

# SAR-LAM: 面向小样本 SAR 目标识别的轻量化适应策略

史松昊, 王晓丹

(空军工程大学防空反导学院, 西安, 710051)

**摘要** 针对小样本学习中跨域迁移导致模型性能下降的问题, 提出一种面向小样本 SAR 目标识别的轻量化适应策略(SAR-LAM)。该方法通过知识蒸馏预训练一个具有泛化性能的通用编码器, 向其中嵌入一个只在少量目标域样本上进行训练的适应模块, 而后将提取的特征映射到一个分辨性更高的空间内, 最终以原型网络为基线对查询集样本进行分类。该适应策略以增加少量学习参数为代价, 克服了数据分布差异导致模型迁移受限的困难, 增强了模型在目标域提取特征的能力, 在小样本条件下将 SAR 目标识别的准确率提升了至少 1.93 个百分点, 较其他方法展现出一定的优越性。

**关键词** SAR 目标识别; 跨域小样本学习; 轻量化

**DOI** 10.3969/j.issn.2097-1915.2024.03.015

**中图分类号** TP183 **文献标志码** A **文章编号** 2097-1915(2024)03-0103-09

## SAR-LAM: A Lightweight Adaptation Method Being Geared to Few-Shot SAR Target Recognition

SHI Songhao, WANG Xiaodan

(Air Defense and Antimissile School, Air Force Engineering University, Xi'an 710051, China)

**Abstract** In view of the issue of model performance degradation caused by cross-domain transfer in few-shot learning, a lightweight adaptation strategy for few-shot SAR target recognition named SAR-LAM is proposed. This method is to utilize knowledge distillation for pre-training a generalized encoder and embedding an adaptation module trained only with very few target domain samples. The extracted features are then mapped into a more discriminative space, and finally, the query set samples are classified by taking a prototypical network as the baseline. This adaptation strategy is to increase at a few cost in learning parameters, and by so doing, the limitations of model transfer caused by data distribution differences is overcome, improving the model's ability to extract features in the target domain, and simultaneously improving the accuracy of SAR target recognition by at least 1.93 percentage points under few-shot conditions. And this adaptation strategy is superior in performance to the other methods.

**Key words** SAR target recognition; cross-domain few-shot learning; lightweight

合成孔径雷达(synthetic aperture radar, SAR)具备不受天时和气候影响的传感器信息获取能力, 已成

收稿日期: 2023-12-27

基金项目: 国家自然科学基金(61876189, 61703426, 61806219)

作者简介: 史松昊(1994-), 男, 陕西大荔人, 硕士生, 研究方向为目标识别、小样本学习。E-mail: cutee\_squirrel@163.com

通信作者: 王晓丹(1966-), 女, 陕西安康人, 教授, 博士, 研究方向为智能信息处理。E-mail: shiningvv@yeah.net

**引用格式:** 史松昊, 王晓丹. SAR-LAM: 面向小样本 SAR 目标识别的轻量化适应策略[J]. 空军工程大学学报, 2024, 25(3): 103-111. SHI Songhao, WANG Xiaodan. SAR-LAM: A Lightweight Adaptation Method Being Geared to Few-Shot SAR Target Recognition[J]. Journal of Air Force Engineering University, 2024, 25(3): 103-111.

为军事领域目标情报信息获取的重要手段<sup>[1-2]</sup>。SAR 自动目标识别(automatic target recognition, ATR)技术通过图像数据处理和信息解译,可以将复杂的 SAR 图像转化为有用情报信息。SAR-ATR 技术需要大量的样本进行训练,而在实际情况中却往往无法满足这一条件,原因有三:一是 SAR 图像由专业设备产生,只有少部分专业人士才能获得,一般研究人员无法获得大量样本;二是 SAR 图像样本通常无法公开,现有的公开数据集也较少,尤其是军事领域,很难获取高质量、数量多的样本;三是 SAR 图像成像机制与普通光学图像不同,成像频率超出了可见光范围,需要经过专业人员进行标注,人工成本较高。因此 SAR 目标识别是一个天然的小样本学习问题,在小样本条件下获得较好的识别率具有重要研究价值。

针对这一问题,刘旗等提出一种特征注意力融合的元残差网络,利用残差结构有效传递 SAR 图像的对比度信息,通过多尺度特征注意力融合模块不同的残差层特征,为目标识别提供更丰富的特征信息<sup>[3]</sup>;应自炉等提出一种自注意力多尺度特征融合网络,将注意力机制与幽灵模块相结合提取特征,并通过添加通道混洗单元构建多尺度信息融合支路完成目标识别,最后使用知识蒸馏缩减模型参数量<sup>[4]</sup>;张翼鹏等通过散射关键点构建拓扑结构,以表征 SAR 目标的结构和形状特征,并计算拓扑结构的拉普拉斯矩阵,最后将 SAR 图像和拉普拉斯矩阵分别作为双分支网络的输入进行特征提取<sup>[5]</sup>。虽然以上方法获得了一定效果,但都未引入充足的先验知识,因此模型存在泛化性能不强、容易过拟合等缺陷,而本文利用迁移学习的思想则能够较好地克服这类问题。

预先学习可迁移的先验知识是解决小样本学习问题富有竞争力的方法,即利用一个或多个其他成熟领域(源域)上的先验知识,去完成另一个缺少样本领域(目标域)上的小样本学习任务,由于迁移过程存在较大的域跨度,因此被称为跨域小样本学习<sup>[6]</sup>。目前跨域小样本学习大多是在光学图像领域进行的,如 Dvornik 等和 Liu 等对多个源域中提取出的不同特征进行组合,前者采用一种固定系数加权的方法,后者采用一种基于注意力机制的加权方法,从而获得对目标域的通用表征,再进行小样本分类<sup>[7-8]</sup>;Requeima 等和 Bateni 等调整基于 FiLM 层<sup>[9]</sup>的特定任务适应模块,让模型的编码器适应目标域的分布,便于下一步提取出泛化性更好的表征,其中 FiLM 层是指一种通道仿射变换,以串行方式与主干网络相连接<sup>[10-11]</sup>。然而以上 2 种做法中,多源域加权表征的方法需要学习庞大的参数,往往需

