

## 基于多源信息跨域学习的SAR图像目标检测技术研究进展与展望

周正 赵凌君 何奇山 孙忠镇 计科峰\* 匡纲要

(国防科技大学电子科学学院电子信息系统复杂电磁环境效应国家重点实验室 长沙 410073)

**摘要:** 深度学习虽已成为合成孔径雷达(SAR)图像目标检测领域主流方法,但其性能高度依赖于大规模标注数据集。在测试不同分布的SAR数据时,模型的检测性能会出现一定程度下降,难以直接迁移应用,且人工标注成本高昂。针对此瓶颈,学术界开始探索基于多源信息的跨域学习策略,通过整合不同来源(传感器)的光学遥感图像或异源SAR图像等先验信息,辅助检测模型实现跨域知识迁移。该文聚焦深度学习框架下的跨域学习技术,系统梳理该领域最新研究进展,分析该领域的核心问题,从方法论层面分析现有技术的核心优势与适用场景,并基于技术演进规律提出未来发展方向,旨在为提升SAR图像目标检测的泛化能力提供理论支撑与方法论参考。

**关键词:** 合成孔径雷达;深度学习;多源信息;跨域学习;目标检测

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2026)02-0387-22

DOI: 10.12000/JR25205

CSTR: 32380.14.JR25205

**引用格式:** 周正,赵凌君,何奇山,等.基于多源信息跨域学习的SAR图像目标检测技术研究进展与展望[J].雷达学报(中英文),2026,15(2):387-408. doi: 10.12000/JR25205.

**Reference format:** ZHOU Zheng, ZHAO Lingjun, HE Qishan, *et al.* Research progress and prospects of SAR image target detection based on multi-source information cross-domain learning[J]. *Journal of Radars*, 2026, 15(2): 387-408. doi: 10.12000/JR25205.

## Research Progress and Prospects of SAR Image Target Detection Based on Multi-source Information Cross-domain Learning

ZHOU Zheng ZHAO Lingjun HE Qishan SUN Zhongzhen  
JI Kefeng\* KUANG Gangyao

(State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics and Information System, College of Electronic Science and Technology, National University of Defense Technology, Changsha 410073, China)

**Abstract:** Deep learning is primarily used for target detection in Synthetic Aperture Radar (SAR) images; however, its performance heavily relies on large-scale labeled datasets. The detection performance of deep learning models degrades when applied to SAR data with varying distributions, hindering their real-world applicability. In addition, manual labeling of SAR data is costly. Hence, cross-domain learning strategies based on multisource information are being explored to address these challenges. These strategies can assist detection models in realizing cross-domain knowledge migration by integrating prior information from optical remote sensing images or heterogeneous SAR images acquired from different sensors. This paper focuses on cross-

收稿日期: 2025-10-16; 改回日期: 2025-11-27; 网络出版: 2025-12-31

\*通信作者: 计科峰 jikefeng@nudt.edu.cn

\*Corresponding Author: JI Kefeng, jikefeng@nudt.edu.cn

基金项目: 国家自然科学基金(62471475), 湖南省自然科学基金(2024JJ4045), 湖南省研究生科研创新项目(CX20250019), 国防科技大学研究生科研创新项目(XJQY2025014)

Foundation Items: The National Natural Science Foundation of China (62471475), Hunan Provincial Natural Science Foundation of China (2024JJ4045), Hunan Provincial Innovation Foundation for Postgraduate (CX20250019), NUDT Innovation Foundation for Postgraduate (XJQY2025014)

责任编辑: 张增辉 Corresponding Editor: ZHANG Zenghui

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

domain learning technologies within the deep learning framework. In addition, it provides a systematic overview of the latest research progress in this field and analyzes the core issues, advantages, and applicable scenarios of existing technologies from a methodological perspective. It outlines future research directions based on the law of technological evolution, aiming to offer theoretical support and methodological references to enhance the generalizability of target detection in SAR images.

**Key words:** Synthetic Aperture Radar (SAR); Deep learning; Multi-source information; Cross-domain learning; Target detection

## 1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)是一种具有高空间分辨率成像观测能力的主动式微波遥感成像系统,通过对地球表面发射相干电磁波并对其反射的散射回波进行接收来获取图像<sup>[1]</sup>。此外,它能够全天时全天候地对陆海进行监测,并且不受日照和天气条件的限制,因此在海洋监测、交通监管、灾害评估和环境保护等领域有着重要的应用意义<sup>[2-4]</sup>。

然而,与光学遥感图像相比,SAR图像的解译相对困难,数据采集和处理耗时耗力,人工标注成本较高,这些因素都限制了其广泛应用。图1为某港口的高分辨率SAR图像与其对应的光学遥感图像,展示了它们在几何特性和强度特征上的显著差异。

在人工智能发展进程中,基于深度学习目标检测一直是研究人员的重点研究任务,并取得了一系列研究成果,研究人员已经开发了大量的模型和方法来检测SAR图像中的目标。在实际应用中,SAR图像解译主要实现对地面车辆、海面舰船、机场飞机等目标检测与识别<sup>[5-9]</sup>。综合来看,SAR图像智能处理算法研究及应用成为近些年信号处理、遥感应用和地球观测等研究领域重点关注的研究方向<sup>[10,11]</sup>。

虽然深度学习展现出强大的端到端问题解决能力,但是这种数据驱动+拟合的深度学习算法存在严格的训练测试数据同分布先验假设,当训练和测

试数据不服从同分布假设或者训练数据不足以覆盖整个数据分布时,深度神经网络的性能往往表现不佳,模型对新数据集的泛化能力差。如图2所示,用SSDD (SAR Ship Detection Dataset)数据集训练的舰船检测模型(YOLOv5n)可能不一定对HRSID (High Resolution SAR Images Dataset)数据集的舰船目标检测效果良好,这是由于港口场景、舰船目标的外观尺度、成像分辨率、SAR卫星参数的变化所造成的影响,该现象被称为域偏移或者域分布转换。

通常解决这种域分布差异问题的直接方法是对未见的测试数据集进行大量的人工标注,再将标注好的数据加入模型中进行训练。然而,SAR图像的标注难度远远大于光学图像,需利用到专家知识的经验判读才能对其进行准确的标注,考虑到对新获取不同分布的SAR数据进行重新标注所花费的成本极其昂贵,这种方法在实际中往往并不可取。跨域学习技术的引入为解决这一问题提供了新的思路,它能够实现不同数据分布间的特征适应与知识迁移。同时,随着多源遥感数据的不断积累,多源信息的应用价值日益突出。不同传感器、不同模态及不同成像条件下获取的SAR与光学数据,为跨域目标检测提供了丰富的互补特征信息。通过融合或联合建模多源信息,可有效缓解域间差异,提高跨域



(a) SAR图像  
(a) SAR image  
(b) 光学图像  
(b) Optical image

图1 某港口的高分辨率SAR图像与对应的光学遥感图像对比  
Fig. 1 Comparison between high-resolution SAR images and corresponding optical remote sensing images of a certain port




图2 不同雷达参数对检测模型(YOLOv5n)的影响  
Fig. 2 The influence of different radar parameters on the detection model (YOLOv5n)

模型的适应性和泛化能力。跨域SAR图像目标检测不仅在理论上有助于深入理解SAR散射特性与域间分布差异的关系，而且在实际工程应用中对提升海洋安全监管、灾害应急响应与情报获取的效率具有重要意义与现实紧迫性。

有鉴于此，2021年以来有许多基于多源信息跨域学习的方法被开发出来，其通过跨域学习技术来解决训练测试分布不一致的问题。该技术利用标签丰富的源数据单独训练泛化能力强的模型，或者和标签稀缺的目标数据集共同训练模型。这种基于跨域学习的技术已经在许多相关研究中证明了其泛化能力，从而使训练的模型可在分布明显不同的目标数据集上保持优异的性能。

与跨域识别和分割任务不同，跨域目标检测需对目标域图像的目标进行定位和类别预测，更具有挑战性，这也促使学者在跨域SAR图像目标检测领域提出了一些新方法<sup>[12-17]</sup>。虽然在光学图像领域，跨域目标检测的相关研究已经十分普遍，但是在SAR图像领域，在跨域条件下进行SAR图像目标检测的研究仍然屈指可数。

与光学图像跨域目标检测主要面临光照、气候和视角变化的挑战不同，SAR跨域检测的困难更多来自不同传感器之间的成像参数差异和目标的电磁散射特性差异，域间差异在统计层面和语义层面都更复杂。因此，优秀的跨域SAR目标检测方法需结合散射特性建模、物理先验等目标特性，以解决跨域SAR数据的散射特征分布偏差和语义差异问题。

目前，虽然有多篇综述论文广泛地回顾了光学图像领域的分类<sup>[18-20]</sup>和语义分割<sup>[21,22]</sup>以及目标检测<sup>[23]</sup>的跨域技术，但就本文调研所知，目前还没有针对SAR图像跨域目标检测方法的全面综述。这促使本文对过去几年中提出的所有跨域SAR图像目标检测方法进行详细的分析和比较。该项工作的主要贡献总结如下：

(1) 首先，本文对基于跨域学习的SAR图像目标检测的所有现有工作提供了更加详细和透彻的讨论，同时对每个提出的方法进行了定义和分类。此外，归纳了相关工作和跨域学习问题定义，以便对不熟悉这些概念的读者理解。

(2) 其次，对文献中跨域SAR图像目标检测的现有方法进行了全面的比较，并详细总结了使用的实验数据集和实验设置。

(3) 最后，讨论了未来潜在的研究方向，这些方向可能对该领域工作的研究人员有益，以期进一步推动跨域SAR图像目标检测技术的发展，突破跨域SAR图像目标检测时所面临的问题和挑战。

## 2 相关工作和问题定义

由于本文主要聚焦深度学习框架下的跨域学习技术，因此，本节首先对基于深度学习的SAR图像目标检测领域的相关工作进行了简要介绍，接着针对深度学习领域跨域学习的相关问题和符号进行正式定义，最后，对跨域SAR图像目标检测识别面临的挑战进行了总结。表1总结了基于深度学习的非跨域学习方法和跨域学习方法各自的优劣势。

### 2.1 基于深度学习的SAR图像目标检测技术研究

基于深度学习的SAR图像目标检测方法由于无须人工提取特征、自动学习表征能力强、检测效率和精度高等特点得到了广泛的应用，并且涌现出一大批优秀的方法。如图3所示，目标检测方法主要包含按阶段数、锚框生成技术、模型架构以及边界框输出类型4种不同分类方式。其中，阶段数划分(单阶段与双阶段)是最具代表性和普适性的分类方式，涵盖了主流检测框架的核心思路，这一分类的关键标准在于是否包含独立的候选区域生成模块。由于跨域SAR图像目标检测的工作是在常规深度学习驱动的SAR图像目标检测方法发展而来的，因此，简要介绍其技术框架及其在SAR目标检测中的表现，对于推动该领域的技术进步和实际应用具有重要意义。

#### (1) 单阶段SAR图像目标检测方法

单阶段检测方法去除了区域建议网络(Region Proposal Network, RPN)生成步骤，直接从输入图像中提取目标信息。通过在预测阶段同时回归目标的位置信息和类别信息，最终得出检测结果。典型的单阶段目标检测方法包括YOLO<sup>[24]</sup>、SSD<sup>[25]</sup>、RetinaNet<sup>[26]</sup>等。与两阶段检测方法相比，单阶段模型不

表 1 基于深度学习的非跨域和跨域学习方法对比

Tab. 1 Comparison of non/cross-domain learning methods based on deep learning

方法	适用场景	优势	局限性	面临挑战
非跨域学习	指训练与测试数据分布基本一致的情形	数据准备和训练过程简单、模型容易优化	需大量标注样本、模型训练成本高、泛化性差、易过拟合	SAR标注数据稀缺、模型泛化能力不足、计算资源需求大
跨域学习	指训练与测试数据分布存在差异的情形	缓解数据稀缺问题、可利用多源信息、泛化能力强	域差异建模复杂、知识迁移效率低、易引入噪声、方法设计难度高	SAR图像数据获取难、域分布差异大、跨域知识迁移失效

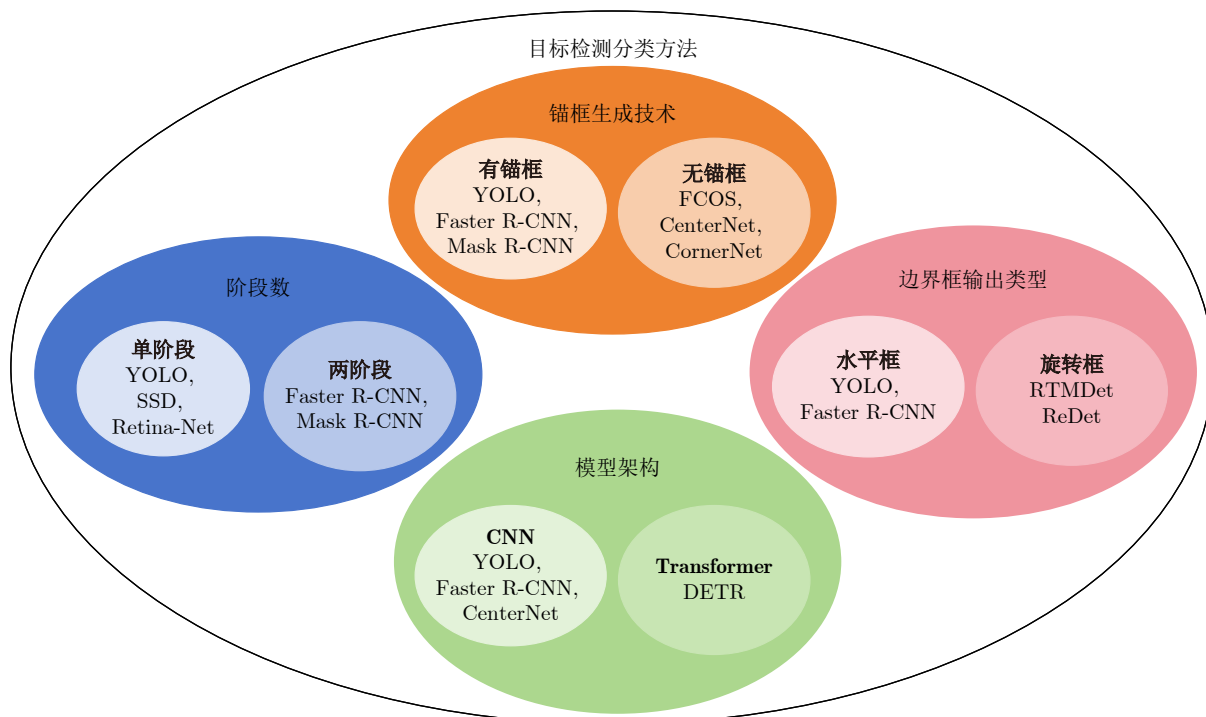


图3 目标检测不同分类方法

Fig. 3 Different classification methods for target detection

仅能够同时进行类别预测和位置回归，而且其运算和推理速度较快，因此在SAR图像目标检测中得到了广泛应用<sup>[27,28]</sup>。

### (2) 两阶段SAR图像目标检测方法

与单阶段目标检测方法相比，两阶段目标检测方法通过引入RPN来处理前景和背景的二分类任务，同时进行初始候选框的位置回归，生成初步的感兴趣区域(Region Of Interest, ROI)。在此基础上，RPN产生的ROI候选框通过感兴趣特征提取器映射到骨干网络的特征图上，提取相关区域的特征子集。接着，这些提取的特征被输入到检测头，进行精细化的位置回归修正和类别预测，最终完成目标检测任务。两阶段检测模型一般包含两个主要阶段：初步的区域生成和后续的区域分类与回归。RCNN<sup>[29]</sup>是首个应用于目标检测的两阶段深度学习方法。此后，许多两阶段的检测方法相继被提出，包括Fast R-CNN<sup>[30]</sup>，Faster R-CNN<sup>[31]</sup>等。这些方法在不断完善和发展中，已成功应用于SAR图像目标检测中，取得了显著的成果<sup>[32-41]</sup>。

