

基于特征注意力融合元残差网络的小样本SAR目标识别

刘 旗, 刘永祥, 张新禹
(国防科技大学电子科学学院, 湖南长沙 410073)

摘要: 深度学习方法在合成孔径雷达(Synthetic Aperture Radar, SAR)目标识别方面表现良好,但是这些深度模型往往需要大量训练数据来对模型参数进行优化,否则经常会遇到严重的过拟合问题,导致目标识别准确率低,模型泛化能力差. 针对上述问题,基于元学习框架,提出了针对小样本条件下SAR目标识别的特征注意力融合元残差网络. 在该方法中,基于残差网络设计了全新的学习器,通过利用残差结构,有效传递SAR图像的对比度信息,提高目标识别准确率,而且多尺度特征注意力融合模块通过注意力机制,融合不同残差层特征,为目标识别提供更丰富的特征信息. 改进的元学习器不仅能够为学习器学习到易于优化的初始化参数,而且能够为学习器的每一个参数学习一个不同但是合适的学习率. 与其他三种小样本目标识别方法在MSTAR数据集上进行对比实验,结果表明本文方法提高了小样本条件下SAR目标识别方法的识别准确率和识别模型的泛化性能. 对所提方法进行了鲁棒性验证实验,网络结构消融实验,并展示了元学习器为学习器参数学习到的不同但是合适的学习率.

关键词: 雷达目标识别;合成孔径雷达;元学习;残差网络;小样本学习

基金项目: 国家自然科学基金(No.61025006, No.60872134, No.61901482, No.61921001);中国博士后科学基金(No.2018M633667)

中图分类号: TN95;TN911.7

文献标识码: A

文章编号: 0372-2112(2023)09-2366-13

电子学报URL: <http://www.ejournal.org.cn>

DOI:10.12263/DZXB.20211371

Few-Shot SAR Target Recognition Method Based on Feature Fusion Attention and Meta-ResNet

LIU Qi, LIU Yong-xiang, ZHANG Xin-yu

(College of Electronic Science and Technology, National University of Defense Technology, Changsha, Hunan 410073, China)

Abstract: In recent years, traditional synthetic aperture radar (SAR) target recognition methods based on deep learning have achieved promising results. However, these deep models need lots of training samples for parameter optimization, otherwise they would possibly encounter serious overfitting problem, resulting in low recognition accuracy and poor generalization ability of these deep models. Aiming to above problems, this paper proposed a few-shot SAR target recognition method named multi feature attention fusion Meta-ResNet. In this method, we designed a learner based on residual network, which can effectively transmit contrast information in SAR images and thus improve recognition accuracy. Furthermore, the multi feature attention fusion module can provide weighted multi scale features by fusing features of different ResNet layers. The improved meta-learner can not only learn good initialization parameters for learner, but also learn a different but appropriate learning rate for each learner parameter. The comparative experiment between the proposed method and other three few-shot recognition methods demonstrated the effectiveness and progressiveness of the proposed method. We also conducted experiment to verify the robustness and study the influence of the network structure on recognition accuracy. We showed the different but appropriate learning rates of learner parameters learned by the meta-learner.

Key words: radar target recognition; synthetic aperture radar; meta-learning; residual network; few-shot learning

Foundation Item(s): National Natural Science Foundation of China (No.61025006, No.60872134, No.61901482, No.61921001); China Postdoctoral Science Foundation (No.2018M633667)

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)系统通过对被测目标发射电磁波,得到被测目标的散射点回波,进而对被测目标的雷达回波进行相干处理,得到目标的高分辨率图像^[1-3].得益于电磁波的穿透性,SAR系统可以全天时、全天候的在一些极端条件下工作,而且成像质量不受光线强弱以及天气等自然条件的影响^[4],因此,SAR成像系统被广泛应用到民用和军事领域,例如地形测绘^[5]、海洋观测^[6]以及自动目标识别(Automatic Target Recognition, ATR)^[7-12].

SAR图像所反映的距离向和横向上的散射点分布信息有助于研究者进行雷达自动目标识别技术的研究.因此,近年来,基于SAR图像的雷达自动目标识别技术(Radar Automatic Target Recognition, RATR)成为了研究热点并受到诸多研究者的关注^[13-16].传统的SAR图像自动目标识别方法可大致分为两个步骤,第一个步骤是提取能够反映雷达目标特性的特征,第二个步骤根据提取出的特征设计合适的分类器.在过去几年,基于SAR图像的目标识别方法快速发展,就目前而言,研究者提取出的SAR图像特征可大致分为以下几类,极化特征^[17],结构特征^[18],几何特征^[19]和电磁散射特征^[20].很多典型的分类器也被广泛应用到SAR图像的自动目标识别当中,例如支持向量机(Support Vector Machine, SVM)^[21],自适应增长模型^[22]和判别图模型^[23].上述传统方法虽然在不同程度上实现了雷达目标的自动识别,但是需要人工提取特征,费时费力,而且特征的质量是识别效果的瓶颈,制约着识别性能的提升.虽然近年来研究者在提取具有判别力的特征方面做出了很多工作,但是低维度的可视化特征和高维度的语义特征之间的语义鸿沟使得上述传统方法的识别效果不能令人满意.总而言之,传统方法中通过手工提取的特征不足以表征复杂的SAR图像数据,而且浅层结构的分类器也越来越不能满足人们对多种雷达目标进行识别的要求.

深度学习的快速发展极大的促进了基于深度学习的SAR图像自动目标识别方法的发展,基于深度学习的SAR图像目标识别方法避免了复杂的手工提取特征的过程,实现了目标特征的自动提取并且能够根据识别结果进行自适应的调整.目前常见的深度神经网络结构,例如卷积神经网络(Convolutional Neural Networks, CNN)^[24],深度置信网络^[25],堆栈自动编码器^[26]和受限玻尔兹曼机^[27]等都被应用到SAR图像的识别当中.尽管基于深度学习的SAR图像自动目标识别方法能够自动提取多层次的目标特征,而且在最终的识别性能方面较传统识别方法有所提升,但是上述深度模型往往需要大量带标签

的数据进行训练,一旦训练数据不足,这些深度模型经常会出现严重的过拟合现象,最终导致识别准确率下降,模型泛化能力变差.然而,获取大规模带标签的SAR图像数据集与获取大规模带标签的光学图像数据集相比具有一定的难度,主要有以下几个原因.首先大规模SAR图像的获取需要耗费巨大的财力、物力和人力,其次,SAR图像的标注工作要求标注人员具有一定的雷达先验知识.上述原因造成了SAR图像目标识别领域训练样本数量不足的问题,又叫做SAR图像目标识别的小样本问题,导致基于深度学习的SAR图像目标识别方法经常出现过拟合的现象,从而降低了目标识别准确率.除了上述SAR图像的小样本问题,He等人在文献[28]中还发现,随着上述深度神经网络的层数不断增加,会逐渐出现神经网络的退化问题.因此,有必要提出一种新的小样本SAR图像自动目标识别方法来解决上述问题.

近年来,元学习的方法^[29-33]被广泛应用到光学图像识别领域来解决其存在的小样本问题.元学习通过在大量服从同一分布的学习任务上进行学习,从而期望能够在服从相同分布的学习任务上表现出良好的泛化性能.文献[29]提出了匹配网络(Matching Net)的模型,匹配网络通过学习待测目标样本与训练样本之间的映射,实现对待测样本的分类,避免了模型在适应新类型目标时的微调过程,从而降低了对训练样本数量的需求.文献[31]提出了一种模型无关的元学习方法(Model-Agnostic Meta-Learning, MAML),在该方法中,设计了特定的模型结构,使得模型的参数经过训练以后,模型在面对新的学习任务时,只需要少量的学习样本并且少次迭代优化就可以表现出较好的泛化性能.文献[30]提出了一种基于长短时记忆神经单元的元学习器(Meta Long Short Term Memory, Meta-LSTM),利用长短时记忆网络的长时间状态转移矩阵的更新公式代替传统的梯度下降算法公式,经过大量学习任务的训练,元学习器可以在少量样本的条件下优化学习器参数,使得学习器在小样本条件下能够表现出较好的性能.与MAML^[31]相比,文献[32]提出的元梯度下降(Meta Stochastic Gradient Descent, Meta-SGD)算法不仅可以学习到学习器的初始化参数,而且可以学习到学习器参数的更新方向和学习率的大小.与Meta-LSTM^[32]相比,Meta-SGD^[32]算法在概念上更简洁易懂,在具体操作上更容易实现,而且它能够更有效地进行学习.然而,直接将文献[32]提出的原始的Meta-SGD算法应用到SAR图像自动目标识别领域时,经常会遇到训练困难以及梯度消失和梯度爆炸的问题.

