中“2”表示实部和虚部， B 、 C 、 T 、 F 分别表示

批尺寸、通道、帧和频率维度。设复卷积核为 $\mathbf{W}=\mathbf{W}_R+j\mathbf{W}_I$ ，复卷积层输出可以表示为：

$$\mathbf{Z}=(\mathbf{W}_R*\mathbf{X}_R-\mathbf{W}_I*\mathbf{X}_I)+j(\mathbf{W}_R*\mathbf{X}_I+\mathbf{W}_I*\mathbf{X}_R) \quad (1)$$

其中， $*$ 表示卷积运算。该输出包含调制信号的幅度和相位信息，使得编解码器结构具有更强的重构调制信号的能力。通过分别处理实部和虚部，复卷积能够更好地分离和处理IQ信号的幅度和相位信息。在每一个复卷积之后，对实部和虚部进行归一化处理，以稳定训练过程，减少梯度爆炸或消失的风险，加快模型收敛速度。最后增加一个ReLU激活函数，以提高模型的非线性映射能力。




图3 复 Conv2d 网络结构

对 STFT 得到的实部和虚部序列沿通道维度使用层归一化后得到张量 $\mathbf{G}$, 表示为:

$$\mathbf{G} = \text{Concat}(\text{Layernorm}(X_R, X_I)) \quad (2)$$

然后, 对 $\mathbf{G}$ 使用 C-MHA, 本文使用复 Conv2d 对输入张量 $\mathbf{G}$ 进行计算, 得到矩阵 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$, C-MHA 的计算过程如下。

(1) 利用复 Conv2d 计算 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 的值, 得到:

$$\mathbf{Q}_i = G_R \otimes W_R^Q - G_I \otimes W_I^Q + j(G_R \otimes W_I^Q + G_I \otimes W_R^Q), i \in [1, \dots, h] \quad (3)$$

$$\mathbf{K}_i = G_R \otimes W_R^K - G_I \otimes W_I^K + j(G_I \otimes W_I^K + G_I \otimes W_R^K), i \in [1, \dots, h] \quad (4)$$

$$\mathbf{V}_i = G_R \otimes W_R^V - G_I \otimes W_I^V + j(G_R \otimes W_I^V + G_I \otimes W_R^V), i \in [1, \dots, h] \quad (5)$$

其中, G_R 和 G_I 分别表示输入的实部和虚部, W_R^Q 、 W_R^K 、 W_R^V 分别表示计算 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 时的复卷积核的实部的权值, W_I^Q 、 W_I^K 、 W_I^V 分别表示复卷积核的虚部的权值, i 表示第 i 个头, h 为头的个数, $\otimes$ 表示卷积。本文提出的 C-MHA 中的所有复卷积的卷积核大小为 3, 步长和填充均为 1, 通道数与输入通道数保持一致。

(2) 使用缩放点积注意力计算第 i 个头的注意力权重。首先计算复值查询矩阵 $\mathbf{Q}_i$ 和键矩阵 $\mathbf{K}_i$ 的复数乘积的结果。经过 softmax 归一化后得到注意力权重:

$$M = \text{ComplexSoftmax}(\mathbf{Q}_i^R \mathbf{K}_i^R - \mathbf{Q}_i^I \mathbf{K}_i^I + j(\mathbf{Q}_i^R \mathbf{K}_i^I + \mathbf{Q}_i^I \mathbf{K}_i^R)) \quad (6)$$

其中, $\mathbf{Q}_i^R$ 和 $\mathbf{Q}_i^I$ 分别表示第 i 个查询的实部和虚部, $\mathbf{K}_i^R$ 和 $\mathbf{K}_i^I$ 分别表示第 i 个键的实部和虚部, $\text{ComplexSoftmax}(\cdot)$ 表示分别将计算得到的实部和虚部进行 softmax 运算, 之后将得到的结果与值矩阵 $\mathbf{V}_i$ 进行复数相乘, 得到第 i 个头的结果:

$$\text{head}_i = M_i^R \mathbf{V}_i^R - M_i^I \mathbf{V}_i^I + j(M_i^R \mathbf{V}_i^I + M_i^I \mathbf{V}_i^R) \quad (7)$$

