

基于视觉-语义特征协同学习的少样本SAR目标识别

任浩浩*^{①②} 蒋欣好^① 苗磊^① 范利伟^① 李俊毅^① 邹林^①

^①(电子科技大学信息与通信工程学院 成都 611731)

^②(精密测量雷达系统技术四川省重点实验室 成都 611731)

摘要: 针对合成孔径雷达(SAR)目标识别模型在少样本条件下极易发生过拟合、且类间鉴别性差的问题, 该文提出了一种基于视觉-语义特征协同学习的少样本SAR目标识别方法。首先, 考虑到少样本条件下SAR图像数据蕴含的视觉信息有限, 该文提出一种基于“生成-编码-筛选”思路的SAR目标语义信息构建方法, 并基于语义先验信息构建类语义原型, 后与视觉特征协同, 实现目标类属性识别。其次, 提出一种视觉-语义特征双分支协同学习网络来提取更具判别性SAR目标类特征。其中, SAR图像视觉分支通过皮尔逊相关系数对齐视觉原型与语义原型的关系矩阵, 使得语义先验的类别信息向视觉分支传递, 并基于动态四元组损失优化网络, 提升视觉特征的判别性; SAR图像语义分支采用最优传输理论通过视觉特征优化语义特征, 增强语义特征的判别性。最后, 提出一种基于实例级预测置信度的加权决策融合策略, 实现联合语义-视觉特征的SAR目标稳健识别。在MSTAR数据集的标准集和拓展集, 以及OpenSARShip数据集上进行实验。实验结果表明, 该方法在少样本条件下能够有效利用目标视觉与语义特征的互补优势, 识别准确率与鲁棒性均得到显著提升。

关键词: 合成孔径雷达; 少样本目标识别; 视觉-语义协同学习; 跨模态特征对齐; 最优传输

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2026)x-0001-16

DOI: 10.12000/JR26108

CSTR: 32380.14.JR26108

引用格式: 任浩浩, 蒋欣好, 苗磊, 等. 基于视觉-语义特征协同学习的少样本SAR目标识别[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26108.

Reference format: REN Haohao, JIANG Xinyu, MIAO Lei, *et al.* Collaborative learning of visual- and semantic features for few-shot SAR target recognition[J]. *Journal of Radars*, in press. doi: 10.12000/JR26108.

Collaborative Learning of Visual- and Semantic Features for Few-Shot SAR Target Recognition

REN Haohao*^{①②} JIANG Xinyu^① MIAO Lei^① FAN Liwei^①
LI Junyi^① ZOU Lin^①

^①(*Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China*)

^②(*Sichuan Key Laboratory of Precision Measurement Radar System Technology, Chengdu 611731, Sichuan, China*)

Abstract: To address the susceptibility of Synthetic Aperture Radar (SAR) target recognition models to overfitting and their limited inter-class discriminability under few-shot conditions, this paper proposes a few-shot SAR target recognition method that employs collaborative learning of visual and semantic features. First,

收稿日期: 2026-06-16; 改回日期: ; 网络出版: 2026-xx-xx

*通信作者: 任浩浩 haohao_ren@uestc.edu.cn *Corresponding Author: REN Haohao, haohao_ren@uestc.edu.cn

基金项目: 国家自然科学基金(62201124); 四川省自然科学基金(2025ZNSFSC1432)

Foundation Item: National Natural Science Foundation of China (62201124); Sichuan Provincial Natural Science Foundation (2025ZNSF-SC1432)

责任主编: 徐丰 Corresponding Editor: XU Feng

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

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

given the limited visual information available in SAR imagery under few-shot conditions, a semantic information construction method for SAR targets is developed based on a “generation–encoding–selection” paradigm. Class-level semantic prototypes are then constructed from semantic prior information to capture target-class attributes and complement visual features. Second, a dual-branch collaborative learning network for visual and semantic features is developed to extract more discriminative class representations of SAR targets. In the visual branch, the Pearson correlation matrices of the visual and semantic prototypes are aligned, to transfer category-related information from the semantic prior information to the visual branch. A dynamic quadruplet loss is employed to optimize the network and enhance the discriminability of the visual features. In the semantic branch, optimal transport theory is introduced to refine semantic features using visual features, thereby improving their discriminative capability. Third, a weighted decision-level fusion strategy based on instance-level prediction confidence is proposed to achieve robust SAR target recognition by jointly exploiting semantic and visual features. Experiments were conducted on the standard and extended sets of the MSTAR dataset, as well as on the OpenSARShip dataset. The experimental results demonstrate that the proposed method effectively exploits the complementary strengths of visual and semantic target features under few-shot conditions, leading to substantial improvements in both recognition accuracy and robustness.

Key words: Synthetic Aperture Radar (SAR); Few-shot target recognition; Visual-semantic collaborative learning; Cross-modal feature alignment; Optimal transport

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)作为一种主动式微波遥感成像设备,具备全天时、全天候、不受云雾遮挡和光照条件影响的独特优势,因此在军事侦察、地质勘探、环境监测、海洋观测等多个关键领域具有不可替代的应用价值^[1-3]。数十年来,随着SAR成像技术的不断迭代升级,SAR图像质量不断提高,如何从SAR图像中快速、准确地鉴别出感兴趣目标,一直是SAR图像解译领域的研究热点与核心难题。

SAR目标识别是指利用SAR图像信号自动检测、定位、分类并辨识出感兴趣目标的类型、属性、状态等信息的技术,是连接SAR图像数据与实际应用需求的关键环节。总的来说,SAR目标识别的方法可以分为3类,即基于模板的方法^[4]、基于模型的方法^[5]以及基于学习的方法^[6-8]。其中,模板法通过计算类别模板与待识别样本的相似度实现目标类别推断;模型法旨在为各类目标构建可有效表征其特性的复杂物理模型;早期基于学习的方法主要采用几何特征、变换域特征、局部描述子和散射中心特征,并结合支持向量机、稀疏表示等分类器实现目标识别^[9]。这类方法在小规模数据条件下具有一定适用性,但特征设计较为依赖领域知识,其表征能力和跨场景泛化能力有限。

近年来,深度学习技术凭借其强大的自动特征提取能力和端到端的学习模式,逐渐成为了SAR目标识别领域的主流方法^[10-12]。目前,国内外学者提出了多种基于深度学习的SAR目标识别模型。KECHAGIAS-STAMATISO等人^[13]提出一种基于

AlexNet的多模态特征融合策略;Ren等人^[14]设计扩展卷积胶囊网络,结合多尺度特征提取、特征细化和姿态保持机制,提高模型在俯仰角变化、噪声干扰及有限样本条件下的识别鲁棒性。此类方法能够直接从SAR图像中学习判别特征,在标准工作条件下通常优于传统人工特征方法,但网络性能高度依赖训练数据的数量及其对方位角、俯仰角和目标构型的覆盖程度,在扩展工作条件下容易出现性能下降。为增强网络对SAR成像机理和目标散射特性的利用,部分研究将物理先验引入深度特征学习过程。相关方法通过属性散射中心、频域特征、极化信息或预定义滤波器约束网络的特征提取过程^[15-17],XIE等人^[18]提出基于属性散射中心的深度特征提取网络。这些模型在公开SAR目标数据集上取得了优于传统方法的识别性能。然而,这些识别方法取得优异性能时高度依赖大量的标注样本,而在实际SAR目标识别场景中,受目标非合作性、以及标注工作的高成本等因素影响,获取大量标注样本往往面临诸多挑战,因此本文聚焦于少样本研究。

少样本学习打破了传统深度学习对海量样本的依赖,更贴合实际SAR目标识别的应用场景,因此已成为近年来SAR目标识别领域的研究热点。目前,少样本SAR目标识别的研究主要集中在3个方面:一是基于数据扩增的方法,以生成对抗网络(Generative Adversarial Networks, GAN)为代表的扩增方法通过生成器与判别器之间的博弈,合成具有高逼真度的SAR图像,极大地丰富了训练集的多样性^[19]。但是在极度缺乏真实SAR数据时,

GAN的源域数据受限, 极易发生崩塌^[20]。二是基于迁移学习的方法, 迁移学习的核心思想在于利用神经网络的知识复用能力, 将模型在数据量充足的源域上学到的通用特征迁移应用到数据极度匮乏的目标域^[21]。然而在实际应用中, 基于迁移学习的SAR目标识别方法高度依赖于“大规模、高质量且高度相关的源域数据集”, 这个前提限制了该方法在少样本SAR目标识别领域的泛化性和鲁棒性^[22]。

三是基于结构优化的方法, 结构优化是从深度学习模型自身架构出发, 旨在提升SAR目标识别算法在实际中的效率和鲁棒性^[23]。然而, 优化后的结构往往会牺牲网络的特征表征能力, 在小样本场景下的容错率极低, 易陷入过拟合或欠拟合的境地^[24]。上述研究在一定程度上缓解了少样本带来的识别难题, 但面临一个亟待解决的根本性瓶颈: 它们本质上均局限于单一的视觉模态特征空间。现有方法的主要缺陷在于过度依赖纯数据驱动的底层特征学习, 而未能有效引入高维的外部先验知识加以引导。由于少样本 SAR 图像固有的视觉表征稀疏性与信息缺失, 仅在闭合的视觉空间内进行特征映射, 难以应对复杂多变的真实雷达观测场景, 导致模型的鲁棒性严重受限。而文本信息作为一种重要的语义信息载体, 能够清晰、准确地描述目标的属性、结构、功能等关键语义特征, 帮助模型更好地理解目标的本质特征, 提升模型在复杂场景下的识别性能。针对上述问题, 本文的主要工作如下:

(1) 考虑到大语言模型具有强大的推理能力, 本文首先采用该模型生成SAR目标的文本描述, 然

后通过对比语言-图像预训练模型(Contrastive Language-Image Pre-training, CLIP)对文本描述进行编码, 将目标的文本描述转为语义信息, 并提出一种基于目标特有属性描述的筛选准则, 以避免大语言模型生成的文本描述符中出现的语义偏差。得到的语义信息用于图像级视觉信息的补充, 以提升少样本条件下SAR目标识别精度。

(2) 针对独特的SAR成像特性引起SAR图像目标类间相似度高, 类内差异大问题, 本文提出了一种视觉-语义特征双分支协同学习方法, 其基于最优传输和关系矩阵分别引导目标语义原型优化和视觉特征分布矫正, 旨在改善SAR图像目标嵌入空间类内聚合、类间分散。

2 基于视觉-语义特征协同学习的SAR目标识别

本文提出的在少样本条件下基于视觉-语义特征协同学习的SAR目标识别总体框架如图1所示。已有研究表明, 类别语义先验能够有效弥补少样本条件下视觉表征信息的不足。例如, Yan等人^[25]利用类别语义属性指导SAR目标特征生成, 实现了语义信息辅助的零样本SAR目标识别; Cai等人^[26]通过将语义嵌入映射至视觉空间增强视觉原型的类间可分性, 验证了语义先验对少样本类别表征的有效补充作用。

受到文献^[27]的启发, 整个网络可分为两个分支: 最优传输引导的语义原型优化分支和关系矩阵引导的视觉特征分布矫正分支。不同于文献^[27]中将类别语义嵌入, 通过跨模态特征映射校准视觉原




图1 视觉-语义特征协同学习的SAR目标识别网络框架

Fig. 1 Visual-Semantic feature collaborative learning framework for SAR target recognition

型,并将查询样本映射至语义空间进行分类。本文采用“生成—编码—筛选”流程构建语义原型,并通过关系矩阵对齐将语义类别结构迁移至视觉空间,同时利用最优传输根据SAR视觉分布反向校准语义原型,从而形成关系级结构迁移与分布级语义校准相结合的双向协同机制。

2.1 SAR图像目标语义编码

少样本带来的特征多样性缺失和特征鉴别性不足会严重影响识别模型学习效果的泛化性和鲁棒性,导致识别性能下降。AG-MSPN^[28]验证了人工属性监督对少样本SAR分类的促进作用,VSC-Net^[27]进一步表明包含部件和功能信息的详细文本描述优于仅使用类别名称的简单语义,Liu等人^[29]研究证明,大语言模型生成的具体类别实体能够补充少样本视觉信息并改善类别原型的代表性。上述研究共同说明,随着语义信息由固定属性向详细文本及类别实体知识扩展,其对少样本类别表征的辅助能力能够得到增强,这为本文利用大语言模型构建SAR目标类别语义提供了理论和方法依据。

因此,本文采用文本信息对少样本条件下的SAR目标识别任务进行信息补充。为获取能够有效弥补视觉特征缺失的具备可靠性与针对性的文本信息,本文设计了一种基于“生成-编码-筛选”三阶段的SAR目标文本信息构建方法,并结合大语言模型的生成能力与标准化筛选机制,实现目标文本描述的精准构建,再通过对语言-图像预训练模型的文本编码模块对上述文本进行编码,旨在提取高质量的目标语义信息。

在“生成”阶段,本文采用ChatGPT-4生成多组候选文本描述。依托大规模预训练所获得的语

言理解与知识表征能力,ChatGPT-4能够从多个语义维度对目标类别进行描述,并生成具有一定多样性的文本表达,从而丰富目标类别的语义表征。具体实验中,针对每一类目标生成20条候选文本,并在提示词中明确要求模型重点描述目标的外观形态、结构组成及物理属性等具有类别判别性的特征,以降低与识别任务无关的通用语义信息对后续语义建模的影响。然而,大语言模型生成的候选文本仍可能存在语义偏移、类别属性描述不准确以及冗余信息较多等问题,难以直接作为可靠的类别语义先验。为提高候选文本的准确性与类别判别性,本文进一步设计了基于类别先验约束的文本筛选机制,以预先构建的标准文本作为语义筛选基准,通过评价候选文本与各类别标准文本之间的语义一致性,剔除存在明显语义偏差或类别区分能力不足的候选描述,最终获得用于构建类别语义原型的高质量文本集合。

受文献^[28]中先验二进制属性设计的启发,本文在设计标准文本时从二进制属性方向出发,提出一种“增强类内语义一致性、扩大类间语义差异”的筛选机制,旨在使设计的文本既能表现出类别间的可区分性,又包含整个数据集的总体特点,比如在MSTAR数据集中保留作为地面军事目标的特点,充分体现类别之间的关系。以MSTAR数据集中的10类目标为例,人工设计的标准文本如图2所示。

假设第*i*类目标的第*j*条候选文本为 t_i^j ,标准文本为 t_i^s ,通过CLIP的文本编码器 E_t 得到候选文本的语义嵌入 s_i^j 和标准文本的语义嵌入 s_i^s 。表述如下:

$$\begin{aligned} s_i^j &= E_t(t_i^j) \\ s_i^s &= E_t(t_i^s) \end{aligned} \quad i = 1, \dots, M, j = 1, 2, \dots, N \quad (1)$$

BMP2	BTR70	T72	BTR60	2S1
infantry fighting vehicle; tracked armored combat vehicle with dual-side metal tracks; a medium-caliber automatic cannon and a coaxial machine gun mounted on the turret; a square armor layout with a slightly raised top; six pairs of road wheels.	wheeled armored personnel carrier with eight wheels; small turret integrated with a machine gun; a small hatch is respectively arranged between the second and third pairs of wheels on both sides of the hull; amphibious capability and propelled on water by a water-jet propulsor mounted at the rear of the hull.	heavy tank with wide metal tracks for off-road travel; main armament is a large long-barreled cannon, with a coaxial machine gun mounted on the right side of the turret; six road wheels and three carrier wheels on each side	wheeled armored personnel carrier with eight wheels; ring-mounted machine gun rack is installed on the roof; amphibious capability and propelled on water by a water-jet propulsor mounted at the rear of the hull.	tracked self-propelled artillery with dual-sided metal tracks; main armament is a long-barreled howitzer; a turret slightly extending rearward; featuring tank chassis characteristics but primarily for artillery support; seven road wheels on each side.
BRDM2	D7	T62	ZIL131	ZSU234
wheeled armored reconnaissance vehicle with 4×4 drive; two sets of tires at front and rear; a light machine gun mounted on the hull top as main armament with light armor protection; featuring reconnaissance and light defensive characteristics.	tracked bulldozer with dual-side metal track propulsion; a large dozer blade mounted at the front; featuring a tall and sturdy hull structure with the cab positioned centrally and slightly rearward; characterized by engineering machinery traits.	heavy tank with wide metal tracks for off-road travel; main armament is a large long-barreled cannon; a coaxial machine gun mounted on the right side of the turret; five pairs of road wheels.	A 6×6-driven military truck; featuring a angular cab positioned behind a prominent hood; the front of the vehicle is equipped with headlamps and rear-view mirrors; the rear houses a large rectangular cargo compartment.	tracked anti-aircraft combat vehicle with dual -side metal track system; four automatic anti-aircraft guns mounted on the turret as main armament; with a tall profile; featuring tank chassis and anti-aircraft combat characteristics.