在SAR目标识别领域,目前解决小样本问题的思

路可以大致分为两种:基于迁移学习的方法^[34,35]和基于元学习的方法^[36~40]。基于迁移学习的方法利用大量的光学图像对特征提取模块的参数进行预训练,在预训练的特征提取模块的基础上利用少量SAR目标样本对模型参数进行微调,在一定程度上弥补了SAR图像样本不足导致的信息缺失问题,但是光学图像与SAR图像存在的图像域差异制约着上述方法性能的提高。元学习的方法可以大致分为基于优化、基于模型和基于度量的三类元学习方法。目前大部分小样本SAR目标识别方法都属于基于度量的元学习方法,文献[36]的作者在匹配网络的基础上进行了小样本SAR目标识别实验,文献[37~39]的作者在基于度量学习的基础上,在推理策略^[37]、损失函数^[38]和相位信息^[39]等方面进行了改进,提高了度量学习方法在SAR目标识别领域的适应性。文献[40]的工作属于基于优化的元学习方法,指出了小样本SAR目标识别领域存在的“小(少)任务”问题,利用Meta-SGD算法进行了实验,提高了识别准确率,但是其没有对Meta-SGD算法进行更深层次的分析以及对存在的问题进行改进。

为了解决上述问题,论文提出了一种新颖的基于元学习的SAR图像自动目标识别方法——基于特征注意力融合元残差网络的小样本SAR自动目标识别方法。主要创新点可以概括为以下几点:

(1)针对SAR目标识别的小样本问题,提出了一种新颖的基于元学习的SAR图像自动目标识别方法——特征注意力融合元残差网络,通过利用元学习的学习范式和残差网络的结构特点,提高小样本条件下SAR目标的识别准确率和模型泛化能力。

(2)SAR图像具有稀疏的特点,其图像中的对比度信息有助于SAR目标的识别,基于残差网络(Residual Networks, ResNet)设计了学习器,利用残差网络的跳跃连接,有效传递稀疏SAR图像中的对比度信息,提高对SAR目标的识别准确率。残差网络中的跳跃连接不引入额外的网络参数而且不会增加计算的复杂度,实现在有效传递对比度信息的前提下搭建更深层次的网络结构,提取更具辨别力的目标特征。

(3)针对传统Meta-SGD训练困难以及易出现梯度消失和爆炸的问题,对原始的Meta-SGD算法进行了改进,改进的Meta-SGD算法不仅可以学习到易于优化的学习器的初始化参数,而且能够为学习器的每一个网络参数学习一个不同但是合适的学习率。在改进的Meta-SGD算法中,元学习器以不同的元学习率对学习器的初始化参数和每一个参数的学习率进行学习,从而在一定程度上避免了传统Meta-SGD算法存在的训练困难及梯度消失和梯度爆炸的问题。

2 特征注意力融合元残差网络

2.1 方法描述

针对引言提到的SAR图像自动目标识别方法中存在的问题,基于元学习的学习范式和残差网络的跳跃连接结构,在文献[28,32,33]工作的基础上,提出了特征注意力融合元残差网络,用于小条件下的SAR图像自动目标识别。该方法可大致分为两个部分,分别是基于特征注意力融合残差网络的学习器和改进的Meta-SGD元学习器。学习器学习如何识别不同的SAR目标,元学习器的主要目标是学习易于收敛的学习器的初始化参数和合适的更新学习器参数的学习率。

SAR图像中目标的散射强度往往大于背景和噪声的强度,表现出稀疏、对比度强的特点。本文采用残差网络结构旨在利用跳跃连接能够有效传递对比度信息的优势,提高SAR目标识别的准确率。特征注意力融合模块能够提取不同残差模块不同尺度的特征,并根据不同任务对不同尺度的特征赋予不同的权重,实现根据具体识别任务,以不同特征为主导有针对性地完成对SAR目标的有效识别。同时,特征注意力融合模块中采用的 1×1 卷积和自适应池化模块能够分别对特征的通道数和二维空间结构进行压缩,从而减少数据运算量,提高计算效率,有利于小样本条件下SAR目标的识别。

网络的初始化参数对于网络的性能、训练和收敛都有一定的影响。网络的参数过大,在反向传播过程中,根据链式法则可知容易出现梯度爆炸的问题,反之,网络的参数过小,容易出现梯度消失的问题。传统的Meta-SGD元学习器在对学习器的初始化参数进行学习时,由于训练前期元学习器还没有训练完全,导致学习到的初始化参数容易存在过大或过小的现象,使得在训练前期经常出现梯度爆炸或梯度消失的问题,而且初始化参数的学习与学习率的学习是耦合在一起进行的,使得学习到的初始化参数在不同任务之间更新步长很小,一旦训练前期元学习器学习到的初始化参数存在数值过大或过小的问题,在接下来的不同任务中训练时这一问题很难得以改善,导致因梯度爆炸或者梯度消失带来的训练困难,训练过程中断,元学习器还没有被训练完全时训练过程就被迫停止的问题。改进的元学习器采用不同的元学习率将学习器初始化参数的学习与每一个网络参数对应的学习率的学习分离开来,这样一旦训练前期元学习器学习到的初始化参数存在数值过大或过小的问题时,可以采用较大的步长更新初始化参数,使得学习到的初始化参数在不同任务之间有较大的数值上的改变,而且当学习到的初始化参数较为合适时,可以以较小的更新步长控制学习率的改变,实现同一任务上的稳定学习。改进的元学

习器通过采用不同的元学习率将初始化参数的学习和相对应的学习率的学习分离开来,实现了在不同任务之间采用较大的更新步长,在同一任务上采用较小的更新步长的学习方式,改善了学习到的初始化参数存在的数值过大或过小的问题,从而在一定程度上避免了因度消失和梯度爆炸导致的训练困难的问题。

2.2 基于特征注意力融合残差网络的学习器

本文基于特征注意力融合模块和残差模块设计了学习器。学习器由一个输入层,四个残差模块,特征注意力融合模块和一个输出层构成,每个残差模块由卷积层,池化层,跳跃连接和激活函数层构成。SAR 图像中目标的散射强度往往大于背景噪声的散射强度,使

得 SAR 图像呈现出稀疏的特性,并且目标与背景的对比度较为明显,这种对比度信息有助于提高雷达目标识别的准确率,而残差模块中的跳跃连接能够有效传递对比度信息,同时能够防止网络出现退化问题,因此本文选用了残差网络模块来构成学习器。特征注意力融合模块能够提取出残差网络模块中每个残差模块不同尺度的特征,并根据不同的识别任务,通过注意力机制对不同残差模块提取出的特征赋予不同的权重,从而实现根据不同识别任务,以不同残差模块提取的特征为主导进行 SAR 图像的目标识别。基于特征注意力融合残差网络的学习器的结构示意图如图 1 所示。其中蓝色虚线引出的网络结构表示一个残差模块的内部计算流程。

