

基于混合注意力原型网络的调制识别算法

庞伊琼, 许华, 蒋磊, 史蕴豪, 彭翔

(空军工程大学 信息与导航学院, 陕西 西安 710077)

摘 要:针对极少量带标签样本条件下的通信信号调制识别难题,提出一种基于混合注意力原型网络的调制识别算法。综合元学习和度量学习的思想,在原型网络框架下通过特征提取模块将信号映射至一个新的特征度量空间,并通过比较该空间内各类原型与查询信号之间的距离确定查询信号调制样式。根据通信信号 IQ 分量的时序特点设计了由卷积神经网络和长短时记忆网络级联的特征提取模块,并引入卷积注意力机制提升关键特征的权重;采用基于 Episode 的训练策略,使算法可泛化到新的信号识别任务中。仿真结果表明,所提算法在每类信号只有 5 个带标签样本(5-way 5-shot)时平均识别率可达 85.68%。

关 键 词:调制识别;原型网络;元学习;度量学习
中图分类号:TN975 **文献标志码:**A **文章编号:**1000-2758(2022)06-1375-10

通信信号调制识别技术是电磁频谱管理、通信侦察、电子对抗等领域的关键技术之一。传统的调制识别方法可分为基于决策论的似然比检验方法(likelihood-based, LB)^[1]和基于特征提取的模式识别方法(feature-based, FB)^[2],但这两类方法都有其局限性。LB 方法的分类模型参数是针对特殊环境设置的,任何微小偏差都会使识别准确率下降;FB 方法依赖于人工提取的特征,对于特征的表征性要求较高。近年来,深度学习技术展现出了强大的数据处理能力,在图像识别、机器翻译、目标检测等领域都有大量研究的成果。2016 年 O'Shea^[3-4]等首次将深度卷积神经网络(convolution neural network, CNN)用于解决调制识别问题,通过与传统 FB 方法对比,证明了利用深度 CNN 对大量密集编码的时序信号直接进行学习是可行的。目前,已经有大量的研究成果^[5-7]将深度学习技术应用于调制识别领域,CNN 与循环神经网络(recurrent neural network, RNN)^[8-10]的组合网络也进一步提高了不同样式调制信号的识别准确率。然而以上基于深度学习的调制识别算法的成功很大程度上依赖于大量的训练数据,但在实际侦察环境中,面对新出现的调制类型,

往往无法获得足够的带标签样本,限制了深度学习在调制识别中的应用。因此需要对小样本条件下的调制识别方法进行深入研究。

数据增强^[11](data augmentation, DA)和迁移学习^[12](transfer learning, TL)是目前针对样本数据量不足的主要解决方法。数据增强借助已有的一些信息生成新数据,扩充训练样本集。文献[13]中通过一个全连接网络对大量无标签数据进行自动标注,当每类信号样本量只有 600 时就能达到 85% 以上的平均识别率。迁移学习通常先通过源数据集对网络模型进行预训练,然后采用目标数据集对网络的顶层进行参数微调,适用于目标数据集与源数据集分布相似的问题。通过使用基于参数的迁移学习方法^[10,14-15]对网络模型进行预优化,减少了对样本量的需求。文献[10]采用预训练过的 AlexNet 网络进行调制识别,在目标数据集每类信号样本量只有 100 时就达到了 89% 以上的识别准确率。上述方法要达到较好的识别性能仍需至少数百个训练样本,然而侦察环境中有时只能获取十几甚至几个信号样本,远不能满足以上 2 种方法对样本量的需求,在这种极少量样本条件下,以上 2 种方法都难以适用。

人类善于用以往学习的经验指导对新事物的学习,例如首次见到老虎的儿童可能会将其描述为一只脑袋上有“王”字的“大花猫”,“大花猫”作为已知概念有助于儿童快速掌握“老虎”这个新事物。受此启发针对元学习的研究应运而生。元学习^[16]也称学会学习,即令模型可利用以往任务中学过的知识或经验去快速学习新的任务,近年来在解决小样本问题方面取得了很大的进展。在训练过程中,元学习可以通过对每一项历史任务的学习,积累一定的知识经验,如网络的参数更新策略^[17]、初始化参数^[18]等,这使得学习新任务时更加容易,从而在极少的训练样本支持下也能保证算法精度。度量学习^[19]在解决小样本问题时将已知样本和待测样本映射到合适的特征度量空间,通过指定的距离函数计算 2 个样本间的距离,从而度量它们之间的相似性。