图2 MSTAR数据集中各个类别的人工设计标准文本

Fig. 2 Manually Designed Standard Texts for Each Category in the MSTAR Dataset

其中, M 是目标类别的总数量, N 是候选文本的总数量。本文采用CLIP模型中的ViT-B/32文本编码器对目标文本描述进行特征编码, 将语义信息映射为512维语义特征向量, 以实现文本语义信息的语义嵌入表示。

完成候选文本的语义编码后, 进一步进入文本“筛选”阶段。为提高候选语义信息的类别一致性与判别性, 本文遵循“增强类内语义一致性、扩大类间语义差异”的基本原则构建文本筛选准则。具体而言, 该准则一方面衡量候选文本与所属类别标准文本之间的语义一致程度, 以剔除存在明显语义偏差的候选描述; 另一方面考察候选文本与其他类别标准文本之间的语义相关性, 以过滤具有较强跨类别共性、但缺乏类别判别能力的通用描述, 从而保证所保留文本在语义准确性与类别区分性方面具有较高质量。在筛选过程中, 首先计算每条候选文本语义嵌入与所有类别标准文本语义嵌入之间的余弦相似度, 以量化候选文本与不同目标类别之间的语义关联程度。对于第 i 类的第 j 条候选文本, 其与各类别标准文本之间的余弦相似度计算如下:

$$f_i^j = \cos(s_i^j, s_i^s) = \frac{s_i^j \cdot s_i^s}{\|s_i^j\| \|s_i^s\|} \quad i = 1, \dots, M, j = 1, \dots, N \quad (2)$$

根据相似性得分做出如下判断: 若本类候选文本与本类标准文本相似性得分过低, 则认为存在语义偏差; 若与其他类别标准文本相似性得分过高, 则认为是缺乏可区分性的通用描述。所以筛选时, 针对第 i 类的候选文本, 先计算其与所有标准文本的相似性得分并进行排名, 若排名中的前三包含 i 类的标准文本, 则选中该文本。通过这种方式选择的文本既能避免大语言模型文本生成过程中的语义偏差, 又能过滤缺乏可区分性的通用描述, 保证最后得到的语义信息既具有类间可分性又符合数据集的总体特点。通过上述过程, 每个类别选出 K 个文本, 得到第 i 类的文本集合: $t_i^j, j=1, 2, \dots, K$, 对应的语义嵌入集合为 $s_i^j, j=1, 2, \dots, K$ 。

随后, 以 s_i^j 与 s_i^s 的相似性得分 f_i^j 为权重, 联合标准文本进行加权计算, 得到优化后的该类别语义原型 P_s^i , 过程如下:

$$P_s^i = s_i^s + f_i^j \times s_i^j \quad j = 1, 2, \dots, K \quad (3)$$

2.2 关系矩阵引导的视觉特征分布矫正

由于独特的SAR成像机制, SAR图像目标呈现类间相似度高、类内差异大这一现象。在少样本条件下, 该现象更为显著。针对这一问题, 本文利用

类别语义原型之间相对稳定的关系结构对SAR视觉特征空间进行约束, 通过对齐视觉原型与语义原型之间的类别关系, 引导视觉特征学习更有判别性的类间关系, 从而增强不同目标类别的可分性。在此基础上, 借鉴四元组度量学习思想^[30], 设计了动态四元组损失来促进类间分离。

2.2.1 基于关系矩阵的特征对齐

传统度量学习方法通常以样本对或样本组之间的距离约束为优化目标, 侧重于改善特征空间中的局部邻域关系, 而对不同目标类别之间所形成的整体结构关联缺乏显式建模。对于SAR目标而言, 其散射响应对观测方位、俯仰角及目标姿态等因素较为敏感, 少样本条件下获得的视觉特征难以充分表征目标类别之间稳定的结构关系, 容易造成视觉嵌入空间中类别关系失真, 进一步加剧类内离散与类间混叠。

针对上述问题, 本文提出一种语义关系结构引导的视觉特征分布矫正机制。不同于直接约束视觉特征与语义特征之间的点对点一致性, 本文首先在类别原型层面分别构建视觉域与语义域的关系矩阵, 以表征不同目标类别之间的相对结构关联; 随后利用皮尔逊相关系数(Pearson Correlation Coefficient, PCC)度量两个关系矩阵在整体变化趋势上的一致性, 并将其作为跨模态结构约束引入视觉特征学习过程。该机制以相对稳定的类别语义关系作为结构先验, 引导SAR视觉空间保持与语义空间一致的类别相对关系, 从而实现语义知识由“特征级直接匹配”向“关系级结构迁移”的转变, 在降低视觉与文本模态表征差异影响的同时, 对少样本条件下易失真的SAR视觉特征分布进行全局矫正, 增强目标类别之间的结构可分性。

具体而言, SAR目标先通过图像特征提取网络得到图像视觉特征, 对每个类别的图像特征取平均, 得到图像原型集 $P_v^i = \{P_v^{i,1}, P_v^{i,2}, \dots, P_v^{i,M}\}$, 每个类别对应的语义原型集合为 $P_s^i = \{P_s^{i,1}, P_s^{i,2}, \dots, P_s^{i,M}\}$, M 是目标类别数量。然后分别构建图像域和语义域的距离矩阵 $M^v \in R^{m \times m}$ 和 $M^s \in R^{m \times m}$, 用以度量各个类别原型之间的距离。为了消除尺度影响, 采用基于余弦相似性的归一化, 即:

$$M_{ij}^v = 1 - \frac{P_v^i \cdot P_v^j}{\|P_v^i\| \|P_v^j\|} \quad i, j = 1, 2, \dots, M \quad (4)$$

$$M_{ij}^s = 1 - \frac{P_s^i \cdot P_s^j}{\|P_s^i\| \|P_s^j\|}$$

随后, 将距离矩阵的下三角元素展平为向量

m^v 和 m^s 。为了使SAR目标视觉空间的结构关系接近语义先验,本文采用皮尔逊相关系数对齐两个距离矩阵,即最小化如下损失函数^[31]:

$$\mathcal{L}_{\text{RKD}} = 1 - \rho(m^v, m^s) = 1 - \frac{\text{Cov}(m^v, m^s)}{\sigma_{m^v} \sigma_{m^s}} \quad (5)$$

其中, Cov 表示协方差, σ 表示标准差。该损失函数通过约束视觉空间与语义空间中类别间相对关系的一致性,将语义原型所蕴含的类别判别结构迁移至视觉特征空间。具体而言,当类别 i 与类别 j 在语义空间中具有较大的原型间距离、表现出较强的语义可分性时,该约束将引导其对应的视觉原型在特征空间中保持相应的分离趋势,从而增强视觉特征空间对类别间相对结构的保持能力,扩大易混淆目标类别之间的判别边界,并提升SAR目标视觉表征的类间可分性。

2.2.2 基于动态四元组损失的模型优化

上述关系矩阵对齐机制能够从类别级全局结构层面引导SAR视觉特征空间保持与语义空间一致的相对关系,从而改善不同目标类别之间的整体分布。然而,该类全局结构约束主要关注类别原型之间的相对关系,对类内样本分布的紧凑性以及局部易混淆样本之间的判别边界缺乏直接约束。尤其在少样本SAR目标识别场景下,同一类别内部仍可能存在较大的特征离散,因此仅依赖全局关系对齐难以获得具有充分判别性的局部特征分布。为进一步优化视觉特征空间的局部几何结构,本文在关系矩阵约束的基础上引入动态四元组度量学习机制。区别于传统度量学习方法对不同类别统一采用固定边距的策略,本文依据类别原型之间的相对距离自适应调节度量边距,使约束强度能够随不同类别间的特征分布关系动态变化,从而避免固定边距对不同难度类别对实施同等约束所带来的局限。该机制在增强同类样本聚合性的同时,对邻近及易混淆类别施加更具针对性的分离约束,进一步实现类内紧凑性与类间可分性的协同优化。具体而言,所设计的动态四元组损失由动态三元组项和四元组约束项两部分构成。

在某一训练批次中,对于给定第 i 类的样本 x_i , 构建一个四元组 $\{x_i, x_p, x_{n1}, x_{n2}\}$, 其中 x_p 是正样本, x_{n1} 是当前训练批次中距离 x_i 最近的负样本, 而 x_{n2} 是当前训练批次中距离 x_{n1} 最近的负样本。示意图如图3所示。为了应对不同类别间固有的语义距离差异,本文设计了动态边距 α_d 。如果两个类别的原型在特征空间中距离较远,为了保证约束的有效性,促进样本向原型聚集,需要施加更大的边距约束;反之则减小约束。动态边距定义为:




图3 动态四元组损失示意图

Fig. 3 Schematic illustration of the dynamic quadruplet loss

$$\alpha_d(P_i, P_{n1}) = \lambda \cdot \|P_i - P_{n1}\| \quad (6)$$

其中, λ 是超参数, 本文取0.5, 即两个原型距离的中点, 符合度量学习中类内距离小于类间的要求。动态的三元损失表达为:

$$\mathcal{L}_{\text{trip}} = d(x_i, x_p) - d(x_i, x_{n1}) + \alpha_d \quad (7)$$

其中, $d(\cdot, \cdot)$ 表示欧氏距离。

所提方法的总损失函数由两部分组成: 第一部分是引入动态边距的三元组项, 用于推开样本 x_i 与最近负样本; 第二部分是四元组项, 用于约束负样本之间的相对距离, 有助于在特征空间形成更紧凑的簇, 促进类间分离。总损失定义如下:

$$\begin{aligned} \mathcal{L}_{\text{qu}} &= \max(0, d(x_i, x_p) - d(x_{n1}, x_{n2})) \\ \mathcal{L}_{\text{Quad}} &= \mathcal{L}_{\text{qu}} + \mathcal{L}_{\text{trip}} \end{aligned} \quad (8)$$

