

基于元学习的小样本调制识别算法

庞伊琼, 许华, 蒋磊, 史蕴豪

(空军工程大学信息与导航学院, 西安, 710077)

摘要 针对基于深度学习的调制识别算法对带标签样本需求量过大的问题,采用基于元学习思想的多任务训练策略,通过大量不同的任务训练网络来获取一种跨任务的信号识别能力,使得网络在面对新信号类别时仅需少量样本就能快速适应。为更全面地提取信号样本的特征,设计了一种由卷积神经网络和长短时记忆网络并联组成的混合特征并行网络,通过度量样本特征向量间距离的方式完成识别任务;并引入可同时考虑信号类内与类间距离的联合损失函数,以使信号样本特征在度量空间内的分布能更加紧凑,从而实现更高效的相似性比对。实验结果表明,该算法在仅有5个带标签信号样本条件下最高可达到88.43%的识别准确率。

关键词 调制识别;元学习;小样本;联合损失函数

DOI 10.3969/j.issn.2097-1915.2022.05.012

中图分类号 TN 975 **文献标志码** A **文章编号** 2097-1915(2022)05-0077-06

A Few-Shot Modulation Recognition Algorithm Based on Meta-Learning

PANG Yiqiong, XU Hua, JIANG Lei, SHI Yunhao

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

Abstract Aimed at the problem that the demands of the modulation recognition algorithm based on deep learning for the labeled samples are too heavy, a multi-task training strategy based on meta learning is adopted. This strategy obtains a ability of cross task signal recognition through a large number of different task training networks to make the network quickly adapt to new signal categories with a small number of samples. In order to extract the features from signal samples more comprehensively, a hybrid parallel feature extraction network is designed, completing the recognition task by measuring the distance between sample feature vectors. And a joint loss function is introduced to take both inter-class and intra-class distance into account, making the samples realize comparison more efficiently after feature extraction. The experimental results show that the algorithm can achieve a highest recognition accuracy of 88.43% when there are only five labeled signal samples.

Key words modulation recognition; meta-learning; few-shot; joint loss function

近年来,以深度学习方法为基础的新一代通信信号调制识别技术成为了国内外的研究热点。2016

年 O'Shea^[1] 等人利用卷积神经网络(convolution neural network, CNN)提取信号特征,证明了用深

收稿日期: 2022-04-29

基金项目: 国家自然科学基金(61906156)

作者简介: 庞伊琼(1998—),女,陕西宝鸡人,硕士生,研究方向为通信信号识别。E-mail: pyq980321@163.com

引用格式: 庞伊琼,许华,蒋磊,等. 基于元学习的小样本调制识别算法[J]. 空军工程大学学报, 2022, 23(5): 77-82. PANG Yiqiong, XU Hua, JIANG Lei, et al. Few-Shot Modulation Recognition Algorithm Based on Meta-Learning [J]. Journal of Air Force Engineering University, 2022, 23(5): 77-82.

度 CNN 直接学习密集编码的时序信号是可行的, 2018 年又进一步提出了基于 VGG-Net 和 ResNet 的信号识别模型^[2]。文献[3]通过 ResNet50 和 Inception V2 网络提取信号星座密度矩阵特征, 在样本量达到 2 000 以上时对低信噪比信号实现准确识别。文献[4]提出一种基于长短时记忆网络(long short term memory, LSTM)的去噪自编码器, 通过最小化重构损失与分类损失的和来拟合网络, 在 RadioML 数据集上取得了良好的效果。以上基于深度学习的调制识别方法实现了更高的识别准确率, 但深度学习方法的成功都需要数千个以上的训练样本。然而实际应用中受各类条件制约, 有时只能获取几个信号样本, 因此针对极少量样本条件下调制识别方法的研究工作已逐渐被越来越多的人关注。