其中, $\mathbf{V}_i^R$ 和 $\mathbf{V}_i^I$ 分别表示第 i 个键的实部和虚部。最终通过拼接得到的结果表示为:

$$\text{MultiHead} = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \quad (8)$$

为充分获取通道特性的表征能力, 本文将得到的 MultiHead 的实部和虚部再次沿通道维度使用批归一化后得到:

$$\mathbf{T} = \text{Concat}(\text{Layernorm}(\text{Multihead}_R, \text{Multihead}_I)) \quad (9)$$

最后将 $\mathbf{T}$ 经过 C-FSMN 得到最终输出的结果。

C-FSMN 结构中, 首先将输入 $\mathbf{T}$ 经过复 Conv2d 层, 然后将通道数翻倍后分割为两个维度相等的张量 $\mathbf{T}_1$ 、 $\mathbf{T}_2$, 将 $\mathbf{T}_1$ 经过 sigmoid 激活函数后与 $\mathbf{T}_2$ 相乘, 得到输出结果:

$$\text{out} = \text{sigmoid}(\mathbf{T}_1) \odot \mathbf{T}_2 \quad (10)$$

在 WST 网络编码器中, 对于第 i 个模块, 其中间变量 R'_i 和输出 R_{i+1} 可以表示为:

$$\begin{aligned} R'_i &= \text{C-MHA}(\text{LN}(R_i)) + R_i, i=0, \dots, L-1 \\ R_{i+1} &= \text{MLP}(\text{LN}(R'_i)) + R'_i, i=0, \dots, L-1 \end{aligned} \quad (11)$$

其中, C-MHA 表示复多头注意力机制, MLP 表示多层感知机, LN 表示层标准化, L 表示编码器模块数。

1.2 基于局部特征提取的教师网络模块

ShuffleNet V2 是一种面向移动端计算优化的轻量化网络^[14]。ShuffleNet V2 网络结构如图 4 所




图4 ShuffleNet V2网络结构

示。图4(a)为第一种单元模块,该模块对特征图进行通道分割,将其分为两个并行支路,第一个支路为恒等映射,第二个支路依次通过 1×1 的卷积层和 3×3 的卷积层,步长均为1。两个支路完成操作后即进行通道分割和通道混合运算。通道分割使网络在不过度依赖密集卷积或分组卷积的情况下,保持充足的通道和适当的宽度。在卷积操作之间引入通道混合操作,使不同通道之间的信息能够更好地交互和融合,从而提高特征表达能力。通道混合能够在保持参数量不增加的情况下,实现特征的全局交互。图4(b)为第二种单元模块,即下采样模块,该模块可使特征图的宽高减小至其 $1/2$,通道数增加1倍。

为提取调制信号深层语义特征和局部特征,同时降低网络参数数量和计算复杂度,受ShuffleNet V2启发,本文提出基于级联的轻量化残差Shuffle模块的局部特征提取网络,其中轻量化Shuffle残差的两个基本模块(lightweight basic

block, LWBB)如图5所示。

在ResNet34基础上,本文设计了局部特征提取的轻量化教师网络,如图6所示。将调制信号的频谱数据作为输入信号,首先经过卷积层、最大池化层,然后进入本文提出的轻量化残差级联模块,级联规则设计如下。