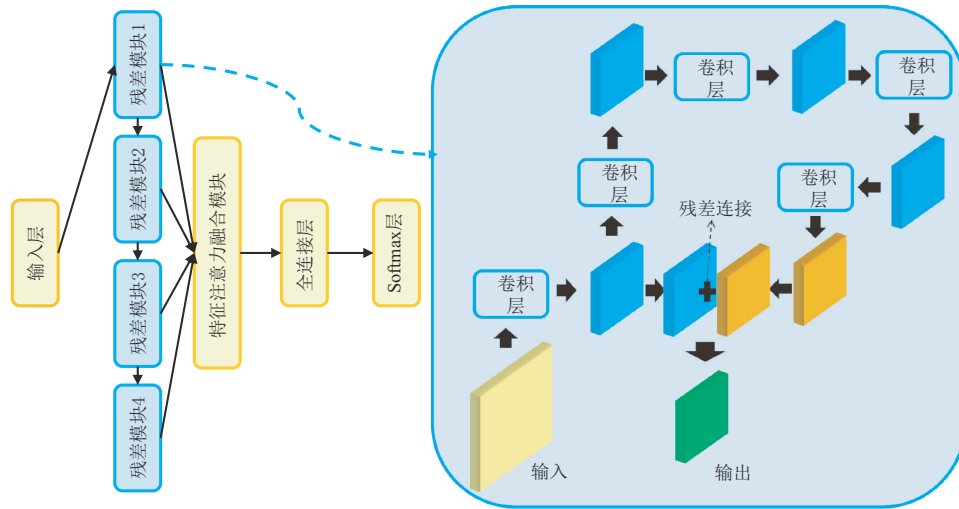


图 1 基于特征注意力融合残差网络的学习器

2.2.1 残差模块

每个残差模块由卷积层,池化层,跳跃连接和激活函数构成。

式(1)表示卷积层操作,其中 W_{conv}, b_{conv} 分别表示卷积层的权重和偏置参数, X 表示输入的 SAR 图像或者是上一个残差模块输出的特征图, Z_{conv} 表示卷积层的输出特征图, $*$ 表示卷积操作。

$$Z_{conv} = W_{conv} * X + b_{conv} \quad (1)$$

经过卷积处理以后,卷积网络输出的特征图会依次经过池化层进行特征压缩以及 ReLU 激活函数层进行非线性激活,如式(2)和式(3)表示,其中 maxpool 表示最大池化操作,relu 表示 ReLU 激活函数, A_{conv} 表示经过池化层和激活函数处理后的特征图。

$$A_{conv} = \text{maxpool}(\text{relu}(Z_{conv})) \quad (2)$$

$$\text{relu}(x) = \max\{0, x\} \quad (3)$$

由池化层压缩和激活函数非线性激活后的特征图作为输入,输入到跳跃连接结构,跳跃连接结构可以由

式(4)和式(5)表示,其中 Conv 表示卷积操作,由式(1)定义, H_{res} 表示跳跃连接的输出。跳跃连接^[28]表示跨越一层或者多层的连接。跳跃连接既不引入额外的参数也不增加计算复杂度,而且能够有效传递对 SAR 目标识别有帮助的目标与背景散射强度的对比度信息。我们定义上述一个残差模块的处理操作为式(6)。

$$R_{res} = \text{Conv}(\text{relu}(\text{Conv}(A_{conv}))) \quad (4)$$

$$H_{res} = \text{relu}(Z_c + R_{res}) \quad (5)$$

$$H_{res} = \text{Resnet}(X) \quad (6)$$

2.2.2 特征注意力融合模块

假设由一个残差模块处理后的特征可以表示为 $H_{res} = [h_1, h_2, \dots, h_{C_m}] \in \mathbf{R}^{H \times W \times C_m}$, C_m 表示通道数,特征每个通道的二维空间结构为 $H \times W$ 。特征注意力模块首先会通过一个 1×1 卷积层和一个自适应池化层分别对 H_{res} 的通道数和二维空间结构进行精炼压缩,以减少数据运算量、提高运算效率。处理之后的特征可以表示为 $F = [f_1, \dots, f_{C_{out}}] \in \mathbf{R}^{\tilde{H} \times \tilde{W} \times C_{out}}$, 一般情况下 $C_{out} < C_{in}$ 。上述

过程可以由式(7)表示. 其中 Adapool 表示自适应池化层, \mathbf{u}_i 表示第 i 个卷积因子, $*$ 表示卷积操作.


$$\mathbf{f}_i = \text{Adapool}(\mathbf{u}_i * \mathbf{H}_{\text{res}}) \quad (7)$$

每个残差模块的输出经过上述处理后得到的特征图 \mathbf{F} 会经过注意力机制被赋予不同的权重大小, 从而实现以不同残差模块输出的特征为主要特征来完成不同的识别任务. 文中注意力机制由一个 1×1 卷积层, 一个全连接层和一个 sigmoid 激活函数层构成. 注意力机制 $\mathbf{A}_{\text{atten}} \in \mathbf{R}^{H_s \times W_s \times C_{\text{out}}}$ 的计算公式为式(8). 其中 σ 表示 sigmoid 激活函数, \mathbf{W}_f 表示全连接层的权重参数, δ 表示 ReLU 激活函数, \mathbf{W}_c 表示卷积层权重参数.

$$\mathbf{A}_{\text{atten}} = \sigma(\mathbf{W}_f \delta(\mathbf{W}_c * \mathbf{F})) \quad (8)$$

式(9)表示注意力机制 $\mathbf{A}_{\text{atten}}$ 和特征图 \mathbf{F} 进行元素对应相乘, 是注意力机制对特征赋予权重的过程, \odot 表示哈达玛积.

$$\mathbf{F}_a = \mathbf{A}_{\text{atten}} \odot \mathbf{F} \quad (9)$$



特征注意力融合模块

图2 特征注意力融合模块结构示意图

2.2.3 输出模块

输出层由一个全连接层和一个 Softmax 层组成, 式(10)表示全连接层的前向传播过程, 其中, $\mathbf{W}_{\text{fc}}, b_{\text{fc}}$ 分别表示全连接层的权重和偏置参数, \mathbf{Z}_{fc} 表示全连接层的输出.

$$\mathbf{Z}_{\text{fc}} = \mathbf{W}_{\text{fc}} \mathbf{H} + b_{\text{fc}} \quad (10)$$

$$p(y_i | \mathbf{Z}_{\text{fc}}) = \text{softmax}(\mathbf{Z}_{\text{fc}}) = \frac{\exp(\mathbf{Z}_{\text{fc}_i})}{\sum_{j=1}^n \exp(\mathbf{Z}_{\text{fc}_j})} \quad (11)$$

式(11)表示 Softmax 的计算公式, 其中 \mathbf{Z}_{fc} 可以写成 $[\mathbf{Z}_{\text{fc}_1}, \mathbf{Z}_{\text{fc}_2}, \dots, \mathbf{Z}_{\text{fc}_n}]$, $y_i (i=1, 2, \dots, n)$ 表示每一类的概率.

2.3 改进的 Meta-SGD 元学习器

如上所述, 学习器是由不同结构的神经网络层搭建而成的. 深度神经网络, 经常采用随机梯度下降算法进行参数优化, 传统的随机梯度下降算法可以表示为式(12), 网络参数通常是随机初始化的, 不同初始化的值对模型最终的性能具有较大的影响, 具有一定的不稳定性.

$$\boldsymbol{\theta}' = \boldsymbol{\theta}^{t-1} - \alpha \nabla \mathcal{L}_T(\boldsymbol{\theta}^{t-1}) \quad (12)$$

在式(12)中, $\boldsymbol{\theta}'$ 表示更新后的网络参数 (在本文中即学习器参数, 下面用学习器参数代替网络参数), $\boldsymbol{\theta}^{t-1}$ 表示学习器参数经过 $t-1$ 次更新后的值, α 表示学习

特征注意力融合模块的结构示意图如图2所示. 特征注意力融合模块本质上是一种基于空间结构 (spatial-wise) 的注意力机制, 文献[41]采用的是一种基于通道 (channel-wise) 的注意力机制, 文献[42]同时采用了基于空间结构和基于通道的注意力机制. 与光学三通道 (“RGB”) 图像相比, SAR 图像是单通道图像, 没有多余的通道信息, 而且考虑到所提方法是面向小样本条件下的 SAR 目标识别, 同时采用两种注意力机制会增加网络需要训练的参数, 为网络参数的收敛训练增加难度, 因此本文只采用了基于空间结构的注意力机制, 特征注意力融合模块能够将特征图中对识别重要的空间位置赋予更大的权重, 使得网络学习到更具代表性、可分辨性更强的目标特征, 在一定程度上减少小样本条件下对训练样本的需求量, 同时特征注意力融合模块中采用的 1×1 卷积和自适应池化能够减少数据运算量, 提高网络运算效率.

