

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2024)07-1902-19

论文引用格式: Wang Z Q, Li Y, Zhang R, Wang J B, Li Y C and Chen Y. 2024. Few-shot SAR image classification: a survey. Journal of Image and Graphics, 29(07): 1902-1920(王梓祺, 李阳, 张睿, 王家宝, 李允臣, 陈瑶. 2024. 小样本 SAR 图像分类方法综述. 中国图象图形学报, 29(07): 1902-1920)[DOI: 10. 11834/jig. 230359]

小样本 SAR 图像分类方法综述

王梓祺, 李阳, 张睿*, 王家宝, 李允臣, 陈瑶

陆军工程大学指挥控制工程学院, 南京 210007

摘要: 合成孔径雷达(synthetic aperture radar, SAR)图像分类作为 SAR 图像应用的重要底层任务受到了广泛关注与研究。SAR 图像分类是处理和分析遥感图像的重要手段, 在环境监测、目标侦察和地质勘探等任务中发挥着关键作用, 但是目前基于深度学习的 SAR 图像分类任务存在小样本问题。本文针对小样本 SAR 图像分类方法进行全面的论述和分析。1) 介绍了 SAR 图像分类任务的重要性和早期的 SAR 图像分类方法, 并阐述了小样本 SAR 图像分类任务的必要性。2) 介绍了小样本 SAR 图像分类任务的定义、常用的数据集、评价指标和应用。3) 整理了各类方法的贡献点和使用的数据集, 将已有的小样本 SAR 图像分类方法分为基于迁移学习的方法、基于元学习的方法、基于度量学习的方法和综合性方法 4 类。根据分类总结了 4 类方法存在的缺陷, 为后续工作提供了一定的参考。在统一的框架内测试了 16 种可见光数据集方法迁移到 SAR 图像数据集上的分类性能, 并从分类精度和运行时间两个方面综合评估了小样本学习模型迁移效果。该项工作利用 SAR 图像分类通用数据集 MSTAR(moving and stationary target acquisition and recognition)完成, 极大地补充了小样本 SAR 图像分类任务的测评基准。4) 对小样本 SAR 图像分类方法的发展趋势进行了展望, 提出了未来可能的一些严峻挑战。

关键词: 小样本学习; SAR 图像分类; 迁移学习; 元学习; 度量学习

Few-shot SAR image classification: a survey

Wang Ziqi, Li Yang, Zhang Rui*, Wang Jiabao, Li Yunchen, Chen Yao

Command and Control Engineering College, Army Engineering University of PLA, Nanjing 210007, China

Abstract: Few-shot synthetic aperture radar (SAR) image classification aims to use a small number of training samples to classify new SAR images and facilitate subsequent vision tasks further. In recent years, it has received widespread attention in the field of image processing, especially playing a crucial role in tasks such as environmental monitoring, target reconnaissance, and geological exploration. Moreover, the growth of deep learning has been promoting deep learning-based few-shot SAR image classification. In particular, the improvement of few-shot learning algorithm, such as the attention mechanism, transfer learning, and meta learning, has led to a qualitative leap in few-shot SAR image classification performance. However, a comprehensive review and analysis of state-of-the-art deep learning-based few-shot SAR image classification algorithms for different complex scenes need to be conducted. Thus, we develop a systematic and critical review to explore the developments of few-shot SAR image classification in recent years. First, a comprehensive and systematic introduction of the few-shot SAR image classification field is presented from three aspects: 1) overview of early SAR image classification methods, 2) the existing dataset, and 3) the prevailing evaluation metrics. Then, the existing

收稿日期: 2023-06-20; 修回日期: 2023-11-03; 预印本日期: 2023-11-10

* 通信作者: 张睿 3959966@qq.com

基金项目: 江苏省自然科学基金项目(BK20200581)

Supported by: Natural Science Foundation of Jiangsu Province, China (BK20200581)

few-shot SAR image classification methods are categorized into four types: transfer learning, meta learning, metric learning, and comprehensive methods. The main contributions and the datasets used for each method are summarized. Therefore, we test the classification accuracy and runtime of 16 classic few-shot visible light image classification methods on the moving and stationary target acquisition and recognition (MSTAR) dataset. In this way, the evaluation benchmark for few-shot SAR image classification methods is supplemented for future research reference. Finally, the summary and challenges in the few-shot SAR image classification community are highlighted. In particular, some prospects are recommended further in the field of few-shot SAR image classification. First, starting from the classification criteria, SAR image classification methods can be divided into four categories based on the feature information used, whether manual sample labeling is required, technical methods, and processing objects. These traditional SAR image classification methods lay the foundation for subsequent few-shot SAR image classification methods. We briefly introduce the popular public datasets and prevailing evaluation metrics. The existing datasets for few-shot SAR image classification include MSTAR, OpenSARShip, COSMO-SkyMed, FuSAR-Ship, OpenSARUrban, and SAR-ACD. Among them, MSTAR is the most commonly used standard few-shot SAR image classification dataset. The evaluation indicators for method performance in few-shot SAR image classification tasks mainly include classification accuracy, precision, and recall. Precision and recall represent two different indicators, which is why intuitively reflecting the performance of the model is difficult. Therefore, the harmonic mean of these two indicators has become a direct indicator for judging the performance of the model. In addition, few-shot learning commonly uses top 1 and top 5 as evaluation indicators. Second, few-shot SAR image classification methods based on deep learning can be divided into three categories: transfer learning, meta learning, and metric learning. Transfer learning methods quickly adapt to the new class image classification by using the association between similar tasks to assist the model after completing the pre-training on a large number of base class data. This type of method can effectively overcome the problem of insufficient training samples in the field of SAR images. Meta learning methods aim to enable models to learn by training a meta learner to evaluate the dataset learning process and gain learning experience. Then, the model utilizes the acquired learning experience to complete relevant classification tasks on the target dataset. Metric learning methods are an end-to-end training approach that utilizes data from each K -shot category to learn a feature embedding space. In this feature embedding space, the model can more effectively measure the similarity between samples. This type of method relatively reduces the difficulty of training feature extractors, making the structure of the model more flexible and able to quickly adapt to the task of identifying new classes. As a result of the different imaging principles between SAR images and visible light images, some comprehensive methods guided by physical knowledge and domain knowledge have also been used in SAR image classification tasks and achieved great results. Therefore, in addition to the above three classification methods, some methods that combine deep learning and SAR image characteristics have been applied to solve the problem of few-shot SAR image classification. We summarize the limitations of different few-shot SAR image classification algorithms and provide some recommendations for further research. Third, we tested the classification performance of 16 visible light dataset methods migrating to SAR image datasets within a unified framework and comprehensively evaluated the transfer effect of few-shot learning models from two aspects: classification accuracy and runtime. This work can effectively supplement the evaluation benchmark for few-shot SAR image classification tasks. The experiment found that the few-shot learning method based on metric learning achieved good performance in the field of SAR image classification without comprehensive methods. Finally, the review summarizes the future development trends and challenges of few-shot SAR image classification based on a summary of existing methods.

Key words: few-shot learning; SAR image classification; transfer learning; meta learning; metric learning

0 引言

在计算机视觉领域中,图像分类扮演着十分重要的角色,是许多下游任务的基础。图像分类的结

果可广泛应用于目标检测(Kaul等,2022)、图像分割(Xie等,2021)和位姿估计(Liu等,2023b)等领域。合成孔径雷达(synthetic aperture radar,SAR)是遥感场景分类任务中重要的主动式设备。SAR图像分类是处理和分析遥感图像的重要手段,在环境监测、目

标侦察和地质勘探等任务中发挥着十分关键的作用(张睿等,2022;石争浩等,2023)。

近年来,SAR图像分类作为SAR图像应用的重要底层任务受到广泛关注与研究。早期的研究主要针对SAR图像的后向散射强度和纹理特征,设计的方法分类性能未能很好地满足实际应用需求(Huang等,2021;邢孟道等,2022)。随后的研究可以根据所用特征信息、是否需要人工标记样本、技术方法和处理对象分为4个大类(魏丹等,2020),如表1所示。

随着深度学习(deep learning, DL)和卷积神经网络(convolutional neural network, CNN)的快速发

展,利用数据作为驱动的图像分类方法性能得到了飞速提升(Krizhevsky等,2017;唐霖峰等,2023)。但是,CNN需要利用大量带标注的数据不断学习才能够达到预期效果,当缺乏训练数据时,模型很容易陷入到过拟合的困境中(LeCun等,2015)。目前,SAR图像分类任务缺乏大量带标注的训练样本,分类时存在小样本问题(Zhu等,2023; Yazdanpanah等,2022)。通过人工标注的方法扩充数据集需要昂贵的人力成本,因此利用小样本学习方法完成SAR图像分类任务成为亟待解决的问题(Chen等,2022)。

表1 早期SAR图像分类方法总结

Table 1 Overview of early SAR image classification methods

分类依据	类型	主要思想
所用特征信息	基于统计分析的分类	利用SAR图像的散射特性等特征信息,完成SAR图像分类任务
	基于SAR图像散射特性的分类	
	基于目标散射特性和统计方法相结合的分类	
是否需要人工标记样本	无监督分类	根据训练样本是否带标注,使用不同的深度学习方法解决SAR图像分类问题
	有监督分类	
	半监督分类	
技术方法	基于模糊理论的分类	利用机器学习的技术方法,从不同角度完成SAR图像分类任务
	基于神经网络的分类	
	基于支持向量机的分类	
	基于融合算法的分类	
	基于马尔可夫随机场模型分类	
处理对象	基于主动轮廓模型分类	针对不同的层级进行特征提取,完成SAR图像分类任务
	基于像素级的分类	
	基于对象的分类	

本文针对小样本SAR图像分类经典方法和最新工作进行概述性总结,与已有小样本学习综述区别如下:

1)与已有小样本学习图像分类的综述相比,本文聚焦于SAR图像领域,对该领域的小样本图像分类方法进行了更详尽的总结。

2)由于小样本SAR图像分类是小样本学习与SAR图像分类的交叉性学科,各项研究尚处于起步阶段,因此该领域缺乏较为全面的综述性文章,本文弥补了该领域综述类文章的空白。

3)本文不仅总结现有的22种小样本SAR图像

分类方法,还利用统一的框架复现了16种可见光方法在SAR图像数据集MSTAR(moving and stationary target acquisition and recognition)上的分类性能。这些工作可为后续研究提供参考,启发读者在现有方法的基础上不断创新,提升小样本SAR图像分类方法的性能。

1 概述

1.1 问题定义

小样本学习旨在通过学习少量的带标注样本,

使模型具备识别新类的能力(Antonelli等,2022;Gao等,2022;Zeng和Geng,2022)。因此,小样本 SAR 图像分类任务与传统 SAR 图像分类任务不同,支持集与查询集中的类别没有交集(Jian和Torresani,2022)。假设 S 表示支持集(support set), Q 表示查询集(query set), S 和 Q 中均为 SAR 图像样本(Liu等,2023a;Zhao和Cheung,2023)。在支持集 S 中包含 N 类互不相同的图像,每类中含有 K 个带标记的 SAR 图像样本,这些样本用于模型的训练。根据支持集 S 对查询集 Q 中的每个未标记样本执行分类任务,并且满足 $S \cap Q = \emptyset$,该任务称为一次 N -way K -shot 任务(Liang等,2022;Afrasiyabi等,2022)。对于 N -way K -shot 分类任务,从支持集的 N 类样本中抽取 K 幅(K 通常很小,取值为1或5)用于小样本模型学习。该任务最终的目标是利用支持集 S 中的少量 SAR 图像样本对查询样本进行正确的分类(Xu和Le,2022)。