图5 轻量化Shuffle残差的两个基本模块

(1) 轻量化残差模块1由1个LWBB-2和2个LWBB-1构成。

(2) 轻量化残差模块2由1个LWBB-2和3个LWBB-1构成。

(3) 轻量化残差模块3由1个LWBB-2和4个




图6 局部特征提取的轻量化教师网络

LWBB-1 构成。

接着经过平均池化、全连接层，最终得到调制信号的局部特征。

1.3 局部特征向全局特征引导模块

传统知识蒸馏的目的是将健硕的教师模型的知识转移到表达能力较弱的学生模型中，以实现模型压缩。本文所提出方法的创新之处在于教师模型只起到局部特征引导作用，而不是完全转移教师模型提取的特征。在这种网络结构下，学生模型会通过分类标签的监督实现独立学习，教师模型只是为学生模型提供一些局部性特征的指导。因此，教师模型不会造成强学生模型的性能瓶颈。学生模块中的特征提取过程可定义为：

$$\begin{aligned} S_0 &= \text{PatchEmbedding}(\mathbf{X}), S_0 \in \mathbb{R}^{L \times D} \\ S_i &= \text{TransformerBlock}_i(S_{i-1}), S_i \in \mathbb{R}^{L \times D} \end{aligned} \quad (12)$$

其中， $\mathbf{X}$ 为学生网络的输入向量， S_0 为初始 token 序列， S_i 为 Transformer 编码器第 i 个模块生成的 token 序列， L 为编码器模块数， D 为嵌入维数。教师模块中的特征提取过程可定义为：

$$\begin{aligned} \mathbf{Y}_1 &= f_1(\mathbf{X}), \mathbf{Y}_1 \in \mathbb{R}^{T_1 \times F_1 \times C_1} \\ \mathbf{Y}_i &= f_i(\mathbf{Y}_{i-1}), \mathbf{Y}_i \in \mathbb{R}^{T_i \times F_i \times C_i} \end{aligned} \quad (13)$$

其中， $\mathbf{Y}_i$ 为第 i 层卷积层所提取的特征向量， $f_i(\cdot)$ 表示第 i 层特征提取运算由于 S_i 与 $\mathbf{Y}_i$ 的空间维度、通道维度不同，为了便于优化特征，需要将二者转化为相同尺寸的张量。首先通过 Reshape 操作从学生模型中恢复特征的空间维度，为了更准确地计算距离度量，采用线性上采样来实现大小调整，将两个特征调整为相同的大小，即调整为它们的最大长度和宽度，具体计算过程可定义为：

$$\begin{aligned} \widehat{\mathbf{Y}}_i &= \text{Re shape}(\mathbf{Y}_i), \widehat{\mathbf{Y}}_i \in \mathbb{R}^{T_i \times F_i \times C} \\ \widehat{T} &= \text{Max}(T_i, T_j), \widehat{F} = \text{Max}(F_i, F_j) \\ \mathbf{F}_{\text{stu}}^{\text{spatial}} &= \text{Re size}(\widehat{\mathbf{Y}}_i), \mathbf{F}_{\text{stu}}^{\text{spatial}} \in \mathbb{R}^{\widehat{T} \times \widehat{F} \times C} \\ \mathbf{F}_{\text{teacher}}^{\text{spatial}} &= \text{Re size}(\mathbf{Y}_j), \mathbf{F}_{\text{teacher}}^{\text{spatial}} \in \mathbb{R}^{\widehat{T} \times \widehat{F} \times C_j} \end{aligned} \quad (14)$$

其中， $\mathbf{Y}_j \in \mathbb{R}^{T_j \times F_j \times C_j}$ 表示教师网络第 j 层提取到的

局部特征图谱， T_j 、 F_j 、 C_j 分别表示教师网络第 j 层的时间、频率和通道维度， $\widehat{\mathbf{Y}}_i$ 表示数据重拍后的教师网络特征中间向量， $\widehat{T}$ 和 $\widehat{F}$ 分别表示时间和频率维度的最大值， $\mathbf{F}_{\text{stu}}^{\text{spatial}}$ 和 $\mathbf{F}_{\text{teacher}}^{\text{spatial}}$ 分别为来自学生网络和教师网络经过空间维度变换后的特征向量。

在对齐通道尺寸时选择的方法是对 WST 网络的特征向量进行可学习的逐点线性投影，通道对齐后的学生特征向量 $\mathbf{F}_{\text{stu}}$ 表示为：

$$\mathbf{F}_{\text{stu}} = \text{Linear}(\mathbf{F}_{\text{stu}}^{\text{spatial}}), \mathbf{F}_{\text{stu}}^{\text{CH}} \in \mathbb{R}^{\widehat{T} \times \widehat{F} \times C_j} \quad (15)$$