本文结合度量学习与元学习的思想,提出一种基于混合注意力原型网络的调制识别算法。在原型网络框架下设计了由 CNN 与长短时记忆(long short-term memory, LSTM)网络级联的特征提取网络,同时为进一步提高网络性能,在特征提取网络中引入了卷积自注意力模块(convolutional block attention module, CBAM)。该原型网络通过特征提取网络将带标签信号样本和待识别信号样本映射至统一的特征度量空间,在该空间内将同类信号的均值作为类原型代表该类信号,并通过比较待识别信号与不同类原型之间的欧式距离来确定最终识别结果。为实现元学习目的,算法采用一种基于 Episode 的训练策略优化模型参数,即通过从训练集中随机抽样出大量不同的小样本学习任务来模拟测试场景的识别任务。模型通过训练将学习到一个合适的特征度量空间,进而在面对新类型的调制信号时只需要极少量样本就可以实现快速分类。

1 相关工作

1.1 原型网络

原型网络的基本思想是创建每个类的类原型点,并根据类原型点与测试点之间的欧式距离进行分类。具体地,给定支持集 D^S 和查询集 D^Q ,则类原型为 D^S 中每类信号样本的平均特征向量,其中第 k 类信号的类原型可表示为

$$c_k = \frac{1}{K} \sum_{x_{kn} \in D^S} f_{\varphi}(x_{kn}) \quad (1)$$

式中: f_{φ} 表示特征提取网络; φ 为网络参数; x_{kn} 表示第 k 类的第 n 个样本; K 表示 D^S 中第 k 类样本的样本量。

假设 $\mathbf{x}$ 为来自 D^Q 的待识别样本,通过计算样本 $\mathbf{x}$ 的特征向量与各类原型间的欧式距离,并将所得距离利用 Softmax 函数进行归一化处理,样本 $\mathbf{x}$ 属于第 k 类样本的概率为

$$P_{\varphi}(y = k | \mathbf{x}) = \frac{\exp(-d(f_{\varphi}(\mathbf{x}), c_k))}{\sum_{k'} \exp(-d(f_{\varphi}(\mathbf{x}), c_{k'}))} \quad (2)$$

式中, d 表示一种距离度量函数,一般为欧氏距离。

训练过程中利用负对数概率损失函数 $J(\varphi) = -\ln p_{\varphi}(y = k | \mathbf{x})$ 计算损失,并使用随机梯度下降法最小化训练损失。

1.2 训练策略

本文算法针对极少量带标签样本下的调制识别难题,给定训练集 D^{base} 和测试集 D^{novel} ,其中 D^{base} 内包含多种类型的调制信号,且每类调制信号都拥有大量带标签信号样本; D^{novel} 由支持集 D^S 和查询集 D^Q 组成,即 $D^{\text{novel}} = \{D^S, D^Q\}$, D^S 中每类调制信号含有少量带标签样本, D^Q 中为未知的待识别信号样本。测试集中查询集 D^Q 和支持集 D^S 的样本标签空间相同且与训练集 D^{base} 的样本标签空间不相交。在测试时网络模型需要在只有 D^S 中少量带标签样本的条件下识别出 D^Q 中未知信号的调制样式,即 D^S 和 D^Q 组成一个识别任务。若 D^S 中包含 C 类调制信号,且每类信号都拥有 K 个样本,将此类任务称为 C -way K -shot 任务。

为充分利用训练集内的带标签样本,采用一种基于 Episode 的训练策略,即在训练时模拟测试过程中的小样本设置,从训练集中采样多个小样本的任务对网络进行优化,使训练好的模型可以泛化到测试环境中。具体地,针对 C -way K -shot 任务,在每次训练迭代过程中,网络模型都从 D^{base} 中随机地选择 C 种类别信号组成样本集 D^V ,然后从 D^V 的每类信号中随机抽取 K 个样本组成元支持集 D^{TS} , D^{TS} 模拟测试阶段的支持集 D^S ,最后再从集合 $D^V - D^{\text{TS}}$ (D^V 中不属于 D^{TS} 的样本)中的每类信号中随机抽取 N_Q 个样本组成元查询集 D^{TQ} , D^{TQ} 用于模拟测试阶段的查询集 D^Q 。通过这种训练策略优化得到的模型对测试阶段新类型的信号样本具有良好的泛