其中, $\mathcal{L}_{\text{qu}}$ 表示四元组项, $\mathcal{L}_{\text{Quad}}$ 表示完整的四元组损失。

2.2.3 图像分支的分类损失

在SAR图像目标识别网络中, 给定输入图像 x , 首先由特征提取网络将其映射为高维特征向量 f_{vis} ; 随后, 利用全连接层权重矩阵 W_{fc} 对该特征进行线性变换以计算Logits, 输出向量 z_{vis} ; 最后通过 Softmax 函数对其进行归一化处理, 得到目标类别的预测概率分布, 即:

$$\begin{aligned} z_{\text{vis}} &= W_{\text{fc}}^T f_{\text{vis}} + b \\ P_{\text{vis}}(y = k|x) &= \text{Softmax}(z_{\text{vis}}) = \frac{\exp(z_{\text{vis}}^k)}{\sum_j \exp(z_{\text{vis}}^j)} \end{aligned} \quad (9)$$

公式9得到图像分支目标类别的预测概率分布, 之后结合语义分支得到的概率分布进行动态加权, 得到最终的分类结果。两个分支如何进行动态

加权将在后文论述。图像分支的分类损失函数 $\mathcal{L}_{ce}$ 定义为：

$$\mathcal{L}_{ce}^v = -\log \left(\frac{\exp(z_{vis}^k)}{\sum_j \exp(z_{vis}^j)} \right) \quad (10)$$

整合式(5)，(8)以及(10)，视觉特征学习分支的总损失函数 $\mathcal{L}_{total}^v$ 如下：

$$\mathcal{L}_{total}^v = a\mathcal{L}_{RKD} + b\mathcal{L}_{Quad} + c\mathcal{L}_{ce}^v \quad (11)$$

a ， b ， c 为各个损失的权重，在实验时 $a=1$ ， $b=0.02$ ， $c=1$ 。

2.3 基于最优传输的文本原型优化

因为CLIP主要基于大规模自然光学图像—文本对进行预训练，未对SAR成像机理和目标电磁散射特性进行针对性建模，所以本文引入一种基于最优传输(Optimal Transport, OT)^[32]的跨模态特征对齐机制来缓解上述由预训练模态差异引起的语义偏移。该机制以实际SAR样本形成的视觉原型为依据，通过全局传输代价和软匹配关系估计SAR视觉分布与CLIP语义分布之间的对应关系，并将视觉域中的散射判别信息用于校准静态语义原型。与直接要求SAR视觉特征和CLIP文本特征逐点一致相比，原型之间的最优传输允许不同模态保留各自的表征特点，可降低因光学语义与SAR散射机理不一致而产生的错误匹配。与此同时，残差网络保留了原始文本语义中的结构和功能先验，避免了语义原型完全向少样本条件下的视觉原型拟合。

具体而言，首先将得到的视觉特征 $\mathbf{f}_{vis}$ 和目标原型 $\mathbf{P}_v^i$ 通过映射层映射到语义空间，将映射后的视觉特征和目标原型记为 $\mathbf{f}_{vt}$ 和 $\mathbf{P}_{vt}$ ，语义空间的原始语义原型记为 $\mathbf{P}_s$ 。然后，计算映射后的视觉原型 $\mathbf{P}_{vt}$ 与原始语义原型 $\mathbf{P}_s$ 之间的成对距离。为了消除尺度影响，采用余弦距离作为传输代价，代价矩阵 $\mathbf{C}_{ij} \in R^{n \times n}$ 定义为：

$$C_{ij} = 1 - \cos(\mathbf{P}_{vt}^i, \mathbf{P}_s^j) = 1 - \frac{\mathbf{P}_{vt}^i \cdot \mathbf{P}_s^j}{\|\mathbf{P}_{vt}^i\| \|\mathbf{P}_s^j\|}, \quad i, j = 1, 2, \dots, M \quad (12)$$

其中， M 表示类别的数量。

接着，通过Sinkhorn算法^[33]计算得到最优传输矩阵 $\mathbf{T}^*$ ，利用该传输矩阵对原始目标原型 $\mathbf{P}_{vt}$ 进行加权重新组合，使其在特征空间结构上与文本原型达到高度对齐，即：

$$\mathbf{P}_{aligned}^{vt} = \mathbf{T}^* \cdot \mathbf{P}_{vt} \quad (13)$$

最后，将新的目标原型通过一个由两个线性层和 ReLU 组成非线性残差网络 F_{res} 来提取语义原型的修正项，以此来修正原语义原型。得到优化后融合了图像特征的语义原型 $\mathbf{P}_{calib}^s$ ，即：

$$\mathbf{P}_{calib}^s = \mathbf{P}_s + F_{res}(\mathbf{P}_{aligned}^{vt}) \quad (14)$$

在优化语义原型的基础上，本文在语义空间中还引入了监督对比损失，旨在避免同类样本原本相似的图像特征因映射而在语义空间中被过度拉开，损失定义如下：

$$\mathcal{L}_{SupCon} = - \sum_{i \in I} \frac{1}{|P(i)|} \cdot \sum_{p \in P(i)} \log \frac{\exp(z_i \cdot z_p / \tau)}{\sum_{a \in A(i)} \exp(z_i \cdot z_a / \tau)} \quad (15)$$

其中， I 表示当前Batch中样本索引的合集， $\mathbf{z}_i$ 表示样本 x 经过投影并归一化后的特征向量， $P(i)$ 表示与样本 x 同属一个类别的正样本合集， $A(i)$ 表示与样本 x 不同类别的其他样本，其中 τ 是温度系数。

与图像分支的分类过程类似，语义分类时首先通过对应的全连接层权重计算Logits，得到输出向量 $\mathbf{z}_s$ ，然后通过 Softmax 归一化得到分类结果，其对应的分类交叉熵损失记为 $\mathcal{L}_{ce}^s$ ，定义如下：

$$\mathcal{L}_{ce}^s = -\log \left(\frac{\exp(z_s^k)}{\sum_j \exp(z_s^j)} \right) \quad (16)$$

语义分支的总损失函数 $\mathcal{L}_{total}^v$ 表述如下：

$$\mathcal{L}_{total}^s = d\mathcal{L}_{SupCon} + e\mathcal{L}_{ce}^s \quad (17)$$

d 和 e 是损失的权重，在训练时 $d=1$ ， $e=1$ 。

2.4 总损失

训练总的损失如下：

$$\mathcal{L}_{total} = p\mathcal{L}_{total}^v + q\mathcal{L}_{total}^s \quad (18)$$

其中， p 和 q 分别表示两项损失函数的权重系数。在小样本场景下，设置 $p=1$ 、 $q=2$ 。由于训练样本数量有限，视觉分支所能提取的有效信息相对不足，因此模型需要更多地依赖语义分支提供的先验信息。随着样本规模的扩大，视觉分支能够获得更加充分且具有判别性的特征表示，因而将权重调整为 $p=1$ 、 $q=1$ ，以增强视觉信息对模型优化过程的贡献，从而获得更优的模型性能。

2.5 动态加权的决策级融合

为了在推理过程中充分利用视觉特征与语义特征，本文采用一种动态置信度加权融合(Dynamic

Confidence-Weighted Fusion, DCWF)策略, 其可基于各分支的实例级置信得分自适应调整对决策结果的贡献权重。

设 Y_v 表示图像分支得到的类预测概率, Y_s 表示语义分支得到的类预测概率。样本的最高置信得分 S_{vis} 和 S_{sem} 计算如下:

$$\begin{aligned} S_{vis} &= \max(Y_v) \\ S_{sem} &= \max(Y_s) \end{aligned} \quad (19)$$

为了自适应地融合不同分支的预测结果, 本文通过归一化过程计算动态融合权重。该过程可确保权重之和为1, 在赋予高置信度分支更大决策比重的同时, 有效保留低置信度分支的补充信息:

$$\begin{aligned} \mu &= \frac{S_{vis}}{S_{vis} + S_{sem}} \\ \eta &= \frac{S_{sem}}{S_{vis} + S_{sem}} \end{aligned} \quad (20)$$

最终的分类决策通过图像与语义两个分支预测概率的加权线性融合得出:

$$\begin{aligned} Y_{final} &= \mu \cdot Y_v + \eta \cdot Y_s \\ \hat{y} &= \arg \max(Y_{final}) \end{aligned} \quad (21)$$

其中, $\hat{y}$ 表示样本的类别预测标签, $\arg \max(\cdot)$ 操作用于提取概率向量中最大值所在的维度索引, 并将其映射为最终预测概率最高的类别标签。

3 实验结果与分析


3.1 数据集与实验设置

为验证本文所提方法的有效性, 本文采用MSTAR数据集^[34]和OpenSARShip数据集^[35]开展了多组性能分析实验。MSTAR数据集由美国国防高级研究计划局和空军研究实验室资助, 由美国桑迪亚国家实验室采集, 是SAR图像目标检测与识别算法性能评估的基准数据集, 共涵盖10类地面军事目标, 每类目标均包含不同方位、俯仰角下的SAR图像, 其光学图像和相应的SAR图像如图4所示。

参照文献^[36-38], 本文设计了两个实验一是标准数据集(SOC), 选取俯仰角17°的图像作为训练集, 俯仰角15°的图像作为测试集, 数据集的具体配置详见表1; 二是MSTAR的EOC-1扩展工作条件数据集, 数据集选取俯仰角17°的图像作为训练集, 俯仰角30°的图像作为测试集, 数据集的具体配置详见表2。