要训练成倍的时间才能收敛;建立串行适应模块的方式则加深了神经网络的结构,容易造成梯度爆炸或消失等问题,导致模型无法训练。

对于以上方法存在的不足,本文提出一种面向小样本 SAR 目标识别的轻量化适应策略(SAR-lightweight adaption method, SAR-LAM),主要创新点如下:

1)由于多个源域存在数据不均衡现象,直接采取有监督的预训练会导致模型存在偏见,因此本文提出一种基于知识蒸馏的预训练方式,用于训练一个泛化性好的通用编码器。

2)将预训练的编码器直接迁移到目标域提取特征存在局限性,原因在于源域与目标域的样本分布存在巨大差异,因此本文提出一种轻量化的编码器目标域自适应方法,让模型能够仅以少量参数为代价,学习到更好的表征能力。

3)为了在非常有限的样本中实现更准确地分类,本文提出一种能够适应目标域的特征对齐模块,以增大样本类间距离、缩小样本类内距离,更好地实现小样本分类任务。

4)实验表明,与其它小样本学习方法相比,本文所提方法在 SAR 图像数据集 MSTAR 上表现出了较好的分类效果。

## 1 面向小样本 SAR 目标识别的轻量化适应策略

1.1 节首先介绍了具体问题定义和符号说明,1.2 节阐述了如何在多个光学源域  $D_s$  上训练通用编码器  $f$ ,1.3 节介绍了将该编码器从源域迁移到目标域后进一步适应目标域特性的方法,1.4 节说明了如何将目标域样本编码后映射到一个更容易分辨的特征空间内,便于后续分类。通过以上步骤,模型可以从光学源域中获得有利的先验知识,并适应目标域样本分布特点,从而克服跨域带来的不利影响,更加准确地完成 SAR 图像的小样本分类任务。

### 1.1 问题定义

小样本学习旨在学习如何仅从少量现有的样本中分辨出新类别的样本,每个小样本学习任务都由 1 个含有  $|S|$  个样本的支持集  $S = \{(x_i, y_i)\}_{i=1}^{|S|}$  和 1 个含有  $|Q|$  个待分类样本的查询集  $Q = \{(x_i)\}_{j=1}^{|Q|}$  组成,其中  $x_i$  为第  $i$  个样本, $y_i$  为对应的标签。

跨域小样本学习的过程是先在光学源域  $D_s$  上预训练编码器  $f$ ,获得参数的最优初始化点,然后在 SAR 目标域  $D_t$  上进行元训练微调,最后冻结编码

器参数对目标域样本提取特征,从而在  $D_i$  的支持集  $S$  上学习一个能够准确预测查询集  $Q$  样本类别的分类器,这一过程称为元测试阶段。

## 1.2 基于知识蒸馏的预训练

学习一个与任务无关的通用表征是小样本学习过程中成功进行域泛化的关键<sup>[12]</sup>,常用的方法包括训练一个通用的编码器<sup>[13]</sup>和多种特征加权融合<sup>[7-8]</sup>2种方式,后者需要通过多个编码器计算每个样本的特征,计算成本较高,因此主要考虑前者。

为了提高编码器的表征能力,获得更强大、泛化性更强的通用表征,可以采用多域学习(multi-domain learning, MDL)的方法进行训练,对于分布迥异的 SAR 图像目标域更需要这样的支持。1个典型的 MDL 过程<sup>[12]</sup>即最小化下式,在  $K$  个不同源域的样本上来优化网络参数:

$$L_{MDL} = \min_{\varphi, \psi_k} \sum_{k=1}^K \frac{1}{|D_k|} \sum_{x, y \in D_k} \ell(g_{\psi_k} \circ f_{\varphi}(x), y) \quad (1)$$

式中: $\ell$ 为交叉熵损失; $f_{\varphi}$ 为以  $\varphi$  为参数的编码器,在  $K$  个源域上共享参数,对样本进行编码后输出  $d$  维的特征; $g_{\psi_k}$ 为以  $\psi_k$  为参数的针对第  $k$  个域的分类器; $\circ$ 代表复合运算。虽然优化式(1)最终可以得到1个多域编码器  $f_{\varphi}$ ,但相关研究指出<sup>[14-15]</sup>,由于不同训练任务之间会存在干扰,且数据集大小和提取特征的难度也各不相同<sup>[16-17]</sup>,最终通用编码器的表征能力甚至不如单个域的编码器,因此本文采用知识蒸馏的方法获得通用编码器,知识蒸馏一般包括教师网络和学生网络,而学生网络提炼知识的过程主要包括目标蒸馏和特征蒸馏2个过程。

目标蒸馏方法的主要思想是让学生网络直接模仿教师网络的最终预测<sup>[18]</sup>,即通过最小化教师网络和学生网络输出的 logits 分布差异来训练学生网络的参数,这一过程等价于最小化下式:

$$L_{logits} = \ell^p(g_{\psi_k} \circ f_{\varphi}(x), g_{\psi_k^*} \circ f_{\varphi_k^*}(x)) \quad (2)$$

式中: $\ell^p$ 为 KL 散度; $g_{\psi_k} \circ f_{\varphi}(x)$ 和  $g_{\psi_k^*} \circ f_{\varphi_k^*}(x)$ 分别代表输入样本为  $x$  时学生网络和教师网络输出

的 logits 向量。

SAR 图像的特殊成像机制使其具有丰富的纹理特征、边缘特征等低层语义信息,这就要求预训练得到的编码器充分挖掘样本的底层特征,因此需要引入特征蒸馏方法,让学生模型充分学习到教师模型提取中间层特征的能力。然而给定同一个输入,教师网络和学生网络的输出特征仍旧可能存在很大差异,直接使用距离度量函数对特征的相似性进行度量存在局限性,模型会丧失非线性度量的能力。受到 Kornblith 等工作的启发<sup>[19]</sup>,本文采用中心核对齐(center kernel alignment, CKA)的方法将提取的特征映射到同一个更高维的空间中进行比较,该映射模块记为  $A_{\theta_k} \in \mathbb{R}^{d \times d}$ ,其参数与通用编码器一起进行训练,记为  $\theta_k$ 。以上过程等价于最小化下式:

$$L_d = \ell^f(A_{\theta_k} \circ f_{\varphi}(x), f_{\varphi_k^*}(x)) \quad (3)$$