1.2 数据集

SAR 图像的获取往往依赖部署在卫星和舰船等载体上的合成孔径雷达,日常生活中较难获取大量 SAR 图像数据(Li等,2017)。同时,SAR 的快速发展与分类方法的不断创新,导致数据集、问题假设与实际需求方面出现了较大差异,数据集未能很好地满足小样本 SAR 图像分类任务。因此,现有高质量且公开的 SAR 图像分类数据集较少(Huang等,2020;Tan等,2021)。表2总结了常见的6种小样本 SAR 图像分类数据集。

MSTAR(Keydel等,1996)是一个 SAR 车辆数据集,该数据集由美国国防高等研究计划署(Defense Advanced Research Projects Agency, DARPA)公布,

采用 HH 极化(horizontal horizontal polarization)方式。该数据集目前公开的部分包含 10 类 SAR 车辆目标,共计 2 万余幅不同俯仰角的图像样本。OpenSARShip(Huang等,2018)是一个采自 41 幅 Sentinel-1 卫星图像的 SAR 船舶数据集,该数据集由上海交通大学构建并发布。该数据集采用 VV 极化(vertical vertical polarization)和 VH 极化(vertical horizontal polarization)方式,包含 11 346 幅图像样本。COSMO-SkyMed(Wang等,2018)是一个自建的 SAR 船舶数据集,该数据集采用 HH 和 VV 极化方式,包含 6 个场景的 3 类船舶目标,共计 446 幅图像样本。FuSAR-Ship(Hou等,2020)是一个具有高分辨率的 SAR 船舶数据集,该数据集由复旦大学电磁波信息科学教育部重点实验室构建并发布,采用 DH(double aperture HH)和 DV(double aperture VV)极化方式。该数据集中包含 15 个主要船舶类别,98 个子类别以及一些非船舶海洋目标,共计 16 144 幅图像样本。OpenSARUrban(Zhao等,2020)是一个采自 Sentinel-1 卫星图像的 SAR 城市图像数据集,该数据集由上海交通大学构建并发布,采用 VV 和 VH 极化方式。OpenSARUrban 中包含取自 21 个中国城市的 10 种不同类型的目标场景,共计 33 358 幅图像样本。SAR-ACD(Sun等,2022)是一个自建的 SAR 飞机数据集,该数据集由 Sun 等人(2022)构建且尚未公开,采用 HH 极化方式。该数据集中包含 6 个民用和 14 个其他类别的 SAR 飞机目标,共计 4 322 幅图像样本。

图1展示了4种常见的小样本 SAR 图像分类数据集。MSTAR(Keydel等,1996)是现阶段最为常用的数据集,大部分工作均基于该数据集展开。MSTAR 被众多学者广泛应用于 SAR 图像分类任务,

表2 常见数据集汇总

Table 2 Summary of common datasets

名称	极化方式	样本分辨率/像素	SAR 成像分辨率	图像数量	主要目标对象	采集工具
MSTAR(Keydel等,1996)	HH	128 × 128	0.3 m × 0.3 m	20 000+	SAR 车辆	聚束式 SAR
OpenSARShip(Huang等,2018)	VV、VH	100 × 100	-	11 346	SAR 船舶	Sentinel-1 卫星
COSMO-SkyMed(Wang等,2018)	HH、VV	-	-	446	SAR 船舶	-
FuSAR-Ship(Hou等,2020)	DH、DV	512 × 512	1.124 m × 1.728 m	16 144	SAR 船舶	高分三号卫星
OpenSARUrban(Zhao等,2020)	VV、VH	100 × 100	-	33 358	SAR 城市	Sentinel-1 卫星
SAR-ACD(Sun等,2022)	HH	-	1.124 m × 1.728 m	4 322	SAR 飞机	高分三号卫星

注:“-”表示未公开相关信息。

并且该数据集具备一定的普适性和可拓展性。因此, MSTAR 也被作为小样本 SAR 图像分类标准数据集, 使用该数据集进行测试有利于公平比较不同方法的分类性能。

除了 MSTAR 之外, 也有一些论文采用 FuSAR-Ship (Hou 等, 2020)、SAR-ACD (Sun 等, 2022) 和 OpenSARUrban (Zhao 等, 2020) 3 种自建数据集。这些数据集往往专注于某一具体领域, 如 FuSAR-Ship 侧重于 SAR 船舶分类任务, SAR-ACD 侧重于 SAR 飞机分类任务, OpenSARUrban 侧重于 SAR 城市场景分类任务。这些数据集虽然在小样本 SAR 图像分类领域尚未得到广泛使用, 但是在面对具体的应用场景时, 可以利用相应的 SAR 图像数据集训练模型。

1.3 应用

与光学成像系统相比, 由于雷达电磁波具有穿透性, SAR 系统可以全天候执行探测任务, 不会受到气候等自然条件的影响 (Li 等, 2019a; Song 等, 2023)。但是, SAR 图像相较于光学图像获取难度较大, 公开的高质量 SAR 图像相对较少。同时, 公开的 SAR 图像标注需要昂贵的专家知识, 使得构建用于模型训练的 SAR 图像数据集十分困难 (Xu 等, 2021a)。因此, SAR 图像分类在实际应用中存在小样本问题 (Zhai 等, 2022; 陈良臣和傅德印, 2022)。

小样本 SAR 图像分类方法对于军事目标侦察 (Yasir 等, 2023)、海洋环境监测 (Xu 和 Lang, 2020)、城市场景测绘 (Yang 等, 2020) 和灾害应急响应 (Yang 等, 2022a) 等应用具有较大的现实意义。在军事应用层面, 小样本 SAR 图像分类方法可以利用少量带标注的 SAR 图像样本学习, 迅速提升侦察该类新目标的能力 (Lai 等, 2022; Zhang 等, 2023a)。在海洋环境监测和灾害应急响应层面, 由于存在待探测范围广、环境多变、需要全天候监测和目标样本缺乏的问题, 利用小样本 SAR 图像分类方法可以有效提升实时监测能力 (Chen 等, 2018; 刘颖 等, 2021)。在城市场景测绘方面, 尽管光学成像系统已经可以较好地执行该类任务, 并且 3D 城市建模技术也日趋成熟。但是, 在面临恶劣天气和复杂地质条件时, 小样本 SAR 图像分类方法可以有效地克服不利因素带来的影响 (Oh 等, 2021a)。因此, 对小样本 SAR 图像分类方法的深入研究是十分必要的。




图1 常见数据集示例

Fig. 1 Examples of common dataset ((a) MSTAR; (b) FuSAR-ship; (c) SAR-ACD; (d) OpenSARUrban)

2 小样本 SAR 图像分类方法

针对不同类型的分类思路, 本文将小样本 SAR 图像分类方法分为基于迁移学习的方法、基于元学习的方法和基于度量学习的方法 3 类 (龚声蓉 等, 2022; 王蓉芳 等, 2023)。表 3 对现有的小样本 SAR 图像分类方法进行了归纳。

2.1 基于迁移学习的方法

基于迁移学习的方法是一种利用模型微调的分类思路 (Zhong 等, 2019; Wang 等, 2022)。如图 2 所

表 3 现有小样本 SAR 图像分类方法归纳
Table 3 Overview of existing few-shot SAR image classification methods

方法	来源	年份	类型	主要贡献	数据集	优缺点
Wang 等人 (2018)	Sensors	2018	迁移学习	利用简单的微调取得较好的 SAR 船舶分类性能	COSMO-SkyMed	优点: 针对目前可用于训练的 SAR 图像样本较少的问题, 可以通过迁移学习让模型学到一定的先验知识, 弥补 SAR 图像样本不足的问题。 缺点: 当源域与目标域图像差异较大时, 迁移学习效果较差。
Rostami 等人 (2019a)	CVPR	2019	迁移学习	设计半监督域自适应的小样本 SAR 图像分类方法	SAR 船舶	
Rostami 等人 (2019b)	Remote Sensing	2019	迁移学习	从理论上阐述半监督域自适应方法可以很好地泛化到 SAR 领域的原因	SAR 船舶	
Ying 等人 (2020)	Sensors	2020	迁移学习	提出一种轻量级卷积神经网络, 并设计 Atrous-Inception 模块	MSTAR	
Zhai 等人 (2020)	Remote Sensing	2020	迁移学习	设计一种多级特征注意力 SAR 网络	MSTAR	
Li 等人 (2022b)	IEEE Global Communications Conference	2022	迁移学习	设计一种结合空间和频率信息的混合分类网络	自建数据集	
Wang 和 Zhang (2020)	Sensors	2020	元学习	设计一种元学习与摊销变分推理相结合的分类方法	MSTAR	优点: 可以让模型具备像人类一样快速学习 SAR 图像新类的能力。 缺点: 当 SAR 图像训练样本较少时, 元学习器难以学到有效的先验知识。
Fu 等人 (2022)	IEEE Transactions on Geoscience and Remote Sensing	2021	元学习	设计一个简单的元学习方法, 并提出硬任务挖掘方法有效提升元学习的有效性	MSTAR、NIST-SAR	
Sun 等人 (2022)	IEEE Transactions on Geoscience and Remote Sensing	2022	元学习	设计散射特性分析网络用于小样本 SAR 图像分类, 引入物理知识启发的策略。	SAR-ACD	
Wang 等人 (2019)	The 6th Asia-Pacific Conference on Synthetic Aperture Radar	2019	度量学习	基于 Conv-BiLSTM 原型网络设计一种有效的小样本 SAR 图像分类方法	MSTAR	优点: 基于度量学习的方法减少了对先验知识的依赖, 在 SAR 图像训练样本较少时, 有更好的分类表现。 缺点: 过于依赖采样策略, 当采样策略过于简单时, 度量学习只会学习到简单的样本, 难以继续训练; 当采样策略过于困难时, 会导致收敛慢、不收敛, 甚至过拟合的问题出现。
Lu 等人 (2019)	The 6th Asia-Pacific Conference on Synthetic Aperture Radar	2019	度量学习	设计一种引入三元组损失函数的深度神经网络	MSTAR	
Tang 等人 (2019)	IEEE International Geoscience and Remote Sensing Symposium	2019	度量学习	改进 Siamese 网络, 在有效利用度量学习优势的同时, 还显著降低了该类模型的预测时间消耗	MSTAR	
Liu 等人 (2020)	Journal of Physics: Conference Series	2020	度量学习	设计一种基于特征转移的原型网络, 并引入了单样本学习方法	MSTAR	
Wang 等人 (2021)	IEEE Transactions on Geoscience and Remote Sensing	2021	度量学习	设计一种混合推理网络, 并提出了增强混合损失	MSTAR	
Zhao 等人 (2021)	Sensors	2021	度量学习	设计一种基于原型网络的多方位 SAR 图像分类方法	MSTAR	
刘旗等人 (2022)	Systems Engineering and Electronics	2022	度量学习	设计一种基于门控多尺度匹配网络, 利用多尺度特征提取模块与权重门控单元有效地完成了分类任务	MSTAR	