率, 在传统的梯度下降算法中, 学习率大小的设置仍然依靠人根据经验和实验结果进行相应的调整. $\nabla \mathcal{L}_T(\boldsymbol{\theta})$ 表示损失函数值 $\mathcal{L}_T(\boldsymbol{\theta})$ 的梯度, $\mathcal{L}_T(\boldsymbol{\theta})$ 通过交叉熵损失函数式(13)计算, 其中 p_i 表示目标的真实类别, y_i 表示网络预测目标属于类别 i 的概率.

$$\mathcal{L}_T(\boldsymbol{\theta}) = -\frac{1}{n} \sum_{i=1}^n p_i \log(y_i) \quad (13)$$

在小样本条件下, 如何初始化学习器的参数以及什么时候停止训练, 对防止网络模型出现过拟合问题尤为重要. 学习率设置的过大, 容易导致网络训练过程中明显的振荡现象, 学习效果差, 甚至导致网络无法收敛, 学习率设置的过小, 经常产生学习缓慢的问题. 学习率的设定目前通常需要设计人员具有丰富的调整网络参数的经验并根据具体情况进行判断. 而且, 神经网络不同的参数采用相同的学习率进行优化同样会导致网络训练过程中的振荡现象以及学习缓慢等问题.

本文改进的 Meta-SGD 元学习器能够学习到有利于收敛并进行下一步优化的学习器的初始化参数, 而且能够为学习器的每一个参数学习一个不同但是合适的学习率, 避免了人工对学习器参数进行随机初始化导致的模型性能波动和不稳定的问题以及依靠经验调整学习率的繁琐过程. 同时, 改进的元学习器改变了原始

元学习器将学习器参数和学习率糅合在一起的学习方式,实现了采用不同的元学习率对学习器的参数和学习率分别进行学习,将学习器参数与学习器参数对应的学习率分离开来进行学习,实现分别对两个过程的精准学习,在一定程度上缓解了训练困难的问题。

改进的元学习器的数学定义如式(14),由初始项 Φ 和更新项 $\mathcal{A} \odot \nabla \mathcal{L}_T(\theta)$ 构成。其中 Φ 和 \mathcal{A} 是改进的元学习器的参数,称为元参数。具体而言, $\mathcal{A} = [\alpha_1, \alpha_2, \dots, \alpha_m]$ 表示每一个参数对应的学习率,向量的长度和 $\Phi = [\phi_1, \phi_1, \dots, \phi_m]$ 的长度相同, m 表示参数的总量。 Φ 和 \mathcal{A} 的优化更新公式如式(14)和式(15)所示。其中 $\Phi^{i-1}, \mathcal{A}^{i-1}$ 表示更新前元学习器的参数, Φ^i, \mathcal{A}^i 表示更新后元学习器的参数, β_1, β_2 分别表示更新元参数 Φ 的元学习率和更新元参数 \mathcal{A} 的元学习率。值得一提的是,本文中元学习器参数 Φ 的值等于学习器参数 θ 的值,实现元学习器为学习器学习初始化参数的作用。

$$\Phi' = \Phi - \mathcal{A} \odot \nabla \mathcal{L}_T(\theta) \quad (14)$$

$$\Phi^i \leftarrow \Phi^{i-1} - \beta_1 \nabla_{\Phi^{i-1}} \mathcal{L} \quad (15)$$

$$\mathcal{A}^i \leftarrow \mathcal{A}^{i-1} - \beta_2 \nabla_{\mathcal{A}^{i-1}} \mathcal{L} \quad (16)$$

改进的元学习器的学习过程可以用如(17)所示的优化问题所表示。

$$\min_{\Phi, \mathcal{A}} \sum_{T_i \sim p(T)} \mathcal{L}_{T_i}(\Phi') = \sum_{T_i \sim p(T)} \mathcal{L}_{T_i}(\Phi - \mathcal{A} \odot \nabla \mathcal{L}_T(\theta)) \quad (17)$$

综上所述,改进的元学习器能够为学习器学习到

易收敛的初始化参数 Φ ,同时能够为学习器的每一个参数学习一个不同但是合适的学习率。而且,经过改进的元学习器实现了以不同的元学习率来学习学习器的初始化参数和学习率。

2.4 基于 episode 的训练策略

在本文中,受文献[29,30]的启发,采用了一种 episode 的训练策略。具体而言,在元学习的框架中,针对小样本 SAR 目标识别任务,需要两种类型的数据集,分别是元训练集 D_{train} 和元测试集 D_{test} 。元训练集和元测试集都由大量的 episode 构成。每一个 episode 包含支撑集和质询集。Episode 是在元训练集和元测试集中通过“N-way K-shot”的采样方法得到的。具体而言,支撑集中包含 N 类目标每类目标 K 个样本,质询集中包含和对应支撑集中目标种类相同但未包含在支撑集中的一部分样本。将元训练集中的支撑集和质询集分别命名为 $D_{\text{train-s}}, D_{\text{train-q}}$,类似地,将元测试集中的支撑集和质询集分别命名为 $D_{\text{test-s}}, D_{\text{test-q}}$ 。元训练集在元训练阶段被用来对元学习器进行训练,元测试集在元测试阶段被经过训练的元学习器用来对学习器进行训练以验证元学习器的训练效果。元训练阶段的目标函数是最小化元训练集中所有 episode 的分类误差。所提方法的前向传播过程如图 3 所示,元训练阶段的详细过程如算法 1 所示。在图 3 中,浅蓝色方框表示基于特征注意力融合残差网络设计的学习器,用 L 表示,浅黄色方框表示改进的元学习器,用 ML 表示。

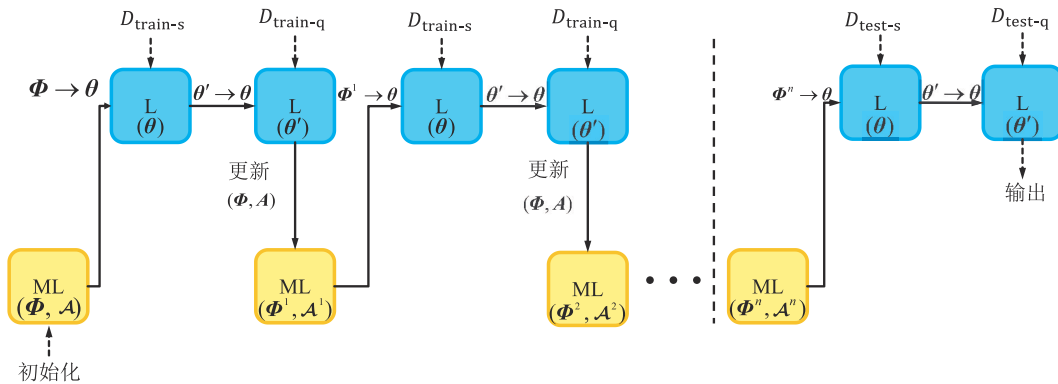


图 3 特征注意力融合元残差网络前向传播示意图

正如算法 1 所示,整个元训练过程可以分为两个阶段。第一个阶段是学习器的训练阶段,通过元学习器利用元训练集中的支撑集 $D_{\text{train-s}}$ 对学习器进行训练。在学习器的训练过程中,元学习器的参数保持不变。第二个阶段是元学习器的训练阶段,通过随机梯度下降算法利用元训练集中的质询集 $D_{\text{train-q}}$ 对元学习器进行训练,对元参数 Φ, \mathcal{A} 进行优化更新。值得一提的是,改进的元学习器改变了之前将不同的元参数 Φ, \mathcal{A} 糅合在一起进行学习的方式,并分别以元学习率 β_1 和 β_2 作为元参数 Φ 和

\mathcal{A} 优化更新的学习率,因为学习器网络参数的更新范围应该大于学习器网络参数对应的学习率的更新范围。

3 实验结果与分析

为了验证本文方法的有效性,在公开 SAR 图像数据集 Moving and Stationary Target Acquisition and Recognition(MSTAR)上对提出的方法进行了性能验证实验。对 MSTAR 数据集以及实验条件和实验的具体实施细节进行了简要介绍。将本文方法与其他方法(Meta-

LSTM^[30], MAML^[31], Matching Net^[29])进行了对比. 对所提方法进行了消融实验, 探究残差模块的个数对实验结果的影响, 进行了噪声环境下的SAR目标识别实验, 验证了所提方法的鲁棒性. 展示了元学习器通过训练, 学习到的与每一个学习器参数相对应的学习率.