目前针对基于深度学习的调制识别方法所需训练样本量较大的问题, 采用的解决方案有半监督学习和数据增强。半监督学习^[5]将大量无标签信号样本引入到网络的训练过程中, 有效降低了网络对有标签信号样本的需求。数据增强^[6]利用已有数据生成新数据从而扩充训练样本集^[7]。虽然以上两种方法在很大程度上降低了深度学习技术所需的训练样本量, 但仍需至少几百个信号样本才能保证算法识别性能, 对仅有几个带标签信号样本的调制识别问题, 以上两种方法均难以解决, 本文的“小样本”特指标签样本量仅为个位数的极端小样本条件。元学习^[8]为此提供了新的解决思路, 其通过提高网络模型对新任务的适应性来解决小样本问题。元学习模型在训练阶段学习大量不同任务以积累相关经验,

从而测试时在仅有几个带标签样本时, 也能很快地适应对新任务的学习。元学习方法包括学习度量和学习初始化, 其中学习度量的目标是得到一个合适的度量空间, 通过比较样本特征间的距离完成分类^[9-11]; 学习初始化^[12]通过学习相关任务以获取更优的网络初始化参数, 面对新任务只需少量样本微调网络就可以达到与一般深度学习模型在大量训练数据下相当的性能。

针对待测信号仅有几个带标签样本的小样本调制识别问题, 本文采用学习度量的算法框架, 提出了一种基于元学习的小样本调制识别模型, 该模型通过基于任务的策略训练网络学习一种合适的映射关系, 以实现信号样本在特征度量空间高效对比, 在面对新类信号的识别任务时, 在少量样本条件下也能实现快速准确识别, 从而解决训练样本量严重不足的小样本问题。

1 识别模型

如图 1 所示, 调制信号识别模型分为特征提取和类原型度量两个模块。本文主要针对包含 5 种调制类别的测试识别任务, 因此每次训练迭代都会首先从训练集中随机采样调制信号训练任务, 由特征提取模块将该任务元查询集内的待测调制信号样本与元支持集内的少量带标签调制信号样本映射至同一度量空间, 通过类原型度量模块计算各类调制信号的原型, 并比较待测信号样本与各类原型间的距离, 从而完成信号分类, 根据分类结果计算识别损失来更新网络参数。