不同阶段架构在跨域任务中表现差异显著。双阶段检测器通常依赖更精确的区域提议，对域间特征偏差更敏感；而单阶段方法结构简洁、端到端优化，更适合引入域自适应模块与特征对齐策略。

## 2.2 跨域学习

在深度学习领域，跨域学习是一种重要的研究

方向，旨在解决训练(源域)和测试(目标域)数据来自不同分布时，如何使模型仍然能够有效应用的问题，核心目标是提升模型的泛化能力。由于缺乏足够的标注SAR图像数据，且SAR图像容易受到多种因素的影响，使得相同目标在不同条件下的形态差异显著，因此训练一个鲁棒的SAR目标检测模型十分困难。然而，跨域学习可以利用充足的光学图像数据或者已标注的SAR图像数据中迁移知识来解决这一问题，从而提高模型在SAR图像上的泛化能力。

### 2.2.1 跨域学习问题定义

跨域学习主要包括域适应(Domain Adaptation, DA)和域泛化(Domain Generalization, DG)两个子任务。域适应关注当源域和目标域之间存在显著的分布差异，但目标域有一定数量的标注数据时，可通过从源域迁移知识到目标域，帮助模型适应目标域的特征。例如，在同一物体的不同地理区域或不同成像角度下，源域和目标域存在一定差异，这时可以通过域适应方法进行特征对齐。域泛化则致力于当目标域缺乏足够的标注数据时，采用域适应方法效果较差，而域泛化方法通过训练出一个能够跨多个域都能有效工作的通用模型，成为更好的选择。例如，在无法获取目标区域数据标注的情况下，域泛化方法能够通过源域的多样性提高模型的泛化能力。下面给出在计算机视觉中关于域适应和域泛化任务的形式化定义。

**域：**令 $\mathcal{X}$ 为一个非空输入空间， $\mathcal{Y}$ 为一个输出空间。一个域指从一个分布中采样得到的数据集。数据集表示为 $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n \sim P_{(X,Y)}$ ，其中 $x \in \mathcal{X} \subset \mathbb{R}^d$ 为样本， $y \in \mathcal{Y} \subset \mathbb{R}$ 为标签， $P_{(X,Y)}$ 表示为输入样本和标签的联合概率分布， $X$ 和 $Y$ 为对应的随机变量。本文的研究对象是跨域SAR图像目标检测，因此本文将“域”限定在图像层面，即源域和目标域的图像分布存在差异。

**域适应：**如图4(a)所示，给定一个训练源域 $\mathcal{D}_{\text{train}}^S = \{(x_i^S, y_i^S) | i = 1, 2, \dots, N_S\}$ 和一个测试目标域 $\mathcal{D}_{\text{test}}^T = \{(x_j^T, y_j^T) | j = 1, 2, \dots, N_T\}$ ，目标域的标签 $\{(y_j^T) | j = 1, 2, \dots, N_T\}$ 本质上是稀缺的，其各个研究方向的变体通常根据目标域数据集的标签稀缺程度分为无监督、半监督、弱监督和小样本域适应等。其中，无监督的方式最具有挑战性和实用性，因此通常针对该方式所设计的方法也很容易地改进并迁移到其他监督方式任务中。

源域和目标域的数据是从两个不相等的联合概率分布 $P_{(X,Y)}^S \neq P_{(X,Y)}^T$ 中采样得到的，其中标签空间中的类别有可能不一致，即属于开集问题。目前跨域SAR图像目标检测研究也主要采用的是闭集设定，因此，本文主要聚焦于闭集跨域SAR图像目标检测问题研究。域适应的目标从源域和目标域中训练学习得到一个目标函数 $f: \mathcal{X} \rightarrow \mathcal{Y}$ ，使得该函数能够在目标域 $\mathcal{D}_{\text{test}}^T$ 达到最小的损失误差的期望值 $\min_h \mathbb{E}_{(x,y) \in \mathcal{D}_{\text{test}}^T} [\ell(f(x), y)]$ 。其中，目标域在训练阶段是可见的。

**域泛化：**如图4(b)所示，给定 $M$ 个训练源域数据，可表示为 $\mathcal{D}_{\text{train}}^S = \{(x_i^{S_j}, y_i^{S_j}) | i = 1, 2, \dots, N_S; j = 1, 2, \dots, M\}$ ，其中第 $j$ 个域表示为 $\{(x_i^{S_j}, y_i^{S_j})\}_{i=1}^{N_S}$ 。两两领域之间的联合概率分布不相等，即 $P_{(X,Y)}^{S_j} \neq$

$P_{(X,Y)}^{S_k}$ ，其中 $1 \leq j \neq k \leq M$ 。如前文所述，域泛化任务中的目标域是不参与训练的，目标域的数据只进行验证和测试。其各个研究方向的变体通常根据其源域数据集域的个数 $M$ 分为单源域泛化( $M = 1$ )、多源域泛化( $M \geq 2$ )。在目标检测领域中，单源域泛化方式是假设只有一个源域样本集完全用边界框和相应的类别标签进行标注并参与训练；多源域泛化方式是假设多个不同的源域样本集完全用边界框和相应的类别标签进行标注并参与训练。

域泛化的目标是仅从 $M$ 个源域中训练学习一个泛化性强的目标函数 $f: \mathcal{X} \rightarrow \mathcal{Y}$ ，使得该函数能够在目标域 $\mathcal{D}_{\text{test}}^T$ 达到最小的损失误差的期望值 $\min_h \mathbb{E}_{(x,y) \in \mathcal{D}_{\text{test}}^T} [\ell(f(x), y)]$ ，与域适应不同的是， $\mathcal{D}_{\text{test}}^T$ 在训练阶段不可见且 $P_{(X,Y)}^{S_j} \neq P_{(X,Y)}^T$ ，其中， $j \in \{1, 2, \dots, M\}$ 。

### 2.2.2 跨域SAR图像目标检测面临挑战

跨域学习可以有效地解决跨域目标检测所遇到的问题，但针对光学图像设计的跨域目标检测方法在用来解决跨域SAR图像目标检测任务时仍然面临着许多新的问题和挑战。其中，最关键的两大核心挑战如下：

#### (1) SAR域间散射特性差异显著

SAR图像的成像机制决定了其表现形式高度依赖于传感器参数(频段、极化方式、分辨率)和观测条件(入射角、地表覆盖、气候因素等)。即便是同类目标，在不同场景或传感器条件下的散射模式可能完全不同，导致跨域检测模型在目标域中识别准确率大幅下降。这一问题是跨域SAR目标检测性能退化的直接根源。图5为使用同一深度网络对不同成像条件下的SAR数据集SSDD和SRSDDD-v1.0

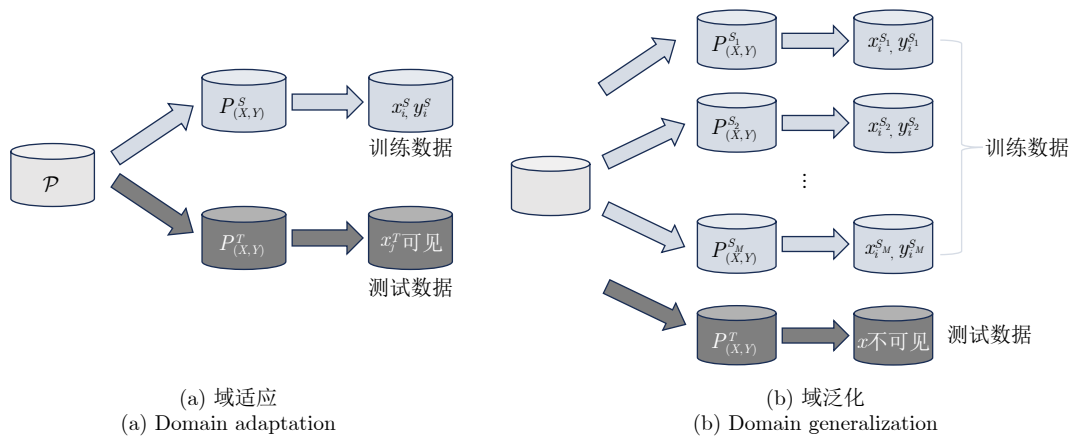


图4 域适应和域泛化的训练测试过程示意图

Fig. 4 Schematic diagram of the training and testing process for domain adaptation and domain generalization

(SAR Rotation Ship Detection Dataset)图像进行特征提取并降维后的t-SNE (t-Distributed Stochastic Neighbor Embedding)特征分布图。由图5中两种颜色特征点的分布情况可以看出,不同来源图像的分布差异较为明显,深度学习网络难以提取到其共有特征,不同SAR传感器之间的成像参数以及成像条件的变化都会导致数据分布之间的差异,这种较大的域间隙给跨域检测带来了严重的挑战。

### (2) 异构模态迁移困难

在光学图像到SAR图像等跨模态任务中,源域与目标域之间不仅存在统计分布差异,还存在表征机制上的本质差异:光学影像强调纹理与光照,而SAR图像受斑点噪声、几何畸变及电磁散射效应影响显著。此类模态差异使得源域特征在目标域中难以复用,直接导致知识迁移失效。图6为使用同一深度网络对SAR数据集SSDD和光学数据集DIOR (Object Detection in Optical Remote Sensing Images)的舰船目标图像进行特征提取并降维后的t-SNE特征分布图。同样,由图6中特征点的分布情况可知,不同来源图像的分布差异较为明显,深度学习网络难以提取到其共有特征,这是因为光学传感器和SAR传感器的成像原理截然不同。

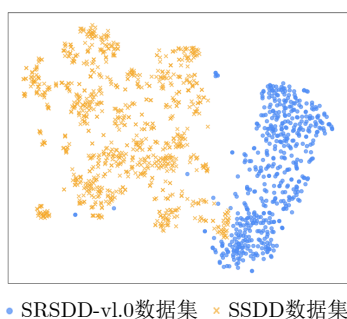


图5 不同成像条件下的SAR舰船数据集t-SNE分布

Fig. 5 The t-SNE distribution map of SAR ship dataset under different imaging




图6 光学和SAR舰船数据集t-SNE分布

Fig. 6 The t-SNE distribution map of optical and SAR ship datasets

## 3 方法

第2节从任务范式角度对跨域学习进行了归纳,区分了域适应与域泛化两条主线,强调二者在训练可见性、数据假设与评测设定上的差异。虽然在光学视觉任务中已提出了包括元学习等多样化的域泛化方法,但在跨域SAR目标检测领域相关研究仍处于起步阶段,目前所提出的域泛化SAR目标检测方法仍然较少,因此,基于域泛化SAR目标检测方法在未来具有巨大的研究潜力。本节将详细归纳总结近五年来跨域SAR图像目标检测方法。重点探讨跨域SAR图像目标检测中的域差异(光学→SAR、SAR→SAR),而其他模态如红外、文本、声音等属于不同研究范畴,未在本文涉及。

**SAR图像→SAR图像:**这类方法通常解决的是合成孔径雷达成像参数敏感性问题,模型训练的数据和实际的测试数据虽然有相同的目标,但是成像条件或来源不同导致两者之间有一定的差异,导致模型检测识别性能有所下降。

**光学图像→SAR图像:**这类方法通常解决的是SAR图像数据样本稀缺且标注成本高的问题,利用大量易获取且易标注的光学图像辅助SAR图像目标检测识别,将丰富的光学图像目标信息知识迁移到SAR图像上,从而在降低人工成本的同时提升对SAR图像目标检测识别的精度。

这两大类方法源域数据不同,但目标域皆为SAR图像,旨在提升SAR图像的检测能力,互为补充,方法相互借鉴,可以结合起来提高性能。因此,针对跨域SAR图像目标检测任务所提出的各种方法,本文进行了详细的回顾和总结,并根据所提方法的核心思想与主要适用场景进行详细的划分,相互之间可结合使用,主要可分为以下几类:

(1) 域特有性(Domain Specific Feature, DSF)与不变性特征(Domain Invariant Feature, DIF)学习

该类跨域方法将特征层面对所提取的特征分为域特有性特征和域不变性特征。在SAR图像中,域特有性特征表示的是背景、深度语义等信息,而不变性特征则代表目标轮廓等信息。借助对域特征的分解,使得检测模型能学习特定的特征,从而更有助于在目标域进行检测。文献中的许多方法都利用这一策略使检测器适应目标域<sup>[12,14,42-51]</sup>。