算法1 元训练过程的具体细节

输入: 元学习器 M ; 元学习器的参数—元参数 (Φ, \mathcal{A}) ; 学习器 L ; 学习器的参数 θ ; 元学习器的学习率—元学习率 (β_1, β_2) ; 元训练集 D_{train} .

输出: 易于优化的学习器的初始化参数; 与学习器每一个参数对应的合适的学习率向量.

```

1: 初始化  $M$  的参数
2:  $\Phi \leftarrow \Phi^0$ 
3:  $\mathcal{A} \leftarrow \mathcal{A}^0$ 
4:
5: for  $i=1$  to  $n$ 
6:  $D_{\text{train-s}}, D_{\text{train-q}}$ 
7:  $\theta \leftarrow \Phi$ 
8: for  $j=1$  to  $J$ 
9:  $(X^j, Y^j) \leftarrow D_{\text{train-s}}$ 
10:  $\mathcal{L}^j \leftarrow \mathcal{L}(L(X^j; \theta^{j-1}), Y^j)$ 
11:  $\theta^j \leftarrow \theta^{j-1} - \mathcal{A}^{i-1} \odot \nabla_{\theta^{j-1}} \mathcal{L}^j$ 
12: end for
13:  $(X, Y) \leftarrow D_{\text{train-q}}$ 
14:  $\mathcal{L}_{\text{test}} \leftarrow \mathcal{L}(L(X; \theta^j), Y)$ 
15:  $\Phi^i \leftarrow \Phi^{i-1} - \beta_1 \nabla_{\Phi^{i-1}} \mathcal{L}_{\text{test}}$ 
16:  $\mathcal{A}^i \leftarrow \mathcal{A}^{i-1} - \beta_2 \nabla_{\mathcal{A}^{i-1}} \mathcal{L}_{\text{test}}$ 
17: end for

```

3.1 MSTAR数据集

MSTAR数据集是由美国国防高级研究计划局和美国空军研究实验室使用X波段的SAR传感器创建的用于研究的公开数据集. MSTAR数据集中的每一张SAR图像都是从360°方位角每隔1°到2°方位角采样得到的, 方位向和距离向的分辨率都是0.3 m, SAR图像的大小为128×128. 数据集中包含了10类军事目标. 图4给出了MSTAR数据集中10类军事目标的光学图像和对应的SAR图像.

3.2 实验条件及具体实施

在本文中, 选用俯仰角为17°的SAR图像为元训练集 D_{train} , 选用俯仰角为15°的SAR图像为元测试集 D_{test} . 定义识别不同方位角的SAR目标被为元学习框架下不同的学习任务. 具体而言, 支撑集是从方位角为0°~180°的SAR图像中采样得到, 质询集是从方位角为180°~360°的SAR图像中采样得到. 采样方式选用文献[29]中一种叫做“ N -way K -shot”的采样方式, 即从 N 类

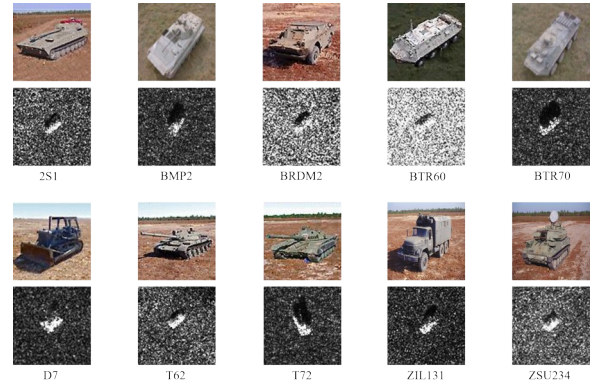


图4 MSTAR数据集中10类军事目标的光学图像和其对应的SAR图像

不同目标中, 每类目标随机选取 K 个样本构成一个大小为 $N \times K$ 的支撑集, 然后从同样 N 类目标中随机选取未被支撑集选用的少量样本构成质询集. 元训练集和元测试集的具体划分方式如图5所示. 文中 $N=10, K=1, 2, 5, 10$. 元训练集和元测试集中的支撑集都包含了MSTAR数据集中的10类目标. 下面以 $K=1$ 为例说明数据集的设置. 支撑集中包含10类目标每类目标1个样本, 从10类目标未出现在支撑集中的样本中随机挑选一部分样本构成质询集. 如图5所示, 长方形框内的一个支撑集和对应的质询集构成一个 episode, 元训练集和元测试集由大量的 episode 构成.

学习器由一个输入层, 4个残差网络模块, 一个权重多尺度特征提取模块, 一个全连接层和一个 softmax 层前后连接构成, 每一个残差网络模块的结构如表1所示. 其中, “Conv-64”表示具有64个卷积核的卷积网络, “ $K(2, 2)$ ”表示卷积核的大小是 2×2 , “ $S(2, 2)$ ”表示步幅大小为 2×2 , “ $P(1, 1)$ ”表示填充的大小为 1×1 , “ReLU”表示 ReLU 激活函数, “BN”表示批归一化层, “MP”表示最大池化层, “DP”表示 dropout 层. 除了特别说明, 本文所有实验都是在以下条件下进行的, 元学习器通过 Adam 优化器进行训练, β_1 设置为 0.001, β_2 设置为 0.000 1. 本文实验都是在带有 8 块 NVIDIA Tesla-V100GPU 的服务器上基于 Pytorch 库进行的.

3.3 与其他小样本识别方法进行对比

为了验证所提方法的有效性, 设计SAR目标识别

表1 残差模块的网络结构

模块名	网络结构	输出
残差模块	Conv-64-K(2,2)-S(2,2)-P(1,1), ReLU, BN, MP, DP	X
	Conv-64-K(3,3)-S(1,1)-P(1,1), ReLU	
	Conv-64-K(3,3)-S(1,1)-P(1,1), ReLU	
	Conv-64-K(3,3)-S(1,1)-P(1,1), ReLU	
	Conv-64-K(3,3)-S(1,1)-P(1,1), ReLU	R
	残差连接 $X+R$, ReLU	