OpenSARShip数据集是专为SAR图像船舶目标识别算法评估公开大型基准数据集, 其光学图像和相应的SAR图像如图5所示。OpenSARShip数据集利用Sentinel-1卫星遥感影像与自动识别系统信号进行时空双模态精准对齐, 提供了兼具高置信度物理标签与多极化特征的船舶切片。数据集的具体配置见表3, 本文选取其中最常见的三个类别(散货船、集装箱船和油罐船)开展性能分析实验。

本文所提方法训练时采用自适应矩估计(Adaptive Moment Estimation, Adam)优化算法。所有评估实验均在配备NVIDIA GeForce RTX 3090 Ti GPU的服务器上进行。遵循SAR目标识别的常规预处理方式^[39], 本文首先将图像中心裁剪至72×72像素以消除背景杂波干扰。接着, 为增加少样本场景下的数据多样性, 进一步对图像进行64×64像素的随机裁剪。在模型训练过程中, 批量大小(batch size)设置为64, 学习率设置为0.0001, 最大训练轮数设置为5000。为降低随机初始化及样本随机采样对实验结果的影响, 每组实验在10个不同随机种子(1111、2222、3333、3366、4444、5555、6666、7777、8888、9999)下独立重复运行, 并对所得结果取平均。此外, 在基于最优传输的语义原型优化过程中, Sinkhorn正则系数为0.05, 最大迭代次数为20次。在模型训练过程中, 视觉分支与语义分支对应损失项的权重分别设置为1和2。对于MSTAR扩展工作条件(EOC)数据集和OpenSARShip数据集, 当每类训练样本数超过60时, 将语义分支的损失权重由2调整为1。



注: BTR70、BTR60为苏联装甲运输车; 2S1为苏联自行榴弹炮; BRDM2为苏联装甲侦察车; BMP2为苏联步兵战车; ZIL131为苏联卡车;

T62、T72为苏联主战坦克; D7为美国推土机; ZSU23/4为苏联自行高射炮。

图4 MSTAR数据集中地面军事目标的光学图像及相应的SAR图像

Fig. 4 Optical images and corresponding SAR images of ground military targets in the MSTAR dataset

3.2 算法识别性能对比分析


本文所提出方法在MSTAR SOC 数据集上的

表 1 MSTAR SOC数据集的详细设置
Tab. 1 Detailed setting of MSTAR SOC dataset

类别	训练样本(17°)	测试样本(15°)
BMP2	233(9563)	192(9563)
BTR70	233	196
T72	233(132)	196(132)
BTR60	255	195
2S1	299	274
BRDM2	298	274
D7	299	274
T62	299	273
ZIL131	299	274
ZSU23/4	299	274

表 2 MSTAR EOC-1数据集的详细设置
Tab. 2 Detailed setting of MSTAR EOC-1 dataset

类别	训练样本(17°)	测试样本(30°)
2S1	299	288
BRDM2	298	287
T72	233(132)	288(132)
ZSU23/4	299	288



注：Bulk Carrier为散货船；Container ship为集装箱船；Tanker为油罐船。

图 5 OpenSARShip数据集中船舶目标的光学图像及相应的 SAR图像

Fig. 5 Optical images and corresponding SAR images of target ships in the OpenSARShip dataset

识别性能如表4和表5所示。由表中结果可知，在少样本条件下，当各类别的训练样本数超过20个后，本文方法即可达到94%以上的高精度识别。因为BTR60与BTR70在文本语义中均具有“八轮”“装甲运输”和“两栖”等共同属性，因此二者的语义原型距离相对较近。但在极少样本条件下，可用于构造有效困难样本组合的视觉信息仍然有限。随着样本数量增加，视觉原型和困难样本距离估计更加可靠，关系级全局约束与四元组局部约束的互补作用得到充分发挥，因此BMP2、BTR60和BTR70等易混淆类别获得了更明显的性能提升。表4和表5中的综合指标进一步反映了类别识别性能逐渐均衡的趋势。5-shot条件下，总体准确率为73.06%，而宏平均召回率和F1值分别为71.72%和71.37%，说明总体准确率受到高识别率类别的贡献，而BMP2、BTR60和BTR70等困难类别降低了宏平均指标。随着样本数量增加至50，总体准确率、宏平均召回率和F1值分别达到98.52%、98.32%和98.33%，三者之间的差距明显缩小，表明所提方法在提高总体性能的同时，也逐渐改善了不同类别之间的识别均衡性。

在MSTAR EOC-1数据集上的识别性能如表6和表7所示，当每类训练样本数量达到20个时，本文方法的平均识别准确率已超过91%。尽管受训练集与测试集俯仰角差异的影响，其识别性能较标准工作条件下略有下降，但总体仍保持较高水平。该结果表明，引入语义先验能够在一定程度上缓解俯仰角变化引起的目标投影结构及散射特征偏移，从而增强模型在扩展工作条件下的识别能力和泛化性能。

表 3 OpenSARShip数据集的详细设置
Tab. 3 Detailed setting of OpenSARShip dataset

类别	训练样本	测试样本
Bulk Carrier	120	218
Container ship	120	218
Tanker	120	218

表 4 MSTAR SOC 数据集上不同样本数量下各类的识别准确率
Tab. 4 Recognition Accuracy of Each Class with Different Sample Sizes on MSTAR SOC

Class	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23/4	Average
5shot	67.63	51.79	81.06	56.43	51.85	80.69	78.28	85.66	76.57	87.26	73.06
10shot	84.89	70.41	94.12	69.34	74.05	90.26	94.18	92.14	90.22	95.44	86.67
20shot	92.59	87.38	98.61	89.59	84.87	97.30	98.17	94.49	97.12	98.50	94.48
30shot	96.13	91.69	98.54	94.74	89.44	98.58	98.64	98.37	98.54	99.31	96.77
40shot	97.77	94.26	99.34	95.92	93.03	99.64	99.45	99.34	98.83	99.67	98.00
50shot	98.50	95.85	99.64	97.55	94.10	99.49	99.30	99.49	99.60	99.67	98.52

在OpenSARShip数据集上的识别性能如表8和表9所示。由表中的实验结果可以看到,在各类别目标样本数量为20时,本文所提方法可达到71.30%的识别精度,在每类目标只有120个样本的场景中,本文所提方法在OpenSARShip数据集上所有目标的平均识别精度可高达78.93%。

为了全面评估所提方法的优势,本文选取了一些近年来具有代表性的主流 SAR ATR 模型作为对比方法。在MSTAR数据集上的对比方法包括:基于半监督学习框架的分类网络(Semisupervised)^[40]、结合方位角作为物理先验知识的分类网络(Probability-Designed Network, PD Net)^[41]、结合电磁模拟与跨子域特征对齐的双分支重构网络(Dual-Branch

image reconstruction and Subdomain Alignment, DBRSA)^[42]、引入密集块的胶囊网络(Dense Capsule Network, Dens-CapsNet)^[43]、以及多级结构化散射特征融合网络(Multi-level Structured scattering Feature Fusion Network, MSF-Net)^[44]、为进一步分析语义信息对SAR目标识别的作用,本文引入RemoteCLIP^[45]和GeoRSCLIP^[46]作为对比方法。表中两种方法的实验结果引自王君宇等人^[47]的综述文献,均采用完整的MSTAR-SOC训练集。RemoteCLIP和GeoRSCLIP在MSTAR数据集上的识别性能相对有限,主要原因在于其预训练数据以自然图像和光学遥感图像为主,尚未充分建立SAR散射特征与类别语义之间的对应关系。综合对比实验结果如表10所示。

在OpenSARShip数据集上的对比方法包括:结合改进盲点的Swin Transformer用于分类的网络(Swin Transformer with improved Blind-Spot network,STr-BS)^[48]、同样引入语义信息进行数据增强的网络(Semantic Data Augmentation Transformer,SDA-Tr)^[49]、基于半监督学习框架的分类网络(Supervised)^[40]、融合 CNN 特征嵌入与度量学习的分类方法(CNN+Matrix)^[50]、以及利用半监督策略挖掘无标签数据信息的遥感分类网络(Unsupervised Data Augmentation-Absolute Log-Likeli-

表 5 MSTAR SOC数据集上不同样本数量下的

F1、acc、recall、precision

Tab. 5 F1 Score, accuracy, recall, and precision under different sample sizes on the MSTAR SOC Dataset

样本数	F1	acc	recall	precision
5shot	71.37	73.06	71.72	73.18
10shot	85.40	86.67	85.50	86.25
20shot	93.84	94.48	93.86	93.97
30shot	96.41	96.77	96.40	96.52
40shot	97.74	98.00	97.72	97.79
50shot	98.33	98.52	98.32	98.38

表 6 MSTAR EOC-1数据集上不同样本数量下各类的识别准确率

Tab. 6 Recognition accuracy of each class with different sample sizes on MSTAR EOC-1

Class	2S1	BRDM2	T72	ZSU23/4	Average
10shot	96.08	92.13	79.90	71.98	85.01
20shot	98.19	93.34	90.42	82.99	91.23
40shot	98.75	95.99	93.61	84.72	93.27
60shot	99.13	96.27	94.41	89.93	94.93
80shot	99.10	96.93	94.44	91.84	95.58
100shot	99.10	97.28	95.14	93.26	96.19