化性能。训练过程中损失函数 $J(\varphi)$ 的迭代计算伪代码如表 1 所示。

表 1 训练伪代码


输入:训练集 $\boldsymbol{D}^{\text{base}} = \{(\boldsymbol{x}_i, y_i)\}_{i=1}^n, y_i \in \{1, 2, \cdots, N\}$, 其中 $\boldsymbol{x}_i$ 表示信号样本, y_i 表示样本标签
过程:
step 1: 从含有 N 个类别的 $\boldsymbol{D}^{\text{base}}$ 中随机选取 C 类样本组成样本集 $\boldsymbol{D}^{\text{v}}$ 用于构建 $\boldsymbol{D}^{\text{TS}}$ 和 $\boldsymbol{D}^{\text{TQ}}$
step 2: For k in $\{1, \cdots, N_C\}$ do
step 3: 从 $\boldsymbol{D}^{\text{v}}$ 中的第 k 类样本中随机抽取 K 个样本组成 $\boldsymbol{D}^{\text{TS}k}$
step 4: 从 $\boldsymbol{D}^{\text{v}} - \boldsymbol{D}^{\text{TS}k}$ 中的第 k 类样本中随机抽取 N_Q 个样本组成 $\boldsymbol{D}^{\text{TQ}k}$
Step 5: $\boldsymbol{D}^{\text{TS}} \leftarrow \boldsymbol{D}^{\text{TS}k}$
Step 6: $\boldsymbol{D}^{\text{TQ}} \leftarrow \boldsymbol{D}^{\text{TQ}k}$
Step 7: $c_k \leftarrow \frac{1}{K} \sum_{(\boldsymbol{x}_i, y_i) \in \boldsymbol{D}^{\text{TS}k}} f_{\varphi}(\boldsymbol{x}_i)$
Step 8: End for
Step 9: $J(\varphi) = 0$
Step 10: For k in $\{1, \cdots, N_C\}$ do
Step 11: For $(\boldsymbol{x}, y)$ in $\boldsymbol{D}^{\text{TQ}k}$ do
Step 12: $J(\varphi) \leftarrow J(\varphi) + \frac{1}{N_C N_Q} \left[d(f_{\varphi}(\boldsymbol{x}), c_k) + \ln \sum_{k'} \exp(-d(f_{\varphi}(\boldsymbol{x}), c_{k'})) \right]$
Step 13: End for
Step 14: End for
输出:训练损失 $J(\varphi)$

2 基于混合注意力原型网络的调制识别算法

2.1 算法模型

本文算法整体框图如图 1 所示,算法模型可分为 2 个模块:特征提取模块和类原型度量模块。为提取到信号样本更具代表性的特征,其中特征提取

模块设计为由 CNN 和 LSTM 级联的特征提取网络 (CLN),CLN 可充分提取信号不同维度的特征;同时通过在 CLN 中引入 CBAM 使得网络在特征提取过程中更加关注对分类有益的特征。模型通过特征提取模块将信号样本映射至统一的特征度量空间,由类原型模块进行距离度量并确定待识别信号的调制样式。



a) 训练过程




图 1 混合注意力原型网络算法整体框图

本文算法的实现可分为训练和测试 2 个过程。根据元学习思想,算法在训练过程中采用一种基于 Episode 的训练策略,该策略不针对特定信号的识别进行训练,而是利用在每次训练迭代过程中随机选取的几类信号组成识别任务去训练网络,使网络学习如何将原始信号转化为更易于分类的表示,即在训练过程中学习分类的经验。通过大量不同识别任务优化得到的模型对新任务具有良好的泛化性能,根据以往的经验可在测试过程中只有极少量带标签样本条件下实现对新类信号的识别。

2.2 CLN-CBAM 特征提取模块

针对信号序列内的时序特征,本文设计由 CNN 和 LSTM 搭建的特征提取模块 CLN,可充分提取信号不同维度的特征,同时在 CLN 网络中引入 CBAM 模块,组成 CLN-CBAM 特征提取模块,其中 CBAM 模块可以从通道域和空间域 2 个维度建立特征权重向量,使网络更加关注对分类有益的特征。

2.2.1 卷积注意力模块

CBAM 注意力模块是一种简单且高效的注意力模块,其是轻量级的通用模块,运算开销很小,故可集成到任何前馈 CNN 架构中,并与基础卷积网络一起进行端到端的训练,CBAM 的整体结构如图 2 所示。CBAM 是一种结合通道 (channel) 和空间 (spatial) 的注意力机制,每个子注意力模块通过增加关键特征的权重比值,抑制冗余特征,提高深度神经网络的性能。通道注意力模块和空间注意力模块如图 3~4 所示。