其中，Linear 指通过 1×1 卷积核实现的可学习线性投影。可学习线性投影不仅能够实现对齐通道维度的目标，同时也可以防止教师网络与学生网络学习相同的特征，避免造成网络训练的性能瓶颈。

假定通过维度变换的局部特征集和全局特征集分别为： $\{\mathbf{F}_{\text{stu}_i} | i=1, 2, \dots, n\}$ 、 $\{\mathbf{F}_{\text{teacher}_j} | j=1, 2, \dots, n\}$ 。在实现特征引导时选择使用 L_2 距离进行度量，其计算方法如下所示：

$$L_g = \sum_{i=1}^k \frac{1}{\widehat{T}_i \cdot \widehat{F}_i} \left\| \mathbf{F}_{\text{stu}} - \mathbf{F}_{\text{teacher}_j} \right\|_F^2 \quad (16)$$

其中， k 为进行特征引导时的特征数量。由此，损失函数可以表示为：

$$L = L_{\text{cls}} + \lambda L_g \quad (17)$$

其中， λ 为超参数，用于平衡模仿和自学习。损失函数由两部分组成，其中 L_{cls} 为分类任务的交叉熵损失函数，目的是使学生网络进行自监督学习，而 L_g 则使学生网络模仿教师网络学习到的特征，以达到更好地融合局部特征的目的。在这样的双任务设置下，学生模型能够以自己的方式进行表征，而不只是复制教师模型学习到的特征。局部特征向全局特征引导模块如图 7 所示。

假设教师模块与学生模块构建的特征集表示为：




图7 局部特征向全局特征引导模块

$$\begin{aligned} S_{\text{VIT}} &= \{T_{i_1}, T_{i_2}, \dots, T_{i_k}\}, T_{i_k} \in R^{L \times C} \\ S_{\text{Res}} &= \{F_{j_1}, F_{j_2}, \dots, F_{j_k}\}, F_{j_k} \in R^{T_{j_k} \times F_{j_k} \times C_{j_k}} \end{aligned} \quad (18)$$

其中, i_k 、 j_k 分别表示 Transformer 编码器的 block 下标序列以及学生模型中的 stages 特征索引。由 C-FSMN 结构可知, 每一个 block 或 stages 提取到的特征都是在上一层特征的基础上产生的, 如当 $j_1, j_2, \dots, j_k$ 单调增加时, 则 $i_1, i_2, \dots, i_k$ 也是单调增加的。为了充分利用学生模型学习到的特征信息, 根据上述规则, 可构建一一对应的特征集:

$$\begin{aligned} j_k &= k \\ i_k &= \left\lfloor (k-1) \cdot \frac{R \cdot N_{\text{stu}} - 1}{N_{\text{teacher}} - 1} \right\rfloor + 1 \end{aligned} \quad (19)$$

其中, k 为被选择的特征索引值, N_{stu} 表示学生模型中的 block 总数, N_{teacher} 表示教师中 stages 的总数, R 为超参数, 表示在执行特征指导时教师模型提取的特征所占的比例。

2 实验结果及分析

2.1 数据集及实验环境

实验采用开源无线数据集 RadioML2016.10a^[11], 数据集中包括 8 种数字调制方式 (BPSK、QPSK、8PSK、QAM16、QAM64、GFSK、CPFSK、PAM4) 以及 3 种模拟调制方式 (WBFM、AM-SSB、

AM-DSB)。数据集 RadioML2016.10a 中有 220 000 个调制信号, 共有 20 种不同的信噪比 (signal-to-noise ratio, SNR), 均匀分布在 -20~18 dB 范围, 间隔为 2 dB, 每种调制方式的每个 SNR 有 1 000 个信号。调制信号的采样率为 200 kHz, 每个样本都是由 128 个采样点组成的, 其数据格式为 2×128 的矩阵, 其中“2”表示复数形式信号的实部及虚部。该数据集添加的是加性高斯白噪声或非平稳噪声。