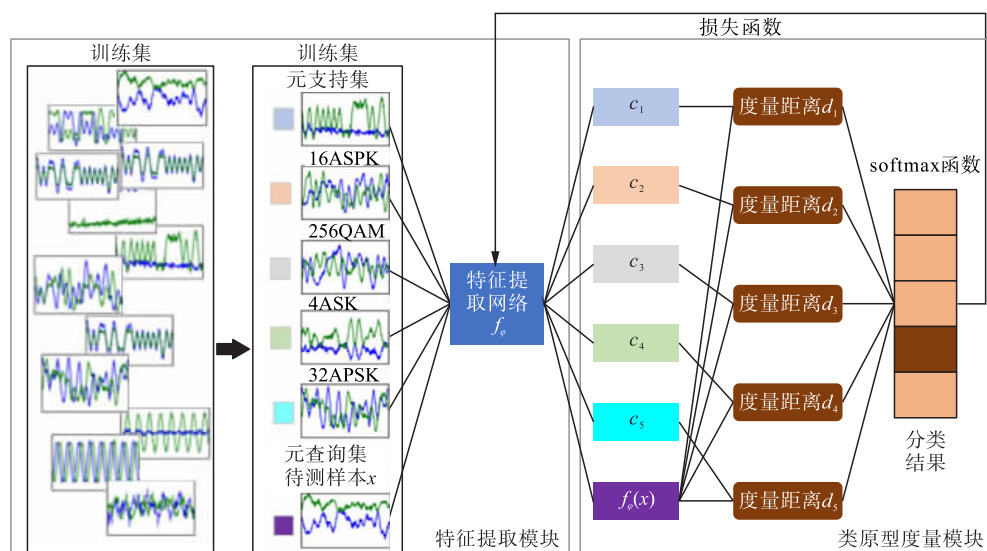


图 1 识别模型原理框架

1.1 算法训练策略

不同于以数据为基本单元的学习方法, 元学习

的训练集和测试集都是以任务为基本单元的, 且训练任务和测试任务都由支持集和查询集组成, 其识

别的信号类别完全不同。在训练阶段,元学习模型通过学习大量不同的训练任务获取一种跨任务的信号识别能力,当测试阶段面对包含全新类别调制信号的识别任务时,即使只有少量带标签样本也能实现准确识别。一般的,若任务的支持集中包含 C 个类别,且每个类别拥有 K 个样本,则该任务称为 C -way K -shot 任务。

本文训练集 D_{base} 内包含 N 类调制信号,且每类信号都有大量带标签信号样本,通过随机采样 D_{base} 内的信号样本构造多个不同的训练任务。训练过程中的每次迭代首先从 D_{base} 中随机选取 C 类信号,然后从每类信号的样本集 D_k 中随机抽取 K 个样本组成支持集 D_S ;从 D_k 的剩余样本中随机抽取 N_Q 个样本组成查询集 D_Q , D_S 和 D_Q 组成一个训练任务。通过学习大量不同的训练任务,网络模型具备了跨任务的信号识别能力,即在测试阶段面对新的测试任务 $T_{\text{test}} = \{D_S, D_Q\}$,仅需 D_S 内的少量带标签信号样本,就能识别出 D_Q 内待测信号的调制样式,其中 D_S 与 D_Q 内信号样本标签空间相同且与 D_{base} 的样本标签空间不相交。为区别于测试任务中的支持集 D_S 和查询集 D_Q ,文中将训练任务的支持集称为元支持集 D_{TS} ,查询集称为元查询集 D_{TQ} 。

训练过程中通过不断迭代来最小化损失从而优化网络参数,本文中每个 Epoch 包含 100 个训练任务。

每个训练任务的损失为:

$$L(\varphi, D_{\text{TS}}, D_{\text{TQ}}) = \frac{1}{|D_{\text{TQ}}|} \sum_{(x, y) \in D_{\text{TQ}}} L_{\varphi}(y | x, D_{\text{TS}}) \quad (7)$$

式中: $L_{\varphi}(\cdot | \cdot, \cdot)$ 表示损失函数; x 为信号样本; y 为样本标签; φ 为特征提取网络参数。

1.2 特征提取模块

如图 1 所示,特征提取模块将 D_{TS} 与 D_{TQ} 内的调制信号样本通过特征提取网络映射到同一特征度量空间。针对 CNN 所具备的空间特征提取能力和 LSTM 所具备的时序特征提取能力,设计了一种由 CNN 和 2 层 LSTM 并联组成的混合并行神经网络 HPN 作为本文算法的特征提取网络。将数据集内的信号样本的同向分量 $I(t)$ 和正交分量 $Q(t)$ 作为网络输入,由并行的 2 个支路分别提取信号的空间特征和时序特征,如图 2 所示,相较于单一网络所提特征,HPN 所提信号样本特征更具代表性。

每个卷积层依次包含一个 (3×1) 卷积、批归一化层(batch normalization, Batch Norm)、修正线性单元(rectified linear, ReLU)、 (2×1) 最大池化层(maxpool),卷积核个数依次设置为 16、32、64、128,

将通过 4 个卷积块提取到的特征向量通过 Flatten 层展平。LSTM 网络设置为 2 层,隐藏单元的个数设置为 128。网络最后设置 Concatenate 层用于将 2 个并行网络所提特征拼接起来作为最终的特征向量。