图 2 CBMA 注意机制整体结构




图 3 通道注意力模块




图 4 空间注意力模块

2.2.2 CLN-CBAM 特征提取网络

本文所提特征提取网络 CLN-CBAM 结合了不同神经网络的性能优势,并引入了卷积注意力模块,有助于原型网络算法识别准确率提升。CLN-CBAM 网络中包含 5 个卷积块,卷积块由 1 个卷积层、1 个批量归一化层、1 个 ReLU 激活函数和 1 个最大池化层组成。为防止网络在训练过程中出现过拟合,在最大池化层后设置 1 个 Dropout 层,并在每个卷积块后插入 CBAM 模块。本文仿真所用数据为通信信号的 I、Q 2 路分量,数据格式为[1 024, 2],基于此卷积核大小分别设置 7×2,5×2,3×2,2×1,2×1,卷积核数量分别为 16,32,64,128,256,最大池化层核大小都设置为 3×1。卷积块完成特征提取后,将特征序列展开成一维数据送入全连接层,最后再通过 LSTM 输出特征。网络结构如图 5 所示。




图 5 CLN-CBAM 结构图

2.3 算法实现流程

本文算法利用训练集模拟测试阶段的识别场景,训练完成的网络可泛化到测试过程的 C -way K -shot 任务,具体实现步骤如下:

步骤 1 信号样本采样。从训练集中随机选取 C 类样本,并从每类样本中随机抽取 K 个样本组成元支持集 D^{TS} ,再从每类剩余样本中随机抽取 N_Q 个样本组成元查询集 D^{TQ} 。

步骤 2 特征映射。由 CLN-CBAM 特征提取网络将 D^{TS} 和 D^{TQ} 中的样本映射到低维的特征度量空间,得到 D^{TS} 和 D^{TQ} 中信号样本的特征向量。

步骤 3 类原型度量。将 D^{TS} 中每类信号的平均特征向量作为类原型,并计算 D^{TQ} 中样本特征向量与各个类原型的欧氏距离,将欧氏距离输入 Softmax 函数,计算查询样本属于每个类的概率,由负对数概率损失函数计算损失对网络进行训练。

步骤 4 由测试集(测试集与训练集标签空间不相交)对网络进行测试。将含有少量带标签信号样本的支持集 D^S 和待识别信号样本送入训练好的特征提取网络,由类原型度量模块确定待识别信号的调制样式。

3 实验仿真与结果分析

实验选取 RadioML2018.01A 公开调制信号集^[4]验证本文所提算法性能。该信号集由 24 种调制信号组成,各个信号包括 I、Q 2 路数据,数据格式为 $[1\ 024, 2]$,信噪比分布从 $-20 \sim 30$ dB,间隔为

2 dB。本文算法训练和测试阶段所用信号样本的标签空间不相交,随机选取 14 种调制信号作为训练集,另外 10 种作为测试集,在信噪比为 $-20 \sim 30$ dB 的条件下进行实验仿真。训练集、测试集调制样式如表 2 所示。

表 2 实验数据集

数据来源	调制
训练集	32PSK、16APSK、32QAM、FM、GMSK、32APSK、
	OQPSK、8ASK、BPSK、8PSK、AM-SSB-SC、
测试集	4ASK、16PSK、64APSK
	128QAM、128APSK、AM-DSB-SC、AM-SSB-WC、
测试集	64QAM、QPSK、256QAM、AM-DSB-WC、
	OOK、16QAM

实验模型在 python 深度学习神经网络 pytorch 框架下进行搭建,硬件平台为基于 windows 7、32 GB 内存、NVIDIA P4000 显卡的计算机。实验模型采用端到端的训练方式,Adam 优化网络,初始学习率为 0.001,测试阶段从测试集中采样 1 000 组相互独立测试任务来计算算法的识别准确率,并采用所有测试任务识别准确率的平均值来表示算法最终的识别性能。

3.1 支持集样本量(K 值)对识别性能影响

为验证元支持集/支持集内每类信号样本量(K 值)对本文算法识别准确率的影响,本节在 K 值分别为 1、5、10、15、20 时进行对比实验。网络训练集和测试集如表 2 所示,特征提取模块为 CLN-CBAM 网络。本节仿真实验针对 5 类调制信号的识别任务,即 5-way K -shot 任务,元查询集/查询集样本量 N_Q 设置为 10。不同样本量下算法测试识别准确率随信噪比的变化情况如图 6 所示。