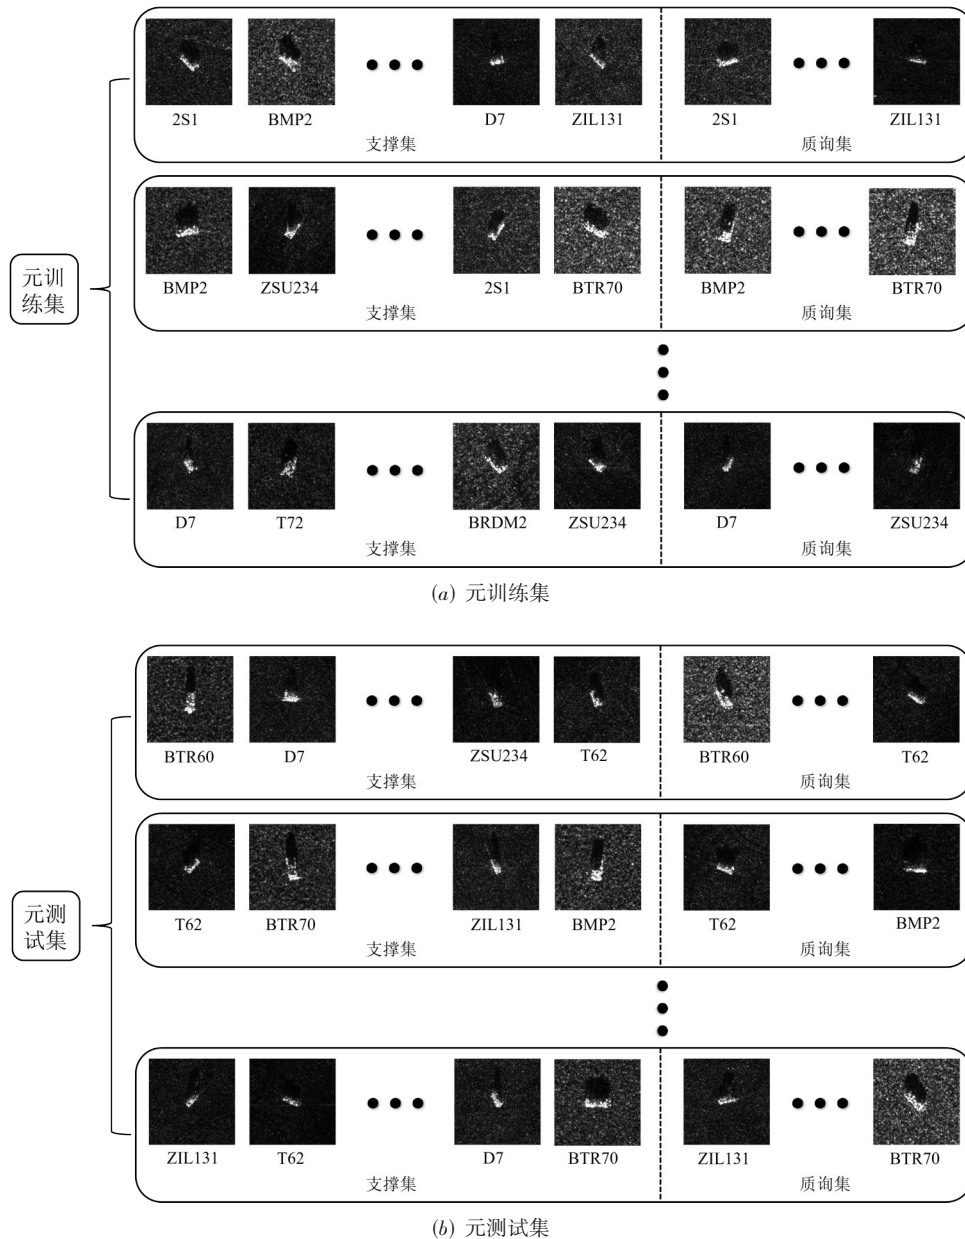


图5 数据集的设置形式

实验,与其他三种小样本识别方法进行了对比.值得一提的是,其他三种小样本学习方法都在公开的光学图像数据集上都实现了较高的识别准确率,在小样本条件下表现出了较强的泛化性能,为了能够更加真实的反映它们对 SAR 目标识别的效果,作者没有对它们做任何改变,三种方法分别是 Meta-LSTM^[30], MAML^[31]和 Matching Net^[29].

根据“ N -way K -shot”采样方式的特点,设计了四种小样本条件进行了对比实验,分别是“10-way 1-shot”, “10-way 2-shot”, “10-way 5-shot”和“10-way 10-shot”.下

面以“10-way 1-shot”为例说明四种小样本条件的具体含义.如上文所述,“10-way 1-shot”表示支撑集中共有 10 类不同目标,而每类目标只有 1 个训练样本,其他三种小样本条件类似.可以看到,所设置的四种小样本条件模拟了不同程度的缺少训练样本的情况,四种实验条件的设置在一定程度上可以反映 SAR 目标识别方法在不同小样本条件下的性能.

表 2 给出了上述四种小样本条件下,所提方法与其他三种小样本目标识别方法在迭代训练 500 次,每种方法在每种小样本条件下取得的最高识别准确率.

由表2可以看出,虽然三种方法在光学图像小样本目标识别任务中都表现出了优越的识别性能,但是在小样本SAR目标识别任务中,所提方法在设置的四种小样本条件下均获得了最高的识别准确率,表现出了一定的泛化性能。


可能的原因是,由于所提方法所设计的基于残差模块的学习器借助于跳跃连接能够有效传递有利于SAR目标识别的对比度信息,而且残差连接可以在不增加网络参数,不提高计算复杂度的基础上,搭建更深层次的网络结构,同时避免出现网络退化的问题。对于SAR图像目标而言,图像中的对比度信息对于目标识别而言较为重要,所设计的学习器中的跳跃连接可以有效地传递这种对比度信息,从而提高了识别准确率。除此之外,本文改进的元学习器能够以不同的元学习率学习到易于学习器优化的初始化参数和适应于每一个参数更新的学习率,从而避免了因为梯度消失和梯度爆炸导致的训练困难的问题。

表2 所提方法与三种小样本识别方法的对比实验结果


方法	10-way 1-shot	10-way 2-shot	10-way 5-shot	10-way 10-shot
Meta-LSTM ^[30]	0.828	0.841	0.885	0.911
MAML ^[31]	0.835	0.841	0.882	0.914
Matching Net ^[29]	0.627	0.683	0.804	0.834
所提方法	0.939	0.944	0.947	0.976

图6给出了所提方法与三种小样本识别方法在迭代训练500次过程中识别准确率的实时变化情况。其中图6(a)~(d)分别展示了“10-way 1-shot”, “10-way 2-shot”, “10-way 5-shot”和“10-way 10-shot”条件下训练500轮,不同方法识别准确率的变化情况。


可以看到,所提方法虽然存在学习缓慢的问题,但是最终识别准确率要远远高于其他三种小样本识别方法。分析所提方法学习缓慢的原因主要有以下几点,第一点,为了提取更丰富的目标特征,借助于跳跃连接,在不出现网络退化的前提下,搭建了较其他三种方法层数更深的学习器网络结构,所以在训练前期会出现学习缓慢的现象。第二点,其他三种小样本识别方法学习器参数优化更新的学习率是人为设定的,在整个训练过程中是不变的,这样做的优点在于参数优化过程中不需要考虑学习率大小变化的问题,可以凭借人的调参经验优势,使网络参数在训练前期能够快速朝着性能更好的方向更新优化,但是这样做的缺点在于容易使模型出现过拟合问题,使模型性能受限。而所提方法能够实现在训练过程中实时学习更新学习器每一个参数所对应的学习率的值,虽然学习过程会因此变得缓慢,但是这样做的优势在于能够在一定程度上克服过拟合问题,提高目标识别准确率,提升模型泛化性能。




(a) “10-way 1-shot”



(b) “10-way 2-shot”



(c) “10-way 5-shot”



(d) “10-way 10-shot”

图6 四种小样本条件下所提方法与其他三种小样本学习方法的识别准确率变化曲线

3.4 残差模块个数实验

由于跳跃连接具有不引入额外网络参数,不增加计算复杂度的优点,为搭建更深层次的网络结构而不出现退化问题提供了基础.为此,设置了实验探究残差模块的个数对小样本条件下 SAR 目标识别准确率的影响.分别将残差模块的个数设置为 1,2,3,4 和 5,探究其对模型识别准确率的影响.表 3 给出了学习器不同残差模块个数条件下,所提方法在四种不同小样本条件下达到的最高识别准确率.表中类似“10shot”的写法实际是“10-way 10-shot”的省略写法.

表 3 差模块个数对识别准确率的影响

残差模块个数	10shot	5shot	2shot	1shot
1	0.945	0.919	0.915	0.911
2	0.956	0.945	0.934	0.918
3	0.962	0.945	0.944	0.939
4	0.976	0.947	0.944	0.940
5	0.949	0.942	0.923	0.917

分析表 3 可以发现,在四种小样本条件下,不同数量的残差模块对模型最终的识别效果影响并不是很大,含有不同残差模块的模型在四种小样本条件下表现相差不大.尤其是在“10-way 1-shot”和“10-way 2-shot”两种小样本条件下,所提方法所达到的最高识别准确率对残差模块个数并不敏感.观察表 3 可以发现,在残差模块的个数为 4 个时,所提方法在四种小样本条件下均实现了最高的识别准确率,因此本文设计基于残差网络的学习器时,选用了 4 个残差模块.