式中: $\ell^f$ 为特征空间内的距离度量函数,一般取欧氏距离或余弦相似度。映射模块  $A_{\theta_k}$  的激活函数选择高斯函数  $\varphi(x, z) = \exp(-\frac{\|x-z\|^2}{2\sigma^2})$ ,能够将原特征编码成更高维度的表征,从而区分原特征之间的非线性相似性。

综上,学生网络不仅需要学会在多个源域中提取特征,并且需要其提取的特征以及最终的结果与教师网络尽可能接近,因此建立在式(1)~(3)的基础上,可以得到预训练阶段的损失函数:

$$L_u = \min_{\varphi, \psi_k, \theta_k} \sum_{k=1}^K \frac{1}{|D_k|} \sum_{x, y \in D_k} (\ell(g_{\psi_k} \circ f_{\varphi}(x), y) + \lambda_k^p (\ell^p(g_{\psi_k} \circ f_{\varphi}(x), g_{\psi_k^*} \circ f_{\varphi_k^*}(x)) + \lambda_k^f (\ell^f(A_{\theta_k} \circ f_{\varphi}(x), f_{\varphi_k^*}(x)))) \quad (4)$$

式中: $\lambda_k^p$ 和  $\lambda_k^f$ 为超参数,分别控制 logits 蒸馏损失和特征蒸馏损失的贡献程度。优化式(4)的目的是获取一个通用编码器  $f_{\varphi}$ ,在中心核对齐映射模块  $A_{\theta_k}$  的作用下,提取的特征需要和教师网络尽可能相近,并且能够预测真实的样本类别  $y_i$ ,蒸馏过程如图1所示。

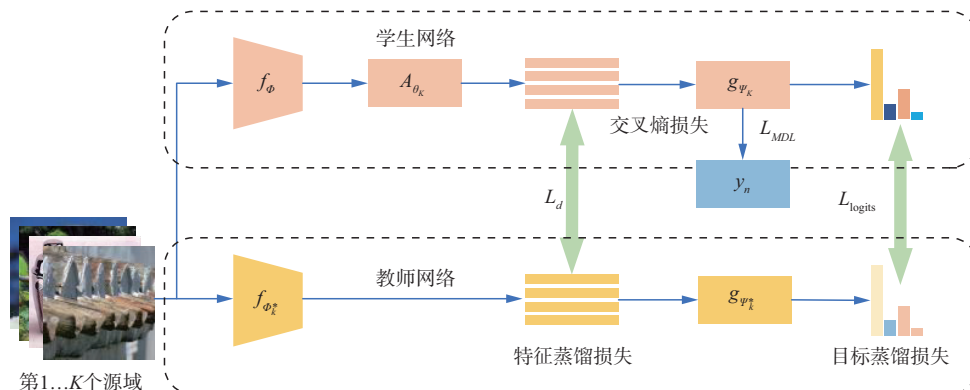


图1 知识蒸馏过程示意图

### 1.3 编码器自适应方法

Luo 等的研究工作指出,当域间隙很大导致编码器学习到的特征空间在新的目标域上发生变化时,基于微调或 backbone 的自适应策略可以获得较好的性能<sup>[20]</sup>。而由于 SAR 图像存在大量的散斑噪声,在纹理、边缘等低层语义信息就与光学图像存在较大差异,主要针对高层语义信息的微调策略无法让模型在 SAR 图像上拥有更为全面的分辨能力,并且这一策略往往会出现优化不均衡的问题,即需要从少量支持集样本中更新非常高维的权重,因此本文提出一种面向 SAR 图像目标域的 backbone 自适应策略,具体来说就是将适应模块附加在 ResNet<sup>[21]</sup> 的每一个卷积块之中,从而让编码器能够从少量样本中高效地学习。令  $f_{\varphi_l}$  表示 ResNet 中第  $l$  层的卷积运算,权重为  $\varphi_l$ ,其输出的特征由适应模块  $r_a$  变换后表示为:

$$f_{\{\varphi_l, \alpha\}}(\mathbf{h}) = r_a(f_{\varphi_l}(\mathbf{h}), \mathbf{h}) \quad (5)$$

式中:  $\mathbf{h} \in R^{W \times H \times C}$  为该层输入的张量。

对于适应模块嵌入编码器  $f_{\varphi}$  的方式,存在 2

种常见的连接类型:

1) 串行连接又称为 FiLM 结构<sup>[11]</sup>,也就是将卷积层的输出作为适应模块的输入:

$$f_{\{\varphi_l, \alpha\}}(\mathbf{h}) = r_a \circ f_{\varphi_l}(\mathbf{h}) \quad (6)$$

2) 并行连接又称为残差结构,即适应模块和卷积层共用同一个输入,而后将输出融合:

$$f_{\{\varphi_l, \alpha\}}(\mathbf{h}) = r_a(\mathbf{h}) + f_{\varphi_l}(\mathbf{h}) \quad (7)$$

对于  $r_a$  的参数化方式,本文优选 2 种形式:

1) 矩阵乘法

$$r_a(\mathbf{h}) = \mathbf{h} * \alpha \quad (8)$$

式中:  $*$  为以  $1 \times 1$  为卷积核的卷积运算,对于某一层输入维度  $C_{in}$  和输出维度  $C_{out}$  不同的神经网络,可以使用  $\alpha \in R^{C_{in} \times C_{out}}$ ,由于本文使用 ResNet 架构,其中大多数的输入和输出维度是相同的,因此  $\alpha \in R^{C \times C}$ 。