示, 迁移学习通过在大量基类数据上完成预训练后, 利用相似任务间的关联关系辅助模型快速适应新类

图像分类(Wu 等, 2020; Yao 等, 2023)。该类方法可以很好地克服 SAR 图像领域训练样本不足的问题。

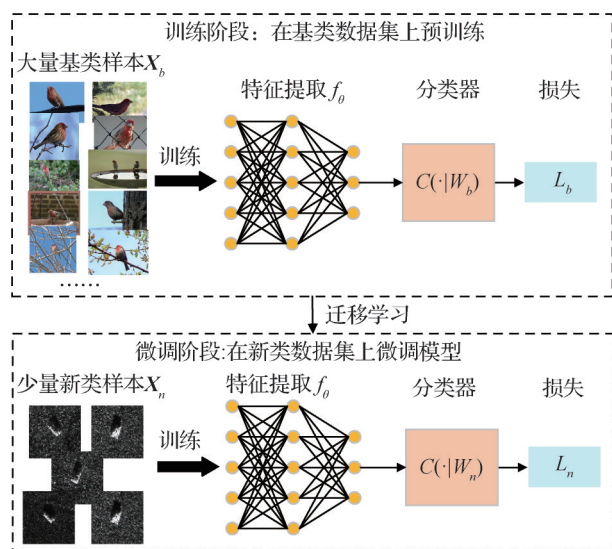


图2 迁移学习结构图

Fig. 2 Structure of transfer learning

Wang等人(2018)设计了小样本SAR船舶分类方法。该方法利用ImageNet数据集对VGG (Visual Geometry Group) 网络进行预训练,然后通过构建的SAR船舶数据集对训练好的VGG网络进行微调,在SAR船舶分类任务中取得了较好的效果。

Rostami等人(2019a)设计了一种半监督域自适应的小样本SAR图像分类方法,该方法使用Sliced-Wasserstein距离来测量和最小化源域和目标域分布之间的差异,以便监督域特定的编码器进行训练。该方法在SAR船舶目标检测数据集上测试了分类性能,并通过消融实验证明了他们所提出的优化方法的有效性。同年,Rostami等人(2019b)进一步优化了上述半监督域自适应方法,并从理论上阐述了该方法能训练一个可泛化到SAR目标领域分类器的原因。该方法旨在为地区海洋安全与环境监测提供一个有效的解决方案,体现了小样本SAR图像分类在实际应用中具有极大的价值。

Ying等人(2020)设计了一种轻量级卷积神经网络用于小样本SAR图像分类。该方法提出了Atrous-Inception模块,该模块结合了Atrous卷积和Inception模块。在获得丰富的全局感受野的同时,Atrous-Inception模块还严格控制参数数量,从而实现轻量级网络架构。与此同时,该方法将光学和非光学领域的先验知识有效地迁移到SAR图像分类任务中,从而提高模型在小样本SAR图像任务中的分类性能。

Zhai等人(2020)设计了一种具有双重优化损失的深度迁移多级特征融合注意力网络,简称为多级特征注意力合成孔径雷达网络(multi-level feature attention synthetic aperture radar network, MFFA-SARNET)。该方法首先建立多级特征注意力网络,使其更加关注目标特征信息;然后设计了新的双重优化损失来进一步优化分类网络,有效地提升了该方法的鲁棒性。

Li等人(2022b)设计了一种结合空间和频率信息的混合分类网络,该方法首先在源数据集中训练所提出的网络,该数据集包含大量相关但非分类任务目标的SAR图像。然后,通过在由几幅分类任务目标的组成的训练数据集上微调模型,使模型能够完成对目标任务的分类工作,并在自建数据集上取得了良好的分类效果。

在面对小样本困境时,基于迁移学习的方法可以很好地利用任务间的联系,从而克服目标任务中训练样本不足的问题。一方面,通过迁移学习可以有效利用源领域中丰富的数据,提升模型的泛化能力;另一方面,迁移学习通过利用已学到的知识和经验可以加速训练过程,降低训练成本。但是,当源域与目标域图像差异较大时,迁移学习性能较差,该类方法的鲁棒性难以得到保障。与此同时,该类方法跨域学习与训练的时间也会相应增加,从而造成额外的训练成本。

2.2 基于元学习的方法

基于元学习的方法是一种让模型学会学习(learning to learning)的分类思路(Chen等,2021; Frikha等,2021)。如图3所示,该类方法通过训练一个元学习器来评估数据集学习过程,进而获得学习经验(Xu等,2021b)。然后,模型利用获得的学习经验去对目标数据集完成相关分类任务(Li等,2021)。

Wang和Zhang(2020)设计了一种元学习与摊销变分推理(amortized variational inference, AVI)相结合的分类方法,其中包含全局参数和特定于任务的参数。该方法通过元学习训练的全局参数,从而构建了所有分类任务之间共享的公共特征提取器;通过AVI推断出特定于任务的参数,从而利用少量的训练数据适应新的小样本SAR图像分类任务。该方法引入的AVI有效地减少了计算与存储成本,提升了基于元学习方法的分类性能。

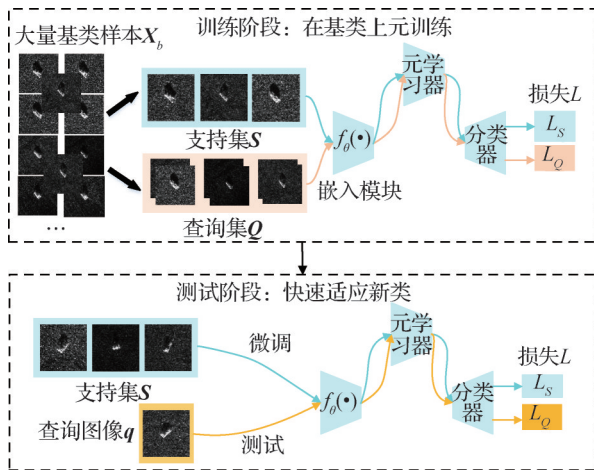


图3 元学习结构图

Fig. 3 Structure of meta learning

Fu 等人(2022)设计了一种由一个元学习器和一个分类器组成的小样本 SAR 图像分类方法 MSAR。同时,该方法划分了 MSTAR 数据集用于 MSAR 的训练与测试,并将分割后的数据集命名为 NIST-SAR。MSAR 利用 3 种迁移学习方法解决了元学习过程中的小样本问题,并提出了一种硬任务挖掘方法提高元学习的有效性。实验表明,MSAR 在 NIST-SAR 数据集上的分类精度相较作者复现的最佳方法均有所提升。在 5-way 1-shot 任务中提升了 1.7%,在 5-way 5-shot 任务中提升了 2.3%。

Sun 等人(2022)设计了一种利用 SAR 散射特性分析的分类方法,提出了散射特性分析网络(scattering characteristics analysis network, SCAN)。该网络首先设计了一个散射提取模块,该模块将目标成像机制与网络相结合。结合后的网络有效利用了显式监控,从而学习每种类型目标的散射点数量和分布情况。此外,SCAN 考虑到 SAR 目标成像的变异性,设计了由角度自适应分类器和频率嵌入式模块组成

的元学习网络。角度自适应分类器引导网络关注具有不同目标姿态角的正样本对,频率嵌入式模块将脉冲余弦变换与网络训练过程有效地结合在一起,以丰富频域信息。该方法在自建 SAR 飞机数据集 SAR-ACD 上取得了良好的分类效果。值得一提的是,SCAN 针对散射特性进行分析,从而解决小样本 SAR 飞机图像分类问题。该思路突破了仅针对深度学习方法进行优化的局限,在元学习中引入了物理知识启发的策略,是未来解决该类问题值得借鉴的方法。

虽然基于元学习的方法在面对小样本学习问题时,可以通过元学习器和元学习算法实现“举一反三”的目标,并从少量数据中获得较好的泛化能力,这使得它在数据稀缺或昂贵的场景中颇具价值。但是,当训练样本极少时,元学习器难以学到有效的先验知识,容易在训练时出现过拟合的情况。同时,元学习具有“维度诅咒”的缺陷,即随着任务空间维度的增加,元学习模型有效训练所需要的参数量也会随之增加。这些缺陷会导致在某些任务上表现较好的模型推广到新任务上时,分类精度出现较为明显的下降。

2.3 基于度量学习的方法

基于度量学习的方法是一种训练模型不需针对测试任务进行调整的分类思路(Li 等, 2022a; Feng 和 Chaspari, 2023)。如图 4 所示,度量学习是一种端到端的训练方式,该类方法利用每个类别 K -shot 的数据,学习一个特征嵌入空间(Li 等, 2023c)。在此特征嵌入空间中,模型能够更有效地度量样本之间的相似度(Pan 等, 2019; Jiang 等, 2021)。该类方法相对降低了特征提取器的训练难度,使得模型的结构更加灵活,可以快速适应识别新类的任务(Li 等, 2019b; Dong 等, 2022)。

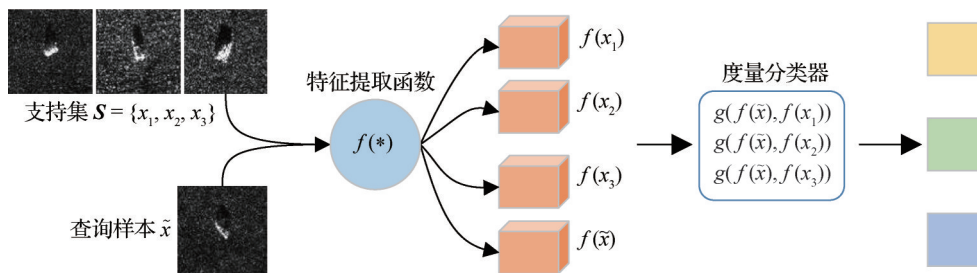


图4 度量学习结构图

Fig. 4 Structure of metric learning

Wang 等人(2019)基于 Conv-BiLSTM 原型网络设计了一种小样本 SAR 图像分类方法。该方法首先训练原型网络将 SAR 图像映射到一个新的特征空间中,然后利用欧氏距离的分类器获得分类结果。

Lu 等人(2019)设计了一种引入三元组损失函数的深度神经网络。该网络利用三元组损失来学习每个目标的嵌入,以确保在嵌入空间中来自相同目标的图像是接近的。实验结果证明,该网络在有限的标注数据上展现了良好的分类性能。

Tang 等人(2019)改进了 Siamese 网络用于小样本 SAR 图像分类,该网络包含 CNN 编码器、相似性鉴别器和分类器。与原有 Siamese 网络不同的是,改进的 Siamese 网络目标类别由分类器输出,而不是由相似性鉴别器输出。这项改进在有效利用度量学习优势的同时,还显著降低了基于度量学习模型的预测时间消耗。