### (2) 伪标签生成

文献<sup>[12,42,48,49,52-59]</sup>中的许多工作利用由源域标记数据训练的检测模型对目标域数据进行预测,并筛选高置信度的预测结果作为监督信息在目标域数据上进行训练。该类方法通过不断地迭代可

可靠性预测使得检测模型逐步学习到目标域数据的可靠性知识。

### (3) 图像风格转换

该类策略通过学习源域和目标域之间风格转换映射关系,构建转换模型将源域图像映射转换成类似于目标域数据图像的风格,可有效减少视觉中的分布差异,使得源域图像学习到的知识更有利于在目标域上应用。文献[14,42,44,46,48,60-70]中的许多工作利用这种方法来提高目标域上的检测器性能。

### (4) 特征对齐

特征对齐策略是跨域学习领域最常用的方法,文献[17,44,46,47,50,52,53,56,59,71-77]中的相关工作通过在不同层级对提取的两个域的特征进行对齐,从而拉近两个域之间的距离,提升检测器在目标域上的泛化能力。

### (5) 先验知识约束

利用先验知识提升SAR图像目标检测性能也是较为常见的方法,相关学者将其应用在跨域SAR图像目标检测中[13,16,78-84],利用源域和目标域之间的先验特征信息,如几何结构信息、特征相似性等对跨域学习网络进行约束,从而达到学习特定特征的目的。

### (6) 统计特征动态调整

统计特征动态调整策略主要用于跨域目标检测中的域泛化学习,其通过对源域数据进行多个风格化版本的统计特征增强,构成能尽量满足不同域风格的数据训练检测模型,从而尽可能消除所有源类型的偏差,使得模型不偏向某一种特定风格,从而在未知的目标域上更好地学习。文献中的一些作品[15,51]遵循这一策略。

### (7) 视觉基础大模型微调

随着深度学习技术的快速发展,参数量更多、

结构更复杂的视觉大模型相较于常规模型表现出明显的优势。近期也有相关研究<sup>[85,86]</sup>开始利用视觉基础模型进行跨域检测的工作。

## 3.1 域特有性与不变性特征学习

如图7所示,域特有性与不变性学习通过网络学习两个域的域特有性特征和域不变特征,并通过距离度量函数计算这些特征之间的距离从而引导网络学习。

为解决不同卫星SAR数据分布差异导致传统检测方法失效的问题,Zhao等人<sup>[43,45]</sup>认为在像素级层面引入循环生成对抗网络(Cycle Generative Adversarial Networks, CycleGAN)生成过渡域图像会增加算法的计算复杂度,于是2022年和2023年针对跨卫星SAR舰船数据集在特征分解层面提出了自己的解决思路。文献[43]将特征分解引入域适应检测任务,提出一种基于局部和全局特征分解的域适应检测算法,将分解得到的域特有特征用于实例级域适应,域不变特征用于目标的定位回归。在此基础上,文献[45]引入视觉转换器(Vision Transformer, ViT)作为骨干网络解决CNN局部特征提取受限的问题,并且对源域和目标域设立了独立的分类token提取DSF特征。针对光学到SAR图像的跨域目标检测问题,也有许多研究工作<sup>[12,14,42,44,46-50]</sup>在学习域不变性特征和域特有性特征方面做出了贡献。Shi等人<sup>[42,48]</sup>采用对抗学习策略使检测器学习两个域之间的域不变特征。此外,Shi等人<sup>[12]</sup>还构建了多粒度视角的跨域依赖编码机制,设计特征解耦网络对域不变与域特有特征进行显式建模,仅通过光学图像域不变表示训练跨域共享检测器。Yuan等人<sup>[46]</sup>则将分类器分解为域不变和域特有有两个独立的特征子分类器,并通过正则化学习提升前者的识别能

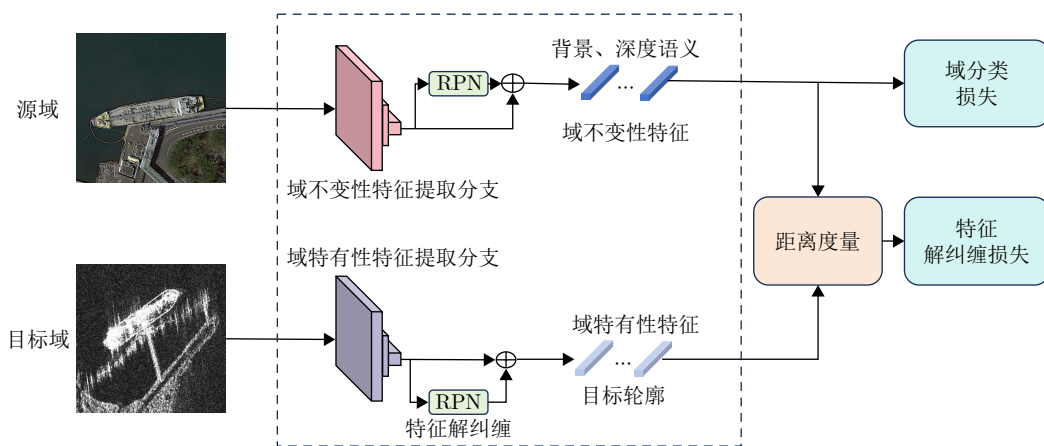


图7 域特有性与不变性特征学习流程示意图

Fig. 7 Schematic diagram of domain specific and invariant feature learning process

力。Xu等人<sup>[44]</sup>在每次卷积的特征激活时训练域分类器,最小化学习域不变特征的域距离。Zhang等人<sup>[49]</sup>通过跨模态知识解耦策略将特征迁移过程与检测器训练分离,设计多教师知识蒸馏架构,实现跨模态特征表示与域不变特征的协同优化。然而,这些方法都只是针对水平框的检测问题,旋转框检测可去掉冗余的背景信息,更加关注目标本身,因此,针对跨域SAR舰船旋转框检测问题,Huang等人<sup>[44]</sup>通过实例不变特征解耦实现旋转特征的跨域迁移。为解决现有的域泛化方法尚未充分解决SAR图像域漂移解耦问题,Zhao等人<sup>[51]</sup>设计了一个多源域泛化SAR图像目标检测统一框架,设计了域不变特征和域特定特征解纠缠模块,去除冗余的域鉴别信息。

### 3.2 伪标签生成

图8为伪标签生成策略示意图,其通常通过设置学生教师网络,在有标注源域上训练的模型推理目标域数据获得伪标签,利用伪标签指导目标域数据进行训练,并且伪标签的质量不断迭代优化,从而指导目标域更高质量的学习优化。

为应对目标域SAR图像无标签或少标签的情况,很多学者基于迭代伪标签生成策略提出许多域适应SAR目标检测识别方法。Shi等人<sup>[52,53]</sup>2021年针对跨机载SAR车辆数据分别提出两种三阶段跨域框架,提取并迁移传感器无关特征并通过迭代伪标签自训练的方式,提升跨传感器检测鲁棒性。为解决伪标签噪声累积严重的问题,Zou等人<sup>[56]</sup>通过置信度引导特征对齐以及不确定性感知伪标签学习优化技术逐步实现图像级和实例级的特征自适应,弥合源域和目标域在潜在特征空间中的分布差异。Zhang等人<sup>[58]</sup>则利用自监督预训练提升目标域泛化性,伪标签动态修正减少错误累积。虽然无监督或自监督的方式更符合实际设定和需求,但是目标域缺乏强监督信息使其具有一定的性能上限,而半监督域适

应方法相比无监督方法利用了目标域上部分样本的标注信息,解决目标域SAR图像上标签有限的问题。基于此,Chen等人<sup>[54]</sup>构建基于YOLOv5的域适应框架,通过不确定性感知伪标签筛选策略实现域间知识迁移的闭环优化,交互式训练实现域间隙的渐进式压缩。在处理光学到SAR图像的跨域检测问题时,Shi等人<sup>[12,42,48]</sup>同样引入了基于伪标签迭代优化的自训练范式,构建伪标签筛选机制,通过在实例级和图像级构建不确定性选择方法选取高质量伪标签,降低噪声标签对模型训练的负面影响。同样针对实例级和图像级的伪标签高质量筛选策略,Chen等人<sup>[59]</sup>设计一种在线伪标签自训练策略,在RPN和ROI模块上进行两个前向传播和一个后向传播过程,实现了端到端的伪标签筛选自训练过程。针对SAR舰船方向随机性导致的特征表征困难以及雷达信号非连续性特征引起的背景干扰,Zhang等人<sup>[55]</sup>设计伪特征生成网络,通过对抗生成策略构建过渡特征域,并计算目标区域和背景区域的对比损失函数,实现上下文语义信息的自适应提取。针对实际应用场景中极少量标注样本构成的SAR域监督信息,Zheng等人<sup>[57]</sup>利用双路师生协同学习框架<sup>[49]</sup>,通过双向知识交互机制实现跨域伪标签生成与半监督特征精调的协同优化,持续提升伪标签质量。

### 3.3 图像风格转换

图像风格转换策略则是通过风格转换器将源域图像的风格转换为近似目标域的形式,即通常被称为“中间域”或“过渡域”,具体流程示意图如图9所示,其旨在减小两个域的间隙。

现有跨域SAR目标检测方法基本上都假设目标域测试数据是高质量的情况下,而目标域SAR图像成像质量较低且严重受噪声干扰时,难以获取精确的目标信息,从而会严重阻碍检测器的性能。Pu等人<sup>[61,62]</sup>2023年针对目标域SAR图像在受到强干扰

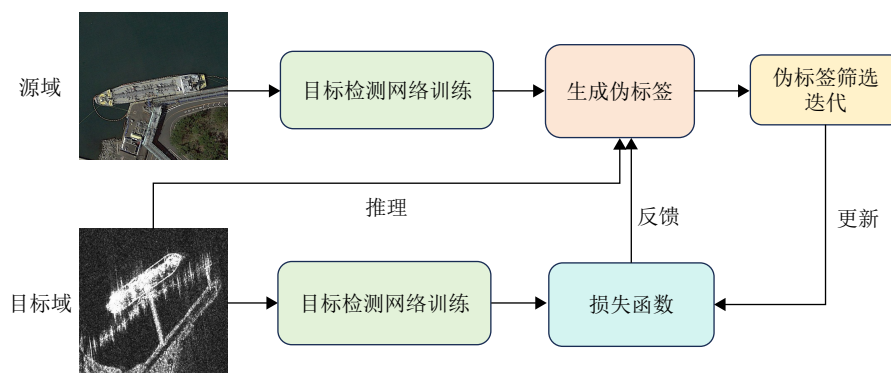


图8 伪标签生成流程示意图

Fig. 8 Schematic diagram of pseudo label generation process

的低质条件下，提出了相应的解决思路。文献[61]将其看作跨域问题，利用CycleGAN生成从源域到目标域的具有复杂干扰的低质量SAR图像，结合标注继承，使生成的SAR图像参与训练过程。文献[62]则考虑SAR图像中的复杂干扰会导致目标特征模糊，同样利用CycleGAN去生成强干扰SAR图像，并结合对抗训练增强模型抗干扰能力。该种风格迁移策略通常更多用于和SAR图像分布差异更大的光学图像上，在像素层面，Shi等人[42,48]基于成像机理差异分析，设计面向舰船目标的特异性数据增强策略，采用跳跃连接生成对抗网络构建过渡域空间；Yuan等人[46]则通过将目标域样式注入源域来最大限度地减少视觉差异；Huang等人[14]通过注入SAR域散斑噪声特征构建混合光谱域。文献[44,60,63-66]则利用生成式对抗网络从光学图像生成SAR图像和真实的SAR图像来训练检测器，从而有效弥合可见光与SAR影像的表观差异。不同于使用常见的生成式对抗网络，艾加秋教授团队[70]构建纹理增强风格转换网络，融合Haar小波变换实现空频域联合特征解耦转换，有效抑制跨模态图像转换过程中的伪影畸变。为提高基于生成对抗网络的检测样本质量，Wu等人[67]提出一种新的跨域注意力GAN模型，设计的跨域多尺度特征融合模块从全局特征的角度进

一步强调了特征图中目标的几何信息和语义信息。然而，生成式对抗网络的训练成本通常面临成本高的问题，因此，陈亮等人[68]利用傅里叶转换改变光学图像的振幅信息，生成对应的伪SAR图像，实现模态域差异缩减。Luo等人[69]通过图像模态混合与实例交换策略生成类SAR域增强样本，充分利用有限标注实现图像级与实例级域偏移消减。

### 3.4 特征对齐

如图10所示，特征对齐方法则是利用特征提取网络提取两个域的像素级、图像级或实例级特征，再利用多级特征对齐网络，将这些特征分别进行对齐，从而从不同的层次拉近两个域之间的距离。

特征对齐是跨域SAR图像目标检测领域常用的学习策略，在许多方法中发挥了重要的作用。大多研究工作[44,46,47,50,52,53,56,59,71-76]通过多级特征对齐策略，在像素级、图像级和实例级或局部与全局等层面实现了特征对齐，将源域的知识分级传输到目标域中，使被适应的SAR图像特征表示更好地聚焦在被检测目标。Hu等人[77]则将显著性检测与域适应方法结合，通过对齐目标区域的显著性特征，有效地减轻背景干扰对跨域检测的影响。由于SAR图像舰船目标和背景环境往往表现出高度的视觉相似