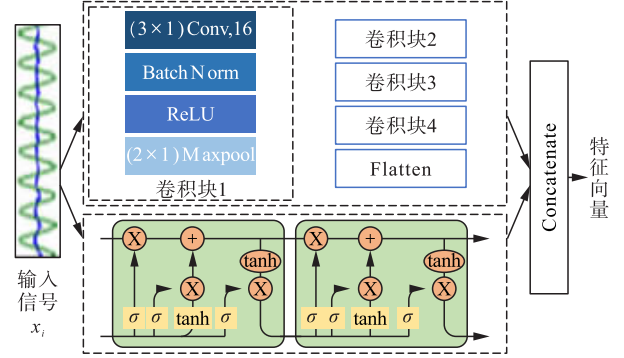


图 2 混合并行网络结构

1.3 类原型度量模块

如图 1 所示,针对一个包含 5 种调制信号的识别任务,本文算法通过比较元支持集 D_{TS} 内带标签信号样本与元查询集 D_{TQ} 内待测信号样本的距离的方式实现分类。通过特征提取模块将 D_{TS} 内信号样本和 D_{TQ} 内待测信号样本 x 映射至度量空间后,由类原型度量模块将 D_{TS} 内每类信号样本特征向量的均值作为类原型,分别得到 5 种调制信号的类原型“ $c_1 \sim c_5$ ”,则第 n 类信号的类原型 c_n 可表示为:

$$c_n = \frac{1}{K} \sum_{k=1}^K f_{\varphi}(x_{nk}), x_{nk} \in D_{\text{TS}} \quad (1)$$

式中: f_{φ} 表示特征提取网络; φ 表示网络参数; x_{nk} 表示 D_{TS} 中第 n 类信号的第 k 个样本; K 表示 D_{TS} 内每类信号的样本量。

在得到 D_{TS} 内每类信号的类原型后,分别计算各类原型 c_n 与待测样本特征向量 $f_{\varphi}(x)$ 间的欧式距离 d_n ,即 $d_n = |c_n - f_{\varphi}(x)|$,并将 d_n 作为 softmax 函数的输入,从而得到待测样本属于每个类别的概率。样本与某类原型的距离越近,则它属于该类原型所表示类别的概率越大,将最大概率所属的类别作为最终的识别结果。待测样本 x 属于第 k 类信号的概率 p_{φ}^k 可表示为:

$$p_{\varphi}^k = \frac{\exp(-d(f_{\varphi}(x), c_k))}{\sum_{n=1}^c \exp(-d(f_{\varphi}(x), c_n))} \quad (2)$$

训练过程中为使拟合好的网络针对测试任务能综合考虑信号样本类内距离与类间距离,使得样本在度量空间内的表示更易于分类,本文引入了一种新的联合损失函数。该损失函数定义样本损失为同类损失 L_l 与异类损失 L_f 的线性组合,

$$L_t = -\log p_{\varphi}^k = -\log \frac{\exp(-d(\mathbf{f}_{\varphi}(x_i), c_k))}{\sum_{n=1}^C \exp(-d(\mathbf{f}_{\varphi}(x_i), c_n))} \quad (3)$$

$$L_f = -\sum_{k'=1, k' \neq k}^C \log \left[1 - \frac{\exp(-d(\mathbf{f}_{\varphi}(x_i), c_{k'}))}{\sum_{k''=1, k'' \neq k}^C \exp(-d(\mathbf{f}_{\varphi}(x_i), c_{k''}))} \right] \quad (4)$$

则模型的联合损失为 L 为:

$$L = L_t + \lambda L_f \quad (5)$$

式中: λ 为比例系数。

2 实验仿真

2.1 数据集与仿真设置

仿真数据集选用 RadioML2018.01A 公开调制信号集, 包含 24 类调制信号, 每个信号样本数据格式为 $[1 \ 024, 2]$, 即为序列长度 $L=1 \ 024$ 的 I、Q 两路数据, 每类信号信噪比从 -20 dB 到 30 dB, 分布间隔为 2 dB。本文算法模型可识别训练时从未出现的新类信号, 为验证算法性能, 本文从数据集中随机选取 14 类信号用于训练网络, 即 $N=14$, 其余 10 类信号用于测试网络性能, 具体调制样式如下:

训练集的信号调制样式为: 32PSK、32QAM、GMSK、OQPSK、BPSK、AM-SSB-SC、16PSK、128QAM、AM-DSB-SC、64QAM、256QAM、OOK、16APSK、FM; 测试集的信号调制样式为: 32APSK、8ASK、8PSK、4ASK、64APSK、128APSK、AM-SSB-WC、QPSK、AM-DSB-WC、16QAM

本文基于 python 下的 pytorch 神经网络架构搭建网络模型, 实验在 Windows 7 系统、32 GB 内存、配备 NVIDIA P4000 显卡的服务器上进行。

模型选用 Adam 优化器训练网络参数, 初始学习率设置为 0.001, 共设置 200 个 Epoch 完成参数训练。由于不同的识别任务识别精度可能不同, 因此在测试阶段, 从测试集中随机采用 1 000 组不同的测试任务, 通过所有测试任务识别准确率的平均值来表征算法的识别性能。

2.2 算法性能分析

2.2.1 样本量对识别性能的影响

本节针对本文算法在小样本条件下的识别性能进行实验分析, 首先针对 5 种 (5-way) 调制信号的识别任务, 对比任务支持集内每类信号样本量 (K 值) 分别为 1, 5, 10, 20 时的识别性能, 实验设置特征提取网络为 HPN 网在 “5-way 5-shot” 和 “5-way 1-shot” 测试任务下 3 种算法的识别准确率随信噪比

的变化情况见图 3, 训练损失函数的比例系数设置为 0, 每个识别任务中每类信号选取 15 个样本组成查询集。当信噪比为 20 dB, 测试任务支持集内每类信号样本只有 1 个时, 识别准确率就可达到 82.23% , 这充分证明了本文算法在小样本条件下的可行性。随着样本量的增加, 测试任务的识别准确率进一步提高, 当每类信号带标签样本量为 5、10、20 时, 测试识别准确率比 20 dB 时分别提高了 5.11% 、 6.5% 、 7.94% 。当样本量大于 5 后, 增加样本量对识别准确率的提升效果趋缓。


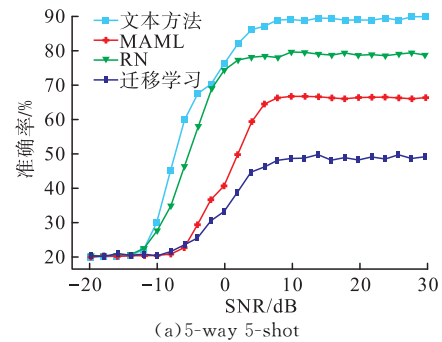



图 3 不同样本量下算法的识别性能

2.2.2 不同小样本识别模型对比分析

为验证本文算法相对于其它调制识别算法的性能优势, 本节选取几类方法与本文算法进行对比实验, 包括模型无关联学习 (model-agnostic meta-learning, MAML)^[13]、关系网络 (relation network, RN)^[14]、迁移学习^[15], 为保证对比实验的公平性, 所有方法都采用表 2 所列数据集。在 “5-way 5-shot” 和 “5-way 1-shot” 测试任务下几种算法的识别准确率随信噪比的变化情况如图 4 所示。



(a) 5-way 5-shot



(b) 5-way 1-shot

图 4 不同方法与本文算法的性能对比

从图中可以看出,本文算法具有最高的识别准确率,其中采用迁移学习的识别准确率最低,主要是由于目标域信号样本每类只有几个,样本量过少导致网络模型在测试出现严重的过拟合问题,网络模型对测试信号样本的泛化性不足,导致识别准确率显著下降。这进一步证明,迁移学习方法无法解决只有几个带标签信号样本的调制识别问题。