Liu 等人(2020)设计了一种基于特征转移的原型网络用于小样本 SAR 图像分类。为了克服 SAR 图像分类中神经网络训练样本量少的问题,该网络引入了单样本学习(one-shot learning, OSL)方法。经过实验证明,在目标域的训练样本严重不足但有合格的辅助训练数据的情况下,引入 OSL 的原型网络分类性能优于基于深度迁移学习的方法。

Wang 等人(2021)设计了一种混合推理网络(hybrid inference network, HIN)用于小样本 SAR 图像分类。该网络分为两个阶段:在第 1 阶段,利用嵌入网络来将 SAR 图像映射到一个嵌入空间;在第 2 阶段,采用归纳推理和直接推理相结合的混合推理策略对嵌入空间中的样本进行分类。在归纳推理时,HIN 通过欧氏距离度量来独立地识别每个样本;在直接推理时,所有样本被识别为一个整体,根据其流形结构的标签进行分类;最后,在混合推理时将上述两种推理方法相结合得到最终的分类结果。同时,为了有效地对 HIN 进行训练,该方法还提出了一种新的损失函数,称为增强混合损失。该损失可以通过限制样本,从而使得嵌入空间具有更好的类间可分性。

Zhao 等人(2021)设计了一种基于原型网络的多方位 SAR 目标图像分类方法。该方法通过多任务学习和多层次特征融合等方法,有效地提高了在少量训练样本情况下的 SAR 图像分类精度。

刘旗等人(2022)设计了一种基于门控多尺度匹

配网络的小样本 SAR 图像分类方法,该方法的核心在于多尺度特征提取模块与权重门控单元。多尺度特征提取模块能够针对匹配网络的不同卷积层进行多尺度特征提取,权重门控单元能够针对不同的分类任务赋予特征不同的权重值。在与 3 种小样本学习方法和两种小样本 SAR 图像分类方法的比较中,该方法取得了一定的性能提升。

虽然基于度量学习的方法结构灵活,相对降低了特征提取器的训练难度。但是,该类方法过于依赖采样策略,当采样策略过于简单时,度量学习只会学习到简单的样本,难以继续训练;当采样策略过于困难时,会导致收敛慢、不收敛,甚至出现过拟合的问题。同时,基于度量学习的方法在一定程度上缺乏可解释性,虽然可以根据“像哪类归哪类”的原则进行解释,但是具体分类过程是在深度网络学习到的特征嵌入空间中进行的,而如何定义嵌入空间中的特征仍是尚未解决的难题。因此,如何进一步提升基于度量学习的方法的可信性是有待进一步研究的课题。

2.4 综合性方法

由于 SAR 图像与可见光图像成像原理不同,一些由物理知识和领域知识等要素引导的综合性方法也被用于 SAR 图像分类任务,并取得了良好的效果(Guo 等, 2017; Li 等, 2022c)。因此除了以上 3 种分类方法以外,一些综合了深度学习和 SAR 图像特性的方法也得以应用于解决小样本 SAR 图像分类问题,如表 4 所示。

Lin 等人(2017)设计了一种名为卷积高速公路单元(convolutional highway unit)的新型架构用于小样本 SAR 图像分类任务,该架构可以用有限的 SAR 图像数据训练更深层次的网络。卷积高速公路单元架构由修改的卷积高速公路层、最大池化层和 dropout 层组成,可以通过堆叠单元架构来灵活地构成分类网络。构成的网络可以有效提取用于分类的深度特征表示,从而提升小样本 SAR 图像分类精度。

汪航等人(2020)设计了一种深度卷积自编码网络,该网络在卷积神经网络的基础上加入了自编码器用于小样本 SAR 图像分类任务。深度卷积自编码网络首先利用 2D Gabor 滤波对输入的 SAR 图像进行增强,然后利用增强后的图像训练网络,最后构建小样本 SAR 图像分类模型。该网络可以有效避免过拟合问题,提高分类性能。

表 4 综合性小样本 SAR 图像分类方法归纳

Table 4 Overview of comprehensive few-shot SAR image classification methods

方法	来源	年份	类型	主要贡献	数据集	优缺点
Lin 等人(2017)	IEEE Geoscience and Remote Sensing Letters	2017	综合性方法	设计一种名为卷积高速公路单元的新型架构,可以有效提取用于分类的深度特征表示	MSTAR	
汪航等人(2020)	Computer Science	2020	综合性方法	设计一种深度卷积自编码网络,有效避免过拟合问题	MSTAR	优点:与 SAR 图像领域知识相结合,更好地利用 SAR 图像自身特性指导小样本学习。
Cao 等人(2021)	Remote Sensing	2021	综合性方法	设计一种集成的反事实样本生成和过滤方法用于小样本 SAR 图像分类	MSTAR	缺点:依赖人工设计的数据增强方法和专家知识,导致高昂的人工成本且泛化能力有待验证。
Yang 等人(2022c)	IEEE Transactions on Geoscience and Remote Sensing	2021	综合性方法	设计混合损失图注意力网络	MSTAR	
Zhang 等人(2022)	IEEE Transactions on Geoscience and Remote Sensing	2022	综合性方法	设计以领域知识引导的双流深度网络	MSTAR	
应自炉等人(2023)	Journal of Signal Processing	2023	综合性方法	设计一种基于孪生自监督学习的小样本 SAR 图像识别方法	MSTAR	

Cao 等人(2021)设计了一种集成的反事实样本生成和过滤方法,该方法包括一个生成组件和一个过滤组件。生成组件利用生成对抗网络生成反事实目标样本,过滤组件利用多个支持向量机器学习不同的 SAR 目标样本集,从而提供伪标签来训练模型,从而提升分类性能。

Yang 等人(2022c)设计了混合损失图注意力网络(mixed loss graph attention network, MGA-Net),该网络的分类过程包括 3 个阶段。首先,通过数据增强模块扩展任务集来获得更多的样本;其次,设计了将样本映射到具有强类内相似性和类间发散性的嵌入空间;最后,构建了多层图注意力网络,并提出了新的混合损失来获得分类结果。MGA-Net 中的多层图注意力网络通过注意力机制准确捕捉样本之间的关系,同时混合损失增加了类间可分性并加速收敛。因此,该网络在 MSTAR 和 OpenSARShip 均取得了良好的分类性能。

Zhang 等人(2022)设计了以领域知识引导的双流深度网络(domain knowledge-powered two-stream deep network, DKTS-N),该网络结合了车辆方位角、振幅和相位数据等 SAR 领域知识来辅助小样本 SAR 图像分类任务。DKTS-N 通过提取整个图像和图像 patches 的特征,有效利用了 SAR 领域知识。同时,DKTS-N 改进了推土距离(earth mover's distances,

EMD)来测量车辆的全局特征和局部特征之间的结构信息距离,实现了双流深度网络的特征度量。DKTS-N 还利用最近邻分类器代替结构化的全连接层进行 K -shot 分类,解决了不同方位角下同一目标的 SAR 图像存在差异的难题。最后,DKTS-N 充分利用 SAR 车辆域知识的概念(两栖步战车具有防浪板、不同型号的主战坦克炮管大小具有差异等),用于辅助识别任务,有效提升了小样本 SAR 车辆分类精度。

应自炉等人(2023)设计了一种基于孪生自监督学习的小样本 SAR 图像识别方法。首先,该方法通过孪生特征提取网络对无标注 SAR 图像进行数据增强,从而建立正负样本对。其次,通过孪生自监督学习模块,利用对比学习方法降低头部网络,并根据无监督对比学习方法,对损失函数和特征信息冗余损失函数进行联合优化。经过联合优化之后,预训练网络会具有较好的表征能力。最后,在下游网络中加载自监督预训练网络权重,再利用交叉熵损失完成下游网络中的小样本 SAR 图像识别任务。该方法可在无标注数据中获得较好的表征能力,针对小样本 SAR 图像识别中的过拟合问题提供了有效的解决方案。

虽然综合性方法充分利用了 SAR 的成像特征和各领域知识,有效提升了特定领域的小样本 SAR

图像分类性能。但是,该类方法较为依赖人工设计的数据增强方法和专家知识,从而导致高昂的人工成本。同时,特定领域知识引导的分类方法泛化能力还有待进一步验证。

综合分析以上4类小样本SAR图像分类方法,基于迁移学习的方法、基于元学习的方法和基于度量学习的方法均属于深度学习方法,而综合性方法则引入了SAR成像特性和领域知识等要素辅助小样本SAR图像分类任务。综合性方法虽然现阶段还存在一定依赖专家知识等问题,但是由于其紧密结合SAR图像自身的特性,本文认为该类方法最具发展潜力,值得进一步研究与探索。

3 小样本学习模型迁移效果分析

本节利用MSTAR数据集测试了3类16种经典小样本学习方法的分类性能。这些小样本学习方法仅利用可见光图像进行训练和测试,并未迁移到SAR图像上测试其分类效果(葛轶洲等,2022; Zhang等,2023b)。因此,本文利用小样本学习方法综合库(library for few-shot learning, LibFewShot)进行实验,在统一的框架内测试了16种经典方法的分类精度和运行时间(Li等,2023a),如表5所示。

表5 小样本学习模型在MSTAR上的分类精度
Table 5 Classification accuracy of few-shot learning model on MSTAR

方法	来源	类型	骨干网	分类精度/%		运行时间/min	
				5-way 1-shot	5-way 5-shot	5-way 1-shot	5-way 5-shot
Baseline(Chen等,2019)	ICLR 2019	迁移学习	Conv64F	54.44	<u>83.13</u>	0.90	2.18
Baseline++(Chen等,2019)	ICLR 2019	迁移学习	Conv64F	59.98	86.37	5.85	15.27
SKD_Model(Rajasegaran等,2021)	BMVC 2021	迁移学习	Conv64F	<u>57.92</u>	78.39	0.48	0.52
MAML(Finn等,2017)	ICML 2017	元学习	Conv64F	19.87	60.67	0.10	0.18
Versa(Gordon等,2019)	ICLR 2019	元学习	Conv64F	66.96	<u>68.01</u>	0.72	0.76
R2D2(Bertinetto等,2019)	ICLR 2019	元学习	Conv64F	<u>63.99</u>	68.88	0.58	0.68
MTL(Sun等,2019)	CVPR 2019	元学习	Conv64F	18.13	47.07	0.08	0.10
Leo(Rusu等,2019)	ICLR 2019	元学习	Conv64F	36.00	44.00	0.08	0.10
ANIL(Raghu等,2020)	ICLR 2020	元学习	Conv64F	20.99	61.91	0.62	0.84
Boil(Oh等,2021b)	ICLR2021	元学习	Conv64F	43.94	54.50	0.38	0.52
Proto_Net(Snell等,2017)	NIPS 2017	度量学习	Conv64F	39.68	42.72	0.46	0.52
Relation Net(Sung等,2018)	CVPR 2018	度量学习	Conv64F	64.84	77.51	0.64	0.78
DN4(Li等,2019b)	CVPR 2019	度量学习	Conv64F	<u>67.37</u>	<u>85.15</u>	0.64	0.80
CovaMNet(Li等,2019c)	AAAI 2019	度量学习	Conv64F	58.75	45.75	0.62	0.76
Feat(Ye等,2020)	CVPR 2020	度量学习	Conv64F	46.11	56.36	0.60	0.74
ATL_Net(Dong等,2020)	IJCAI 2020	度量学习	Conv64F	72.03	88.81	0.63	0.76