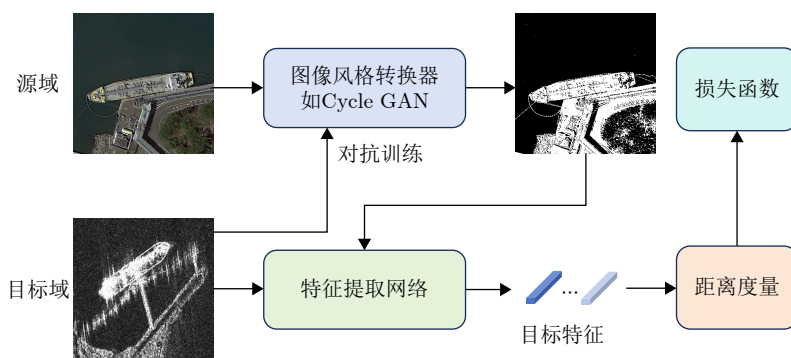


图9 图像风格转换流程示意图

Fig. 9 Schematic diagram of image style conversion process

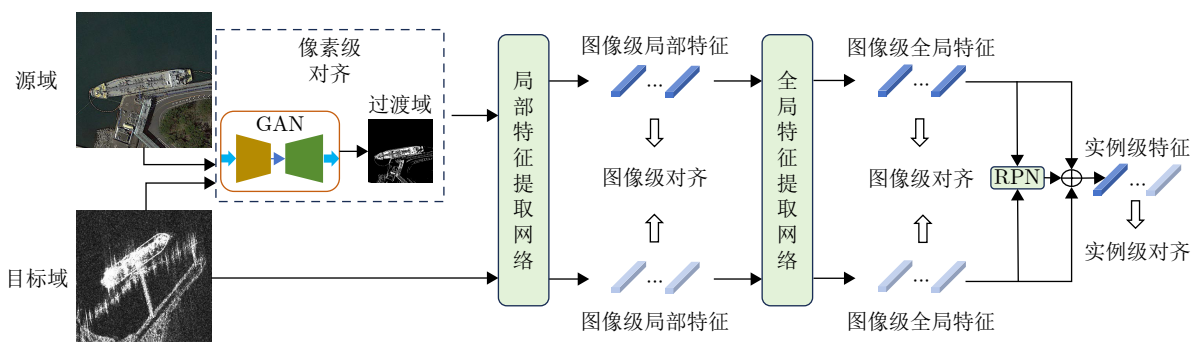


图10 特征对齐流程示意图

Fig. 10 Schematic diagram of feature alignment process

性, 现有的跨域方法可能会无意中破坏舰船目标的区分性表示, 为解决该问题, Liu等人<sup>[76]</sup>设计源辅助语义对增强模块, 引导对目标多级语义特征的校准, 并且构建了感知不确定性的特征级对齐模块和实例级对齐模块, 更有效地捕获目标的特征。为解决传统特征对齐方法的性能容易与有限数量的可观测目标过度拟合问题, Zhao等人<sup>[17]</sup>将源域实例的集合分为目标域容易和目标域困难集合两组, 在源实例的目标域困难集合和目标实例的扩展数据集之间执行异步对齐, 实现有效的监督学习。在对齐光学和SAR图像特征时, Zhang等人<sup>[72]</sup>通过挖掘和对齐光学和SAR图像之间的全局结构和局部实例信息, 利用结构对齐模块和原型对齐模块在两个层次进行特征对齐。但光学源域数据和SAR目标域数据往往存在不平衡问题, Pan等人<sup>[75]</sup>为此设计一种不平衡判别对比方法, 确保在图像级和实例级上保持一致性, 并专注于源域的一致性, 以增强对抗网络的特征提取能力, 以提高网络的判别能力并防止负迁移。

### 3.5 先验知识约束

图11为先验知识约束策略示意图, 其旨在利用从源域学习获取到的先验知识来辅助或约束目标域数据的学习。相关研究者考虑源域和目标域数据之间目标的几何结构关系或特征相似性进行跨域SAR目标检测, 主要包括目标的几何结构先验信息、特征相似性两方面。

Qin等人<sup>[81]</sup>利用几何感知聚类和最优传输实现目标域特征到源域原型的映射, 缓解传统对抗训练不稳定的问题。然而, 该方法并未考虑到分辨率以及极化方式对跨域检测所造成的影响。因此, 针对中分辨率全极化与高分辨率单极化数据分布差异大的问题, 仇晓兰研究员团队<sup>[82]</sup>利用了极化通道图像之间的相关性, 在推理时这种相关性会丰富由模型提取的单极化图像的特征信息。Zhang等人<sup>[16]</sup>则考

虑到SAR图像的目标散射特性, 对水平和垂直两个方向的特征进行聚合, 增强散射特征和语义特征, 并动态约束目标位置提高目标识别能力, 利用中心感知校准模块解决特征传递中的对准偏差问题, 构建了基于不同位置与目标中心距离的目标显著性关系模型。为充分利用光学数据的先验知识, Liao等人<sup>[78,83]</sup>利用半监督学习框架, 通过特征域自适应约束实现光学图像特征空间向SAR域的有效映射, 将光学数据的丰富先验知识迁移至目标域, 并设计特征重构解码器对未标注SAR数据进行潜在特征重建, 充分挖掘数据中的有用信息。然而, 在样本极其有限的情况下, 基于小样本域适应的跨域SAR目标检测方法<sup>[80]</sup>通常难度更大。针对SAR数据稀缺的现实约束, 且在小样本训练场景下深度学习方法易出现模型性能显著衰减的问题, Guo等人<sup>[79]</sup>采用实例级域适应约束代替特征级域适应约束, 实现更精确的先验知识传递, 并将生成对抗网络约束应用于自适应模块中作为域适应约束。针对极端有限(仅3个标注目标)的观测样本条件下, Zhou等人<sup>[13]</sup>结合丰富的光学图像信息, 通过计算光学图像和SAR图像之间的分布差异, 利用光学图像和SAR图像之间的潜在相似性驱动, 在仅需极少量SAR图像的训练样本就可高效地利用域间信息。然而, 这些方法都是进行单源检测, 限制了其在跨域船舶检测中的实际应用。受人类视觉皮层机制的启发, Dong等人<sup>[84]</sup>设计出一种端到端跨域多源舰船检测网络, 引导模型专注于不同频域图像中与舰船相关的视觉特征, 提取一致的形状、纹理或对比度信息, 实验结果表明, 与单域检测相比, 跨域多源检测提供了更广泛的应用场景和潜在的性能增强。

### 3.6 统计特征动态调整

统计特征动态调整方法通常使用在域泛化情形中, 其基本流程如图12所示, 其旨在利用统计特征

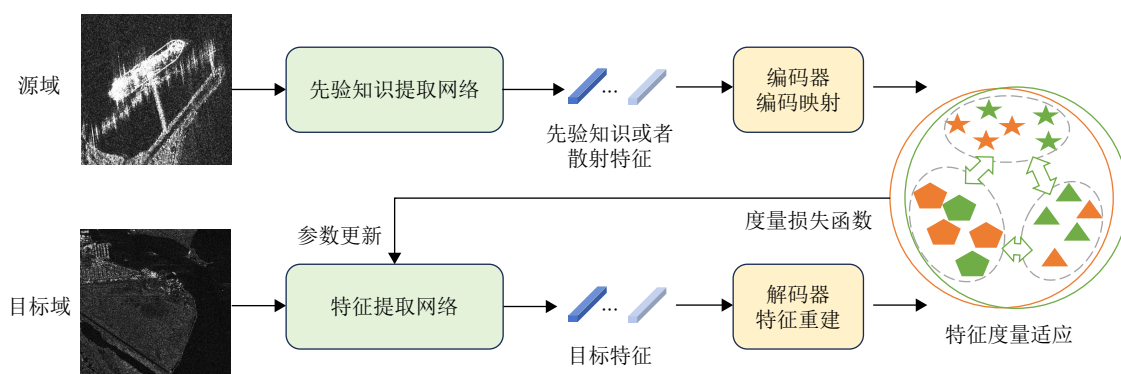


图 11 先验知识约束流程示意图

Fig. 11 Schematic diagram of prior knowledge constraint process

调整网络或其他数据增强方式将源域数据扩展到不同的域，以适应未见的目标域。

如3.1至3.6节所述，许多跨域SAR目标检测方法取得了突破性的成就。然而，其有效性往往取决于训练时目标域SAR图像数据的可用性。然而，获取大量实际需测试的目标域SAR数据可能是不切实际的，此外，每当需测试的目标域SAR数据不同时，域适应检测方法需要重新训练，这并不符合实际需求。因此，Yuan等人<sup>[15]</sup>利用域泛化的思想设计仅在单个源域上训练的模型，通过基于特征归一化的低阶潜在空间填充模块插值方法，允许框架模拟由不同设备捕获的图像，使得特征提取器能够学习通用的特征表示，从而解决单源域特征分布空间有限的问题，最终在4个不同卫星SAR舰船数据集上的实验验证了该模型的泛化性。在面向多源域泛化的情况时，Zhao等人<sup>[51]</sup>认为不同设备的成像结果具有不同的域分布，对应于表征不同SAR图像的散射特性，并且这种分布可以通过图像特征图的统计度量来表征，不同域之间具有大的域间隙，并且这种域间隙是由不同的分布引起的，因此，其对SAR图像散射特征进行动态统计匹配，扩展域特征空间，模拟其他域，最后在多源数据集上进行的跨域实验结果表明，其方法在以RCNN为基线网络的检测头中达到了现有的最先进性能。

### 3.7 视觉基础大模型微调

视觉基础大模型微调则是利用原有大量源域数据上训练得到的预训练模型，通过冻结模型参数并使用微调适配器，指导小样本的目标域数据微调学习，从而达到知识迁移的目的，具体流程示意图如图13所示。视觉大模型通常具有更深的网络结构和更多的参数，使得它们能够学习更复杂、更抽象的特征，具有强大的特征提取能力，可捕获数据中更细微的变化，因此，近期利用视觉大模型技术来尝试解决跨域SAR图像目标检测识别问题也有了部分的研究<sup>[85,86]</sup>。

针对大模型展现出的良好的泛化能力，Hu等人<sup>[85]</sup>提出了一种参数高效微调的跨域SAR目标检测方法，该方法在SAM编码器中插入适配器模块，在微调阶段冻结原始参数，通过少量标注数据微调适配器，从而实现跨域检测。同样基于SAM基础模型，Zhang等人<sup>[86]</sup>结合SAR散射机制，考虑SAR图像中强散射点的离散分布特征，设计了一种边缘增强形态学适配器，可有效增强目标的边缘形态，允许在SAR范围内进行快速微调；其次，实现了基于小波和软阈值技术的自适应去噪模块，以降低SAR相干斑噪声的影响，从而提高特征表示性能。

虽然本文将该领域研究所设计或使用的的方法划分成了以上7类，但每类方法有着各自的优势和局

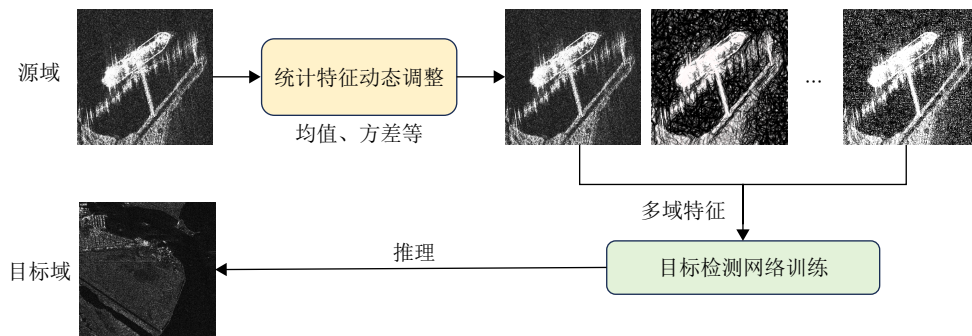


图 12 统计特征动态调整流程示意图

Fig. 12 Schematic diagram of dynamic adjustment of statistical features process

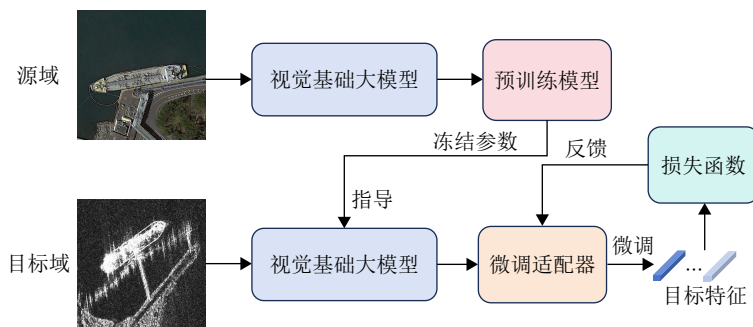


图 13 视觉基础大模型微调流程示意图

Fig. 13 Schematic diagram of the fine-tuning process for large visual foundation models

限性以及适用场景,在现有的研究中,往往可能会同时采用多种策略来综合性地解决跨域SAR图像目标检测问题。表2对上述7类策略的核心思路、优势、局限及适用场景进行了对比,便于读者整体把握7类方法之间的区别与联系。此外,针对第2节提到的SAR域间散射特性差异显著挑战,域特有性与不变性特征学习、特征对齐、图像风格转换与域随机化策略更为直接有效;针对异构模态迁移困难挑战,基于先验知识约束、伪标签生成以及域特有性与不变性特征学习更有优势;视觉基础大模型微调适用于目标域有少量标签的情形。

## 4 公开数据集与评价指标

本节将讨论用于评估第3节讨论的各种跨域SAR图像目标检测方法性能的评估要求。4.1节和4.2节对目前已公开发表论文里使用的跨域SAR图像目标检测识别数据集及常用性能评估指标进行了汇总整理。4.3节阐述了部分方法在相关跨域SAR图像目标检测数据集上的对比与分析。

### 4.1 数据集

跨域SAR图像数据集的不规范性显著制约了跨域目标检测研究的发展。为此,本文搜集了上述公开发表的论文里构建使用的跨域SAR目标检测数据集,以方便广大科研人员和学者更好地开展研究和对比,从而促进数据集的扩展和标准化建设。这些数据集覆盖了不同的分辨率、极化模式、传感器类型和复杂的场景条件,具有较大的潜力为未来的跨域SAR目标检测研究提供新的验证平台。

### (1) 光学数据集

目前在光学到SAR图像的跨域SAR图像目标检测识别领域公开发表的论文所使用的源域光学数据集基本上都是公开的光学遥感数据集。

LEVIR<sup>[87]</sup>:该数据集由大量0.2~1.0 m分辨率的谷歌地球图像构成,图片像素大小为800×600,共包含了飞机、舰船和油罐3种目标类型。所有图像总共标注了包含4724架飞机、3025艘船和3279个油罐在内的11000个目标边界框。