所有实验均在 Windows 10 环境下实现与调试, 32 GB 内存, 基于 Python 完成识别网络的构建, 采用 Keras 深度学习框架, 实验的 GPU 环境为 NVIDIA GTX1060。

训练和测试网络之前对 IQ 信号进行预处理, 获取 STFT 复数域时频二维数据, 测试集与训练集均采用复数域信号作为输入信号。

2.2 对比实验

2.2.1 高斯白噪声作用下不同调制识别算法性能对比

本节验证测试数据集混合高斯白噪声时的识别性能。将本文方法 LKDN 与 CLDNN^[15]、CGDNet^[16]、MCLDNN^[17] 的调制样式识别方法以及团队前期研究成果 SEBMR^[18] 方法进行识别准确率方面的比较。

CLDNN^[15]: 以 CNN 作为基础网络的识别模型。

CGDNet^[16]: 以 CNN、门控循环单元 (gated recurrent unit, GRU) 和 DNN 为基础网络的识别模型。

MCLDNN^[17]: 以一维卷积、二维卷积和 LSTM 网络作为基础网络的时空特征融合识别网络。

SEBMR^[18]: 以生成对抗网络 (generative adversarial network, GAN) 为基础网络的基于调制信号增强的识别模型。

不同 SNR 下的识别结果对比如图 8 所示。从

图8可以看出,本文方法LKDN在低SNR条件下的识别准确率优于其他方法,表明其对弱信号特征的提取能力更强。本文方法在16 dB时的最大识别准确率达到94.3%,而课题组前期研究成果SEBMR方法在16 dB时准确率为93.7%,本文方法较SEBMR模型在准确率方面提高了0.6个百分点。




图8 不同SNR下的识别结果对比

2.2.2 相同信噪比下混淆矩阵对比

本节将通过CGDNet、MCLDNN以及LKDN这3种算法在SNR为-4 dB时识别混淆矩阵,更直观地对比不同调制方式的分类结果性能。SNR为-4 dB情况下3种调制识别算法的混淆矩阵如图9所示。由图9可知,CGDNet、MCLDNN两种算法的识别错误判断主要集中于QAM16和QAM64之间以及WBFM和AM-DSB之间。低SNR环境

下,QAM16和QAM64之间特征可能会存在一定程度的混淆。本文方法LKDN相较于其他算法在低SNR下有更强的特征提取能力及鲁棒性。

2.2.3 脉冲噪声作用下平均识别准确率对比

将本文方法LKDN与主流深度学习方法CLDNN^[15]、LSTM^[19]、Resnet^[20]、MM-Net^[21]、DGFDNN^[22]、TADCNN^[23]在脉冲噪声的作用下进行平均识别准确率对比,以验证本文方法在脉冲噪声作用下的识别性能的优势。

CLDNN^[15]:以CNN作为基础网络的识别模型。

LSTM^[19]:以LSTM作为基础网络的识别模型。

ResNet^[20]:以残差网络作为基础网络的识别模型。

MM-Net^[21]:以CNN作为基础模型,对IQ信号的增强星座图和高阶累积量进行多模态特征融合的识别模型。

DGFDNN^[22]:以图神经网络为基础,将IQ信号转换为图进行识别的模型。

TADCNN^[23]:以CNN作为基础网络,融合小波去噪算法的识别模型。

脉冲噪声作用下的几种调制识别网络平均识别准确率对比见表1。从表1可以看出,本文方法LKDN的平均识别准确率达到70%,高于其他几种方法,主要原因有:第一,本文方法LKDN