注:加粗、下划线字体分别表示每类方法中分类精度最优、次优的结果;SKD_Model: self-supervised knowledge distillation model; MAML: model-agnostic meta-learning; R2D2: ridge regression differentiable discriminator; MTL: meta-transfer learning; LEO: latent embedding optimization; ANIL: almost no inner loop; BOIL: body only update in inner loop; Proto_Net: prototypical networks; DN4: deep nearest neighbor neural network; CovaMNet: covariance metric networks; FEAT: few-shot embedding adaptation transformer; ATL_Net: adaptive task-aware local representations network。

3.1 分类精度分析

表 5 中分类精度的两列分别展示在 5-way 1-shot 和 5-way 5-shot 任务中 16 种方法的分类准确性。整体上看,基于度量学习的小样本方法迁移到 SAR 图像分类领域整体上取得了较好的效果;基于元学习的方法整体精度较差;基于迁移学习的方法精度介于度量学习和元学习之间。

基于迁移学习的方法通过在 SAR 图像数据集上微调可见光图像预训练得到的初始参数来实现跨域迁移(Pan 和 Yang, 2010; Zhang 等, 2017; Zamir 等, 2018)。在跨域迁移的过程中, SAR 领域知识未能得到很好的利用,导致了初始参数在微调后未能适配小样本 SAR 图像分类任务(Zhong 等, 2019; Geng 等, 2020)。因此,虽然迁移学习的方法在一定程度上可以弥补数据不足带来的缺陷,但是当源域与目标域图像差异较大时,基于迁移学习的方法性能难以得到保障(Lang 等, 2022)。

基于元学习的方法十分依赖于元学习器学习到的先验知识来指导后续训练,而现有的 SAR 图像数据集训练样本较少(Singh 等, 2021)。因此,过少的训练样本难以很好地支持元学习器的学习,进而导致基于元学习的方法整体分类性能下降(赵凯琳 等, 2021)。该类方法虽然很好地运用了“learning to learn”的思想,但是在仅有少量 SAR 图像训练样本的情况下,元学习器难以挖掘 SAR 图像分类任务的特点(Li 等, 2022d)。在今后的研究工作中,如何能够设计更加高效的元学习器,从而提升基于元学习的小样本 SAR 图像分类方法性能是值得进一步挖掘的课题。

此外,基于度量学习的方法整体上取得了较好的分类精度。该类方法不仅减少了对先验知识的依赖,还很好地运用了对比学习的思想,很好地解决了当前 SAR 图像分类任务中训练样本缺乏的问题(Li 等, 2020; Yuan 等, 2023)。此外,在该类方法中, ATL_Net(Dong 等, 2020)和 DN4(Li 等, 2019b)分别取得了最优和次优分类精度。结合具体方法来看,发现这两种方法均聚焦于局部表示(local representations)。SAR 图像的特点决定了关注其局部表示有利于提升分类方法的分类性能(Cai 等, 2022)。最后, ATL_Net(Dong 等, 2020)在 5-way 1-shot 和 5-way 5-shot 任务中均取得了最优分类精度。该方法设计了一种自适应的情景注意力机制,该机制利用多层

感知机学习一个任务感知的自适应阈值。该阈值可以根据不同任务找到关键语义 patches 来提升方法的整体性能,从而得到了目前的最优分类精度。同时,可以看到在 5-way 1-shot 任务中,仅有包含自适应的情景注意力机制的 ATL_Net 精度超过 70%, 在 5-way 5-shot 任务中 ATL_Net 也取得了最佳的分类性能。因此,可以推测自适应的情景注意力机制能够较好地解决小样本 SAR 图像分类问题。但是,目前基于度量学习的方法往往不使用或仅使用单一的注意力机制,忽略了 SAR 图像样本的多尺度特征。因此,设计合理的多尺度注意力机制能够更加充分地提取训练样本的多尺度特征,从而在一定程度上提升该类方法的分类性能。

3.2 运行时间分析

表 5 的最后两列分别展示在 5-way 1-shot 和 5-way 5-shot 任务中 16 种方法的运行时间。仅凭分类精度来评判一个方法的好坏过于武断,在一些应用场景下对方法的运行效率也有着较高的要求。因此,本文还测试了 16 种方法的运行时间来初步判断它们的运行效率。由于训练时为每个方法设定了相同的 epoch,因此采用平均运行时间进行比较。

整体上看,基于迁移学习的方法在这 3 个类别中具有最长的运行时间。出现这种现象的原因可能是迁移学习需要学习新的领域知识来微调初始模型,这个过程需要很长的运行时间。基于元学习的方法具有最短的运行时间,但分类精度较差。出现这种现象的原因可能是 MSTAR 数据集相较于可见光数据集数据量非常少。在训练阶段,元学习器未能学习到足够的知识,这导致最终准确率通常较低,并且相应地减少了训练时间。

基于度量学习的方法具有较短的运行时间,同时该类方法可以得到更好的分类精度。因此,该类方法是现阶段最适合小样本 SAR 图像分类的方法,可以在实际应用中起到良好的效果。基于度量学习的方法巧妙地利用类与类中心的距离来判别特征相似性,这个判别方式极大地简化了相似性判别的过程。特别是 ATL_Net(Dong 等, 2020)和 DN4(Li 等, 2019b)两种方法在精度上与基于迁移学习的方法最优精度相当,但与 Baseline 和 Baseline++(Chen 等, 2019)相比,前两种方法的运行时间大大缩短。这一现象值得进一步探索和研究,从而结合基于度量学习方法的优势改进其他方法。

4 趋势与挑战

本文根据不同的学习方式总结了小样本 SAR 图像分类方法,阐述了各种已有方法的特点和主要贡献。经过整理,发现虽然小样本 SAR 图像分类问题作为交叉学科,各项研究仍处于起步阶段,但是已有很多值得进一步探索的方法出现,体现了该领域研究存在着极大的潜力。本节基于对以上方法的总结,归纳了小样本 SAR 图像分类问题的未来发展趋势和发展挑战。

1)深度学习和物理特性启发的综合性方法。小样本 SAR 图像分类的综合性方法虽然目前展现出强大的潜力,但是如何有效地将深度学习方法(Li 等,2022e)与 SAR 成像相关的物理知识有机结合,需要依赖专家知识(Huang 等,2022)。同时,特定的物理知识和 SAR 领域知识引导的分类方法有时会出现泛化能力不足的问题,在脱离特定的数据集后分类精度显著下降。因此,若要在 SAR 领域实现深度学习的应用价值,必须发展物理启发的基于深度学习的 SAR 图像处理技术,即微波视觉这一交叉学科研究方向(Shang 等,2022)。该方向通过借鉴人脑视觉感知机理和计算机视觉相关技术,融合电磁物理规律与雷达成像机理,研究面向雷达等电磁感知数据的物理智能理论与方法。通过对该领域的深入研究,可以设计深度学习技术、SAR 成像物理特性和领域知识引导的综合性方法,从而有效地解决小样本 SAR 图像分类问题。

2)结合多种 SAR 领域知识的分类方法。SAR 成像的时间序列等序列特征和不同极化模式下的相位信息都可以作为 SAR 图像分类的依据(Yang 等,2022b)。同时,针对特定数据集,待分类目标也具有一定的领域特征。例如 SAR 飞机的机翼以及 MSTAR 数据集中坦克的炮管和履带等,这些领域知识都可以辅助小样本 SAR 图像分类。因此,如何充分挖掘 SAR 成像和特定数据集的领域知识并设计自适应的损失函数也值得进一步探索。

3)结合 SAR 图像数据增强与分辨率重建的分类方法。SCAN(Sun 等,2022)中提到传统的通过旋转等方式的数据增强方法生成的 SAR 图像与现实中的该角度下的成像不符,而利用现实中不存在的图像训练分类模型难以保证最终分类性能的同时,也

存在模型可信性缺陷。此外,图像高分辨率重建算法已经得到了广泛的研究。而当 SAR 成像的分辨率提高到 0.3 m 时,可从 SAR 图像中确认绝大多数军事目标。因此,设计一种满足 SAR 图像特性的数据增强与分辨率重建方法,也是未来小样本 SAR 图像分类任务中的一大挑战。

4)鲁棒的轻量化稀疏 SAR 图像分类网络。在小样本 SAR 图像分类任务中,除了数据缺少带来的过拟合等问题,电磁干扰导致的 SAR 目标变形和强干扰等复杂条件,也为该任务带来了极大的挑战(Li 等,2023b)。此外,由于带标注且可用于训练的 SAR 图像较少,通过剪枝减少模型冗余参数,或者对分类模型进行正则化操作,可以有效防止捕获 SAR 图像中的噪声(Wang 等,2023)。因此,如何设计轻量化稀疏 SAR 图像分类网络,使其在强干扰条件下具备鲁棒的分类性能也是不容忽视的一大挑战。

5 结语

本文首先回顾了早期 SAR 图像分类方法,并提出 SAR 图像分类存在小样本问题。其次,给出了小样本 SAR 图像分类的问题定义,并归纳了现有的数据集和评价指标。根据使用的深度学习方法,将小样本 SAR 图像分类方法分为 3 类的同时,还归纳总结了 6 种综合性方法。通过综合分析,认为综合性方法最具发展潜力,是未来值得进一步挖掘的研究方向。为了进一步补充小样本 SAR 图像分类的测评基准,本文利用 LibFewShot 和 MSTAR 数据集测试了 16 种可见光小样本学习方法迁移到 SAR 图像领域的分类性能。最后,基于对现有小样本 SAR 图像分类方法的归纳,讨论了其未来的研究方向与发展挑战。

尽管小样本 SAR 图像分类方法在近年来得到了广泛关注,并取得了一定的研究进展,但是,现有方法仍难以满足实际应用需求,亟需进一步研究。本文希望通过对小样本学习与 SAR 图像分类这一交叉学科进行综述,能让更多学者关注这一领域,进而提出更好性能的小样本 SAR 图像分类方法。

参考文献(References)