HRRSD (High Resolution Remote Sensing Detection)<sup>[88]</sup>:该数据集是中国科学院大学于2019年发布的高分辨率遥感检测数据集,包含从谷歌地球和百度地图获取的21761幅图像,空间分辨率从0.15 m~1.20 m。共包含飞机、船、篮球场、桥梁、港口等13类目标在内的55740个目标实例,每个类别4000左右。

Toronto<sup>[89]</sup>:该数据集是基于复杂场景的多伦多城市遥感光学图像的一种测量数据,包含了11张空间分辨率为0.15 m、图片像素大小为500×7500的RGB图像。涵盖了多伦多城市街道景观,包括车辆、建筑物、道路、草地、树木等。

DIOR<sup>[90]</sup>:该数据集是由谷歌地图构建的光学图像目标检测基准数据集,共包含23463张图像,192472个目标实例,从舰船、飞机到桥梁和油罐等20个目标类别。每张图像的尺寸大小均为800×800,空间分辨率为0.5~30.0 m不等。通常在跨域SAR图像目标检测实验中,抽取该数据集的舰船或者飞机目标为源域。

HRSC2016 (High Resolution Ship Classifica-

表2 7类跨域SAR图像目标检测方法对比

Tab. 2 Comparison of seven cross-domain SAR image target detection methods

方法	核心思路	优势	局限性	适用场景
域特有性与不变性特征学习	将特征空间分解为域特有与不变特征	能有效建模域间差异与共性	需要有效的特征分解算法,增加计算复杂度	适用于域间成像差异但仍处于同一模态空间的场景;[SAR→SAR]
伪标签生成	基于自训练生成伪标签,通过伪标签增强训练数据	在标签稀缺的情况下可以提升性能	伪标签质量难以控制,可能引入噪声,影响模型效果	适用于标签稀缺或标注成本高的任务;[两者]
图像风格转换	将源域与目标域图像风格转化为一致的风格,减少风格差异影响	能从输入层面对齐模态差异	可能无法捕捉到目标域的真实特征,风格转换质量可能不稳定	适用于源与目标域视觉风格差异较大的场景;[光学→SAR]
特征对齐	对源域和目标域特征进行对齐,使其在共享空间中表现相似	与检测网络结合紧密,可端到端训练	对齐的准确性影响模型性能,且过度对齐可能损失判别信息	适用于特征差异较大或目标域数据变化较大的任务;[两者]
先验知识约束	利用已有的先验知识(如物理特性或标签信息)引导模型学习	能充分利用SAR成像物理特性	需要有效的先验知识支持,依赖领域专业知识	适用于典型SAR目标(如舰船、车辆)检测,以及具有明确成像规律的场景;[两者]
统计特征动态调整	通过调整统计参数生成不同的源域样本	方法简单,易于与现有模型结合	仅能对齐低阶统计特征,增加训练成本	适用于模拟复杂未知环境或需要处理多个域数据的任务;[SAR→SAR]
视觉基础大模型微调	利用预训练大模型学习源域知识加速目标域学习	简单直接,性能提升明显	易过拟合目标域,训练成本高	适用于大规模源域数据预训练任务;[光学→SAR]

注:“适用场景”中使用[SAR→SAR]、[光学→SAR]或[两者]说明每类方法更适用于哪种情况。

tion 2016)<sup>[91]</sup>: 该数据集是西北工业大学从谷歌地球采集的用于远海和近岸的舰船检测数据, 图像空间分辨率为0.4~2.0 m。总共包含1070张图片并使用旋转框标注了2976个实例, 图像尺寸大小从300×300到1500×900之间, 大部分在1000×600左右。

DOTA (Dataset for Object Detection in Aerial Images)<sup>[92]</sup>: 该数据集是武汉大学于2018年首次发布1.0版本的用于航空图像中目标检测的大规模数据集, 共包含2806幅航拍图像, 尺寸大小在800×800到4000×4000之间。采用有向边界框的标注方式标注了包含舰船、飞机等在内的15类目标的188282个实例边界框。

ShipRSImageNet<sup>[93]</sup>: 该数据集包含来自不同传感器、平台、时间和地点的3435张图像, 每个图像的空间分辨率为0.12~6.00 m, 尺寸大小为930×930, 使用水平和有向边界框的方式注释了17573个舰船目标实例, 且这些舰船实例具有不同的比例、方向和长宽比。

SpaceNet 6<sup>[94]</sup>: 该数据集是一个结合SAR和光学的多传感器全天候测绘数据集。其中SAR和光学图像的空间分辨率为0.5 m, 尺寸为900×900。包含820对油罐图像。

WorldView遥感数据集<sup>[95]</sup>: 该数据集包含66419张2048×2048的图像, 并提供了飞机、汽车和船只类别的对象边界框。

Airbus Ship Detection<sup>[96]</sup>: 该数据集是Kaggle竞赛的数据集, 旨在定位数据集中船舶的位置。包含具有各种场景信息的船舶目标, 每张图片中的船舶目标形式丰富多样。

## (2) SAR数据集

同样的, 目前在跨域SAR图像目标检测领域公开发表的论文所使用的目标域SAR数据集基本上都是公开的SAR图像数据集。

SSDD<sup>[97]</sup>: 该数据集是国内外公开的第1个专门用于SAR图像舰船目标检测的数据集, 该数据集是由RadarSat-2, TerraSAR-X和Sentinel-1卫星传感器获取到的1160幅图像构成, 包含4种极化方式。图像空间分辨率为1~15 m, 共包含各种不同大小的2456个舰船目标实例, 主要关注较小的舰船目标。

HRSID<sup>[98]</sup>: 该数据集是电子科技大学于2020年发布的用于高分辨率SAR图像舰船检测、语义分割和实例分割任务的数据集, 共包含5604张分辨率为0.5 m, 1.0 m, 3.0 m的不同分辨率SAR图像和16951个舰船实例, 具有不同的极化方式、海况、海域和沿海港口。

miniSAR<sup>[99]</sup>: 该数据集是美国桑迪亚国家实验室于2005年采集的实测SAR图像数据集, 采集的模式为条带模式, 波段为Ku波段, 入射角大小在26°~29°, 图像尺寸大小为1638×2510。

FARADSAR<sup>[100]</sup>: 该数据集同样是美国桑迪亚国家实验室于2015年采集的实测SAR图像数据集, 采集的模式为聚束模式, 波段为Ka波段, 入射角大小在26°~34°, 图像尺寸大小介于1300×580和1700×1850之间。

SRSDD-v1.0<sup>[101]</sup>: 该数据集是由高分三号卫星聚束模式采集的高分辨率SAR旋转舰船目标检测数据集, 图像的分辨率为1 m, 图像尺寸大小为1024×1024, 共包含6个类别的666幅图像和2884艘舰船实例。其中, 近岸场景数据占63.1%, 背景的复杂性增大了检测的难度。

AIR-SARShip-1.0<sup>[102]</sup>: 该数据集是由高分三号卫星聚束和条带模式采集的高分辨率SAR舰船目标检测数据集, 包含了31幅具有港口、岛礁、不同等级海况的海面场景的分辨率为1 m和3 m的单极化大场景SAR图像, 涵盖运输船、油船、渔船等十余类879艘舰船实例, 图像尺寸约为3000×3000。

SAR-Ship-Dataset<sup>[103]</sup>: 该数据集是以高分三号卫星采集的102景图像和Sentinel-1卫星采集的108景图像构建的高分辨率SAR舰船目标检测数据集。共计包含59535个船舶实例在内的43819个船舶切片。

MSAR-1.0 (Large-scale multi-class SAR image target detection dataset-1.0)<sup>[104]</sup>: 该数据集是安徽大学于2022年发布的大规模多类SAR目标检测数据集。其共包括由海丝一号和高分三号卫星采集的28449张切片, 具有4种不同的极化方式。涵盖了6368架飞机、12319个油罐、1851架桥梁和39858条舰船4类目标实例。

RSDD-SAR (Rotated ship Detection Dataset in SAR images)<sup>[105]</sup>: 该数据集是由84景高分三号和41景TerraSAR-X数据切片及2景未剪裁大图共计127景数据构成的SAR图像舰船旋转框检测数据集。包含了多种成像模式、极化方式以及分辨率共计10263个舰船实例在内的7000张切片, 舰船实例具有不同的旋转方向、长宽比, 且小目标占比高。

本文对上述调研文献所实验的数据集进行了详细统计, 如表3所示, 其统计了2021年以来在相同跨域SAR图像目标检测数据集进行实验超过两篇的文献。

## 4.2 评价指标

在跨域SAR图像目标检测领域, 所使用的评价

表3 2021年以来在相同跨域数据集上实验的论文(2篇以上)统计

Tab. 3 Statistics of two or more papers experimented on the same cross-domain dataset in recent years

任务	数据	类别	文献
SAR→SAR	SSDD↔Gaofen-3	舰船	[17,43,45,58,71]
	miniSAR↔FARADSAR	车辆	[16,52,53,56]
光学→SAR	LEVIR→SSDD		[67,72,75]
	HRRSD→SSDD		[44,46,68,70,72]
	LEVIR→SAR-Ship-Dataset		[67,72,75]
	DIOR→SSDD	舰船	[55,57,60,65-67,70,80]
	HRSC2016→SSDD		[47,50,75,84]
	HRSC2016→HRSID		[47,50,69,84]
	Toronto→miniSAR		[12,48,78,79]
	Toronto→FARADSAR	车辆	[12,78,83]

指标仍然是目标检测领域常见的评估标准,如精确率(Precision, P)、召回率(Recall, R)、平均精度(Average Precision, AP)、F1-score等。精确率是指在所有检测到的目标中正确检测目标的概率。召回率是指实际所有目标中正确检测到的目标的概率。平均精度AP和F1-score则是通过结合精确率和召回率的综合表现来评估算法整体检测性能。具体的计算公式为

$$P = \text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

$$R = \text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

$$AP = \int_0^1 P(R) dR \quad (3)$$

$$\text{F1-score} = \frac{2 \times P \times R}{P + R} \quad (4)$$

其中, TP表示正确检测到的目标数量, FP表示错误检测到的目标数量, FN表示漏检的目标数量。

### 4.3 典型方法的对比与分析

由于该研究领域未形成统一的基准,所使用的数据集和实验设置均不相同,此外,考虑到现有的跨域SAR图像目标检测方法大都未开源,难以通过实验复现原始论文里所提方法的检测性能。此外,域泛化方法在该领域的应用尚未广泛展开,目前尚未形成一个完整的、可供比较的基准实验,实验部分暂未引入域泛化相关的对比分析,以避免对比结果的有限性。因此,本文分别聚焦光学到SAR图像以及SAR到SAR图像这两种跨域方式,统计了引用量较多文献的域适应检测性能结果,虽然这些方法实验参数设置和网络设计互不相同,但是本文还是借此希望从性能比较中获得的信息可为现有算法的

检测性能改进以及未来跨域检测算法设计和研究提供有益的参考和启发。

#### (1) 光学到SAR图像跨域目标检测方法性能分析

西安电子科技大学杜兰教授团队<sup>[12,48,78,79]</sup>在光学到SAR图像之间的车辆目标跨域检测任务上提出了一系列研究方法,本文搜集并分析了这些跨域车辆目标检测方法的结果。所提方法在光学数据集Toronto到机载SAR数据集miniSAR和星载SAR数据集FARADSAR两种跨域设置下进行了相关实验验证,3个数据集的载荷成像参数如表4所示,表5统计了这些方法的性能指标。由实验结果可以看出,由于光学到SAR图像的成像参数差异较大,其对模型的检测性能产生了较大影响,使用常规目标检测方法Faster R-CNN进行光学到SAR的跨域目标检测时性能较低,而相关的跨域方法在引入跨域学习策略后实现了较高的F1-score,其中,文献<sup>[79]</sup>使用一定量的目标域SAR训练样本进行跨域目标检测时,取得了较优的实验性能,这表明在进行跨域目标检测时,当有适当目标域的监督信息参与训练时,可显著提升模型的性能。

#### (2) SAR到SAR图像跨域目标检测方法性能分析

赵思源等人<sup>[17,43,45,58,71]</sup>基于跨域迁移学习等技术,在不同星载图像之间的跨域SAR舰船目标检测任务中取得了一系列的创新性成果,本文搜集并分析了这些方法的实验结果。所提方法在Gaofen-3和SSDD舰船检测数据集之间进行跨域目标检测实验验证,表6统计了两个数据集的载荷成像参数,表7统计了这些方法的性能指标。从表中的实验对比结果可以看出,相比光学到SAR图像的成像参数差异,虽然星载SAR之间成像参数差异较小,但是其仍然对模型的检测性能产生了较大影响。使用常规目标检测方法Faster R-CNN进行跨域目标检测时性能

表4 3种车辆检测数据集的成像参数

Tab. 4 Imaging parameters of three vehicle detection datasets

数据集	传感器	波段	带宽(GHz)	年份	场景	位置	俯仰角度(°)	入射角度(°)	分辨率(m)
Toronto	光学	-	-	2016	高尔夫球场、直升机场、棒球场等	克特兰空军基地	-	-	0.15
miniSAR	机载SAR	Ku	3	2005	密集城市建筑	新墨西哥大学	26~29	61~64	0.10
FARADSAR	星载SAR	Ka, X	3, 5	2015	晴天密集的城市建筑	加拿大多伦多市	26~34	56~61	0.10

表5 典型方法在Toronto到miniSAR和FARADSAR上跨域检测性能对比(%)

Tab. 5 Comparison of cross-domain detection performance of typical methods on Toronto to miniSAR and FARADSAR (%)

方法	Toronto→miniSAR			Toronto→FARADSAR		
	P	R	F1-score	P	R	F1-score
Gaussian-CFAR	35.87	80.48	49.62	28.13	46.71	35.12
Faster R-CNN <sup>[31]</sup>	70.97	90.36	79.39	74.82	92.19	82.60
文献[48] (无监督)	77.60	78.05	77.82	-	-	-
文献[79] (少样本)	80.49	73.47	76.82	-	-	-
文献[12] (无监督)	80.16	87.80	83.81	78.82	71.43	74.95
文献[78] (半监督)	81.69	91.87	85.92	81.84	92.91	86.81
文献[79] (少样本)	84.56	93.50	88.76	-	-	-