2) Hadamard 积

$$r_a(\mathbf{h}) = \mathbf{h} \odot \alpha \quad (9)$$

式中:  $\alpha \in R^C$ ,具体结构如图 2 所示。

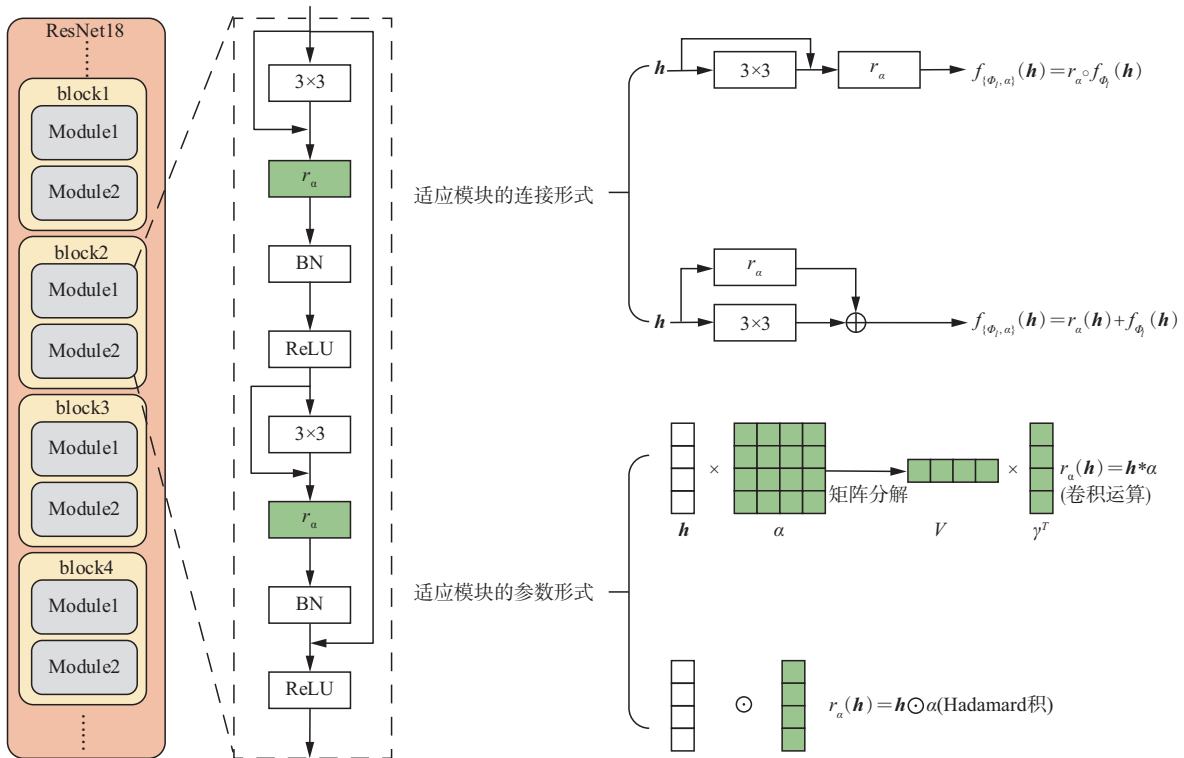


图 2 基于 backbone 的轻量化适应模块

为降低矩阵乘法中  $\alpha$  的维度,通过矩阵分解后表示为:  $\alpha = V\gamma^T$ ,其中  $V \in R^{C \times B}$ ,  $\gamma \in R^{C \times B}$ ,且  $B \ll C$ ,具体设置为  $B < \frac{C}{2}$ ,从而减少运算过程中的参数量,以上结构带来的增益以及最优组合方案参见实验部分 3.3.3。

### 1.4 特征对齐模块

由于 SAR 图像的特殊成像机制导致其存在较大的类内差异和较小的类间差异性,在元测试阶段,使用训练得到的通用编码器  $\{f_{\theta}(x_i)\}_{i=1}^{|S|}$  来提取 SAR 图像目标域特征后,为避免直接分类可能导致的性能下降问题,本文提出一种特征对齐模块  $C_{\tau}$ :

$R^d \rightarrow R^d$ , 将输出的特征映射到一个更容易分辨的空间, 这一模块是在目标域的支持集上训练得到的,

能够充分适应目标域的特点, 从而实现更好的分类效果, 元测试阶段流程如图 3 所示。

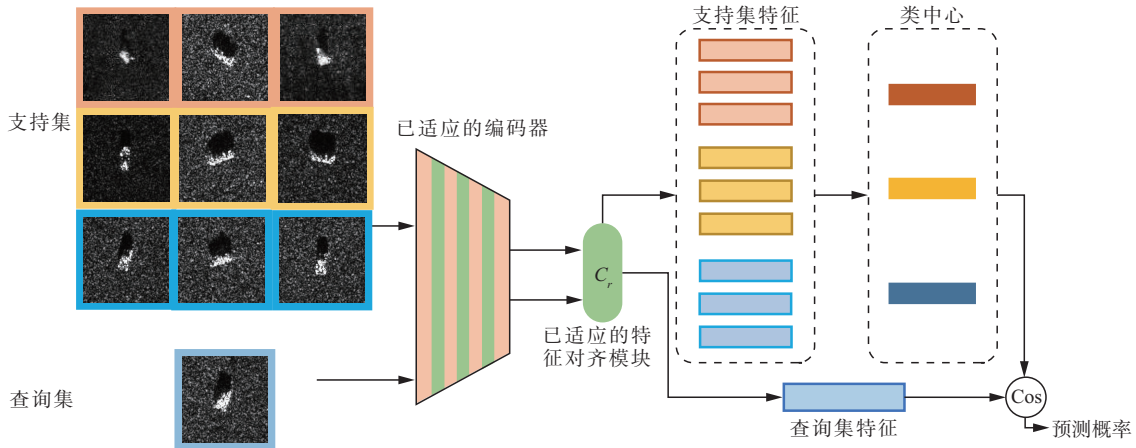


图 3 元测试阶段示意图

令  $z_i = \{C_\tau \circ f_\theta(x_i)\}_{i=1}^{|S|}$ , 即经过  $C_\tau$  转换后的特征。本文采用原型网络<sup>[22]</sup>的框架, 得到转换后特征的类中心:

$$c_j = \frac{1}{|S_j|} \sum_{z_i \in S_j} z_i, S_j = \{z_k : y_k = j\}, j = 1, 2, \dots, N \quad (10)$$