Afrasiyabi A, Larochelle H, Lalonde J F and Gagné C. 2022. Matching

- feature sets for few-shot image classification//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 9004-9014 [DOI: 10.1109/CVPR52688.2022.00881]
- Antonelli S, Avola D, Cinque L, Crisostomi D, Foresti G L, Galasso F, Marini M R, Mecca A and Pannone D. 2022. Few-shot object detection: a survey. *ACM Computing Surveys*, 54 (11s) : #242 [DOI: 10.1145/3519022]
- Bertinetto L, Henriques J F, Torr P H S and Vedaldi A. 2019. Meta-learning with differentiable closed-form solvers//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA: OpenReview.net
- Cai J L, Zhang Y T, Guo J Y, Zhao X, Lv J W and Hu Y X. 2022. ST-PN: a spatial transformed prototypical network for few-shot SAR image classification. *Remote Sensing*, 14 (9) : #2019 [DOI: 10.3390/RS14092019]
- Cao C J, Cui Z Y, Cao Z J, Wang L Y and Yang J Y. 2021. An integrated counterfactual sample generation and filtering approach for SAR automatic target recognition with a small sample set. *Remote Sensing*, 13 (19) : #3864 [DOI: 10.3390/rs13193864]
- Chen J K, Qiu X L, Ding C B and Wu Y R. 2022. SAR image classification based on spiking neural network through spike-time dependent plasticity and gradient descent. *ISPRS Journal of Photogrammetry and Remote Sensing*, 188: 109-124 [DOI: 10.1016/j.isprsjprs.2022.03.021]
- Chen L C and Fu D Y. 2022. Survey on machine learning methods for small sample data. *Computer Engineering*, 48 (11) : 1-13 (陈良臣, 傅德印. 2022. 面向小样本数据的机器学习方法研究综述. *计算机工程*, 48 (11) : 1-13) [DOI: 10.19678/j.issn.1000-3428.0065347]
- Chen W Y, Liu Y C, Kira Z, Wang Y C F and Huang J B. 2019. A closer look at few-shot classification//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA: OpenReview.net
- Chen Y, Meng H B, Wen X L, Ma P G, Qin Y X, Ma Z X and Liu Z Y. 2018. Classification methods of a small sample target object in the sky based on the higher layer visualizing feature and transfer learning deep networks. *EURASIP Journal on Wireless Communications and Networking*, 2018 (1) : #127 [DOI: 10.1186/s13638-018-1133-2]
- Chen Y B, Liu Z, Xu H J, Darrell T and Wang X L. 2021. Meta-baseline: exploring simple meta-learning for few-shot learning//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 9062-9071 [DOI: 10.1109/ICCV48922.2021.00893]
- Dong C Q, Li W B, Huo J, Gu Z and Gao Y. 2020. Learning task-aware local representations for few-shot learning//Proceedings of the 29th International Joint Conference on Artificial Intelligence. Yokohama, Japan: IJCAI. org: 716-722 [DOI: 10.24963/IJCAI.2020/100]
- Dong H W, Song K C, Wang Q, Yan Y H and Jiang P. 2022. Deep metric learning-based for multi-target few-shot pavement distress Classification. *IEEE Transactions on Industrial Informatics*, 18 (3) : 1801-1810 [DOI: 10.1109/THL2021.3090036]
- Feng K X and Chaspari T. 2023. Few-shot learning in emotion recognition of spontaneous speech using a Siamese neural network with adaptive sample pair formation. *IEEE Transactions on Affective Computing*, 14 (2) : 1627-1633 [DOI: 10.1109/TAFFC.2021.3109485]
- Finn C, Abbeel P, Levine S. 2017. Model-agnostic meta-learning for fast adaptation of deep networks//Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia: JMLR. org: 1126-1135
- Frikha A, Krompaß D, Köpken H G and Tresp V. 2021. Few-shot one-class classification via meta-learning//Proceedings of the 35th AAAI Conference on Artificial Intelligence, 33rd Conference on Innovative Applications of Artificial Intelligence, The 11th Symposium on Educational Advances in Artificial Intelligence. [s.l.] : AAAI Press: 7448-7456 [DOI: 10.1609/aaai.v35i8.16913]
- Fu K, Zhang T F, Zhang Y, Wang Z R and Sun X. 2022. Few-shot SAR target classification via metalearning. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #2000314 [DOI: 10.1109/TGRS.2021.3058249]
- Gao H H, Xiao J S, Yin Y Y, Liu T and Shi J G. 2022. A mutually supervised graph attention network for few-shot segmentation: the perspective of fully utilizing limited samples. *IEEE Transactions on Neural Networks and Learning Systems*, 35 (4) : 4826-4838 [DOI: 10.1109/TNNLS.2022.3155486]
- Ge Y Z, Liu H, Wang Y, Xu B L, Zhou Q and Shen F R. 2022. Survey on deep learning image recognition in dilemma of small samples. *Journal of Software*, 33 (1) : 193-210 (葛轶洲, 刘恒, 王言, 徐百乐, 周青, 申富饶. 2022. 小样本困境下的深度学习图像识别综述. *软件学报*, 33 (1) : 193-210) [DOI: 10.13328/j.cnki.jos.006342]
- Geng J, Deng X Y, Ma X R and Jiang W. 2020. Transfer learning for SAR image classification via deep joint distribution adaptation networks. *IEEE Transactions on Geoscience and Remote Sensing*, 58 (8) : 5377-5392 [DOI: 10.1109/TGRS.2020.2964679]
- Gong S R, Xu S J, Zhou L F, Zhu J and Zhong S. 2022. Deformable atrous convolution nearshore SAR small ship detection incorporating mixed attention. *Journal of Image and Graphics*, 27 (12) : 3663-3676 (龚声蓉, 徐少杰, 周立凡, 朱杰, 钟珊. 2022. 融入混合注意力的可变形空洞卷积近岸 SAR 小舰船检测. *中国图象图形学报*, 27 (12) : 3663-3676) [DOI: 10.11834/jig.210866]
- Gordon J, Bronskill J, Bauer M, Nowozin S and Turner R E. 2019. Meta-learning probabilistic inference for prediction//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA: OpenReview.net

- Guo J Y, Lei B, Ding C B and Zhang Y T. 2017. Synthetic aperture radar image synthesis by using generative adversarial nets. *IEEE Geoscience and Remote Sensing Letters*, 14 (7) : 1111-1115 [DOI: 10.1109/LGRS.2017.2699196]
- Hou X Y, Ao W, Song Q, Lai J, Wang H P and Xu F. 2020. FUSAR-Ship: building a high-resolution SAR-AIS matchup dataset of Gaofen-3 for ship detection and recognition. *Science China Information Sciences*, 63 (4) : #140303 [DOI: 10.1007/s11432-019-2772-5]
- Huang L Q, Liu B, Li B Y, Guo W W, Yu W H, Zhang Z H and Yu W X. 2018. OpenSARShip: a dataset dedicated to Sentinel-1 ship interpretation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11 (1) : 195-208 [DOI: 10.1109/JSTARS.2017.2755672]
- Huang Z L, Dumitru C O, Pan Z, Lei B and Datcu M. 2021. Classification of large-scale high-resolution SAR images with deep transfer learning. *IEEE Geoscience and Remote Sensing Letters*, 18 (1) : 107-111 [DOI: 10.1109/LGRS.2020.2965558]
- Huang Z L, Pan Z X and Lei B. 2020. What, where, and how to transfer in SAR target recognition based on deep CNNs. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4) : 2324-2336 [DOI: 10.1109/TGRS.2019.2947634]
- Huang Z L, Yao X W, Liu Y, Dumitru C O, Datcu M and Han J W. 2022. Physically explainable CNN for SAR image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 190: 25-37 [DOI: 10.1016/j.isprsjprs.2022.05.008]
- Jian Y R and Torresani L. 2022. Label hallucination for few-shot classification//Proceedings of the 36th AAAI Conference on Artificial Intelligence, 34th Conference on Innovative Applications of Artificial Intelligence, The 12th Symposium on Educational Advances in Artificial Intelligence. [s.l.]: AAAI Press: 7005-7014 [DOI: 10.1609/AAAI.v36i6.20659]
- Jiang W, Huang K, Geng J and Deng X Y. 2021. Multi-scale metric learning for few-shot learning. *IEEE Transactions on Circuits and Systems for Video Technology*, 31(3) : 1091-1102 [DOI: 10.1109/TCSVT.2020.2995754]
- Kaul P, Xie W D and Zisserman A. 2022. Label, verify, correct: a simple few shot object detection method//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 14217-14227 [DOI: 10.1109/CVPR52688.2022.01384]
- Keydel E R, Lee S W and Moore J T. 1996. MSTAR extended operating conditions: a tutorial//Proceedings of SPIE 2757. Algorithms for Synthetic Aperture Radar Imagery III. Orlando, USA: SPIE: 228-242 [DOI: 10.1117/12.242059]
- Krizhevsky A, Sutskever I and Hinton G E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6) : 84-90 [DOI: 10.1145/3065386]
- Lai J X, Yang S Q, Jiang G N, Wang X, Li Y X, Jia Z H, Chen X C, Liu J, Gao B B, Zhang W, Xie Y and Wang C J. 2022. Rethinking the metric in few-shot learning: from an adaptive multi-distance perspective//Proceedings of the 30th ACM International Conference on Multimedia. Lisboa, Portugal: ACM: 4021-4030 [DOI: 10.1145/3503161.3547853]
- Lang H T, Yang G A, Li C N and Xu J W. 2022. Multisource heterogeneous transfer learning via feature augmentation for ship classification in SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5228814 [DOI: 10.1109/TGRS.2022.3178703]
- LeCun Y, Bengio Y and Hinton G. 2015. Deep learning. *Nature*, 521 (7553): 436-444 [DOI: 10.1038/nature14539]
- Li H R, Wang T Y and Wang S W. 2022b. Few-Shot SAR target classification combining both spatial and frequency information//Proceedings of 2022 IEEE Global Communications Conference. Rio de Janeiro, Brazil: IEEE: 480-485 [DOI: 10.1109/GLOBECOM48099.2022.10001168]
- Li P, Zhao G P and Xu X H. 2022a. Coarse-to-fine few-shot classification with deep metric learning. *Information Sciences*, 610: 592-604 [DOI: 10.1016/j.ins.2022.08.048]
- Li W, Gao Y H, Zhang M M, Tao R and Du Q. 2023b. Asymmetric feature fusion network for hyperspectral and SAR image classification. *IEEE Transactions on Neural Networks and Learning Systems*, 34(10) : 8057-8070 [DOI: 10.1109/TNNLS.2022.3149394]
- Li W B, Wang L, Xu J L, Huo J, Gao Y and Luo J B. 2019b. Revisiting local descriptor based image-to-class measure for few-shot learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 7253-7260 [DOI: 10.1109/CVPR.2019.00743]
- Li W B, Wang Z Y, Yang X S, Dong C Q, Tian P Z, Qin T X, Huo J, Shi Y H, Wang L, Gao Y and Luo J B. 2023a. LibFewShot: a comprehensive library for few-shot learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45 (12) : 14938-14955 [DOI: 10.1109/TPAMI.2023.3312125]
- Li W B, Xu J L, Huo J, Wang L, Gao Y and Luo J B. 2019c. Distribution consistency based covariance metric networks for few-shot learning//Proceedings of the 33rd AAAI Conference on Artificial Intelligence, The 31st Innovative Applications of Artificial Intelligence Conference, The 9th AAAI Symposium on Educational Advances in Artificial Intelligence. Honolulu, USA: AAAI Press: 8642-8649 [DOI: 10.1609/AAAI.v33i01.33018642]
- Li X, Zhang G, Cui H, Hou S S, Wang S Y, Li X, Chen Y J, Li Z J and Zhang L. 2022c. MCANet: a joint semantic segmentation framework of optical and SAR images for land use classification. *International Journal of Applied Earth Observation and Geoinformation*, 106: #102638 [DOI: 10.1016/j.jag.2021.102638]
- Li X M, Yu L Q, Fu C W, Fang M and Heng P A. 2020. Revisiting metric learning for few-shot image classification. *Neurocomputing*, 406: 49-58 [DOI: 10.1016/J.NEUCOM.2020.04.040]