图 6 不同 K 值下算法识别准确率变化曲线

本文所提原型网络通过比较待测信号样本特征

向量与支持集内各类信号类原型间的距离确定识别结果,信号类原型取支持集内各类调制信号样本特征向量的平均,故改变支持集中信号样本量(K 值)会对算法的识别准确率产生影响。如图 6 所示,随着支持集内信号样本量 K 的增加,算法的测试识别准确率也在进一步提升。这是由于在特征度量空间中支持集内的每类信号都存在一个类原型点,各类原型点间相互远离,原型网络将每类信号样本特征向量的平均值作为该类信号的类原型估计点,随着样本量 K 值增加,会减少真实类原型点与类原型估计点间的偏差,降低信号识别时产生的期望风险,有助于提升算法的识别准确率。从图 6 可以看出,当支持集内信号样本量 K 较小时, K 值的增加对网络识别性能提升有较大影响,然而当 K 值大于 5 后,增加样本量对算法识别性能的提升效果趋缓。例如在测试信号信噪比为 20 dB 时,当支持集内每类信号样本量 K 值从 1 增加到 5 时,算法的识别准确率提升了 9.01%,但当 K 值从 5 增加到 10 时,算法识别准确率仅提升了 1.23%,这表明本文算法更适宜解决带标签信号样本只有几个的调制识别问题。

3.2 样本类别量(C 值)对识别性能的影响

在支持集内每类信号包含 5 个样本时,验证样本类别量 C 值对于网络识别准确率的影响,设置任务支持集内信号类别量 C 为 3,5,10,元查询集/查询集内信号样本量 N_q 值为 15,当算法特征提取模块为 CLN-CBAM,对比 C -way 5-shot 测试任务平均识别准确率,不同类别量(C 值)下信号识别率随信噪比变化曲线如图 7 所示。




图 7 不同 C 值下算法识别准确率变化曲线

从图中可以看出随着支持集样本类别量 C 值增加,网络识别性能下降。当测试任务支持集内包含 10 类调制信号样本时,在信号信噪比为 20 dB 时算法识别精度只有 75.52%,相较于支持集中含 3 类

调制信号时减少了 15.45%。这是由于支持集内样本类别的增多会增加网络模型的学习难度,提升在度量空间判断 2 个信号特征相似性的复杂度,使得网络训练不易收敛,进而导致算法识别性能下降。

3.3 不同特征提取网络下算法识别性能分析

为验证本文所提 CLN-CBAM 特征提取网络对于本文原型网络算法识别性能的影响,实验设置 CLN、CLN-CBAM、ConvNet、Resnet18^[20]、Resnet18-CBAM、Resnet34^[20] 6 种不同网络作为本文算法模型的特征提取模块。采用表 2 所示数据集,在 5-way 5-shot 任务下进行训练测试,元查询集/查询集样本量 N_q 设置为 15,不同特征提取模块下实验测试平均识别准确率随不同信噪比水平的变化如图 8 所示。采用不同特征提取网络所需训练的网络参数量以及训练时间如表 3 所示。




图 8 不同特征提取网络下原型网络的识别性能

表 3 网络参数量和训练时间

特征提取网络	网络参数量	训练时间/s
CLN	5 377 525	987
CLN-CBAM	5 389 929	1 023
ConvNet	17 270 60	304
Resnet18	11 175 370	1 201
Resnet18-CBAM	11 267 050	2 180
Resnet34	21 283 530	2 481

由图 8 可得,当信噪比大于 10 dB 时,采用本文所提的 CLN-CBAM 特征提取网络的算法识别性能最优。主要原因在于本文所提特征网络结合了 CNN 与 LSTM 的性能优势,可同时提取到调制信号的空间特征与时序特征,对比 ConvNet 特征提取网络,采用 CLN 特征提取网络的算法识别准确率在信

噪比为 20 dB 时提升了 4.67%,同时为使所提特征向量更具代表性,本文在 CLN 特征提取网络中引入了 CBAM 模块,使得网络在提取信号样本特征时能够更加关注对分类有益的部分,实验结果表明在测试信号信噪比为 20 dB 时,CLN-CBAM 特征提取网络算法针对 5-way 5-shot 测试任务的平均识别准确率为 85.68%,相较于 CLN 特征提取网络下的算法识别准确率提升了 5.01%。由表 3 可知,对比 Resnet18、Resnet18-CBAM、Resnet34 特征提取网络,CLN-CBAM 所需训练的网络参数和训练时长都更少,但采用 CLN-CBAM 特征提取网络的算法识别性能更优,这是由于 Resnet 网络只能提取信号样本的空间特征,特征向量代表性较低,增加特征提取网络复杂度无法有效提升算法的识别性能。