表 7 MSTAR EOC-1数据集上不同样本数量下的

F1、acc、recall、precision

Tab. 7 F1 score, accuracy, recall, and precision under different sample sizes on the MSTAR EOC-1 Dataset

样本数	F1	acc	recall	precision
10shot	84.84	85.01	85.02	86.40
20shot	91.23	91.23	91.24	91.97
40shot	93.27	93.27	93.27	93.79
60shot	94.95	94.93	94.94	95.24
80shot	95.58	95.58	95.58	95.76
100shot	96.21	96.19	96.20	96.38

表 8 OpenSARShip数据集上不同样本数量下各类的识别准确率

Tab. 8 Recognition accuracy of each class with different sample sizes on OpenSARShip

Class	Bulk Carrier	Container ship	Tanker	Average
20shot	71.93	65.00	76.97	71.30
40shot	73.99	69.68	80.60	74.76
50shot	74.72	71.47	81.01	75.73
80shot	77.75	73.94	81.65	77.78
100shot	79.08	74.72	81.15	78.32
120shot	78.85	76.97	80.96	78.93

表 9 OpenSARShip数据集上不同样本数量下的

F1、acc、recall、precision

Tab. 9 F1 Score, accuracy, recall, and precision under different sample sizes on the OpenSARShip Dataset

样本数	F1	acc	recall	precision
20shot	71.25	71.30	71.30	72.04
40shot	74.68	74.76	74.76	75.02
50shot	75.73	75.73	75.73	75.93
80shot	77.77	77.78	77.78	77.91
100shot	78.33	78.32	78.32	78.51
120shot	78.95	78.93	78.93	79.11

表 10 MSTAR 数据集上的对比实验结果
Tab. 10 Comparative Experimental Results in MSTAR

Method	Semisupervised	PD Net	DBRSA	Dens-CapsNet	MSF-Net	RemoteCLIP	GeoRSCLIP	Ours
10shot	80.88	83.73	77.36	80.26	65.54	-	-	86.67
20shot	92.62	93.00	-	92.95	85.48	-	-	94.48
30shot	-	94.63	92.45	94.56	87.05	-	-	96.77
40shot	97.11	-	-	96.50	-	-	-	98.00
50shot	-	-	97.58	97.61	-	69.97(total)	76.00(total)	98.52

注：表内加粗数值表示相同样本条件下的最高识别精度

hood Estimation, UDA-ALE)^[51]，对比实验结果如表11所示。

从表4-表9的实验结果可以看出，本文所提方法在MSTAR的标准集和拓展集，以及OpenSARShip数据集上的不同样本量设置下均取得了最优的识别性能。特别是在样本数量极少的情况下，本文所提方法性能优势明显。在MSTAR数据集的每类目标10个样本条件下，本文所提方法的识别精度达到86.67%，比次优的识别方法高出2.94%。在OpenSARShip数据集的每类目标20个样本条件下，本文所提方法的识别精度达到71.30%，比次优方法高出9.42%。上述结果充分表明，本文所提方法通过引入高质量的语义先验信息有效改善了少样本条件下SAR图像目标表征的鉴别性，显著增强了识别模型在少样本SAR场景下的泛化能力与识别鲁棒性。

3.3 文本筛选模块有效性分析实验

为了验证本文所提文本筛选准则的有效性，本节针对该模块设计了有效性分析实验。为保证控制变量一致，各对比方法均沿用本文设计的网络架构，仅在用于语义特征编码的文本构建方式上有所不同。具体而言，实验采用了两种对比方法：一是采用传统的人工设计文本方法，即仅依赖本文中人为设计的标准文本；二是采用未经过滤的大模型生成文本，即随机抽取与本文方法等量的大模型生成文本，不进行任何筛选。两种对比方法得到的文本都会通过CLIP进行嵌入编码并求均值以构建文本原型。实验结果如表12所示。

由表12中的实验结果可以看出，本文提出的文本筛选准则取得了最优的识别性能，而仅依赖传统人工设计文本的方法表现最差。引入大语言模型生成文本的方案在识别精度上显著优于人工设计的文本，可以证明大语言模型生成的文本确实具有更强的特征概括性与类别区分度。此外，经过本文所提准则筛选的语义编码方案，其准确率超越了随机文本的对比方法，这证明本文所提筛选准则的有效

表 11 OpenSARShip 数据集上的对比实验结果
Tab. 11 Comparative Experimental Results in OpenSARShip

Method	Number of training samples		
	1-49	50-99	100-120
SDA-Tr	-	-	68.87(100)
STr-BS	-	-	68.56(100)
Semisupervised	61.88(20)	68.67(80)	71.29(120)
	64.73(40)		
CNN+Matrix	-	72.86(50)	75.31(100)
UDA-ALE	-	73.75(50)	76.25(100)
Ours	71.30(20)	75.73(50)	78.32(100)
	74.76(40)	77.78(80)	78.93(120)

注：表内加粗数值表示相同样本条件下的最高识别精度

表 12 不同文本策略的识别准确率对比
Tab. 12 Recognition Accuracy with Different Text Strategies

Strategies	随机文本	传统文本	筛选文本
5shot	71.18	70.93	73.06
10shot	85.65	85.28	86.67
20shot	94.52	94.31	94.48
30shot	96.12	95.92	96.77

注：表内加粗数值表示相同样本条件下的最高识别精度

性，即通过该准则确实能够挖掘出更具鉴别力、更适合辅助SAR目标识别的高质量语义信息。

本节针对文本数量(超参数 K)的选择进行了实验，实验中 K 依次设置为2, 3, 4，实验结果如表13所示。从实验可以看到，当筛选保留的文本数量为3时，模型得到了最佳的实验结果。从理论层面来看，出现这样结果的原因在于：一方面，当文本数量较少时，所提取的语义信息不足以全面刻画各目标类别的特有属性，语义信息的表征仍存在完善空间；另一方面，当文本数量过多时，部分通用的冗余描述混入了类别特有的特征空间中，降低了各个类别间语义信息的区分性，导致性能下降。图6给出了文本数量不同时各个类别间语义原型的矩阵，可以看到在文本数量为3时，各个语义原型之间的区分性最大。

表 13 不同文本数量的实验结果对比
Tab. 13 Experimental results with different text counts

样本数	K=2	K=3	K=4
5shot	70.79	73.06	70.64
10shot	85.05	86.67	85.05
20shot	93.80	94.48	93.67

注：表内加粗数值表示相同样本条件下的最高识别精度

3.4 消融实验

为了深入分析所提方法中各关键模块在少样本条件下对目标识别性能的贡献，本节在MSTAR数据集上每类样本数量为5, 10, 20条件下开展消融实验。

由表14中实验结果可知，从单模块结果看，关系对齐分别带来24.91%, 21.06%和11.89%的性能提升，说明语义原型所蕴含的类别关系可以为视觉空间提供相对稳定的全局结构先验，降低有限样本造

成的类别拓扑失真。单独引入四元组损失后，准确率分别提高27.19%, 24.52%和13.95%，因为四元组损失直接约束同类样本与困难负样本之间的相对距离，能够同时增强类内聚合性和类间可分性，对少样本条件下局部类别边界模糊的问题具有直接改善作用。单独引入最优传输后，准确率分别提高25.53%, 21.66%和11.93%，说明根据SAR视觉原型分布对CLIP语义原型进行自适应校准，可以有效降低光学图文预训练语义与SAR电磁散射表征之间的模式偏差。

关系对齐与四元组损失联合使用时，准确率达到69.86%, 85.13%和93.78%，高于任一单独模块。二者分别从全局类别关系和局部样本几何两个层面对视觉特征空间进行约束：关系对齐保持不同类别之间的整体相对结构，四元组损失则进一步优化类内紧凑性及困难类别之间的局部边界。二者具有一定互补性。




图 6 不同文本数量下的关系矩阵
Fig. 6 Relation Matrix for Different Text Counts

表 14 消融实验结果
Tab. 14 Ablation Results

关系对齐	四元损失	最优传输	动态加权	5shot	10shot	20shot
纯四层CNN网络				40.74	59.67	79.63
✓				65.65	80.73	91.52
	✓			67.93	84.19	93.58
		✓		66.27	81.33	91.56
✓	✓			69.86	85.13	93.78
✓		✓	✓	72.89	85.82	94.11
	✓	✓	✓	72.87	85.85	94.26
✓	✓	✓		73.00	86.34	94.42
P	P	P	P	73.06	86.67	94.48

注：表内加粗数值表示相同样本条件下的最高识别精度，P说明网络中包含该模块

在关系对齐和四元组损失的基础上进一步引入最优传输后, 识别效果提升, 该增益在5-shot条件下最明显, 这是因为极少样本形成的视觉原型具有较大估计偏差, 静态CLIP语义原型与动态视觉表征之间的跨模态偏移也更加突出。最优传输通过建立视觉原型分布与语义原型分布之间的全局软匹配关系, 将SAR视觉判别信息用于校准语义原型, 使语义分支能够更好地适应实际SAR数据分布。