- Li X X, Sun Z, Xue J H and Ma Z Y. 2021. A concise review of recent few-shot meta-learning methods. *Neurocomputing*, 456: 463-468 [DOI: 10.1016/j.neucom.2020.05.114]
- Li X X, Yang X C, Ma Z Y and Xue J H. 2023c. Deep metric learning for few-shot image classification: a review of recent developments. *Pattern Recognition*, 138: #109381 [DOI: 10.1016/j.patcog.2023.109381]
- Li Y, Wang J B, Xu Y L, Li H, Miao Z and Zhang Y F. 2017. DeepSAR-Net: deep convolutional neural networks for SAR target recognition//Proceedings of the 2nd International Conference on Big Data Analysis (ICBDA). Beijing, China: IEEE: 740-743 [DOI: 10.1109/ICBDA.2017.8078734]
- Li Y B, Li X, Sun Q and Dong Q H. 2022e. SAR image classification using CNN embeddings and metric learning. *IEEE Geoscience and Remote Sensing Letters*, 19: #4002305 [DOI: 10.1109/LGRS.2020.3022435]
- Li Y Y, Peng C, Chen Y Q, Jiao L C, Zhou L H and Shang R H. 2019a. A deep learning method for change detection in synthetic aperture radar images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8): 5751-5763 [DOI: 10.1109/TGRS.2019.2901945]
- Li Z K, Liu M, Chen Y S, Xu Y M, Li W and Du Q. 2022d. Deep cross-domain few-shot learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5501618 [DOI: 10.1109/TGRS.2021.3057066]
- Liang K J, Rangrej S B, Petrovic V and Hassner T. 2022. Few-shot learning with noisy labels//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 9079-9088 [DOI: 10.1109/CVPR52688.2022.00888]
- Lin Z, Ji K F, Kang M, Leng X G and Zou H X. 2017. Deep convolutional highway unit network for SAR target classification with limited labeled training data. *IEEE Geoscience and Remote Sensing Letters*, 14(7): 1091-1095 [DOI: 10.1109/LGRS.2017.2698213]
- Liu D Y, Gao X Z and Shen Q M. 2020. Prototypical network for radar image recognition with few samples. *Journal of Physics: Conference Series*, 1634 (1): #012116 [DOI: 10.1088/1742-6596/1634/1/012116]
- Liu Q, Zhang X Y and Liu Y X. 2022. Few-shot SAR target recognition based on gated multi-scale matching network. *Systems Engineering and Electronics*, 44(11): 3346-3356 (刘旗, 张新禹, 刘永祥). 2022. 基于门控多尺度匹配网络的小样本 SAR 目标识别. *系统工程与电子技术*, 44(11): 3346-3356 [DOI: 10.12305/j.issn.1001-506X.2022.11.08]
- Liu Q F, Cao W M and He Z H. 2023a. Cycle optimization metric learning for few-shot classification. *Pattern Recognition*, 139: #109468 [DOI: 10.1016/j.patcog.2023.109468]
- Liu W, Bao Q, Sun Y and Mei T. 2023b. Recent advances of monocular 2D and 3D human pose estimation: a deep learning perspective. *ACM Computing Surveys*, 55(4): #80 [DOI: 10.1145/3524497]
- Liu Y, Lei Y B, Fan J L, Wang F P, Gong Y C and Tian Q. 2021. Survey on image classification technology based on small sample learning. *Acta Automatica Sinica*, 47(2): 297-315 (刘颖, 雷研博, 范九伦, 王富平, 公衍超, 田奇). 2021. 基于小样本学习的图像分类技术综述. *自动化学报*, 47(2): 297-315 [DOI: 10.16383/j.aas.c190720]
- Lu D, Cao L Y and Liu H W. 2019. Few-shot learning neural network for SAR target recognition//Proceedings of the 6th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR). Xiamen, China: IEEE: 1-4 [DOI: 10.1109/APSAR46974.2019.9048517]
- Oh J, Youm G Y and Kim M. 2021a. SPAM-net: A CNN-based SAR target recognition network with pose angle marginalization learning. *IEEE Transactions on Circuits and Systems for Video Technology*, 31(2): 701-714 [DOI: 10.1109/TCSVT.2020.2987346]
- Oh J, Yoo H, Kim C H and Yun S Y. 2021b. Boil: towards representation change for few-shot learning//Proceedings of the 9th International Conference on Learning Representations. [s.l]: OpenReview.net
- Pan S J and Yang Q. 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22 (10): 1345-1359 [DOI: 10.1109/TKDE.2009.191]
- Pan Z X, Bao X J, Zhang Y T, Wang B W, An Q Z and Lei B. 2019. Siamese network based metric learning for SAR target classification//Proceedings of 2019 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Yokohama, Japan: IEEE: 1342-1345 [DOI: 10.1109/IGARSS.2019.8898210]
- Raghu A, Raghu M, Bengio S and Vinyals O. 2020. Rapid learning or feature reuse? Towards understanding the effectiveness of MAML//Proceedings of the 8th International Conference on Learning Representations. Addis Ababa, Ethiopia: OpenReview.net
- Rajasegaran J, Khan S, Hayat M, Khan F S and Shah M. 2021. Self-supervised knowledge distillation for few-shot learning//Proceedings of the 32nd British Machine Vision Conference. [s.l]: BMVA Press: #179
- Rostami M, Kolouri S, Eaton E and Kim K. 2019a. SAR image classification using few-shot cross-domain transfer learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach, USA: IEEE: 907-915 [DOI: 10.1109/CVPRW.2019.00120]
- Rostami M, Kolouri S, Eaton E and Kim K. 2019b. Deep transfer learning for few-shot SAR image classification. *Remote Sensing*, 11(11): #1374 [DOI: 10.3390/rs11111374]
- Rusu A A, Rao D, Sygnowski J, Vinyals O, Pascanu R, Osindero S and Hadsell R. 2019. Meta-learning with latent embedding optimization//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA: OpenReview.net
- Shang R H, Wang J M, Jiao L C, Yang X H and Li Y Y. 2022. Spatial feature-based convolutional neural network for PolSAR image clas-

- sification. *Applied Soft Computing*, 123: #108922 [DOI: 10.1016/j.asoc.2022.108922]
- Shi Z H, Wu C W, Li C J, You Z Z, Wang Q and Ma C C. 2023. Object detection techniques based on deep learning for aerial remote sensing images: a survey. *Journal of Image and Graphics*, 28(9): 2616-2643 (石争浩, 仵晨伟, 李成建, 尤臻臻, 王泉, 马城城. 2023. 航空遥感图像深度学习目标检测技术研究进展. *中国图象图形学报*, 28(9): 2616-2643) [DOI: 10.11834/jig.221085]
- Singh R, Bharti V, Purohit V, Kumar A, Singh A K and Singh S K. 2021. MetaMed: few-shot medical image classification using gradient-based meta-learning. *Pattern Recognition*, 120: #108111 [DOI: 10.1016/J.PATCOG.2021.108111]
- Snell J, Swersky K and Zemel R. 2017. Prototypical networks for few-shot learning//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA: Curran Associates Inc.: 4080-4090
- Song Y S, Wang T, Cai P Y, Mondal S K and Sahoo J P. 2023. A comprehensive survey of few-shot learning: evolution, applications, challenges, and opportunities. *ACM Computing Surveys*, 55(13s): #271 [DOI: 10.1145/3582688]
- Sun Q R, Liu Y Y, Chua T S and Schiele B. 2019. Meta-transfer learning for few-shot learning//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA: IEEE: 403-412 [DOI: 10.1109/CVPR.2019.00049]
- Sun X, Lv Y X, Wang Z R and Fu K. 2022. SCAN: Scattering characteristics analysis network for few-shot aircraft classification in high-resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5226517 [DOI: 10.1109/TGRS.2022.3166174]
- Sung F, Yang Y X, Zhang L, Xiang T, Torr P H S and Hospedales T M. 2018. Learning to compare: relation network for few-shot learning//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 1199-1208 [DOI: 10.1109/CVPR.2018.00131]
- Tan X F, Li M, Zhang P, Wu Y and Song W Y. 2021. Deep triplet complex-valued network for PolSAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 59(12): 10179-10196 [DOI: 10.1109/TGRS.2021.3053013]
- Tang J X, Zhang F, Zhou Y S, Yin Q and Hu W. 2019. A fast inference networks for SAR target few-shot learning based on improved Siamese networks//*Proceedings of 2019 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Yokohama, Japan: IEEE: 1212-1215 [DOI: 10.1109/IGARSS.2019.8898180]
- Tang L F, Zhang H, Xu H and Ma J Y. 2023. Deep learning-based image fusion: a survey. *Journal of Image and Graphics*, 28(1): 3-36 (唐霖峰, 张浩, 徐涵, 马佳义. 2023. 基于深度学习的图像融合方法综述. *中国图象图形学报*, 28(1): 3-36) [DOI: 10.11834/jig.220422]
- Wang H, Chen X, Tian S Z and Chen D B. 2020. SAR image recognition based on few-shot learning. *Computer Science*, 47(5): 124-128 (汪航, 陈晓, 田晟兆, 陈端兵. 基于小样本学习的SAR图像识别. *计算机科学*, 47(5): 124-128) [DOI: 10.11896/jsjkx.190400136]
- Wang J J, Li W, Gao Y H, Zhang M M, Tao R and Du Q. 2023. Hyperspectral and SAR image classification via multiscale interactive fusion network. *IEEE Transactions on Neural Networks and Learning Systems*, 34(12): 10823-10837 [DOI: 10.1109/TNNLS.2022.3171572]
- Wang K and Zhang G. 2020. SAR target recognition via meta-learning and amortized variational inference. *Sensors*, 20(20): #5966 [DOI: 10.3390/s20205966]
- Wang L, Bai X R, Gong C and Zhou F. 2021. Hybrid inference network for few-shot SAR automatic target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 59(11): 9257-9269 [DOI: 10.1109/TGRS.2021.3051024]
- Wang L, Bai X R and Zhou F. 2019. Few-shot SAR ATR based on conv-BiLSTM prototypical networks//*Proceedings of the 6th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*. Xiamen, China: IEEE: 1-5 [DOI: 10.1109/APSAR46974.2019.9048492]
- Wang R F, Wang L, Li C, Huo C L and Chen J W. 2023. HQ-CNN-based cross-domain change detection of SAR images. *Journal of Image and Graphics*, 28(7): 2208-2220 (王蓉芳, 王良, 李畅, 霍春雷, 陈佳伟. 2023. 整型推理量化CNN的SAR图像跨域变化检测. *中国图象图形学报*, 28(7): 2208-2220) [DOI: 10.11834/jig.211159]
- Wang Y Y, Wang C and Zhang H. 2018. Ship classification in high-resolution SAR images using deep learning of small datasets. *Sensors*, 18(9): #2929 [DOI: 10.3390/s18092929]
- Wang Z C, Fu X Y and Xia K W. 2022. Target classification for single-channel SAR images based on transfer learning with subaperture decomposition. *IEEE Geoscience and Remote Sensing Letters*, 19: #4003205 [DOI: 10.1109/LGRS.2020.3027363]
- Wei D, Li Y and Huang D. 2020. Overview on methods of land classification based on polarimetric SAR images. *Computer Systems and Applications*, 29(11): 29-39. (魏丹, 李渊, 黄丹. 2020. 极化SAR图像地物分类方法综述. *计算机系统应用*, 29(11): 29-39) [DOI: 10.15888/j.cnki.csa.007705]
- Wu J Y, Zhao Z B, Sun C, Yan R Q and Chen X F. 2020. Few-shot transfer learning for intelligent fault diagnosis of machine. *Measurement*, 166: #108202 [DOI: 10.1016/j.measurement.2020.108202]
- Xie H Z, Yao H X, Zhou S C, Zhang S P and Sun W X. 2021. Efficient regional memory network for video object segmentation//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 1286-1295 [DOI: 10.1109/CVPR46437.2021.00134]
- Xing M D, Xie Y Y, GAO Y X, Zhang J S, Liu J M and Wu Z X. 2022. Electromagnetic scattering characteristic extraction and imaging recognition algorithm: a review. *Journal of Radars*, 11(6): 921-