表6 2种星载SAR舰船检测数据集的成像参数

Tab. 6 Imaging parameters of spaceborne SAR for two types of ship detection datasets

数据集	卫星	波段	带宽(MHz)	轨道高度(km)	入射角度(°)	俯仰角扫描角度(°)	成像范围(km)	分辨率(m)
Gaofen-3数据	Gaofen-3	C	240	755	10~60	±20	10~650	0.5~100.0
	Sentinel-1	C	100	693	10~60	±20	20~400	5.0~20.0
SSDD	Radarsat-2	C	100	798	20~45	±11	20~50	1.0~100.0
	TerraSAR-X	X	150	514	20~55	±25	5~100	1.0~16.0

表7 典型方法在Gaofen-3和SSDD上跨域检测性能对比(%)

Tab. 7 Comparison of cross-domain detection performance of typical methods on Gaofen-3 and SSDD (%)

方法	SSDD→Gaofen-3			Gaofen-3→SSDD		
	P	R	mAP	P	R	mAP
Faster R-CNN <sup>[31]</sup>	57.0	71.0	57.9	62.5	77.8	67.0
文献[71] (无监督)	69.8	79.9	68.4	74.6	82.9	78.1
文献[17] (少样本)	72.3	74.6	76.5	75.4	77.0	78.6
文献[43] (无监督)	73.7	81.9	74.4	78.4	86.3	81.5
文献[58] (自监督)	74.1	82.8	75.8	78.9	87.0	82.6
文献[45] (无监督)	74.8	83.3	77.0	79.8	86.3	83.6

较低，难以满足实际检测需求，而引入跨域学习策略的方法实现了较高的mAP，有效地缓解了不同SAR传感器之间的域漂移问题。其中，文献[45]利用Transformer结构设计的无监督跨域SAR目标检测框架，取得了最优的实验性能，这表明Transformer架构的模型能够有效对域间知识编码和提取，能够在全局特征方面做到源域和目标域的有效对齐和统一。

### (3) 实际应用场景下案例分析

以海洋监测场景为例，跨域SAR目标检测方法主要应用于舰船检测、非法捕捞监控、溢油应急预警及海上交通态势感知等任务。由于不同海域和传感器的成像特性、入射角、分辨率及海况条件存在明显差异，传统基于单一场景训练的检测模型往往难以在新海域保持稳定性能。通过引入跨域学习方法，可以有效缓解这一问题：模型在源域上学习的

舰船特征能够通过跨域学习迁移到目标域,从而在缺乏标注数据或成像条件不同的海域中仍具备较好的检测能力。例如,利用特征对齐和伪标签生成技术,模型能够适应不同海杂波背景和散射特性,提高对中小型舰船的检测效果。尽管仍面临海况多变、标注稀缺及背景杂波复杂等挑战,但可借助风格转换、无/半监督学习及物理先验约束等手段加以缓解,从而提高方法的泛化能力与实际应用价值。

## 5 未来展望

如第1节所述,在训练和测试数据不遵循独立同分布假设时,SAR图像目标检测模型面临性能下降的问题,针对该问题,已经提出各种方法来解决。本节将探讨目前研究中仍未彻底解决的问题以及潜在的解决思路和未来的研究方向,主要分为两大类问题和方向:(1)评估体系与基准建设;(2)方法架构创新。

### 5.1 评估体系与基准建设

本文明确了关于数据集和评价指标的相关问题,解决这些问题将会产生更加健全和严格的评估过程。

#### (1) 标准化跨域测试评估

目前所有的跨域SAR图像目标检测方法并没有形成统一的评价标准和体系,大多数现有的跨域SAR图像目标检测方法实验验证所使用的数据集、目标类别、实验设置等均有一定的差异,导致各种方法之间不能很好地进行性能比较,阻碍了该领域科学的发展。因此,建立一个标准化的跨域测试评估标准或体系十分重要。

#### (2) 可解释评估方法

现有大多数跨域SAR图像目标检测方法仅用常见的评估方法对模型进行评估。然而,考虑到不同于常规SAR图像目标检测模式设定的条件以及评估过程缺乏可解释性,使用可解释评估方法评估跨域SAR目标检测性能,增强模型可信度也很重要。

### 5.2 方法架构创新

由调研可知,虽然已经对跨域SAR图像目标检测领域开展了一些研究,但是这些研究均存在着一定的局限性和不充分性。所提方法在某些方面缓解了迁移泛化问题,但是其泛化能力仍然十分有限,因此未来重点的研究方向仍然是在方法架构上进行创新,提升SAR图像检测模型在跨域检测时的泛化能力。

#### (1) 多域综合感知与决策机制的构建

未来的跨域SAR目标检测亟须突破单一域特征

迁移的局限,转向多域综合感知与智能决策的协同范式。在实际应用中,SAR数据往往来源于不同成像模式、观测角度、极化方式及载荷平台,其分布差异显著。如何在多域数据之间实现特征互补与一致性建模,是提升跨域检测性能的关键。未来研究可探索基于多域特征共享表示学习、多模态融合注意力机制与跨域特征蒸馏的方法,构建具备自适应调整能力的统一感知框架。同时,可引入多域知识图谱与语义关联推理机制,使检测模型能够在复杂环境下进行跨域信息的协同决策与智能判断。值得关注的是,多域综合感知不应仅停留在数据层和特征层融合,还应延伸至任务层与决策层的跨域优化,实现由“特征迁移”向“认知融合”的转变,从而构建面向实际应用的多域智能检测体系。

#### (2) 视觉大模型驱动的跨域检测范式

近年来,视觉大模型(Vision Large Model, VLM)在自然场景理解中展现出强大的知识迁移与泛化能力,为SAR图像跨域检测提供了新的技术契机。未来研究可从以下3个方面展开:首先,针对数据稀缺与标签不足问题,视觉大模型可通过大规模多模态遥感数据的自监督预训练,学习可迁移的基础特征表示,从而在SAR任务中实现小样本甚至无标签条件下的有效迁移。其次,在增强跨域泛化能力方面,大模型丰富的层级特征结构和全局注意机制可通过参数高效调优或提示学习实现对不同传感器、地形和成像条件的快速自适应。最后,在结合物理约束的多模态建模方面,未来研究可将SAR成像机理融入大模型训练过程,使模型不仅具备数据驱动的统计泛化能力,还能在物理一致性和解释性层面实现突破。

#### (3) 面向开放环境的自适应与可解释检测

在未来开放环境下,SAR图像的成像条件、噪声特征及场景复杂度将更为多样,跨域检测模型的自适应学习与可解释性将成为关键问题。未来研究可从动态域对齐、元学习(Meta-Learning, ML)、增量迁移学习等方向入手,构建具备持续学习能力的自适应检测模型。同时,可结合因果推理、可视化解释与不确定性评估等手段,提升跨域检测结果的可信度与透明性,为模型在安全关键任务中的应用提供理论支撑。

## 6 结语

SAR图像目标检测模型在进行跨域检测时的性能下降问题是当代智能算法追求稳健泛化性道路上的一大阻碍,该文首先分析了训练测试集分布不同时对SAR目标检测模型的影响并详细阐述了跨域SAR图像目标检测任务面临的困难和挑战,然后调

研并总结了该领域最新的研究进展、实验数据集与评价指标,接着选取了部分典型方法的实验结果进行对比分析,最后根据总结的发展情况,展望了该领域未来的发展趋势,希望推动跨域检测算法能够成为实际侦察的重要保障的同时,更多学者也能够对该领域进行深入研究,快速建立起对跨域SAR图像目标检测领域相对完整的认知,共同解决跨域SAR图像目标检测的难题。

**利益冲突** 所有作者均声明不存在利益冲突

**Conflict of Interests** The authors declare that there is no conflict of interests

### 参 考 文 献

- [1] MOREIRA A, PRATS-IRAOLA P, YOUNIS M, *et al.* A tutorial on synthetic aperture radar[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(1): 6–43. doi: [10.1109/MGRS.2013.2248301](https://doi.org/10.1109/MGRS.2013.2248301).
- [2] 徐丰, 金亚秋. 从物理智能到微波视觉[J]. *科技导报*, 2018, 36(10): 30–44. doi: [10.3981/j.issn.1000-7857.2018.10.004](https://doi.org/10.3981/j.issn.1000-7857.2018.10.004).  
XU Feng and JIN Yaqui. From the emergence of intelligent science to the research of microwave vision[J]. *Science & Technology Review*, 2018, 36(10): 30–44. doi: [10.3981/j.issn.1000-7857.2018.10.004](https://doi.org/10.3981/j.issn.1000-7857.2018.10.004).
- [3] 江碧涛. 我国空间对地观测技术的发展与展望[J]. *测绘学报*, 2022, 51(7): 1153–1159. doi: [10.11947/j.AGCS.2022.20220199](https://doi.org/10.11947/j.AGCS.2022.20220199).  
JIANG Bitao. The development and prospect of China's space earth observation technology[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(7): 1153–1159. doi: [10.11947/j.AGCS.2022.20220199](https://doi.org/10.11947/j.AGCS.2022.20220199).
- [4] 关键. 雷达海上目标特性综述[J]. *雷达学报*, 2020, 9(4): 674–683. doi: [10.12000/JR20114](https://doi.org/10.12000/JR20114).  
GUAN Jian. Summary of marine radar target characteristics[J]. *Journal of Radars*, 2020, 9(4): 674–683. doi: [10.12000/JR20114](https://doi.org/10.12000/JR20114).
- [5] TANG Gang, ZHUGE Yichao, CLARAMUNT C, *et al.* N-YOLO: A SAR ship detection using noise-classifying and complete-target extraction[J]. *Remote Sensing*, 2021, 13(5): 871. doi: [10.3390/rs13050871](https://doi.org/10.3390/rs13050871).
- [6] PELICH R, CHINI M, HOSTACHE R, *et al.* Large-scale automatic vessel monitoring based on dual-polarization Sentinel-1 and AIS data[J]. *Remote Sensing*, 2019, 11(9): 1078. doi: [10.3390/rs11091078](https://doi.org/10.3390/rs11091078).
- [7] 赵琰, 赵凌君, 匡纲要. 基于注意力机制特征融合网络的SAR图像飞机目标快速检测[J]. *电子学报*, 2021, 49(9): 1665–1674. doi: [10.12263/DZXB.20200486](https://doi.org/10.12263/DZXB.20200486).  
ZHAO Yan, ZHAO Lingjun, and KUANG Gangyao. Attention feature fusion network for rapid aircraft detection in SAR images[J]. *Acta Electronica Sinica*, 2021, 49(9): 1665–1674. doi: [10.12263/DZXB.20200486](https://doi.org/10.12263/DZXB.20200486).
- [8] LI Weijie, YANG Wei, HOU Yuenan, *et al.* SARATR-X: Toward building a foundation model for SAR target recognition[J]. *IEEE Transactions on Image Processing*, 2025, 34: 869–884. doi: [10.1109/TIP.2025.3531988](https://doi.org/10.1109/TIP.2025.3531988).
- [9] ZHOU Jie, LIU Yongxiang, PENG Bowen, *et al.* MaDiNet: Mamba diffusion network for SAR target detection[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(11): 10787–10800. doi: [10.1109/TCSVT.2025.3574657](https://doi.org/10.1109/TCSVT.2025.3574657).
- [10] FRANCESCHETTI G, IODICE A, RICCIO D, *et al.* SAR raw signal simulation for urban structures[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(9): 1986–1995. doi: [10.1109/TGRS.2003.814626](https://doi.org/10.1109/TGRS.2003.814626).
- [11] FORNARO G. Trajectory deviations in airborne SAR: Analysis and compensation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1999, 35(3): 997–1009. doi: [10.1109/7.784069](https://doi.org/10.1109/7.784069).
- [12] SHI Yu, LI Yi, DU Lan, *et al.* Unsupervised domain adaptative SAR target detection based on feature decomposition and uncertainty-guided self-training[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 20265–20283. doi: [10.1109/JSTARS.2024.3486922](https://doi.org/10.1109/JSTARS.2024.3486922).
- [13] ZHOU Zheng, ZHAO Lingjun, JI Kefeng, *et al.* A domain-adaptive few-shot SAR ship detection algorithm driven by the latent similarity between optical and SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5216318. doi: [10.1109/TGRS.2024.3421512](https://doi.org/10.1109/TGRS.2024.3421512).
- [14] HUANG Hailiang, GUO Jingchao, LIN Huangxing, *et al.* Domain adaptive oriented object detection from optical to SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5200314. doi: [10.1109/TGRS.2024.3515161](https://doi.org/10.1109/TGRS.2024.3515161).
- [15] YUAN Yuxuan, TANG Luyao, XU Ying, *et al.* Filling and disentanglement: Toward low- and high-order parallel single-domain generalization for SAR ship detection[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2025, 61(2): 3668–3682. doi: [10.1109/TAES.2024.3489572](https://doi.org/10.1109/TAES.2024.3489572).
- [16] ZHANG Xianghui, ZHANG Siqian, SUN Zhongzhen, *et al.* Cross-sensor SAR image target detection based on dynamic feature discrimination and center-aware calibration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5209417. doi: [10.1109/TGRS.2025.3559618](https://doi.org/10.1109/TGRS.2025.3559618).
- [17] ZHAO Siyuan, KANG Yong, YUAN Hang, *et al.* FsDAOD: Few-shot domain adaptation object detection for heterogeneous SAR image[J]. *Science of Remote Sensing*, 2025, 11: 100202. doi: [10.1016/j.srs.2025.100202](https://doi.org/10.1016/j.srs.2025.100202).