3.5 鲁棒性能验证

为了验证所提方法在不同程度噪声干扰条件下对小样本 SAR 目标识别的性能,对其进行了噪声鲁棒性验证实验.分别在四种小样本条件下对原始 MSTAR 数据集中的 SAR 图像加入了高斯白噪声,验证所提方法在信噪比为“-10 dB”,“-5 dB”,“0 dB”,“5 dB”和“10 dB”的噪声环境下对小样本 SAR 目标的识别性能.表 4 展示了四种小样本条件下,每种小样本条件的 5 种信噪比环境下所提方法对 SAR 目标识别实现的最高识别准确率.

观察表 4 可知,在不同信噪比环境下,所提方法在四种小样本条件下均表现出了不同程度的鲁棒性.在“10-shot”和“5-shot”的条件下,所提方法在五种信噪比噪声环境下,识别准确率下降范围在 8 个百分点以内,表现出了对噪声较强的鲁棒性能尤其是在信噪比为“10 dB”的环境下,在上述两种小样本条件下,所提方法达到的最高识别准确率较无噪声环境下相比仅降低了

表 4 四种小样本条件下所提方法在不同信噪比环境下的最高识别准确率

小样本条件	SNR/dB	识别准确率
10-way 1-shot	-10	0.808
	-5	0.856
	0	0.857
	5	0.859
	10	0.894
10-way 2-shot	-10	0.821
	-5	0.880
	0	0.896
	5	0.908
	10	0.910
10-way 5-shot	-10	0.867
	-5	0.892
	0	0.908
	5	0.918
	10	0.927
10-way 10-shot	-10	0.893
	-5	0.908
	0	0.922
	5	0.932
	10	0.950

2 个百分点左右.

3.6 学习器参数的学习率随着训练过程的调整

正如上文提到的,改进的元学习器能够在训练过程中为学习器的每一个参数学习一个不同但是合适的学习率.为了更清楚地观察学习器参数对应的学习率的学习变化情况.

从学习器所有参数中随机挑选了 80 个参数,图 7 展示了与这 80 个参数相对应的学习率随着训练过程的调整情况,其中图 7(a)~(d)分别展示了“10-way 1-shot”,“10-way 2-shot”,“10-way 5-shot”和“10-way 10-shot”四种小样本条件下,学习器 80 个参数,每个参数所对应的学习率的值随着训练过程的学习变化情况.横轴表示从学习器参数中随机挑选的 80 个参数,纵轴表示学习率的值.红色五角星表示学习率的初始值为 0.001,每训练 100 次,保存上述 80 个参数所对应的学习率的值,一共训练了 500 次,不同训练次数的所对应的学习率的值在图中用不同的标志表示.

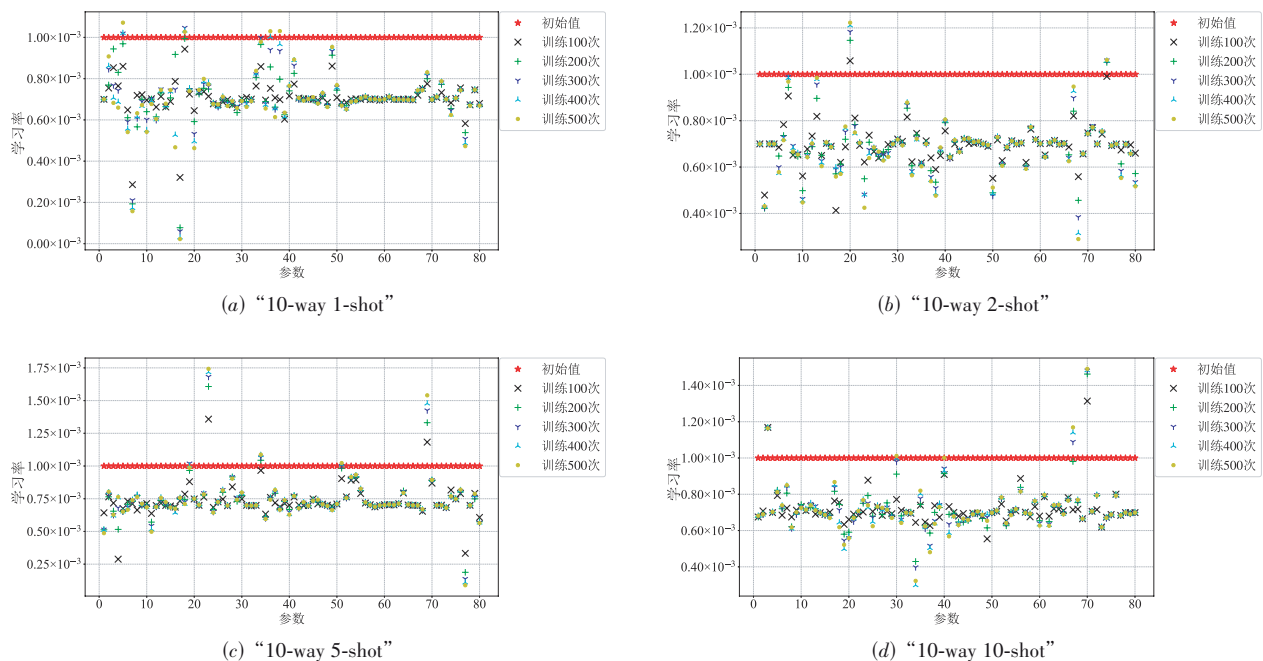


图7 四种小样本条件下元学习器学习到的与学习器参数相对应的学习率大小随着训练过程的调整

4 总结

针对小样本条件下 SAR 目标识别存在的易过拟合, 识别准确率低, 模型泛化能力差的问题, 提出了一种新颖的基于元学习的, 面向小样本条件下 SAR 目标识别的方法, 叫做特征注意力融合元残差网络. 在该方法中, 在残差网络的基础上设计了学习器, 跳跃连接既不增加网络的训练参数, 也不增加网络的计算复杂度, 可以在避免出现网络退化问题的基础上, 搭建层次更深的学习器网络, 从而提取更丰富的目标特征, 而且跳跃连接能够有效地传递 SAR 图像中的对比度信息, 使得新设计的学习器更加适合处理 SAR 图像数据. 改进了原始的 Meta-SGD 元学习器, 改变了改进前学习器参数和对应的学习率糅合在一起进行学习的方式, 将学习器参数和对应的学习率分离开来以不同的元学习率进行学习, 避免了改进前经常遇到的梯度消失和梯度爆炸的问题, 降低了训练难度. 基于 MSTAR 数据集对所提方法进行了验证性实验, 与其他三种小样本学习方法进行对比, 所提方法在识别准确率以及稳定度方面均表现出了一定的优势. 进行了网络结构的消融实验和模型的鲁棒性验证实验, 证明了所提方法具有一定的鲁棒性. 展示了元学习器学习到的与学习器参数相对应的学习率的值, 为后续研究不同任务、不同类型参数学习率的规律以及研究构造合适的元学习器去学习其他网络超参数的工作奠定了基础.