MAML 与 RN 也属于元学习方法,针对“5-way 5-shot”和“5-way 1-shot”测试任务,在信噪比为 20 dB 时本文算法相较于 MAML 分别提高了 21.94%和 26.26%,相较于 RN 方法分别提高了 10.18%和 13.44%,在相同样本量条件下,本文算法具有更高的测试识别准确率。MAML 方法面对新的小样本任务需要对网络参数进行微调,由于样本量较小,针对参数量较大的网络识别准确率较低,微调后的网络性能依然不够理想;RN 方法属于学习度量的元学习方法,但该方法通过神经网络确定样本间的距离,这增加了网络训练的参数量,在相同样本量条件下,与本文算法相比 RN 方法识别性能较差。

2.2.3 损失函数比例系数对识别性能的影响

本节分别针对“5-way 5-shot”和“5-way 1-shot”识别任务在不同 λ 值下的识别性能进行实验分析,当 shot=1 时识别任务元查询集/查询集每类信号样本数设置为 $N_Q=10$,当 shot=5 时设置 $N_Q=15$,所有实验中特征提取网络均采用 CPN 网络。图 5 和图 6 分别为“5-way 5-shot”和“5-way 1-shot”识别任务测试中,在信号信噪比为 20 dB 时平均识别率随 λ 值的变化情况。

如图 5 和图 6 所示, $\lambda=0.15$ 时的平均算法测试识别准确率均优于其它 λ 值下的平均识别率,由此可知,本文引入的联合损失函数在合适的比例系数下可明显提高网络的测试识别准确率。




图 5 “5-way 5-shot”识别任务在不同 λ 值下的识别性能

本节设置 $\lambda=0$ 时的网络模型为 baseline。图 7 为 $\lambda=0$ 和 $\lambda=0.15$ 时不同识别任务下测试识别准

确率随信噪比的变化情况,可以看出 $\lambda=0.15$ 时网络模型具有明显的优势,在“5-way 1-shot”和“5-way 5-shot”识别任务下,平均识别准确率最高分别达到 82.53%和 88.45%,与 $\lambda=0$ 时相比,分别提高了 1.42%和 1.03%。当 $\lambda=0.15$ 时,采用联合损失函数可在测试集上实现更高的识别准确率。




图 6 “5-way 1-shot”识别任务在不同 λ 值下的识别性能

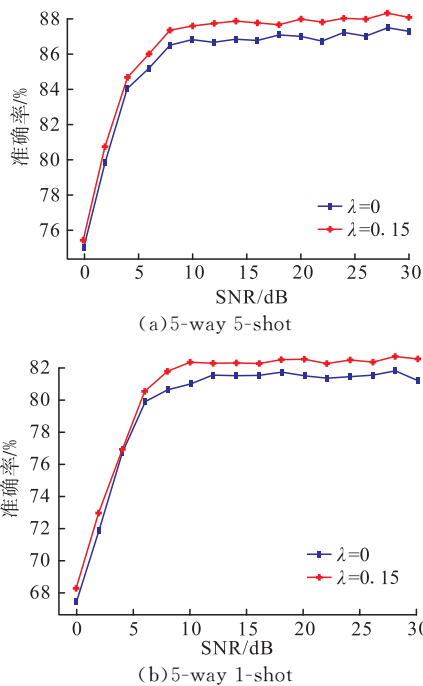


图 7 本文算法与基线网络识别性能比较

2.2.4 特征提取网络对识别性能的影响

基于上一节实验结果,本文接下来所有实验均设置 λ 值为 0.15。本节通过对比采用不同特征提取网络时本文算法的测试结果,验证所设计的 HPN 特征提取网络的性能优势。将 CNN^[1]、Resnet18^[16] 和 Resnet34^[16] 分别作为模型的特征提取网络,与本文 HPN 特征提取网络进行对比实验。5 种不同特征提取网络的模型在“5-way 5-shot”和“5-way 1-shot”识别任务中的测试识别准确率见图 8。表 1 给出了针对“5-way 5-shot”任务不同特征提取网络下模型的网络参数量和训练 200 个 Epoch 所需时间。