$N$  为支持集样本的类别数量, 支持集某一个样本  $z$  属于某一个类别  $l$  的概率为:

$$p(y = l | z) = \frac{\exp(-d(z, c_l))}{\sum_{j=1}^c \exp(-d(z, c_j))} \quad (11)$$

式中:  $d(z, c_l)$  为欧氏距离, 通过优化下式得到  $\tau$ :

$$L_{\text{test}} = \min_{\tau} \frac{1}{|S|} \sum_{(x_i, y_i) \in S} \log(p(y = y_i | x_i)) \quad (12)$$

从而得到模块  $C_\tau$ , 通过结合式(10)得到特征中

心点  $c_j$ 、评估查询集  $Q$  中的每个样本和中心点  $c_j$  的距离, 并进行分类预测。

综上, 由于第一阶段多个源域之间存在数据不均衡现象, 为了平衡从不同大小的源域中学习到的知识, 消除数据偏见, 本文首先针对每个源域进行基于交叉熵损失的有监督学习, 分别获得特定域的编码器, 而后采取知识蒸馏的方法获得一个具有泛化能力的通用编码器; 第二阶段, 为了进一步适应目标域特点, 将在通用编码器中加入一个适应模块, 冻结其余参数之后, 该模块参数只在目标域的支持集上进行学习, 最后采取元学习框架, 将提取到的样本特征映射到一个分辨性更高的空间内, 再计算出支持集的类中心, 并完成查询集的分类, 整体流程如图 4 所示。

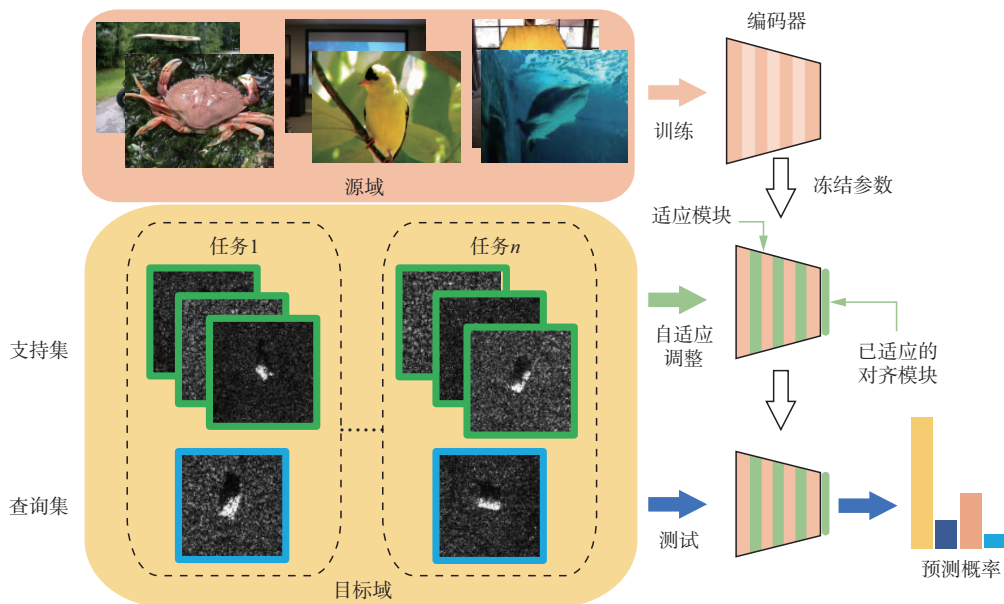


图 4 整体流程图

## 2 实验设置

### 2.1 实验数据集

Meta-dataset<sup>[23]</sup>自2020年被提出后,就成为跨域小样本学习的主要基准,它包含10个子数据集:ILSVRC\_2012(ImageNet)、Omniglot、FGVC-Aircraft(Aircraft)、CUB-200-2011(Birds)、Describable Textures(DTD)、QuickDraw、FGVCx Fungi、VGG Flower(Flower)、Traffic Signs以及MSCOCO。实验将前8个数据集作为预训练阶段获取通用编码器的光学源域,其中每个数据集都被划分为训练集、测试集和验证集3个部分。

用于目标域识别的SAR图像数据集为MSTAR,由美国桑迪亚国家实验室高分辨率的聚束式合成孔径雷达采集多种前苏联目标军事车辆的SAR图像形成,涵盖BMP2、BTR70、T72、BTR60、2S1、BRDM2、D7、T62、ZIL131、ZSU23/4共计10种型号。成像角度主要分为15°和17°两部分,在0°~360°方位角下,每隔1°~2°获取1次目标切片图像,每1类有200张左右的样本,都裁切为84×84的尺寸,且将每张图片的目标放在正中心。该数据集在实验中划分为:15°的10类目标作为训练集、17°的随机5类目标作为测试集、剩余5类目标作为验证集,详情见表1。

表1 数据集构成

数据集	内容	划分类别数量 (训练/验证/测试)
普通 光学 图像	ImageNet	大型可视化数据集 1 000(712/158/130)
	Omniglot	手写字符 1 623(883/81/659)
	Aircraft	飞机 100(70/15/15)
	Birds	鸟类 200(140/30/30)
	Describable Textures	纹理 47(33/7/7)
	Quickdraw	手绘图 345(241/52/52)
	Fungi	真菌类 1 394(994/200/200)
	Flower	花类 102(71/15/16)
SAR 图像	MSTAR	10类前苏联车辆(SOC) 20(10(15°)/5(17°)/5(17°))

### 2.2 实验设置及评估指标

进行实验的硬件环境为Ubuntu 22.04.2版本,在CUDA 11.8环境下运行,使用Python3.7语言、tensorflow-gpu2.4.1和pytorch1.7.0深度学习框架,硬件配置为Nvidia GeForce RTX 3080Ti。为了与其它跨域小样本方法进行比较,实验沿用Li等