3.4 不同小样本学习算法性能对比分析

为验证本文所提算法相较于其他小样本调制识别算法的性能优势,本节选取基于数据增强 (data augmentation, DA) 和基于迁移学习 (transfer learning, TL) 的小样本调制识别算法以及另外 3 种元学习算法进行对比实验,分别为关系网络 (relation network, RN)^[21]、匹配网络 (Matching Networks, MN)^[22] 以及模型无关元学习 (model agnostic meta learning, MAML)^[23]。选取 16APSK、32QAM、FM、AM-SSB-SC、4ASK 5 类调制信号组成信号样本集,为保证实验结果的可靠性,将该样本集作为 DA 和 TL 算法的数据集以及本文算法和 RN、MN、MAML 算法的测试集,将其余 19 类调制信号用于元学习算法的训练阶段。当测试信号信噪比为 20 dB 时,不同算法下的最高识别准确率以及实现最高识别准确率时所需样本量如表 4 所示。本文算法与对比算法针对 5 类调制信号在训练/支持集每类信号样本量为“5-shot”时的测试识别准确率随信噪比的变化情况如图 9 所示。

表 4 不同小样本调制识别算法性能对比

算法模型	训练/支持集每类 信号所需样本量	最高识别 准确率/%
DA	100	89.32
TL	700	91.33
RN	20	78.16
MN	20	77.02
MAML	20	66.43
本文算法	20	87.33




图 9 不同小样本调制识别算法识别准确率对比

从图 9 中可以看出,TL 和 DA 算法的识别性能明显低于 4 种元学习算法,相较于本文算法,当测试信号信噪比为 20 dB 时,TL 和 DA 算法在“5-shot”时识别准确率分别降低了 37.81%和 53.3%,主要原因在于 TL 和 DA 算法在信号样本量只有几个时训练无法收敛,从而导致算法识别性能的显著下降。由表 4 可知,TL 和 DA 算法要实现最优的识别性能至少需要数百个训练样本,无法解决只有几个带标签信号样本条件下的调制识别问题。同时对比本文算法与 RN、MN 以及 MAML 3 种元学习算法,本文算法取得了最优的识别效果,分析其原因在于,RN 和 MN 方法属于基于度量的元学习方法,不同之处在于,RN 通过神经网络度量样本间的相似度,MN 采用余弦距离度量样本间的相似度,而本文原型网络算法采用欧氏距离度量样本间的相似度,欧氏距离属于 Bregman 散度,利用 Bregman 散度的性质^[19],可使不同类调制信号样本集合在特征度量空间内的差异性最大,故可取得更好的识别效果。MAML 通过对多个任务的学习为网络寻找到一个最优的初始化参数,使得网络在面对新类别信号的识别任务时能够快速适应,但 MAML 算法在面对新类信号识别任务时需要对网络进行微调,由于样本量较少,难以适用参数量较大的网络,这限制了网络识别性能的进一步提升。从实验结果可知,在测试信号信噪比为 20 dB 时,本文算法相较于 MAML 算法的识别准确率在样本量为“5-shot”下提高了 29.97%和 18.45%。

3.5 数据集样本类别对网络的影响

本文算法仿真实验所用数据集由 24 类调制信号组成,其中包含 19 类数字调制信号和 5 类模拟调制信号,数字调制信号又分为调幅、调相、调频等多种不同调制信号,不同类的调制信号具有不同的特

点,识别难度也相对不同。由于本文所提原型网络算法在训练阶段和测试阶段所用信号样本的标签空间不相交,故训练集和测试集中样本类别的选取也会对网络识别准确率产生一定影响。根据各类调制

信号的特点将数据集划分为 4 种不同分集进行对比实验,为使实验结果更具代表性,每次划分数据集都选取 5 类调制信号组成测试集,10 类调制信号组成训练集,具体划分方式如表 5 所示。