参考文献

- [1] BARTON D K, LEONOV S A. Radar Technology Encyclopedia[M]. London: Artech House, 1998.
- [2] 胡利平. 合成孔径雷达图像目标识别技术研究[D]. 西安: 西安电子科技大学, 2009.
HU L P. Study on SAR Images Target Recognition[D]. Xi'an: Xidian University, 2009. (in Chinese)
- [3] 庞礴. 多通道 SAR 成像理论与方法研究[D]. 长沙: 国防科学技术大学, 2014.
PANG B. Study on the Imaging Theory and Method of Multi-Channel SAR[D]. Changsha: National University of Defense Technology, 2014. (in Chinese)
- [4] LI Y Y, ZHOU L H, PENG C, et al. Spatial fuzzy clustering and deep auto-encoder for unsupervised change detection in synthetic aperture radar images[C]//IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2018: 4479-4482.
- [5] RAN L, LIU Z, LI T, et al. Extension of map-drift algorithm for highly squinted SAR autofocus[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(9): 4032-4044.
- [6] SHI L J, KARVONEN J, CHENG B, et al. Sea ice thickness retrieval from SAR imagery over Bohai Sea[C]//2014 IEEE Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2014: 4864-4867.
- [7] 赵鹏菲, 黄丽佳. 一种基于 EfficientNet 与 BiGRU 的多角

- 度 SAR 图像目标识别方法[J]. 雷达学报, 2021, 10(6): 895-904.
- ZHAO P F, HUANG L J. Target recognition method for multi-aspect synthetic aperture radar images based on EfficientNet and BiGRU[J]. Journal of Radars, 2021, 10(6): 895-904. (in Chinese)
- [8] 郭倩, 王海鹏, 徐丰. SAR 图像飞机目标检测识别进展[J]. 雷达学报, 2020, 9(3): 497-513.
- GUO Q, WANG H P, XU F. Research progress on aircraft detection and recognition in SAR imagery[J]. Journal of Radars, 2020, 9(3): 497-513. (in Chinese)
- [9] ZHANG J S, XING M D, XIE Y Y. FEC: A feature fusion framework for SAR target recognition based on electromagnetic scattering features and deep CNN features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(3): 2174-2187.
- [10] CHEN L, JIANG X, LI Z, et al. Feature-enhanced speckle reduction via low-rank and space-angle continuity for circular SAR target recognition[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(11): 7734-7752.
- [11] OH J, YOUM G Y, KIM M. SPAM-net: A CNN-based SAR target recognition network with pose angle marginalization learning[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31(2): 701-714.
- [12] GUO Y C, DU L, WEI D, et al. Robust SAR automatic target recognition via adversarial learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 14: 716-729.
- [13] CHO J H, PARK C G. Multiple feature aggregation using convolutional neural networks for SAR image-based automatic target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(12): 1882-1886.
- [14] GAO F, HUANG T, SUN J P, et al. A new algorithm for SAR image target recognition based on an improved deep convolutional neural network[J]. Cognitive Computation, 2019, 11(6): 809-824.
- [15] YANG R, HU Z T, LIU Y M, et al. A novel polarimetric SAR classification method integrating pixel-based and patch-based classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(3): 431-435.
- [16] LI L P, LIU J, SU L Y, et al. A novel graph metalearning method for SAR target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [17] MARGARIT G, MALLORQUI J J, FORTUNY-GUASCH J, et al. Exploitation of ship scattering in polarimetric SAR for an improved classification under high clutter conditions[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(4): 1224-1235.
- [18] 张晰, 张杰, 纪永刚, 等. 基于结构特征的 SAR 船只类型识别能力分析[J]. 海洋学报, 2010, 32(1): 146-152.
- ZHANG X, ZHANG J, JI Y G, et al. The capability analysis of ship classification by structure feature using SAR images[J]. Acta Oceanologica Sinica, 2010, 32(1): 146-152. (in Chinese)
- [19] RAEISI A, AKBARIZADEH G, MAHMOUDI A. Combined method of an efficient cuckoo search algorithm and nonnegative matrix factorization of different zernike moment features for discrimination between oil spills and lookalikes in SAR images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(11): 4193-4205.
- [20] DING B Y, WEN G J. Target reconstruction based on 3-D scattering center model for robust SAR ATR[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(7): 3772-3785.
- [21] SUKAWATTANAVIJIT C, CHEN J, ZHANG H S. GA-SVM algorithm for improving land-cover classification using SAR and optical remote sensing data[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(3): 284-288.
- [22] SUN Y J, LIU Z P, TODOROVIC S, et al. Adaptive boosting for SAR automatic target recognition[J]. IEEE Transactions on Aerospace and Electronic Systems, 2007, 43(1): 112-125.
- [23] SRINIVAS U, MONGA V, RAJ R G. SAR automatic target recognition using discriminative graphical models[J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(1): 591-606.
- [24] HUA W Q, ZHANG C, XIE W, et al. Polarimetric SAR image classification based on ensemble dual-branch CNN and superpixel algorithm[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 5: 2759-2772.
- [25] ZHAO Z Q, JIAO L C, ZHAO J Q, et al. Discriminant deep belief network for high-resolution SAR image classification[J]. Pattern Recognition, 2017, 61: 686-701.
- [26] WANG J L, HOU B, JIAO L C, et al. POL-SAR image classification based on modified stacked autoencoder network and data distribution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(3): 1678-1695.
- [27] QIN F C, GUO J M, SUN W D. Object-oriented ensemble

- ble classification for polarimetric SAR imagery using restricted Boltzmann machines[J]. Remote Sensing Letters, 2017, 8(3): 204-213.
- [28] 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.
- [29] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. 2016: 3637-3645.
- [30] RAVI S, LAROCHELLE H. Optimization as a model for few-shot learning[EB/OL]. (2016-11-05) [2021-09-11]. <https://openreview.net/pdf?id=rJY0-Kcll>.
- [31] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[EB/OL]. (2017-03-09)[2021-09-11]. <https://arxiv.org/abs/1703.03400>.
- [32] LI Z G, ZHOU F W, CHEN F, et al. Meta-SGD: Learning to learn quickly for few-shot learning[EB/OL]. (2017-07-31)[2021-09-11]. <https://arxiv.org/abs/1707.09835>.
- [33] LIU T, LUO W, MA L, et al. Coupled network for robust pedestrian detection with gated multi-layer feature extraction and deformable occlusion handling[J]. IEEE Transactions on Image Processing, 2020, 30: 754-766.
- [34] 王程丽, 赵静, 杨攀攀, 等. 基于迁移学习的小样本 SAR 船只目标识别[J]. 移动通信, 2022, 46(4): 22-27.
WANG C L, ZHAO J, YANG P P, et al. The target recognition of small sample SAR ship based on transfer learning[J]. Mobile Communications, 2022, 46(4): 22-27. (in Chinese)
- [35] TAI Y, TAN Y H, XIONG S Z, et al. Few-shot transfer learning for SAR image classification without extra SAR samples[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 2240-2253.
- [36] 高飞, 赵洁琼, 林翀, 等. 基于距离度量学习的 SAR 图像识别方法[J]. 北京理工大学学报, 2021, 41(3): 334-340.
GAO F, ZHAO J Q, LIN C, et al. A SAR image recognition method based on distance metric learning[J]. Transactions of Beijing Institute of Technology, 2021, 41(3): 334-340. (in Chinese)
- [37] WANG L, BAI X R, GONG C, et al. Hybrid inference network for few-shot SAR automatic target recognition [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(11): 9257-9269.
- [38] YANG M J, BAI X R, WANG L, et al. Mixed loss graph attention network for few-shot SAR target classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [39] WANG S Y, WANG Y H, LIU H W, et al. Attribute-guided multi-scale prototypical network for few-shot SAR target classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 12224-12245.
- [40] FU K, ZHANG T F, ZHANG Y, et al. Few-shot SAR target classification via metalearning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [41] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7132-7141.
- [42] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//European Conference on Computer Vision. Cham: Springer, 2018: 3-19.

作者简介



刘旗男, 1996年出生于山东青岛, 国防科技大学博士研究生在读, 主要研究方向为深度学习、小样本学习、元学习及其在雷达目标识别领域的应用. 中国电子学会会员编号: E190084434M.

E-mail: liuqi19c@163.com



刘永祥(通讯作者)男, 1976年出生河北唐山, 国防科技大学教授、博士生导师, 主要研究方向为雷达目标识别、时频分析和微动. 中国电子学会会员编号: E190002703S.

E-mail: lyx_bible@sina.com



张新禹男, 1990年出生于湖南衡阳, 国防科技大学副教授, 硕士生导师, 主要研究方向为阵列信号处理, 自动目标检测和波形优化.

E-mail: zhangxinyu90111@163.com