- 942 (邢孟道, 谢意远, 高悦欣, 张金松, 刘嘉铭, 吴之鑫). 2022. 电磁散射特征提取与成像识别算法综述. 雷达学报, 11(6): 921-942 [DOI: 10.12000/JR22232]
- Xu H, Wang J X, Li H, Ouyang D Q and Shao J. 2021b. Unsupervised meta-learning for few-shot learning. *Pattern Recognition*, 116: #107951 [DOI: 10.1016/j.patcog.2021.107951]
- Xu J Y and Le H. 2022. Generating representative samples for few-shot classification//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA: IEEE: 8993-9003 [DOI: 10.1109/CVPR52688.2022.00880]
- Xu Y J and Lang H T. 2020. Distribution shift metric learning for fine-grained ship classification in SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 2276-2285 [DOI: 10.1109/JSTARS.2020.2991784]
- Xu Y J, Sun H, Chen J, Lei L, Ji K F and Kuang G Y. 2021a. Adversarial self-supervised learning for robust SAR target recognition. *Remote Sensing*, 13(20): #4158 [DOI: 10.3390/rs13204158]
- Yang M J, Bai X R, Wang L and Zhou F. 2022c. Mixed loss graph attention network for few-shot SAR target classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-13 [DOI: 10.1109/TGRS.2021.3124336]
- Yang M J, Jiao L C, Liu F, Hou B, Yang S Y, Zhang Y K and Wang J L. 2022b. Coarse-to-fine contrastive self-supervised feature learning for land-cover classification in SAR images with limited labeled data. *IEEE Transactions on Image Processing*, 31: 6502-6516 [DOI: 10.1109/TIP.2022.3211472]
- Yang R, Xu X, Li X R, Wang L and Pu F L. 2020. Learning relation by graph neural network for SAR image few-shot learning//*Proceedings of 2020 IEEE International Geoscience and Remote Sensing Symposium*. Waikoloa, USA: IEEE: 1743-1746 [DOI: 10.1109/IGARSS39084.2020.9323139]
- Yang Y J, Singha S and Mayerle R. 2022a. A deep learning based oil spill detector using Sentinel-1 SAR imagery. *International Journal of Remote Sensing*, 43 (11): 4287-4314 [DOI: 10.1080/01431161.2022.210944]
- Yao S Y, Kang Q, Zhou M C, Rawa M J and Abusorrah A. 2023. A survey of transfer learning for machinery diagnostics and prognostics. *Artificial Intelligence Review*, 56(4): 2871-2922 [DOI: 10.1007/s10462-022-10230-4]
- Yasir M, Wan J H, Xu M M, Sheng H, Zeng Z, Liu S W, Colak A T I and Hossain M S. 2023. Ship detection based on deep learning using SAR imagery: a systematic literature review. *Soft Computing*, 27(1): 63-84 [DOI: 10.1007/s00500-022-07522-w]
- Yazdanpanah M, Rahman A A, Chaudhary M, Desrosiers C, Havaei M, Belilovsky E and Kahou S E. 2022. Revisiting learnable affines for batch norm in few-shot transfer learning//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA: IEEE: 9099-9108 [DOI: 10.1109/CVPR52688.2022.00890]
- Ye H J, Hu H X, Zhan D C and Sha F. 2020. Few-shot learning via embedding adaptation with set-to-set functions//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 8805-8814 [DOI: 10.1109/CVPR42600.2020.00883]
- Ying Z L, Wang W Q, Xu Y and Li W B. 2023. Twin self-supervised learning method for small sample SAR images automatic target recognition. *Journal of Signal Processing*, 39(11): 2080-2090 (应自炉, 王文琪, 徐颖, 李文霸). 2023. 面向小样本 SAR 图像自动目标识别的孪生自监督学习方法. *信号处理*, 39(11): 2080-2090 [DOI: 10.16798/j.issn.1003-0530.2023.11.017]
- Ying Z L, Xuan C, Zhai Y K, Sun B, Li J W, Deng W B, Mai C Y, Wang F G, Labati R D, Piuri V and Scotti F. 2020. TAI-SARNET: deep transferred atrous-inception CNN for small samples SAR ATR. *Sensors*, 20(6): #1724 [DOI: 10.3390/s20061724]
- Yuan Z W, Tang C, Yang A X, Huang W D and Chen W. 2023. Few-shot remote sensing image scene classification based on metric learning and local descriptors. *Remote Sensing*, 15 (3): #831 [DOI: 10.3390/RS15030831]
- Zamir A R, Sax A, Shen W, Guibas L, Malik J and Savarese S. 2018. Taskonomy: disentangling task transfer learning//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 3712-3722 [DOI: 10.1109/CVPR.2018.00391]
- Zeng Q J and Geng J. 2022. Task-specific contrastive learning for few-shot remote sensing image scene classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 191: 143-154 [DOI: 10.1016/j.isprsjprs.2022.07.013]
- Zhai Y K, Deng W B, Lan T, Sun B, Ying Z L, Gan J Y, Mai C Y, Li J W, Labati R D, Piuri V and Scotti F. 2020. MFFA-SARNET: deep transferred multi-level feature fusion attention network with dual optimized loss for small-sample SAR ATR. *Remote Sensing*, 12(9): #1385 [DOI: 10.3390/rs12091385]
- Zhai Y K, Zhou W, Sun B, Li J W, Ke Q R, Ying Z L, Gan J Y, Mai C Y, Labati R D, Piuri V and Scotti F. 2022. Weakly contrastive learning via batch instance discrimination and feature clustering for small sample SAR ATR. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5204317 [DOI: 10.1109/TGRS.2021.3066195]
- Zhang G J, Luo Z P, Cui K W, Lu S J and Xing E P. 2023b. Meta-DETR: image-level few-shot detection with inter-class correlation exploitation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(11): 12832-12843 [DOI: 10.1109/TPAMI.2022.3195735]
- Zhang L, Yang J and Zhang D. 2017. Domain class consistency based transfer learning for image classification across domains. *Information Sciences*, 418-419: 242-257 [DOI: 10.1016/j.ins.2017.08.034.]
- Zhang L B, Leng X G, Feng S J, Ma X J, Ji K F, Kuang G Y and Liu

- L. 2022. Domain knowledge powered two-stream deep network for few-shot SAR vehicle recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5215315 [DOI: 10.1109/TGRS.2021.3116349]
- Zhang R, Yang Y X, Li Y, Wang J B, Li H and Miao Z. 2023a. Multi-task few-shot learning with composed data augmentation for image classification. *IET Computer Vision*, 17(2): 211-221 [DOI: 10.1049/cvi2.12150]
- Zhang R, Yang Y X, Li Y, Wang J B, Miao Z, Li H and Wang Z Q. 2022. Self-supervised learning based few-shot remote sensing scene image classification. *Journal of Image and Graphics*, 27(11): 3371-3381 (张睿, 杨义鑫, 李阳, 王家宝, 苗壮, 李航, 王梓祺. 2022. 自监督学习下小样本遥感图像场景分类. *中国图象图形学报*, 27(11): 3371-3381) [DOI: 10.11834/jig210486]
- Zhao J P, Zhang Z H, Yao W, Datcu M, Xiong H L and Yu W X. 2020. OpenSARUrban: a sentinel-1 SAR image dataset for urban interpretation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 187-203 [DOI: 10.1109/JSTARS.2019.2954850]
- Zhao K L, Jin X L and Wang Y Z. 2021. Survey on few-shot learning. *Journal of Software*, 32(2): 349-369 (赵凯琳, 靳小龙, 王元卓. 2021. 小样本学习研究综述. *软件学报*, 32(2): 349-369) [DOI: 10.13328/j.cnki.jos.006138.]
- Zhao P F, Huang L J, Xin Y, Guo J Y and Pan Z X. 2021. Multi-aspect SAR target recognition based on prototypical network with a small number of training samples. *Sensors*, 21(13): #4333 [DOI: 10.3390/s21134333]
- Zhao Y Q and Cheung N M. 2023. FS-BAN: born-again networks for domain generalization few-shot classification. *IEEE Transactions on Image Processing*, 32: 2252-2266 [DOI: 10.1109/TIP.2023.3266172]
- Zhong C L, Mu X D, He X C, Wang J X and Zhu M. 2019. SAR target image classification based on transfer learning and model compression. *IEEE Geoscience and Remote Sensing Letters*, 16(3): 412-416 [DOI: 10.1109/LGRS.2018.2876378]
- Zhu Z D, Lin K X, Jain A K and Zhou J Y. 2023. Transfer learning in deep reinforcement learning: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(11): 13344-13362 [DOI: 10.1109/TPAMI.2023.3292075]

作者简介

王梓祺, 男, 硕士研究生, 主要研究方向为小样本图像分类。

E-mail: ziqi_wang97@163.com

张睿, 通信作者, 男, 教授, 主要研究方向为数据工程和信息融合。E-mail: 3959966@qq.com

李阳, 男, 副教授, 主要研究方向为计算机视觉与图像检索。

E-mail: solarleon@outlook.com

王家宝, 男, 讲师, 主要研究方向为计算机视觉与机器学习。

E-mail: jiabao_1108@163.com

李允臣, 男, 硕士研究生, 主要研究方向为红外目标检测。

E-mail: 710565525@qq.com

陈瑶, 女, 硕士研究生, 主要研究方向为模型轻量化方法。

E-mail: 1916664304@qq.com