相关工作,以ResNet-18为骨干网络,样本像素大小为84×84<sup>[17]</sup>。元测试阶段从目标域数据集中随机抽样组成600个任务,采用Adadelta<sup>[24]</sup>优化器以及余弦退火的学习率迭代方法,迭代次数设为50 000次,超参数 $\kappa_n^p$ 和 $\kappa_n^f$ 在分别设置为4和1。

本文采用了4种指标进行分类情况的评估:

1)准确率(Accuracy),指分类正确的样本数量与总样本数量之比:

$$Accuracy = \frac{\sum_{r=1}^N X_r}{\sum_{r=1}^N X_r + \sum_{r=1}^N \sum_{l=1}^N Y_{r,l}, (r \neq l)} \quad (13)$$

2)精确率(Precision),指被正确预测为正类别的样本数量与所有被预测为正类别的样本数量之比:

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

3)召回率(Recall),指被正确预测为正类别的样本数量与所有真正正类别的样本数量之比:

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

4)F1分数(F1-score),指精确率和召回率的调和平均值,综合考虑了两者的表现:

$$F1 \text{ score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (16)$$

在上述公式中, $N$ 为训练集标签的总数, $TP$ 为真正类, $FN$ 为假负类, $FP$ 为假正类, $X_r$ 表示数据集中真实标签为 $r$ 的样本中被正确分类的数量, $Y_{r,l}$ 则表示这些样本被错误分类为类别 $l$ 的数量。

## 3 实验结果及分析

为评估本文提出的SAR-LAM模型的性能,本节设计了以下实验:

实验1:对比实验,与Prototypical Network等经典小样本学习方法以及SUR<sup>[7]</sup>等跨域小样本学习方法在SAR图像领域的分类效果进行对比。

实验2:适应模块的嵌入方式分析,主要从嵌入位置以及参数量2个方面进行验证。

实验3:消融实验,对比了适应模块的不同连接结构对分类结果的影响,并验证了其它模块的有效性。

### 3.1 对比实验

采用3种实验设定:N-way K-shot方式为依照表1进行数据集划分后的训练测试结果,为便于比较,后续实验结果统一将其作为默认设置;N-way 5-shot表示小样本学习任务的支持集由N类样本(每

类 5 个)组成,5-way 1-shot 表示小样本学习任务支持集由 5 类样本(每类 1 个)组成,其中查询集样本数量为 15,所有实验结果均为 95%置信度的平均分类准确率,可学习参数只代表模型可优化的参数量,不包括骨干网络参数。将 SAR-LAM 与 Prototypical Network<sup>[22]</sup>(PN)、Matching Network<sup>[25]</sup>(MN)、Relation Network<sup>[26]</sup>(RN)以及 MAML<sup>[27]</sup> 4 种经典小样本方法,以及 SUR、SUR-pnf<sup>[7]</sup>、URT<sup>[8]</sup>、MDL<sup>[13]</sup>和 URL<sup>[13]</sup> 5 种跨域小样本方法进行对比获得了更好的效果,实验结果如表 2 所示。

表 2 与其它经典/跨域小样本学习方法的对比

方法	可学习参数	非小样本任务	小样本任务	
			N-way 5-shot	5-way 1-shot
PN			55.39±0.76	43.60±0.39
MN			56.94±0.85	46.61±0.96
RN	0.57M		57.49±0.73	45.32±0.84
MAML			53.82±0.97	43.41±0.78
SUR	79.45M	67.93±0.74	58.66±0.99	47.14±0.67
SUR-pnf	1.67M	70.41±0.73	63.15±0.59	48.72±0.77
URT	7.78M	77.29±0.56	63.27±0.60	47.96±0.81
MDL	3.91M	86.76±0.77	62.87±0.60	49.69±0.59
URL	3.48M	88.61±0.81	67.30±0.56	50.72±0.54
<b>SAR-LAM</b>	<b>4.53M</b>	<b>91.58±0.74</b>	<b>69.19±0.56</b>	<b>52.65±0.68</b>

(注:加粗字体为最优值)

可以看出在 3 种实验条件下,本文所提方法仅在单个域上进行小样本学习的 Prototypical Network 等方法更具优势,因为其充分考虑了源域与目标域样本分布的差异性,在 N-way 5-shot 设置下分别高出 PN、MN、RN、MAML 方法 13.8、12.25、11.7、15.37 个百分点,在 5-way 1-shot 设置下分别高出 9.05、6.04、7.33、9.24 个百分点。

同时,SAR-LAM 比现有面向光学领域的跨域小样本学习方法直接应用在 SAR 图像上的效果更好,原因在于这类跨域小样本方法重心都是放在如何获取一个泛化性强的多域表征上,没有像本文所提方法一样将重点放在对 SAR 图像的适应性上。在 N-way K-shot 设置下分别高出 SUR、SUR-pnf、URT、MDL、URL 方法 23.65、21.17、14.29、4.82、2.97 个百分点,在 N-way 5-shot 设置下分别高出 10.53、6.04、5.92、6.32、1.89 个百分点,在 5-way 1-shot 设置下分别高出 5.51、3.93、4.69、2.96、1.93 个百分点。

参数量和推理速度方面,SUR 需要从多个源域中分别训练网络且同步更新权重,可学习参数为

79.45M,是其余方法的 10 倍以上。在 URL 的基础上,本文所提方法只需要 4.5M 左右的参数量,仅以牺牲少量推理速度为代价,便获得了更高的识别准确率。

如表 3 所示,本研究使用了准确率、精确率、召回率和 F1 分数来评估模型的性能,能够帮助理解模型在正确分类样本、避免误报和漏报方面的能力。SAR-LAM 分别在非小样本任务、N-way 5-shot 和 5-way 1-shot 的测试集上达到了 91.52%、69.13%和 52.48%的准确率,然而在进一步查看精确率和召回率时,发现模型在预测正例时表现出一定的保守性,召回率相对较低,这可能是由于模型在训练过程中对某些正例特征的识别不足。F1 分数分别为 91.08%、68.91%和 51.23%,作为精确率和召回率的综合度量,也指出了模型在平衡这 2 个方面时还有改进的空间。