图9 SNR为-4 dB情况下3种调制识别算法的混淆矩阵



对复数域频谱数据进行特征提取,其注意力机制均设计为适合复数域的算法,对全局特征的提取更为准确,因此对非高斯白噪声也有较好的识别作用。第二,局部特征与全局特征并非简单融合,这点与MM-Net多模态的特征融合方法不同,本文方法LKDN能够更高效地融合不同域特征,对信号识别具有精准定位作用。DGFDNN方法利用图理论将调制信号的全局和局部特征融合,识别准确率较本文方法低的原因可能是图理论在高阶调制信号的表征上,对节点和链路表征能力降低。


表1 脉冲噪声作用下的几种调制识别网络平均识别准确率对比

所用网络名称	网络采用方法	平均识别准确率 (SNR: -20~18 dB)
CLDNN ^[11]	基于模型的方法	45.89%
ResNet ^[20]	基于模型的方法	54.85%
LSTM ^[19]	基于模型的方法	56.69%
MM-Net ^[15]	多模态特征提取及融合方法	59.01%
DGFDNN ^[16]	基于图信号处理的方法	63.74%
TADCNN ^[17]	基于信号去噪的方法	62.23%
LKDN	复数域轻量化知识蒸馏	70.66%


2.2.4 小样本数据集对识别准确率影响对比

本文方法LKDN的目标之一是解决小样本数据集限制条件下,基于深度学习的AMR模型识别效率下降的问题。本文提出的教师模型只起到将调制信号的局部特征引导给学生模型的作用,学生模型通过自我学习获得完备的调制信号全局特征,通过局部特征蒸馏使学生模型得到更好的训练,从而使学生模型在小样本训练下依然能获得较高的识别准确率。同前一节对比模型相同,本节在小样本训练数据集前提下对比本文所提方法与CLDNN^[15]、LSTM^[19]、ResNet^[20]、MM-Net^[21]、DGFDNN^[22]、TADCNN^[23]这6种模型的

识别准确率。小样本环境下识别准确率随SNR变化趋势对比如图10所示。当采用3%和5%数据集训练神经网络时,随着SNR的增加,本文方法LKDN的识别准确率分别接近94%和96%。从图10(a)和图10(b)的变化趋势可以看出,当训练样本增加2%时,本文方法的识别准确率增加,这一现象说明本文采用的局部特征引导模块使复数域Transformer网络学习局部特征的能力以及Transformer网络进行全局自学习的能力在样本量增加时提升明显,从而验证了本文方法对小样本训练数据集作用的高效率。



(a) 3% RadioML2016.10a训练样本



(b) 5% RadioML2016.10a训练样本

图10 小样本环境下识别准确率随SNR变化趋势对比

2.2.5 计算复杂度性能对比

将本文方法LKDN与CIST^[11]进行算法复杂度对比,结果见表2。CIST^[11]方法为适用于无线信号的CNN与Transformer融合模型,其网络复杂度取决于两种基础网络的总和。然而,本文所提方法的轻量化教师模型仅起到局部特征迁移至学生网络的作用,即教师模型仅在训练阶段起作用,在推演阶段仅由学生模型完成识别任务,因此,相较CIST^[11]网络其计算复杂度及推演时间都有所降低,可见本文方法更适用于对识别任务具有较高实时性要求的场景。本文的教师模型为轻量化残差结构,参数量约 2.904×10^7 ,仅起到向复数域Transformer学生网络导引局部特征的作用,因此网络参量主要取决于学生模型,教师网络可以实现真正的轻量化而不影响识别效果。每秒浮点操作数(floating-point operations per second, FLOPS)性能对比,本文方法略低于CIST方法,突出了本文方法在计算复杂度方面的优势,原因可能是本文方法的教师模型采用了轻量化模型。

表2 算法复杂度对比结果

方法	参数量/ $\times 10^6$	推演时间/s	性能/GFLOPS
CIST ^[11]	34.90	50.93	0.12
本文方法	29.04	31.91	0.09