- [18] PATEL V M, GOPALAN R, LI Ruonan, *et al.* Visual domain adaptation: A survey of recent advances[J]. *IEEE Signal Processing Magazine*, 2015, 32(3): 53–69. doi: [10.1109/MSP.2014.2347059](https://doi.org/10.1109/MSP.2014.2347059).
- [19] WANG Mei and DENG Weihong. Deep visual domain adaptation: A survey[J]. *Neurocomputing*, 2018, 312: 135–153. doi: [10.1016/j.neucom.2018.05.083](https://doi.org/10.1016/j.neucom.2018.05.083).
- [20] ZHUANG Fuzhen, QI Zhiyuan, DUAN Keyu, *et al.* A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2021, 109(1): 43–76. doi: [10.1109/JPROC.2020.3004555](https://doi.org/10.1109/JPROC.2020.3004555).
- [21] TOLDO M, MARACANI A, MICIELI U, *et al.* Unsupervised domain adaptation in semantic segmentation: A review[J]. *Technologies*, 2020, 8(2): 35. doi: [10.3390/technologies8020035](https://doi.org/10.3390/technologies8020035).
- [22] ZHAO Sicheng, YUE Xiangyu, ZHANG Shanghang, *et al.* A review of single-source deep unsupervised visual domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 473–493. doi: [10.1109/TNNLS.2020.3028503](https://doi.org/10.1109/TNNLS.2020.3028503).
- [23] OZA P, SINDAGI V A, VS V, *et al.* Unsupervised domain adaptation of object detectors: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(6): 4018–4040. doi: [10.1109/TPAMI.2022.3217046](https://doi.org/10.1109/TPAMI.2022.3217046).
- [24] REDMON J, DIVVALA S, GIRSHICK R, *et al.* You only look once: Unified, real-time object detection[C]. The 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016: 779–788. doi: [10.1109/CVPR.2016.91](https://doi.org/10.1109/CVPR.2016.91).
- [25] LIU Wei, ANGUELOV D, ERHAN D, *et al.* SSD: Single shot multibox detector[C]. The 14th European Conference on Computer Vision—ECCV 2016, Amsterdam, The Netherlands, 2016: 21–37. doi: [10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2).
- [26] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal loss for dense object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318–327. doi: [10.1109/TPAMI.2018.2858826](https://doi.org/10.1109/TPAMI.2018.2858826).
- [27] SUN Zhongzhen, LENG Xiangguang, LEI Yu, *et al.* BiFA-YOLO: A novel YOLO-based method for arbitrary-oriented ship detection in high-resolution SAR images[J]. *Remote Sensing*, 2021, 13(21): 4209. doi: [10.3390/rs13214209](https://doi.org/10.3390/rs13214209).
- [28] ZHOU Zheng, CHEN Jie, HUANG Zhixiang, *et al.* HRLE-SARDet: A lightweight SAR target detection algorithm based on hybrid representation learning enhancement[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5203922. doi: [10.1109/TGRS.2023.3251694](https://doi.org/10.1109/TGRS.2023.3251694).
- [29] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation[C]. The 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014: 580–587. doi: [10.1109/CVPR.2014.81](https://doi.org/10.1109/CVPR.2014.81).
- [30] GIRSHICK R. Fast R-CNN[C]. The 2015 IEEE International Conference on Computer Vision, Santiago, Chile, 2015: 1440–1448. doi: [10.1109/ICCV.2015.169](https://doi.org/10.1109/ICCV.2015.169).
- [31] REN Shaoqing, HE Kaiming, GIRSHICK R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137–1149. doi: [10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031).
- [32] LI Jianwei, QU Changwen, and SHAO Jiaqi. Ship detection in SAR images based on an improved faster R-CNN[C]. The 2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA), Beijing, China, 2017: 1–6. doi: [10.1109/BIGSAR DATA.2017.8124934](https://doi.org/10.1109/BIGSAR DATA.2017.8124934).
- [33] LIN Zhao, JI Kefeng, LENG Xiangguang, *et al.* Squeeze and excitation rank Faster R-CNN for ship detection in SAR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(5): 751–755. doi: [10.1109/LGRS.2018.2882551](https://doi.org/10.1109/LGRS.2018.2882551).
- [34] JIAO Jiao, ZHANG Yue, SUN Hao, *et al.* A densely connected end-to-end neural network for multiscale and multiscale SAR ship detection[J]. *IEEE Access*, 2018, 6: 20881–20892. doi: [10.1109/ACCESS.2018.2825376](https://doi.org/10.1109/ACCESS.2018.2825376).
- [35] CHEN Shiqi, ZHAN Ronghui, and ZHANG Jun. Robust single stage detector based on two-stage regression for SAR ship detection[C]. The 2nd International Conference on Innovation in Artificial Intelligence, Shanghai, China, 2018: 169–174. doi: [10.1145/3194206.3194223](https://doi.org/10.1145/3194206.3194223).
- [36] WEI Shunjun, SU Hao, MING Jing, *et al.* Precise and robust ship detection for high-resolution SAR imagery based on HR-SDNet[J]. *Remote Sensing*, 2020, 12(1): 167. doi: [10.3390/rs12010167](https://doi.org/10.3390/rs12010167).
- [37] CUI Zongyong, LI Qi, CAO Zongjie, *et al.* Dense attention pyramid networks for multi-scale ship detection in SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 8983–8997. doi: [10.1109/TGRS.2019.2923988](https://doi.org/10.1109/TGRS.2019.2923988).
- [38] ZHAO Yan, ZHAO Lingjun, XIONG Boli, *et al.* Attention receptive pyramid network for ship detection in SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 2738–2756. doi: [10.1109/JSTARS.2020.2997081](https://doi.org/10.1109/JSTARS.2020.2997081).
- [39] WANG Shiyu, CAI Zhanchuan, and YUAN Jieyu. Automatic SAR ship detection based on multifeature fusion network in spatial and frequency domains[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 4102111. doi: [10.1109/TGRS.2023.3267495](https://doi.org/10.1109/TGRS.2023.3267495).
- [40] PAN Dece, GAO Xin, DAI Wei, *et al.* SRT-Net: Scattering

- region topology network for oriented ship detection in large-scale SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5202318. doi: [10.1109/TGRS.2024.3351366](https://doi.org/10.1109/TGRS.2024.3351366).
- [41] ZHANG Chongqi, DENG Yao, CHONG Mingzhe, *et al.* Entropy-based re-sampling method on SAR class imbalance target detection[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024, 209: 432–447. doi: [10.1016/j.isprsjprs.2024.02.019](https://doi.org/10.1016/j.isprsjprs.2024.02.019).
- [42] SHI Yu, DU Lan, GUO Yuchen, *et al.* Unsupervised domain adaptation based on progressive transfer for ship detection: From optical to SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5230317. doi: [10.1109/TGRS.2022.3185298](https://doi.org/10.1109/TGRS.2022.3185298).
- [43] ZHAO Siyuan, LUO Ying, ZHANG Tao, *et al.* A feature decomposition-based method for automatic ship detection crossing different satellite SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5234015. doi: [10.1109/TGRS.2022.3201628](https://doi.org/10.1109/TGRS.2022.3201628).
- [44] XU Chujie, ZHENG Xiangtao, and LU Xiaoqiang. Multi-level alignment network for cross-domain ship detection[J]. *Remote Sensing*, 2022, 14(10): 2389. doi: [10.3390/rs14102389](https://doi.org/10.3390/rs14102389).
- [45] ZHAO Siyuan, LUO Ying, ZHANG Tao, *et al.* A domain specific knowledge extraction transformer method for multisource satellite-borne SAR images ship detection[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 198: 16–29. doi: [10.1016/j.isprsjprs.2023.02.011](https://doi.org/10.1016/j.isprsjprs.2023.02.011).
- [46] YUAN Yuxuan, RAO Zhijie, LIN Chuyang, *et al.* Adaptive ship detection from optical to SAR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 3508205. doi: [10.1109/LGRS.2023.3317321](https://doi.org/10.1109/LGRS.2023.3317321).
- [47] HE Jiayue, SU Nan, XU Congan, *et al.* A cross-modality feature transfer method for target detection in SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5213615. doi: [10.1109/TGRS.2023.3300536](https://doi.org/10.1109/TGRS.2023.3300536).
- [48] SHI Yu, DU Lan, GUO Yuchen, *et al.* Optical knowledge assisted unsupervised cross-domain SAR target detection[J]. *IET Conference Proceedings*, 2024, 2023(47): 1474–1480. doi: [10.1049/icp.2024.1303](https://doi.org/10.1049/icp.2024.1303).
- [49] ZHANG Ruixiang, WANG Yuxuan, LI Haoyuan, *et al.* Decoupled multi-teacher: Cross-modal learning enhanced object detection in SAR imagery[C]. IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 7858–7862. doi: [10.1109/IGARSS53475.2024.10641529](https://doi.org/10.1109/IGARSS53475.2024.10641529).
- [50] 何佳月, 宿南, 徐从安, 等. 从光学到SAR: 基于多级跨模态对齐的SAR图像舰船检测算法[J]. *遥感学报*, 2024, 28(7): 1789–1801. doi: [10.11834/jrs.20243249](https://doi.org/10.11834/jrs.20243249).
- HE Jiayue, SU Nan, XU Congan, *et al.* From optical to SAR: A SAR ship detection algorithm based on multi-level cross-modality alignment[J]. *National Remote Sensing Bulletin*, 2024, 28(7): 1789–1801. doi: [10.11834/jrs.20243249](https://doi.org/10.11834/jrs.20243249).
- [51] ZHAO Xiaolin, ZHAO Siyuan, LUO Ying, *et al.* Generalizing SAR object detection: A unified framework for cross-source scenarios[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 4009105. doi: [10.1109/LGRS.2025.3575173](https://doi.org/10.1109/LGRS.2025.3575173).
- [52] SHI Yu, DU Lan, and GUO Yuchen. Unsupervised domain adaptation for SAR target detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 6372–6385. doi: [10.1109/JSTARS.2021.3089238](https://doi.org/10.1109/JSTARS.2021.3089238).
- [53] SHI Yu, DU Lan, GUO Yuchen, *et al.* Cross sensor transfer learning for unsupervised SAR target detection[C]. 2021 CIE International Conference on Radar (Radar), Haikou, China, 2021: 2082–2086. doi: [10.1109/Radar53847.2021.10028188](https://doi.org/10.1109/Radar53847.2021.10028188).
- [54] CHEN Shiqi, ZHAN Ronghui, WANG Wei, *et al.* Domain adaptation for semi-supervised ship detection in SAR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4507405. doi: [10.1109/LGRS.2022.3171789](https://doi.org/10.1109/LGRS.2022.3171789).
- [55] ZHANG Tingting, LOU Xin, WANG Han, *et al.* Context-preserving region-based contrastive learning framework for ship detection in SAR[J]. *Journal of Signal Processing Systems*, 2023, 95(1): 3–12. doi: [10.1007/s11265-022-01799-8](https://doi.org/10.1007/s11265-022-01799-8).
- [56] ZOU Bin, QIN Jiang, and ZHANG Lamei. Cross-scene target detection based on feature adaptation and uncertainty-aware pseudo-label learning for high resolution SAR images[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 200: 173–190. doi: [10.1016/j.isprsjprs.2023.05.009](https://doi.org/10.1016/j.isprsjprs.2023.05.009).
- [57] ZHENG Xiangtao, CUI Haowen, XU Chujie, *et al.* Dual teacher: A semisupervised cotraining framework for cross-domain ship detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5613312. doi: [10.1109/TGRS.2023.3287863](https://doi.org/10.1109/TGRS.2023.3287863).
- [58] ZHANG Xin and ZHAO Siyuan. A domain adaptation detector for heterogenous SAR image object detection[J]. *IET Conference Proceedings*, 2024, 2023(47): 3215–3218. doi: [10.1049/icp.2024.1613](https://doi.org/10.1049/icp.2024.1613).
- [59] CHEN Xi, WANG Zhirui, WANG Wenhao, *et al.* CroMoDa: Unsupervised oriented SAR ship detection via cross-modality distribution alignment[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 11899–11914. doi: [10.1109/JSTARS.2024.3420901](https://doi.org/10.1109/JSTARS.2024.3420901).
- [60] LOU Xin and WANG Han. Object detection in SAR via