表 3 SAR-LAM 分类指标

SAR-LAM	非小样本任务	小样本任务	
		N-way 5-shot	5-way 1-shot
准确率	91.52	69.13	52.48
精确率	92.22	70.05	56.05
召回率	91.52	69.13	52.48
F1 分数	91.08	68.91	51.23

### 3.2 适应模块嵌入方式分析

由于神经网络提取特征的最终目的是获取图像的高层语义信息进行分类,靠近输出的模块对特征提取有着更大的影响,因此本节实验分析了适应模块从嵌入第 4 个 module 开始依次向前增加(即 backbone 的不同嵌入位置)所带来的影响,Block4 表示在 ResNet-18 的第 4 个 module 嵌入该适应模块,Block3/4 表示在第 3、4 个 module 均嵌入,以此类推,结果如图 5 所示。

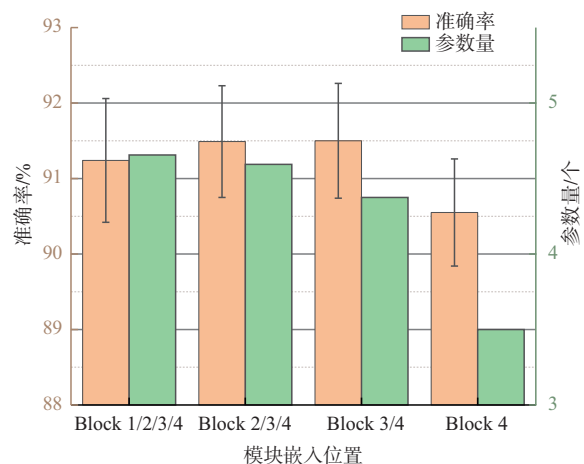


图 5 快速适应模块不同嵌入位置的比较

从图中可得,只在第 4 个 module 加入适应模

块就已经可以获得 90.55% 的准确率,在此基础上,同时第 2、3 个 module 中加入适应模块能够进一步提升准确性。这是因为 SAR 图像分辨率、信噪比较低,因此考虑到 SAR 图像像素的稀疏性,从纹理特征出发,同时学习较底层的特征才能具备较高的识别精度。结合这 4 种不同设置下的参数量,选择 Block 3/4 的嵌入方式能够在最大限度减少参数的同时保持较高的识别精度。

在每个小样本学习任务中,适应模块是通过少量样本,即目标域的支持集进行训练的,通过平均适应模块在 600 个任务中每个支持集上的原型损失 Loss,分析与迭代次数 Iteration 之间的关系可以看出,在 20 次迭代后 Loss 就可以收敛到一个稳定的区间,因此实验中取迭代次数为 40,模型能够获得较好的收敛性,如图 6 所示。

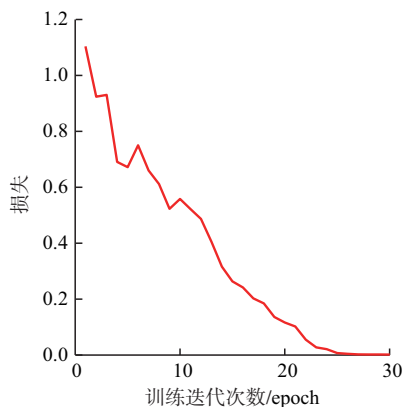


图 6 适应模块训练迭代次数与损失值之间的关系

### 3.3 消融实验

表 4 记录了编码器适应模块  $r_a$  的不同构建形式以及元测试阶段的特征对齐模块  $C_r$  对模型识别能力的贡献,分析如下:

对比序号 1 和 2 可得,如果在 backbone 当中没有适应目标域的模块权重,模型的表征能力会大打折扣,识别准确率低了 2.75 个百分点,而这一点正是本文工作突出解决的问题。

对比序号 1 和 4、1 和 6 可得,仅仅在 backbone 当中嵌入适应模块就已经可以使模型具备很强的目标域适应能力,比仅有特征对齐模块的识别率高 5.62 个百分点,但仍低于本文提出的组合方法 2.7 个百分点。

对比序号 2 和 5、2 和 6 可以发现,适应模块选择残差结构而非串行结构对最终的结果有着积极的影响,不论是矩阵形式还是向量形式存储参数,分别提高了 4.28 和 5.57 个百分点,这是因为采用残差结构能够避免普通卷积层堆叠存在的信息丢失问题,减少过拟合风险,从而能够使得 SAR 目标域所学习到的知识快速有效地参与到最终特征提取的过

程中。

对比序号 2 和 3、5 和 6 可得,向量还是矩阵形式具有竞争力取决于适应模块在 backbone 中的嵌入方式,相比串行结构而言,残差结构下的向量形式能够比矩阵形式高 1.29 个百分点。因此,在元测试阶段附加对齐模块  $C_r$  的前提下,采取这一组合能够获得所有组合中最高的准确率 91.94%。

表 4 消融实验结果

序号	编码器适应模块 $r_a$				对齐模块 $C_r$	准确率/%
	串行结构		残差结构			
	矩阵形式	向量形式	矩阵形式	向量形式		
1					✓	83.62±0.64
2	✓				✓	86.37±0.58
3		✓			✓	79.99±0.81
4			✓			89.24±0.60
5			✓		✓	90.65±0.72
6				✓	✓	91.94±0.73

## 4 结束语

小样本学习范式决定其同时面对两个巨大的挑战,一是在领域跨度较大的情况下高效地迁移先验知识,二是模型只能在数据量非常有限的条件下对未见过的样本进行分类,本文针对小样本 SAR 目标识别过程面临的以上挑战,提出一种名为 SAR-LAM 的轻量化适应策略。首先通过基于交叉熵损失的有监督学习得到各源域编码器,而后结合知识蒸馏的方法,获得一个具有较好泛化能力的通用编码器;为了进一步适应目标域特点,向该通用编码器中嵌入一个适应模块,其参数只在目标域的支持集上进行学习;最后将提取到的样本特征映射到一个分辨性更高的空间内,采取元学习框架计算出支持集的类中心,从而完成查询集的分类。这一针对 SAR 图像的适应策略仅需以增加 4.5M 左右的参数为代价,就可将小样本分类的准确率至少提升 1.93 个百分点,获得了较好的识别效果。