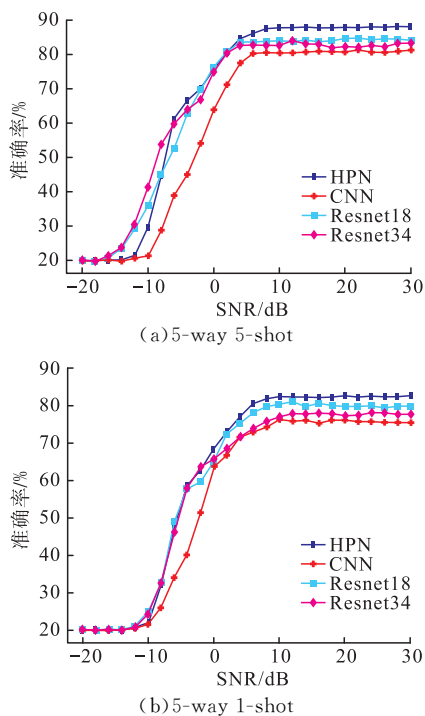


图8 不同特征提取网络下算法性能比较

表3 网络参数数量和训练时间

网络	网络参数数量	训练时间/s
HPN	1 956 140	992
CNN	1 228 070	584
Resnet18	11 267 050	4 596
Resnet34	21 449 866	10 175

如图所示,当信噪比大于 4 dB 时,本文的 HPN 特征提取网络相比其它特征提取网络具有更高的识别准确率。当信噪比为 20 dB 时,相较于 CNN、Resnet18 以及 Resnet34,HPN 特征提取网络下的模型在“5-way 5-shot”测试任务中的识别准确率分别提高了 7.6%、3.92%、6.29%,在“5-way 1-shot”测试任务中的识别准确率分别提高了 7.25%、2.91%、4.8%。本文 HPN 网络通过卷积网络与 LSTM 网络同时提取信号的空间特性与时序特征,由表 1 可知,虽然采用 HPN 会在一定程度上增加网络参数数量以及算法的训练时间,但比仅采用 CNN 作为特征提取网络实现了更高的识别准确率识别性能。相比 Resnet18 和 Resnet34 特征提取网络,HPN 的训练参数数量更少、所需训练时间更短,但测试识别效果更好,同时从图 8 中可以看出,虽然 Resnet34 的网络层数多于 Resnet18,但识别准确率反而下降,这表明网络过于复杂化并不适合小样本条件下的识别任务,易出现过拟合的现象。

3 结语

本文针对带标签信号样本只有几个的调制识别

问题,提出了一种基于元学习的小样本调制识别算法。实验结果表明,在信噪比为 20 dB 时,本文算法在只有 5 个带标签样本时识别准确率可达 88.10%,只有 1 个带标签样本时识别准确率可达 82.23%。同时本文还设计了一种混合并行特征提取网络,并引入一种新的联合损失函数对网络参数进行优化,实验结果表明以上两种改进可有效提升算法在小样本条件下的识别性能。针对在低信噪比条件下识别准确率明显下降的问题,须在下一步工作中重点研究。

参考文献

- [1] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional Radio Modulation Recognition Networks[C]// International Conference on Engineering Applications of Neural Networks. Cham: Springer, 2016:213-226.
- [2] O'SHEA TJ, 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.
- [3] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic Modulation Classification Based on Constellation Density Using Deep Learning[J]. IEEE Communications Letters, 2020,24(6):1275-1278.
- [4] 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.
- [5] 秦博伟,蒋磊,郑万泽,等.基于半监督生成对抗网络的通信信号调制识别算法[J].空军工程大学学报(自然科学版),2021,22(5):75-81.
- [6] 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.
- [7] 朱克凡,王杰贵,刘有军.小样本条件下基于数据增强和 WACGAN 的雷达目标识别算法[J].电子学报,2020,48(6):1124-1131.
- [8] HUISMAN M, VAN RIJN J, PLAAT A. A Survey of Deep Meta-learning[J]. Artificial Intelligence Review, 2021, 54(6): 4483-4541.
- [9] SNELL, JAKE, KEVIN S, et al. Prototypical Networks for Few-Shot Learning[C]//Advances in Neural Information Processing Systems. Long Beach, USA: [s. n.], 2017: 4077-4087.
- [10] VINYS O, BLUNDELL C, LILICRAP T, et al. Matching Networks for One Shot Learning[C]//30th Conference on Neural Information Processing Systems. Barcelona, Spain:[s. n.], 2016: 3630-3638.