- generative knowledge transfer[C]. 2021 IEEE 31st International Workshop on Machine Learning for Signal Processing (MLSP), Gold Coast, Australia, 2021: 1–6. doi: [10.1109/MLSP52302.2021.9596254](https://doi.org/10.1109/MLSP52302.2021.9596254).
- [61] PU Xinyang, JIA Hecheng, XIN Yu, *et al.* Ship detection in low-quality SAR images via an unsupervised domain adaption method[J]. *Remote Sensing*, 2023, 15(13): 3326. doi: [10.3390/rs15133326](https://doi.org/10.3390/rs15133326).
- [62] PU Xinyang, JIA Hecheng, and XU Feng. Cross-domain SAR ship detection in strong interference environment based on image-to-image translation[C]. IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, USA, 2023: 1798–1801. doi: [10.1109/IGARSS52108.2023.10282746](https://doi.org/10.1109/IGARSS52108.2023.10282746).
- [63] YU Wenbo, WANG Zijian, LI Jiamu, *et al.* Unsupervised aircraft detection in SAR images with image-level domain adaption from optical images[C]. The 3rd International Conference on Computer Vision and Pattern Analysis (ICCPA 2023), Hangzhou, China, 2023. doi: [10.1117/12.2684516](https://doi.org/10.1117/12.2684516).
- [64] YU Wenbo, LI Jiamu, WANG Zijian, *et al.* Boosting SAR aircraft detection performance with multi-stage domain adaptation training[J]. *Remote Sensing*, 2023, 15(18): 4614. doi: [10.3390/rs15184614](https://doi.org/10.3390/rs15184614).
- [65] YANG Yanrui, CHEN Jie, SUN Long, *et al.* Unsupervised domain-adaptive SAR ship detection based on cross-domain feature interaction and data contribution balance[J]. *Remote Sensing*, 2024, 16(2): 420. doi: [10.3390/rs16020420](https://doi.org/10.3390/rs16020420).
- [66] 娄欣, 王晗, 卢昊, 等. 生成式知识迁移的SAR舰船检测[J]. 遥感学报, 2024, 28(2): 470–480. doi: [10.11834/jrs.20211354](https://doi.org/10.11834/jrs.20211354).  
LOU Xin, WANG Han, LU Hao, *et al.* SAR ship detection through generative knowledge transfer[J]. *National Remote Sensing Bulletin*, 2024, 28(2): 470–480. doi: [10.11834/jrs.20211354](https://doi.org/10.11834/jrs.20211354).
- [67] WU Baolong, WANG Haonan, ZHANG Cunle, *et al.* Optical-to-SAR translation based on CDA-GAN for high-quality training sample generation for ship detection in SAR amplitude images[J]. *Remote Sensing*, 2024, 16(16): 3001. doi: [10.3390/rs16163001](https://doi.org/10.3390/rs16163001).
- [68] 陈亮, 李健昊, 何成, 等. 多域特征引导的无监督SAR图像舰船检测方法[J]. 上海航天(中英文), 2024, 41(3): 121–129. doi: [10.19328/j.cnki.2096-8655.2024.03.013](https://doi.org/10.19328/j.cnki.2096-8655.2024.03.013).  
CHEN Liang, LI Jianhao, HE Cheng, *et al.* A multi-domain feature-guided method for unsupervised ship detection in SAR images[J]. *Aerospace Shanghai (Chinese & English)*, 2024, 41(3): 121–129. doi: [10.19328/j.cnki.2096-8655.2024.03.013](https://doi.org/10.19328/j.cnki.2096-8655.2024.03.013).
- [69] LUO Cheng, ZHANG Yueting, GUO Jiayi, *et al.* SAR-CDSS: A semi-supervised cross-domain object detection from optical to SAR domain[J]. *Remote Sensing*, 2024, 16(6): 940. doi: [10.3390/rs16060940](https://doi.org/10.3390/rs16060940).
- [70] ZHU Ya'nan, AI Jiaqiu, XUE Weibao, *et al.* Cross-modal ship detection from optical to SAR images based on pixel- and feature-level progressive transfer[J]. *IEEE Sensors Journal*, 2025, 25(8): 13344–13356. doi: [10.1109/JSEN.2025.3543520](https://doi.org/10.1109/JSEN.2025.3543520).
- [71] ZHAO Siyuan, ZHANG Zenghui, GUO Weiwei, *et al.* An automatic ship detection method adapting to different satellites SAR images with feature alignment and compensation loss[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5225217. doi: [10.1109/TGRS.2022.3160727](https://doi.org/10.1109/TGRS.2022.3160727).
- [72] ZHANG Jun, LI Simin, DONG Yongfeng, *et al.* Hierarchical similarity alignment for domain adaptive ship detection in SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5240611. doi: [10.1109/TGRS.2022.3227626](https://doi.org/10.1109/TGRS.2022.3227626).
- [73] 宋玉成, 李景润, 田甜, 等. 跨模态域自适应SAR图像舰船检测与识别[J]. 华中科技大学学报: 自然科学版, 2022, 50(11): 107–113. doi: [10.13245/j.hust.221113](https://doi.org/10.13245/j.hust.221113).  
SONG Yucheng, LI Jingrun, TIAN Tian, *et al.* Ship detection and recognition in SAR images with cross-modality domain adaption[J]. *Journal of Huazhong University of Science & Technology: Natural Science Edition*, 2022, 50(11): 107–113. doi: [10.13245/j.hust.221113](https://doi.org/10.13245/j.hust.221113).
- [74] JEONG S, KIM Y, KIM S, *et al.* Enriching SAR ship detection via multistage domain alignment[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4018905. doi: [10.1109/LGRS.2021.3115498](https://doi.org/10.1109/LGRS.2021.3115498).
- [75] PAN Bin, XU Zhehao, SHI Tianyang, *et al.* An imbalanced discriminant alignment approach for domain adaptive SAR ship detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5108111. doi: [10.1109/TGRS.2023.3303507](https://doi.org/10.1109/TGRS.2023.3303507).
- [76] LIU Shuang, LI Dong, WAN Jun, *et al.* Source-assisted hierarchical semantic calibration method for ship detection across different satellite SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5215221. doi: [10.1109/TGRS.2024.3419025](https://doi.org/10.1109/TGRS.2024.3419025).
- [77] HU Kaiou, WAN Hongjie, and MA Fei. Cross-domain SAR detection method based on salient object alignment[J]. *IET Conference Proceedings*, 2024, 2023(47): 3347–3351. doi: [10.1049/icp.2024.1638](https://doi.org/10.1049/icp.2024.1638).
- [78] LIAO Leiyao, DU Lan, and GUO Yuchen. Semi-supervised SAR target detection based on an improved Faster R-CNN[J]. *Remote Sensing*, 2021, 14(1): 143. doi: [10.3390/rs14010143](https://doi.org/10.3390/rs14010143).
- [79] GUO Yuchen, DU Lan, and LYU Guoxin. SAR target

- detection based on domain adaptive Faster R-CNN with small training data size[J]. *Remote Sensing*, 2021, 13(21): 4202. doi: [10.3390/rs13214202](https://doi.org/10.3390/rs13214202).
- [80] WANG Xu, ZHOU Huaji, CHEN Zheng, *et al.* Few-shot SAR ship image detection using two-stage cross-domain transfer learning[C]. IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022: 2195–2198. doi: [10.1109/IGARSS46834.2022.9883172](https://doi.org/10.1109/IGARSS46834.2022.9883172).
- [81] QIN Jiang, ZOU Bin, ZHANG Lamei, *et al.* Domain adaptive target detection with optimal transportation for different satellite SAR images[C]. EUSAR 2024; 15th European Conference on Synthetic Aperture Radar, Munich, Germany, 2024: 498–502.
- [82] CHAN Haopeng, QIU Xiaolan, GAO Xin, *et al.* A complex background SAR ship target detection method based on fusion tensor and cross-domain adversarial learning[J]. *Remote Sensing*, 2024, 16(18): 3492. doi: [10.3390/rs16183492](https://doi.org/10.3390/rs16183492).
- [83] LIAO Leiyao. Semi-supervised SAR target detection with cross-domain transfer learning based on YOLOv5[C]. IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 7401–7404. doi: [10.1109/IGARSS53475.2024.10641642](https://doi.org/10.1109/IGARSS53475.2024.10641642).
- [84] DONG Jun, FENG Jiewen, and TANG Xiaoyu. OptiSAR-Net: A cross-domain ship detection method for multisource remote sensing data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4709311. doi: [10.1109/TGRS.2024.3502447](https://doi.org/10.1109/TGRS.2024.3502447).
- [85] HU Kaiou, WAN Hongjie, MA Fei, *et al.* Cross-domain SAR object detection by efficiently fine-tuning SAM[C]. 2024 Photonics & Electromagnetics Research Symposium (PIERS), Chengdu, China, 2024: 1–7. doi: [10.1109/PIERS62282.2024.10618373](https://doi.org/10.1109/PIERS62282.2024.10618373).
- [86] ZHANG Chaochen, CHEN Jie, HUANG Zhongling, *et al.* SAR image target segmentation guided by the scattering mechanism-based visual foundation model[J]. *Remote Sensing*, 2025, 17(7): 1209. doi: [10.3390/rs17071209](https://doi.org/10.3390/rs17071209).
- [87] ZOU Zhengxia and SHI Zhenwei. Random access memories: A new paradigm for target detection in high resolution aerial remote sensing images[J]. *IEEE Transactions on Image Processing*, 2018, 27(3): 1100–1111. doi: [10.1109/TIP.2017.2773199](https://doi.org/10.1109/TIP.2017.2773199).
- [88] ZHANG Yuanlin, YUAN Yuan, FENG Yachuang, *et al.* Hierarchical and robust convolutional neural network for very high-resolution remote sensing object detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5535–5548. doi: [10.1109/TGRS.2019.2900302](https://doi.org/10.1109/TGRS.2019.2900302).
- [89] CHEN Ziyi, WANG Cheng, LUO Huan, *et al.* Vehicle detection in high-resolution aerial images based on fast sparse representation classification and multioorder feature[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(8): 2296–2309. doi: [10.1109/TITS.2016.2517826](https://doi.org/10.1109/TITS.2016.2517826).
- [90] LI Ke, WAN Gang, CHENG Gong, *et al.* Object detection in optical remote sensing images: A survey and a new benchmark[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 159: 296–307. doi: [10.1016/j.isprsjprs.2019.11.023](https://doi.org/10.1016/j.isprsjprs.2019.11.023).
- [91] LIU Zikun, YUAN Liu, WENG Lubin, *et al.* A high resolution optical satellite image dataset for ship recognition and some new baselines[C]. The 6th International Conference on Pattern Recognition Applications and Methods, Porto, Portugal, 2017: 324–331. doi: [10.5220/0006120603240331](https://doi.org/10.5220/0006120603240331).
- [92] XIA Guisong, BAI Xiang, DING Jian, *et al.* DOTA: A large-scale dataset for object detection in aerial images[C]. The 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 3974–3983. doi: [10.1109/CVPR.2018.00418](https://doi.org/10.1109/CVPR.2018.00418).
- [93] ZHANG Zhengning, ZHANG Lin, WANG Yue, *et al.* ShipRSImageNet: A large-scale fine-grained dataset for ship detection in high-resolution optical remote sensing images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 8458–8472. doi: [10.1109/JSTARS.2021.3104230](https://doi.org/10.1109/JSTARS.2021.3104230).
- [94] SHERMEYER J, HOGAN D, BROWN J, *et al.* SpaceNet 6: Multi-sensor all weather mapping dataset[C]. The 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Seattle, USA, 2020: 768–777. doi: [10.1109/CVPRW50498.2020.00106](https://doi.org/10.1109/CVPRW50498.2020.00106).
- [95] SHIN C, KIM S, and KIM Y. From planetscope to worldview: Micro-satellite image super-resolution with optimal transport distance[C]. The 2020 IEEE International Conference on Image Processing (ICIP), Abu Dhabi, United Arab Emirates, 2020: 898–902. doi: [10.1109/ICIP40778.2020.9190810](https://doi.org/10.1109/ICIP40778.2020.9190810).
- [96] INVERSION, FAUDI J, and MARTIN. Airbus ship detection challenge[EB/OL]. <https://www.kaggle.com/c/airbus-ship-detection>, 2018.
- [97] ZHANG Tianwen, ZHANG Xiaoling, LI Jianwei, *et al.* SAR Ship Detection Dataset (SSDD): Official release and comprehensive data analysis[J]. *Remote Sensing*, 2021, 13(18): 3690. doi: [10.3390/rs13183690](https://doi.org/10.3390/rs13183690).
- [98] WEI Shunjun, ZENG Xiangfeng, QU Qizhe, *et al.* HRSID: A high-resolution SAR images dataset for ship detection and instance segmentation[J]. *IEEE Access*, 2020, 8: 120234–120254. doi: [10.1109/ACCESS.2020.3005861](https://doi.org/10.1109/ACCESS.2020.3005861).
- [99] SANDIA mini SAR complex imagery[EB/OL]. <http://www.sandia.gov/radar/complex-data/index.html>,

2005. Accessed: Apr. 15, 2021.
- [100] FARADSAR public release data[EB/OL]. 2015. [https://www.sandia.gov/radar/complex\\_data/FARAD\\_KA\\_BAND.zip](https://www.sandia.gov/radar/complex_data/FARAD_KA_BAND.zip).
- [101] LEI Songlin, LU Dongdong, QIU Xiaolan, *et al.* SRSDD-v1.0: A high-resolution SAR rotation ship detection dataset[J]. *Remote Sensing*, 2021, 13(24): 5104. doi: [10.3390/rs13245104](https://doi.org/10.3390/rs13245104).
- [102] 孙显, 王智睿, 孙元睿, 等. AIR-SARShip-1.0: 高分辨率 SAR舰船检测数据集[J]. 雷达学报, 2019, 8(6): 852–862. doi: [10.12000/JR19097](https://doi.org/10.12000/JR19097).  
SUN Xian, WANG Zhirui, SUN Yuanrui, *et al.* AIR-SARShip-1.0: High-resolution SAR ship detection dataset[J]. *Journal of Radars*, 2019, 8(6): 852–862. doi: [10.12000/JR19097](https://doi.org/10.12000/JR19097).
- [103] WANG Yuanyuan, WANG Chao, ZHANG Hong, *et al.* A SAR dataset of ship detection for deep learning under complex backgrounds[J]. *Remote Sensing*, 2019, 11(7): 765. doi: [10.3390/rs11070765](https://doi.org/10.3390/rs11070765).
- [104] 陈杰, 黄志祥, 夏润繁, 等. 大规模多类SAR目标检测数据集-1.0[J/OL]. 雷达学报, <https://radars.ac.cn/web/data/getData?dataType=MSAR>, 2022.  
CHEN Jie, HUANG Zhixiang, XIA Runfan, *et al.* Large-scale multi-class SAR image target detection dataset-1.0[J/OL]. *Journal of Radars*, <https://radars.ac.cn/web/data/getData?dataType=MSAR>, 2022.
- [105] 徐从安, 苏航, 李健伟, 等. RSDD-SAR: SAR舰船斜框检测数据集[J]. 雷达学报, 2022, 11(4): 581–599. doi: [10.12000/JR22007](https://doi.org/10.12000/JR22007).  
XU Congan, SU Hang, LI Jianwei, *et al.* RSDD-SAR: Rotated ship detection dataset in SAR images[J]. *Journal of Radars*, 2022, 11(4): 581–599. doi: [10.12000/JR22007](https://doi.org/10.12000/JR22007).

### 作者简介

周正, 博士生, 主要研究方向为SAR图像解译、跨域SAR图像目标检测与识别。

赵凌君, 教授, 主要研究方向为遥感信息处理、SAR目标自动识别等。

何奇山, 博士生, 主要研究方向为SAR目标检测识别、深度学习。

孙忠镇, 博士生, 主要研究方向为空天遥感图像智能处理、SAR图像目标检测识别。

计科峰, 教授, 主要研究方向为SAR目标电磁散射特性建模、特征提取、检测识别以及多源空天遥感图像智能处理与解译基础理论、核心关键技术以及系统集成与应用等。

匡纲要, 教授, 主要研究方向为遥感图像智能解译、SAR图像目标检测与识别。

(责任编辑: 于青)