完整模型在全部样本设置下均取得最高准确率, 验证了4个模块在特征结构优化、跨模态对齐和分类决策层面的分工及互补关系。

4 结语

本文聚焦于少样本SAR目标识别这一极具挑战性的任务, 提出了一种视觉-语义特征协同学习的目标识别框架。本文的创新点包括两方面。一方面, 针对信息缺失的痛点, 本文利用大语言模型设计了“生成-编码-筛选”文本处理机制, 在标准文本的约束下, 利用LLM扩展候选描述并构建语义先验, 辅助SAR图像视觉特征进行目标类别判定。另一方面, 构建了视觉-语义特征协同学习架构, 充分利用了图像与语义特征的互补优势提升少样本条件下目标识别精度。在MSTAR数据集和 OpenSARShip 数据集上的一系列评估实验证明了所提方法在少样本条件SAR目标识别任务上的有效性与先进性。当前方法也存在一定的局限性, 不能在完全没有类别描述和训练样本的条件下直接识别未知型号或新类别。面向未知型号和新类别, 未来将研究基于开放词汇语义原型、未知类检测及增量原型更新的方法, 以减少对逐类别人工属性描述的依赖。

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] 孙浩, 陈进, 雷琳, 等. 深度卷积神经网络图像识别模型对抗鲁棒性技术综述[J]. 雷达学报, 2021, 10(4): 571–594. doi: [10.12000/JR21048](#).
Sun Hao, Chen Jin, Lei Lin, *et al.* Adversarial robustness of deep convolutional neural network-based image recognition models: A review[J]. *Journal of Radars*, 2021, 10(4): 571–594. doi: [10.12000/JR21048](#).
- [2] 郭炜炜, 张增辉, 郁文贤, 等. SAR图像目标识别的可解释性问题探讨[J]. 雷达学报, 2020, 9(3): 462–476. doi: [10.12000/JR20059](#).
Guo Weiwei, Zhang Zenghui, Yu Wenxian, *et al.* Perspective on explainable SAR target recognition[J]. *Journal of Radars*, 2020, 9(3): 462–476. doi: [10.12000/JR20059](#).
- [3] Kechagias-Stamatis O and Aouf N. Automatic target recognition on synthetic aperture radar imagery: A survey[J]. *IEEE Aerospace and Electronic Systems Magazine*, 2021, 36(3): 56–81. doi: [10.1109/MAES.2021.3049857](#).
- [4] Novak L M, Owirka G J, Brower W S, *et al.* The automatic target-recognition system in SAIP[J]. *The Lincoln Laboratory Journal*, 1997, 10(2): 187–202.
- [5] Diemunsch J R and Wissinger J. Moving and stationary target acquisition and recognition (MSTAR) model-based automatic target recognition: Search technology for a robust ATR[C]. SPIE 3370, Algorithms for Synthetic Aperture Radar Imagery V, Orlando, USA, 1998: 481–492. doi: [10.1117/12.321851](#).
- [6] WANG Zhaocheng, DU Lan, ZHANG Peng, *et al.* Visual attention-based target detection and discrimination for high-resolution SAR images in complex scenes[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(4): 1855–1872. doi: [10.1109/TGRS.2017.2769045](#).
- [7] DONG Ganggang, KUANG Gangyao, WANG Na, *et al.* Classification via sparse representation of steerable wavelet frames on Grassmann manifold: Application to target recognition in SAR image[J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2892–2904. doi: [10.1109/TIP.2017.2692524](#).
- [8] LI Tingli and DU Lan. SAR automatic target recognition based on attribute scattering center model and discriminative dictionary learning[J]. *IEEE Sensors Journal*, 2019, 19(12): 4598–4611. doi: [10.1109/JSEN.2019.2901050](#).
- [9] ZHANG Yukun, GUO Xiansheng, LEUNG H, *et al.* Cross-task and cross-domain SAR target recognition: A meta-transfer learning approach[J]. *Pattern Recognition*, 2023, 138: 109402. doi: [10.1016/j.patcog.2023.109402](#).
- [10] 徐丰, 王海鹏, 金亚秋. 深度学习在SAR目标识别与地物分类中的应用[J]. 雷达学报, 2017, 6(2): 136–148. doi: [10.12000/JR16130](#).
Xu Feng, Wang Haipeng, and Jin Yaqiu. Deep learning as applied in SAR target recognition and terrain classification[J]. *Journal of Radars*, 2017, 6(2): 136–148. doi: [10.12000/JR16130](#).
- [11] 黄钟铃, 姚西文, 韩军伟. 面向SAR图像解译的物理可解释深度学习技术进展与探讨[J]. 雷达学报, 2022, 11(1): 107–125. doi: [10.12000/JR21165](#).
Huang Zhongling, Yao Xiwen, and Han Junwei. Progress and perspective on physically explainable deep learning for synthetic aperture radar image interpretation[J]. *Journal of*

- Radars*, 2022, 11(1): 107–125. doi: [10.12000/JR21165](https://doi.org/10.12000/JR21165).
- [12] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395–411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
Wang Jun, Zheng Tong, Lei Peng, *et al.* Study on deep learning in radar[J]. *Journal of Radars*, 2018, 7(4): 395–411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
- [13] Kechagias-Stamatis O and Aouf N. Fusing deep learning and sparse coding for SAR ATR[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2019, 55(2): 785–797. doi: [10.1109/TAES.2018.2864809](https://doi.org/10.1109/TAES.2018.2864809).
- [14] REN Haohao, YU Xuelian, ZOU Lin, *et al.* Extended convolutional capsule network with application on SAR automatic target recognition[J]. *Signal Processing*, 2021, 183: 108021. doi: [10.1016/j.sigpro.2021.108021](https://doi.org/10.1016/j.sigpro.2021.108021).
- [15] DONG Ganggang and LIU Hongwei. A hierarchical receptive network oriented to target recognition in SAR images[J]. *Pattern Recognition*, 2022, 126: 108558. doi: [10.1016/j.patcog.2022.108558](https://doi.org/10.1016/j.patcog.2022.108558).
- [16] PEI Hao, SU Mingjie, XU Gang, *et al.* Self-supervised feature representation for SAR image target classification using contrastive learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 9246–9258. doi: [10.1109/JSTARS.2023.3321769](https://doi.org/10.1109/JSTARS.2023.3321769).
- [17] 吕艺璇, 王智睿, 王佩瑾, 等. 基于散射信息和元学习的SAR图像飞机目标识别[J]. 雷达学报, 2022, 11(4): 652–665. doi: [10.12000/JR22044](https://doi.org/10.12000/JR22044).
Lyu Yixuan, Wang Zhirui, Wang Peijin, *et al.* Scattering information and meta-learning based SAR images interpretation for aircraft target recognition[J]. *Journal of Radars*, 2022, 11(4): 652–665. doi: [10.12000/JR22044](https://doi.org/10.12000/JR22044).
- [18] Xie Yiyuan, Ferraioli G, Pascazio V, *et al.* Attributed scattering center characteristic extraction with deep learning[C]. 2024 *IEEE International Geoscience and Remote Sensing Symposium*, Athens, Greece, 2024: 7444–7447. doi: [10.1109/IGARSS53475.2024.10641471](https://doi.org/10.1109/IGARSS53475.2024.10641471).
- [19] ZENG Zhiqiang, TAN Xiaoheng, ZHANG Xin, *et al.* ATGAN: A SAR target image generation method for automatic target recognition[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 6290–6307. doi: [10.1109/JSTARS.2024.3370185](https://doi.org/10.1109/JSTARS.2024.3370185).
- [20] LI Jianwei, YU Zhentao, YU Lu, *et al.* A comprehensive survey on SAR ATR in deep-learning era[J]. *Remote Sensing*, 2023, 15(5): 1454. doi: [10.3390/rs15051454](https://doi.org/10.3390/rs15051454).
- [21] GAO Gui, DAI Yuxi, ZHANG Xi, *et al.* ADCG: A cross-modality domain transfer learning method for synthetic aperture radar in ship automatic target recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5109114. doi: [10.1109/TGRS.2023.3313204](https://doi.org/10.1109/TGRS.2023.3313204).
- [22] YANG Xinpeng, JIAO Lianmeng, and PAN Quan. Transfer adaptation learning for target recognition in SAR images: A survey[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 13577–13601. doi: [10.1109/JSTARS.2024.3434448](https://doi.org/10.1109/JSTARS.2024.3434448).
- [23] CHEN Sizhe, WANG Haipeng, XU Feng, *et al.* Target classification using the deep convolutional networks for SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4806–4817. doi: [10.1109/TGRS.2016.25517207](https://doi.org/10.1109/TGRS.2016.25517207).
- [24] WANG Siyuan, WANG Yinghua, ZHANG Xiaoting, *et al.* Visual-semantic cooperative learning for few-shot SAR target classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 6532–6550. doi: [10.1109/JSTARS.2025.3530442](https://doi.org/10.1109/JSTARS.2025.3530442).
- [25] Yan Kaijia, SUN Yuchuang, and LI Wangzhe. Feature generation-aided zero-shot fast SAR target recognition with semantic attributes[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 4006805. doi: [10.1109/LGRS.2024.3380202](https://doi.org/10.1109/LGRS.2024.3380202).
- [26] Cai Hecheng, Liu Yang, Huang Shudong, *et al.* With a little help from language: Semantic enhanced visual prototype framework for few-shot learning[C]. The 33rd International Joint Conference on Artificial Intelligence, Jeju, Korea, 2024: 415. doi: [10.24963/ijcai.2024/415](https://doi.org/10.24963/ijcai.2024/415).
- [27] ZHANG Linbin, LENG Xiangguang, FENG Sijia, *et al.* Domain knowledge powered two-stream deep network for few-shot SAR vehicle recognition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5215315. doi: [10.1109/TGRS.2021.3116349](https://doi.org/10.1109/TGRS.2021.3116349).
- [28] WANG Siyuan, WANG Yinghua, LIU Hongwei, *et al.* Attribute-guided multi-scale prototypical network for few-shot SAR target classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 12224–12245. doi: [10.1109/JSTARS.2021.3126688](https://doi.org/10.1109/JSTARS.2021.3126688).
- [29] Liu Mushui, Wu Fangtai, Li Bozheng, *et al.* Envisioning class entity reasoning by large language models for few-shot learning[C]. The 39th AAAI Conference on Artificial Intelligence, Philadelphia, USA, 2025: 18906–18914. doi: [10.1609/aaai.v39i18.34081](https://doi.org/10.1609/aaai.v39i18.34081).
- [30] CHEN Weihua, CHEN Xiaotang, ZHANG Jianguo, *et al.* Beyond triplet loss: A deep quadruplet network for person re-identification[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 2017: 1320–1329. doi: [10.1109/CVPR.2017.145](https://doi.org/10.1109/CVPR.2017.145).
- [31] Ramakrishnan K, Panda R, Fan Quanfu, *et al.* Relationship matters: Relation guided knowledge transfer for incremental learning of object detectors[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, USA, 2020: 1009–1018. doi: [10.1109/CVPRW](https://doi.org/10.1109/CVPRW)