2.3 超参数对系统性能影响及消融实验

本节研究超参数对识别性能的影响,并设计消融实验验证局部特征引导模块对识别系统性能的作用。

2.3.1 超参数 λ 对识别结果的影响

为了验证超参数 λ 的影响,实验假设 λ 均匀分布在 $[0,3]$ 区间。超参数 λ 对识别结果的影响对比如图11所示。从图11可以看出,如果 λ 值过小,学生网络的特征模仿能力就会削弱,学生模块中无法充分学习来自教师模块提取到的局部特征信息。当 λ 在合适的取值范围时,本文方法可以有效提升调制识别的性能。




图11 超参数 λ 对识别结果的影响对比

2.3.2 局部特征引导模块对识别结果的影响

局部特征引导消融实验对比如图12所示。图12对以下3种网络进行识别准确率比较:本文提出的完整网络、仅由学生WST构成的特征提取及识别网络、仅由残差网络构成的教师特征提取及识别网络。从图12可以看出,本文方法在识别准确率上优于后两种不具备局部特征引导模块的网络,从而验证了本文提出的局部特征引导模块的贡献,即局部特征引导模块不仅提升了模型对调制信号的识别能力,而且在低SNR情况下识别准确率优于其他两种模型,如在-10 dB信噪比下,本文方法识别准确率为38.6%,明显高于仅由WST构成的学生网络(26.7%)和仅由残差网络构成的教师模型(17.2%),从而验证了局部特征引导模块增强了模型对噪声的鲁棒性。




图12 局部特征引导消融实验对比



3 结束语

基于深度学习的调制识别模型需要大量训练样本才能获得较高的识别准确率,然而,实际场景中调制信号样本量较小,抑制了复杂噪声环境下模型的性能。为此,本文提出了一种基于局部特征引导的轻量化调制识别方法。首先,在训练阶段,本文设计轻量化教师网络来获取含噪调制信号的局部特征,构建局部语义特征优化算法,并将局部知识蒸馏给学生网络;然后,针对调制信号频谱为复数域的特点,设计复数域 Transformer 的全局特征提取模型作为学生网络;最后,由学生网络完成识别任务。实验结果表明,该模型在小样本场景下的识别效率优于现有深度学习模型,并在计算复杂度和实时性方面展现出更优的性能。

参考文献:

- [1] 袁莉芬, 宁曙光, 何怡刚, 等. 基于高阶累积量特征学习的调制识别方法[J]. 系统工程与电子技术, 2019, 41(9): 2122-2131.
YUAN L F, NING S G, HE Y G, et al. Modulation recognition method based on high-order cumulant feature learning[J]. Systems Engineering and Electronics, 2019, 41(9): 2122-2131.
- [2] HUANG S, DAI R, HUANG J J, et al. Automatic modulation classification using gated recurrent residual network[J]. IEEE Internet of Things Journal, 2020, 7(8): 7795-7807.
- [3] 党月芳, 徐启建, 张杰, 等. 高阶累积量和分形理论在信号调制识别中的应用研究[J]. 信号处理, 2013, 29(6): 761-765.
DANG Y F, XU Q J, ZHANG J, et al. Research on modulation classification based on high-order cumulants and fractal theory[J]. Journal of Signal Processing, 2013, 29(6): 761-765.
- [4] 查雄, 彭华, 秦鑫, 等. 基于多端卷积神经网络的调制识别方法[J]. 通信学报, 2019, 40(11): 30-37.
ZHA X, PENG H, QIN X, et al. Modulation recognition method based on multi-inputs convolution neural network[J]. Journal on Communications, 2019, 40(11): 30-37.
- [5] 安泽亮, 张天骐, 马宝泽, 等. 基于一维 CNN 的多入多出 OSTBC 信号协作调制识别[J]. 通信学报, 2021, 42(7): 84-94.
AN Z L, ZHANG T Q, MA B Z, et al. Cooperative modulation recognition based on one-dimensional convolutional neural network for MIMO-OSTBC signal[J]. Journal on Communications, 2021, 42(7): 84-94.
- [6] 司海飞, 胡兴柳, 史震, 等. 基于联合特征参数提取的非合作信号调制识别算法[J]. 通信学报, 2020, 41(7): 172-185.
SI H F, HU X L, SHI Z, et al. Non-cooperative signal modulation recognition algorithm based on joint feature parameter extraction[J]. Journal on Communications, 2020, 41(7): 172-185.
- [7] 王延坤, 郭登科, 马东堂, 等. 基于轻量级 CNN 和信道特征辅助的多用户物理层认证机制[J]. 电信科学, 2023, 39(11): 69-79.
WANG Y K, GUO D K, MA D T, et al. Multi-user physical layer authentication mechanism based on lightweight CNN and channel feature assistance[J]. Telecommunications Science, 2023, 39(11): 69-79.
- [8] CAI J J, GAN F M, CAO X H, et al. Signal modulation classification based on the transformer network[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1348-1357.
- [9] ZHENG Q H, ZHAO P H, WANG H J, et al. Fine-grained modulation classification using multi-scale radio transformer with dual-channel representation[J]. IEEE Communications Letters, 2022, 26(6): 1298-1302.
- [10] MA W X, CAI Z R, WANG C. A transformer and convolution-based learning framework for automatic modulation classification[J]. IEEE Communications Letters, 2024, 28(6): 1392-1396.
- [11] HOU D B, LI L X, LIN W S, et al. CIST: a convolutional transformer framework for automatic modulation recognition by knowledge distillation[J]. IEEE Transactions on Wireless Communications, 2024, 23(7): 8013-8028.
- [12] HAN K, WANG Y H, CHEN H T, et al. A survey on vision transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 87-110.
- [13] 江沸波, 彭于波, 董莉. 面向 6G 的深度图像语义通信模型[J]. 通信学报, 2023, 44(3): 198-208.
JIANG F B, PENG Y B, DONG L. Deep image semantic communication model for 6G[J]. Journal on Communications, 2023, 44(3): 198-208.
- [14] FAN Z M, HU W, GUO H, et al. Hardware and algorithm co-optimization for pointwise convolution and channel shuffle in ShuffleNet V2[C]//Proceedings of the 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Piscataway: IEEE Press, 2021: 3212-3217.
- [15] 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.
- [16] 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.
- [17] 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.
- [18] 程风云, 周金. 信号增强网络驱动的调制识别[J]. 电信科学, 2024, 40(4): 139-150.
- CHENG F Y, ZHOU J. Modulation recognition driven by signal enhancement[J]. Telecommunications Science, 2024, 40(4): 139-150.
- [19] ZHOU Q, JING X J, HE Y, et al. LSTM-based automatic modulation classification[C]//Proceedings of the 2020 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB). Piscataway: IEEE Press, 2020: 1-4.
- [20] WU Z L, ZHOU S Y, YIN Z D, et al. Robust automatic modulation classification under varying noise conditions[J]. IEEE Access, 2017, 5: 19733-19741.
- [21] TRIARIDIS K, DOUMANIDIS C, CHATZIDIAMANTIS N D, et al. MM-Net: a multi-modal approach toward automatic modulation classification[J]. IEEE Communications Letters, 2023, 28(2): 328-331.
- [22] ZHANG Q C, JI H B, LI L, et al. Automatic modulation recognition of unknown interference signals based on graph model[J]. IEEE Wireless Communications Letters, 2024, 13(9): 2317-2321.
- [23] AN T T, LEE B M. Robust automatic modulation classification in low signal to noise ratio[J]. IEEE Access, 2023, 11: 7860-7872.

[作者简介]



王子恒 (2000-), 男, 天津财经大学理工学院硕士生, 主要研究方向为自动调制识别、图神经网络。



张徐 (1999-), 男, 天津财经大学理工学院硕士生, 主要研究方向为自动调制识别、多模态融合。



高硕 (2001-), 男, 天津财经大学理工学院硕士生, 主要研究方向为全局及局部特征协作的识别网络。



周金 (1981-), 女, 博士, 天津财经大学理工学院计算机与信息工程系系主任、硕士生导师、副教授, 主要研究方向为调制识别与频谱感知。