(下转第 89 页)

- 1-19.
- [8] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual Dense Network for Image Super-Resolution[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE, 2018:2472-2481.
- [9] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual Dense Network for Image Restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(7):2480-2495.
- [10] PUROHIT K, MANDAL S, RAJAGOPALAN A N. Mixed-Dense Connection Networks for Image and Video Super-Resolution [J]. Neurocomputing, 2020, 398:360-376.
- [11] NELSON R A, OLSSON M G. The Pendulum-Rich Physics from a Simple System[J]. American Journal of Physics, 1986, 54(2):112-121.
- [12] 张太雷. 几类传染病动力学模型研究[D]. 乌鲁木齐:新疆大学, 2008:1-5.
- [13] BLANCO J M. Relationship between the Logistic Equation and the Lotka-Volterra Models[J]. Ecological Modelling, 1993, 66(3):301-303.
- [14] 马知恩, 周义仓, 李承治. 常微分方程稳定性与稳定性方法[M]. 2 版. 北京:科学出版社, 2015:23-28.
- [15] BAKER M R, PATIL R B. Universal Approximation Theorem for Interval Neural Networks[J]. Reliable Computing, 1998, 4(3):235-239.
- [16] WU K, XIU D. Numerical Aspects for Approximating Governing Equations Using Data[J]. Journal of Computational Physics, 2019, 384:200-221.
- [17] ELDAN R, SHAMIR O. The Power of Depth for Feedforward Neural Networks [J]//Proceedings of Machine Learning Research, Columbia University, 2016(49):907-940.
- [18] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely Connected Convolutional Networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA: IEEE, 2017:2261-2269.
- [19] 李贵锋, 童宁宁, 冯为可, 等. 基于 DenseNet 的机载雷达动目标检测[J]. 空军工程大学学报(自然科学版), 2021, 22(2):83-90.
- [20] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: [s. n.], 2016:770-788.
- [21] 杨冰, 徐丹, 张豪远, 等. 基于改进的 Dense Net-BC 对少数民族服饰的识别[J]. 浙江大学学报(理学版), 2021, 48(6):676-683.
- [22] HINDMARSH A C. LSODE. Ordinary Differential Equation System Solver [R]. United States: U. S. Department of Energy Office of Scientific and Technical Information, 1983.

(编辑:徐敏)

(上接第 82 页)

- [11] SUNG F, YANG YX, ZHANG L, et al. Learning to Compare: Relation Network for Few-Shot Learning [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT:IEEE, 2018:1199-1208.
- [12] FINN C, ABBEEL P, LEVINE S. Model-Agnostic meta-Learning for Fast adaptation of Deep Networks [C]//International Conference on Machine Learning. PMLR, 2017:1126-1135.
- [13] YANG N, ZHANG B, DING G, et al. Specific Emitter Identification with Limited Samples: A Model-Agnostic Meta-Learning Approach[J]. IEEE Communications Letters, 2022, 26(2):345-349.
- [14] ZHANG Z, LI Y, GAO M. Few-Shot Learning of Signal Modulation Recognition Based on Attention Relation Network [C]//2020 28th European Signal Processing Conference (EUSIPCO). [S. l.]: IEEE, 2021:1372-1376.
- [15] LIANG Z, MINGLIANG T, WANG L, et al. Automatic Modulation Recognition Based on Adaptive Attention Mechanism and ResNeXt WSL Model [J]. IEEE Communications Letters, 2021, 25(9):2953-2957.
- [16] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, US: IEEE, 2016:770-778.

(编辑:徐敏)