- 50498.2020.00133.
- [32] Wang Xinlin, LIU Baozhu, GOU Shuiping, *et al.* Cross-modal transformer and optimal transport for SAR-optical image matching[C]. 2025 IEEE International Geoscience and Remote Sensing Symposium, Brisbane, Australia, 2025: 3034–3038. doi: [10.1109/IGARSS55030.2025.11244042](https://doi.org/10.1109/IGARSS55030.2025.11244042).
- [33] Cuturi M. Sinkhorn distances: Lightspeed computation of optimal transport[C]. The 27th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2013: 2292–2300.
- [34] Keydel E R, Lee S W, and Moore J T. MSTAR extended operating conditions: A tutorial[C]. SPIE 2757: Algorithms for Synthetic Aperture Radar Imagery III, Orlando, USA, 1996: 228–242. doi: [10.1117/12.242059](https://doi.org/10.1117/12.242059).
- [35] HUANG Lanqing, LIU Bin, LI Boying, *et al.* OpenSARShip: A dataset dedicated to Sentinel-1 ship interpretation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(1): 195–208. doi: [10.1109/JSTARS.2017.2755672](https://doi.org/10.1109/JSTARS.2017.2755672).
- [36] 喻玲娟, 王亚东, 谢晓春, 等. 基于FCNN和ICAE的SAR图像目标识别方法[J]. 雷达学报, 2018, 7(5): 622–631. doi: [10.12000/JR18066](https://doi.org/10.12000/JR18066).
- Yu Lingjuan, Wang Yadong, Xie Xiaochun, *et al.* SAR ATR based on FCNN and ICAE[J]. *Journal of Radars*, 2018, 7(5): 622–631. doi: [10.12000/JR18066](https://doi.org/10.12000/JR18066).
- [37] XU Yanjie, SUN Hao, ZHAO Yan, *et al.* Simulated data feature guided evolution and distillation for incremental SAR ATR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5215917. doi: [10.1109/TGRS.2024.3419794](https://doi.org/10.1109/TGRS.2024.3419794).
- [38] WANG Chenwei, HUANG Yulin, LIU Xiaoyu, *et al.* Global in local: A convolutional transformer for SAR ATR FSL[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4509605. doi: [10.1109/LGRS.2022.3183467](https://doi.org/10.1109/LGRS.2022.3183467).
- [39] DING Jun, CHEN Bo, LIU Hongwei, *et al.* Convolutional neural network with data augmentation for SAR target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 364–368. doi: [10.1109/LGRS.2015.2513754](https://doi.org/10.1109/LGRS.2015.2513754).
- [40] WANG Chen, SHI Jun, ZHOU Yuanyuan, *et al.* Semisupervised learning-based SAR ATR via self-consistent augmentation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(6): 4862–4873. doi: [10.1109/TGRS.2020.3013968](https://doi.org/10.1109/TGRS.2020.3013968).
- [41] ZHANG Linbin, LENG Xiangguang, FENG Sijia, *et al.* Optimal azimuth angle selection for limited SAR vehicle target recognition[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 128: 103707. doi: [10.1016/j.jag.2024.103707](https://doi.org/10.1016/j.jag.2024.103707).
- [42] LV Xiaoling, QIU Xiaolan, YU Wenming, *et al.* Simulation-aided SAR target classification via dual-branch reconstruction and subdomain alignment[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5214414. doi: [10.1109/TGRS.2023.3305094](https://doi.org/10.1109/TGRS.2023.3305094).
- [43] WANG Quan, XU Haixia, YUAN Liming, *et al.* Dense capsule network for SAR automatic target recognition with limited data[J]. *Remote Sensing Letters*, 2022, 13(6): 533–543. doi: [10.1080/2150704X.2022.2044089](https://doi.org/10.1080/2150704X.2022.2044089).
- [44] ZHAO Chenxi, WANG Daochang, ZHANG Siqian, *et al.* Multi-level structured scattering feature fusion network for limited sample SAR target recognition[J]. *Remote Sensing*, 2025, 17(18): 3186. doi: [10.3390/rs17183186](https://doi.org/10.3390/rs17183186).
- [45] Liu Fan, Chen Delong, Guan Zhangqingyun, *et al.* RemoteCLIP: A vision language foundation model for remote sensing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5622216. doi: [10.1109/TGRS.2024.3390838](https://doi.org/10.1109/TGRS.2024.3390838).
- [46] Zhang Zilun, Zhao Tiancheng, Guo Yulong, *et al.* RS5M and GeoRSCLIP: A large-scale vision-language dataset and a large vision-language model for remote sensing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5642123. doi: [10.1109/TGRS.2024.3449154](https://doi.org/10.1109/TGRS.2024.3449154).
- [47] 王君宇, 孙浩, 黄启灏, 等. 基于视觉语言模型的SAR图像目标解译综述[J]. 雷达学报, 2026, 15(2): 409–440. doi: [10.12000/JR25256](https://doi.org/10.12000/JR25256).
- Wang Junyu, Sun Hao, Huang Qihao, *et al.* SAR image target interpretation based on vision-language model: A survey[J]. *Journal of Radars*, 2026, 15(2): 409–440. doi: [10.12000/JR25256](https://doi.org/10.12000/JR25256).
- [48] HE Xin, CHEN Yushi, HUANG Lingbo, *et al.* Swin Transformer with improved blind-spot network for SAR target classification[C]. 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 7268–7271. doi: [10.1109/IGARSS53475.2024.10642795](https://doi.org/10.1109/IGARSS53475.2024.10642795).
- [49] HE Xin, HAN Xiao, CHEN Yushi, *et al.* Semantic data augmentation for SAR target classification[C]. 2025 IEEE International Geoscience and Remote Sensing Symposium, Brisbane, Australia, 2025: 7698–7701. doi: [10.1109/IGARSS55030.2025.11243790](https://doi.org/10.1109/IGARSS55030.2025.11243790).
- [50] LI Yibing, LI Xiang, SUN Qian, *et al.* SAR image classification using CNN embeddings and metric learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4002305. doi: [10.1109/LGRS.2020.3022435](https://doi.org/10.1109/LGRS.2020.3022435).
- [51] LI Yibing, ZHANG Sitong, LI Xiang, *et al.* Remote sensing image classification with few labeled data using semisupervised learning[J]. *Wireless Communications and Mobile Computing*, 2023, 2023: 7724264. doi: [10.1155/2023/7724264](https://doi.org/10.1155/2023/7724264).

作者简介

任浩浩, 副研究员, 主要研究方向为雷达信号处理, SAR图像解译, 目标检测与识别。

蒋欣妤, 硕士, 主要研究方向为基于深度学习的少样本SAR目标识别。

苗 磊, 博士, 主要研究方向为SAR图像智能解译、SAR目标智能识别。

范利伟, 硕士, 主要研究方向为SAR目标识别。

李俊毅, 博士, 主要研究方向为SAR目标检测与识别, 目前已发表论文4篇。

邹 林, 副教授, 主要研究方向为雷达信号处理, SAR图像处理, 目标检测与识别。

(责任编辑: 于青)