然而,本文工作是建立在多源域迁移学习的基础上,因此预训练阶段需要大量的计算时间和资源消耗才能获得具有泛化性的通用编码器,并不能高度耦合 SAR 图像目标识别的军事应用情景。另外,由于小样本学习对样本不均衡条件的敏感性很强,实验部分仅使用了类别均衡的 MSTAR 数据集,并未在其他公开的非均衡 SAR 图像数据集上验证模型的适应性。综上,后续工作需要解决多源域带来的资源消耗问题,并应对不均衡数据集的挑战,进一步提高研究的适用性。

### 参考文献

- [1] 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.
- [2] 王晓丹, 向前, 李睿, 等. 深度学习研究及军事应用综述[J]. 空军工程大学学报(自然科学版), 2022, 23(1): 1-11.
- [3] 刘旗, 刘永祥, 张新禹. 基于特征注意力融合元残差网络的小样本 SAR 目标识别 [J]. 电子学报, 2023, 51(9): 2366-2378.
- [4] 应自炉, 宣晨, 翟懿奎, 等. 面向小样本 SAR 图像识别的自注意力多尺度特征融合网络 [J]. 信号处理, 2020, 36(11): 1846-1858.
- [5] 张翼鹏, 卢东东, 仇晓兰, 等. 基于散射点拓扑和双分支卷积神经网络的 SAR 图像小样本舰船分类 [J]. 雷达学报, 2024, 13(2): 411-427.
- [6] GUO Y H, CODELLA N C, KARLINSKY L, et al. A Broader Study of Cross-Domain Few-Shot Learning [C]//Computer Vision-ECCV 2020: 16th European Conference. UK: Springer, 2020: 124-141.
- [7] DVORNIK N, SCHMID C, MAIRAL J. Selecting Relevant Features from a Multi-Domain Representation for Few-Shot Classification [C]//Computer Vision-ECCV 2020: 16th European Conference. UK: Springer, 2020: 769-786.
- [8] LIU L, HAMILTON W, LONG G D, et al. A Universal Representation Transformer Layer for Few-Shot Image Classification [DB/OL]. arXiv: 2006.11702. <http://arxiv.org/abs/2006.11702>, 2020.
- [9] PEREZ E, STRUB F, DE VRIES H, et al. Film: Visual Reasoning with a General Conditioning Layer [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1).
- [10] REQUEIMA J, GORDON J, BRONSKILL J, et al. Fast and Flexible Multi-Task Classification Using Conditional Neural Adaptive Processes[J]. Advances in Neural Information Processing Systems, 2019, 32.
- [11] BATENI P, GOYAL R, MASRANI V, et al. Improved Few-Shot Visual Classification [C]// Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2020: 14481-14490.
- [12] BILEN H, VEDALDI A. Universal Representations: The Missing Link between Faces, Text, Planktons, and Cat Breeds [DB/OL]. arXiv: 1701.07275, 2017.
- [13] LI W H, LIU X, BILEN H. Universal Representation Learning from Multiple Domains for Few-Shot Classification [C]// International Conference on Computer Vision. Canada: IEEE, 2021: 9506-9515.
- [14] CHEN Z, BADRINARAYANAN V, LEE C Y, et al. Gradnorm: Gradient Normalization for Adaptive Loss Balancing in Deep Multitask Networks [C]// Proceedings of the 35th International Conference on Machine Learning. Sweden: PMLR, 2018: 794-803.
- [15] YU T H, KUMAR S, GUPTA A, et al. Gradient Surgery for Multi-Task Learning [J]. Advances in Neural Information Processing Systems, 2020, 33: 5824-5836.
- [16] CIPOLLA R, GAL Y, KENDALL A. Multi-Task Learning Using Uncertainty to Weigh Losses for Scene Geometry and Semantics [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 7482-7491.
- [17] LI W H, BILEN H. Knowledge Distillation for Multi-Task Learning [C]//Computer Vision-ECCV 2020 Workshops. UK: Springer, 2020: 163-176.
- [18] HINTON G, VINYALS O, DEAN J. Distilling the Knowledge in a Neural Network [DB/OL]. arXiv: 1503.02531, 2015.
- [19] KORNBLITH S, NOROUZI M, LEE H, et al. Similarity of Neural Network Representations Revisited [C]// Proceedings of the 36th International Conference on Machine Learning. USA: PMLR, 2019: 3519-3529.
- [20] LUO X, WU H, ZHANG J, et al. A Closer Look at Few-Shot Classification Again [C]//International Conference on Machine Learning. USA: PMLR, 2023: 23103-23123.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition [C]// Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2016: 770-778.
- [22] SNELL J, SWERSKY K, ZEMEL R. Prototypical Networks for Few-Shot Learning [J]. Advances in neural information processing systems, 2017, 30: 1-10.
- [23] TRIANTAFILLOU E, ZHU T, DUMOULIN V, et al. Meta-Dataset: A Dataset of Datasets for Learning to Learn from few Examples [DB/OL]. arXiv: 1903.03096, 2019.
- [24] ZEILER M D. ADADELTA: An Adaptive Learning Rate Method [DB/OL]. arXiv: 1212.5701, 2012.
- [25] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching Networks for one Shot Learning [J]. Advances in neural information processing systems, 2016, 29.
- [26] SUNG F, YANG Y X, ZHANG L, et al. Learning to Compare: Relation Network for Few-Shot Learning [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 1199-1208.
- [27] FINN C, ABBEEL P, LEVINE S. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks [C]// Proceedings of the 34th International Conference on Machine Learning. Australia: PMLR, 2017: 1126-1135.

(编辑:杜娟)