表 5 实验数据集分集

分集	训练集	测试集
1	4ASK、8ASK、QPSK、8PSK、32PSK、32APSK、128APSK、32QAM、64QAM、256QAM	OOK、BPSK、16APSK、16QAM、GMSK
2	OOK、4ASK、BPSK、8PSK、16PSK、32PSK、64APSK、64QAM、16QAM、128APSK	FM、AM-SSB-SC、AM-DSB-SC、AM-SSB-WC、AM-DSB-WC
3	OOK、4ASK、8ASK、16APSK、32APSK、64APSK、32QAM、128QAM、64QAM、16QAM	BPSK、QPSK、8PSK、16PSK、32PSK
4	OOK、8ASK、16PSK、16APSK、32APSK、AM-SSB-SC、AM-DSB-WC、128APSK、32QAM、GMSK	4ASK、8PSK、FM、256QAM、32APSK

本次实验设置特征提取模块为 CLN-CBAM 网络,验证在 5-way 5-shot 学习任务下测试集的识别准确率,当信噪比为 20 dB 时,实验结果如图 10 所示,4 种不同分集的识别准确率分别为 92.67%,82.63%,79.46%,82.78%,不同分集之间识别准确率有一定差异。由表 5 可知,分集 1,2,3 的训练集都是由数字调制信号组成,而分集 3 的测试识别准确率最低。分集 3 的测试集由 5 种不同进制的相移键控(phase shift keying, PSK)调制信号组成,不同进制 PSK 信号间相似度较高,容易造成混淆,提高了识别难度。分集 1 的测试集是由不同类数字调制信号组成,各类信号相似度较低,且与训练集中的数字调制信号有一定相似度,故分集 1 的测试识别准确率最高。分集 2 测试集都为模拟调制信号,测试识别准确率相较于分集 1 有明显下降,但由于不同模拟调制信号特征间有一定差异,故相较于分集 3 测试识别准确率有一定提高。分集 4 由随机挑选出来的调制信号组成,训练集与测试集都包含数字调制信号与模拟调制信号,在信噪比 20 dB 时,测试识别准确率可达 82.78%。由实验结果可知,本文所提算法可适应训练集与测试集样本类别不同的场合,特别地,当训练集与测试集样本类别差距较大时,该算法也能较好完成小样本的调制识别任务,并且使用样本类别丰富度更高的训练集有利于识别准确率的提高。




图 10 数据集样本对识别准确率的影响

4 结 论

本文针对极少量带标签样本条件下的调制识别难题,结合度量学习与元学习的思想,提出一种混合注意力原型网络的调制识别算法。根据调制信号样本特征设计了由 CNN 与 LSTM 级联的 CLN 特征提取网络,并在当中引入 CBAM 模块,可使网络提取到的信号特征更具代表性。实验结果验证了本文所设计的 CLN-CBAM 特征提取网络可进一步提高原型网络算法的识别性能。同时为更好地从少量数据中学习,算法以元学习的方式进行训练,即利用训练集模拟测试时的识别场景,学习信号分类的经验。训练完成的网络模型具有很好的泛化性能,在测试时面对新类信号,即使只有几个带标签样本也能保证算法的识别性能算法。仿真实验结果进一步验证了本文算法解决小样本调制识别问题的可行性。本

文算法信号识别率还有一定提升空间,后续将在此 基础上进行更深入的研究。

参考文献:

- [1] MILCZAREK H, LESNIK C, DJUROVIC L, et al. Estimating the instantaneous frequency of linear and nonlinear frequency modulated radar signals-a comparative study[J]. *Sensors*, 2021, 21(8): 2840
- [2] JIANG Xinrui, CHEN Hui, ZHAO Yaodong, et al. Automatic modulation recognition based on mixed-type features[J]. *International Journal of Electronics*, 2021, 108(1): 105-114
- [3] O'SHEA T J, CORGAN J, and CLANCY T C. Convolutional radio modulation recognition networks[C] // 17th International Conference on Engineering Applications of Neural Networks, Aberdeen, 2016
- [4] 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 Process*, 2018, 12(1): 168-179
- [5] 白芃远, 许华, 孙莉. 基于卷积神经网络与时频图纹理信息的信号调制方式分类方法[J]. *西北工业大学学报*, 2019, 37(4): 816-823
BAI Pengyuan, XU Hua, SUN Li. A recognition algorithm for modulation schemes by convolution neural network and spectrum texture[J]. *Journal of Northwestern Polytechnical University*, 2019, 37(4): 816-823 (in Chinese)
- [6] KRZYSTON J, BHATTACHARJEA R, STARK A. Complex-valued convolutions for modulation recognition using deep learning [C] // 2020 IEEE International Conference on Communications Workshops, Dublin, Ireland, 2020
- [7] LIANG Zhi, TAO Mingliang, WANG Ling, et al. Automatic modulation recognition based on adaptive attention mechanism and ResNext WSL model[J]. *IEEE Communications Letters*, 2021, 25(9): 2953-2957
- [8] LIU Kai, GAO Wanjun, HUANG Qinghua. Automatic modulation recognition based on a DCN-BiLSTM network[J]. *Sensors*, 2021, 21(5): 1577
- [9] 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
- [10] LI Dongjin, YANG Ruijuan, LI Xiaobai, et al. Radar signal modulation recognition based on deep joint learning[J]. *IEEE Access*, 2020(8): 48515-48528
- [11] ROYLE J A, DORAZIO R M, LINK W A. Analysis of multinomial models with unknown index using data augmentation[J]. *Journal of Computational and Graphical Statistics*, 2007, 16(1): 67-85
- [12] YOSINSKI J, CLUNE J, BENGIO Y, et al. How transferable are features in deep neural networks? [C] // 28th Conference on Neural Information Processing Systems, Montreal, Canada, 2014
- [13] 史蕴豪, 许华, 刘英辉. 一种基于伪标签半监督学习的小样本调制识别算法[J]. *西北工业大学学报*, 2020, 38(5): 1074-1083
SHI Yunhao, XU Hua, LIU Yinghui. A few-shot modulation recognition method based on pseudo-label semi-supervised learning [J]. *Journal of Northwestern Polytechnical University*, 2020, 38(5): 1074-1083 (in Chinese)
- [14] MENG Fan, CHEN Peng, WU Lenan, et al. Automatic modulation classification: a deep learning enabled approach[J]. *IEEE Trans on Vehicular Technology*, 2018, 67(11): 10760-10772
- [15] YU Xu, LI Dezhi, WANG Zhenyong, et al. A deep learning method based on convolutional neural network for automatic modulation classification of wireless signals[J]. *Wireless Networks*, 2019, 25(7): 3735-3746
- [16] HUISMAN M, VAN RIJN J N, PLAAT A. A survey of deep meta-learning[J]. *Artificial Intelligence Review*, 2021, 54(6): 1-59
- [17] CHEN Yutian, HOFFMAN M W, COLMENAREJO S G, et al. Learning to learn by gradient descent by gradient descent[C] // 34th International Conference on Machine Learning, Sydney, Australia, 2017
- [18] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C] // International Conference on Machine Learning, PMLR, 2017
- [19] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C] // 31st Annual Conference on Neural Information Processing Systems, Long Beach, CA, 2017
- [20] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference

on Computer Vision and Pattern Recognition, Las Vegas, US, 2016

- [21] ZHANG Zilin, LI Yan, GAO Meiguo. Few-shot learning of signal modulation recognition based on attention relation network[C] //2020 28th European Signal Processing Conference, 2021
- [22] VINYS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C] //30th Conference on Neural Information Processing Systems, Barcelona Spain, 2016
- [23] YANG Ning, ZHANG Bangning, DING Guoru, et al. Specific emitter identification with limited samples: a model-agnostic meta-learning approach[J]. IEEE Communications Letters, 2022, 26(2): 345-349

Modulation recognition algorithm based on mixed attention prototype network

PANG Yiqiong, XU Hua, JIANG Lei, SHI Yunhao, PENG Xiang

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: A modulation recognition algorithm based on mixed attention prototype network is proposed to solve the modulation recognition problem of communication signals with very few labeled samples. Combining the ideas of meta learning and metric learning, the algorithm maps the signal to a new feature metric space by feature extraction module in the prototype network framework and determines the modulation pattern of the query signal by comparing the distance between each prototype and the query signal in the space. According to the time sequence characteristics of communication signal IQ components, a feature extraction module is designed which is cascaded by the convolutional neural network and long-short term memory network, and the convolutional attention mechanism is introduced to improve the weight of key features. The training strategy based on Episode is used to generalize the algorithm to new signal recognition tasks. The simulation results show that the average recognition rate of the present algorithm can reach 85.68% when there are only 5 labeled samples (5-way 5-shot) for each type of signal.

Keywords: modulation recognition; prototype network; meta learning; metric learning

引用格式: 庞伊琼, 许华, 蒋磊, 等. 基于混合注意力原型网络的调制识别算法[J]. 西北工业大学学报, 2022, 40(6): 1375-1384

PANG Yiqiong, XU Hua, JIANG Lei, et al. Modulation recognition algorithm based on mixed attention prototype network [J]. Journal of Northwestern Polytechnical University, 2022, 40(6): 1375-1384 (in Chinese)