

DOI:10.16356/j.1005-2615.2025.05.001

微小型无人机 SAR 地面小目标检测与识别方法

朱岱寅^{1,2}, 吕吉明^{1,2}, 周 鹏^{1,2}, 俞 翔^{1,2}, 耿 哲^{1,2}, 王 鹏^{1,2},
陈志成^{1,2}, 周 涛^{1,2}, 叶 铮¹, 郭二娜¹, 汤翊钧¹

(1. 南京航空航天大学电子信息工程学院, 南京 211106; 2. 南京工程学院计算机工程学院, 南京 211167)

摘要: 南京航空航天大学(Nanjing University of Aeronautics and Astronautics, NUAA)雷达探测与成像团队利用自主研发的无人机载微小型合成孔径雷达(Synthetic aperture radar, SAR)系统针对不同类型的坦克、装甲车和战机等十余类典型军事目标构建了圆周 SAR 数据集。通过对多次外场试验数据的高精度成像处理,在多俯仰角单基圆周 SAR 图像数据集的基础上,扩展了不同双基角组合的双基圆周 SAR 图像数据集。基于该数据集,本文结合团队在 SAR 图像目标检测 and 识别方法及应用方面的研究成果,对基于深度学习的 SAR 目标检测识别技术进行了回顾和综述,对比了不同神经网络模型在南航无人机载圆周 SAR 数据集上的检测和识别性能。具体地,在目标检测方面,利用 SAR 图像固有属性获得目标位置信息并结合单阶段轻量级检测算法,提出利用信息分布规律并结合全局注意力机制捕捉小目标位置信息的检测算法,以提高复杂背景下的小目标检测准确率和效率。在目标识别方面,在通过 SAR 图像先验信息抑制干扰噪声的基础上,提出利用 SAR 目标多视角信息联合 Transformer 的目标识别算法,通过设计视角正则化项以约束多视角之间的关联性从而实现不同视角间的特征融合,提高 SAR 小目标识别的准确率。从无人机载微型 SAR 系统对地面目标进行实时检测和识别的实际需求出发,本文还探讨了轻量化检测和识别网络在数字信号处理(Digital signal processing, DSP)平台上的部署方案,同时展示了初步试验结果。最后,本文展望了 SAR 目标智能检测和识别领域面临的挑战和发展趋势。

关键词: MiniSAR; 地面目标数据集; 深度学习; SAR 目标特征; DSP 检测与识别

中图分类号: V262

文献标志码: A

文章编号: 1005-2615(2025)05-0781-18

SAR Ground Small Target Detection and Recognition Methods Via Micro-small UAVs

ZHU Daiyin^{1,2}, LYU Jiming^{1,2}, ZHOU Peng^{1,2}, YU Xiang^{1,2}, GENG Zhe^{1,2}, WANG Peng^{1,2},
CHEN Zhicheng^{1,2}, ZHOU Tao^{1,2}, YE Zheng¹, GUO Erna¹, TANG Yijun¹

(1. College of Electronic and Information Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China; 2. School of Computer Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: The radar detection and imaging team at Nanjing University of Aeronautics and Astronautics (NUAA) has developed a circular synthetic aperture radar (SAR) dataset for over ten types of typical military targets, including tanks, armored vehicles, and fighter aircraft, using a self-developed UAV MiniSAR system. Through high-precision imaging processing of multiple field trial datasets, the team expands the original monostatic circular SAR image dataset with multiple elevation angles to include bistatic circular SAR image datasets with varying bistatic angle configurations. Building upon this dataset and integrating the team's research achievements in SAR image target detection, recognition methodologies, and applications, this paper reviews and summarizes deep learning-based SAR target detection and recognition

收稿日期: 2025-08-26; 修订日期: 2025-09-15

通信作者: 朱岱寅, 男, 教授, 博士生导师, E-mail: zhudy@nuaa.edu.cn。

引用格式: 朱岱寅, 吕吉明, 周鹏, 等. 微小型无人机 SAR 地面小目标检测与识别方法[J]. 南京航空航天大学学报(自然科学版), 2025, 57(5): 781-798. ZHU Daiyin, LYU Jiming, ZHOU Peng, et al. SAR ground small target detection and recognition methods via micro-small UAVs[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2025, 57(5): 781-798.

techniques, comparing the performance of different neural network models on NUAA's MiniSAR dataset. Specifically, for target detection, the paper proposes to leverage the inherent attributes of SAR images to extract target location information and incorporates a lightweight one-stage detection algorithm. Additionally, an algorithm utilizing information distribution patterns combined with a global attention mechanism is introduced to enhance the detection accuracy and efficiency of small targets in complex backgrounds. For target recognition, after suppressing interference noise using SAR image prior information, the study presents a recognition algorithm that integrates multi-view SAR target information with Transformer architecture. Furthermore, a viewpoint regularization term is designed to constrain interview correlations, which enables effective feature fusion across different perspectives to improve the recognition accuracy of small SAR targets. Addressing the practical requirement of real-time ground target detection and recognition by MiniSAR systems, this paper also explores the deployment strategy of lightweight detection and recognition networks on digital signal processing (DSP) platforms, accompanied by preliminary experimental results. Finally, the challenges and future trends in intelligent SAR target detection and recognition are discussed.

Key words: MiniSAR; ground target dataset; deep learning; SAR target feature; DSP detection and recognition

合成孔径雷达(Synthetic aperture radar, SAR)是遥感与测量领域的核心技术之一。SAR是一种主动对地观测系统,由于工作在微波波段, SAR图像不受云层、雨雪等天气条件的影响,能够在各种复杂环境中获取清晰的地表信息,在民用和军事等领域具有重要应用价值^[1-3]。相比于光学遥感, SAR具备全天候、全天时成像的优势,但必须以飞机、卫星和无人机等运动平台为载体。微型无人机相较于传统 SAR 平台,在灵活性和机动性方面展现出显著优势,微型无人机能够在复杂地形和城市环境中进行低空飞行,获取更高分辨率的 SAR 图像^[4]。此外,微型无人机 SAR 成本低,部署和维护更为便捷,特别适用于快速响应和局部区域的监测任务。例如在民用领域,为灾害现场提供实时数据支持^[5],在军事领域,则是军事侦察、精确打击和打击效果评估的重要手段^[6]。

然而,尽管微型无人机 SAR 在数据获取的灵活性上具有显著优势,其目标检测识别仍面临诸多瓶颈,严重制约了实际场景下工作的可靠性与效率。首先,微型无人机 SAR 图像中感兴趣目标大多属于目标检测任务中的“小目标”,即目标边界框的宽高与图像的宽高比例小于 1%。这意味着这些目标在 SAR 图像中占据的像素较少,导致特征信息不足。同时,小目标还容易被复杂背景或邻近物体覆盖,进而影响小目标的检测识别精度。此外,微型无人机 SAR 在成像过程中,由于载机飞行稳定性不足以及成像算法本身的局限性,可能导致图像出现模糊、畸变或几何失真,为后续小目标检测与识别带来更大的挑战。

本文聚焦微型 SAR 系统的地面小目标检测与识别,从数据集构建、算法创新、工程应用 3 个方面

展开系统性论述。首先,针对 SAR 小目标实测数据匮乏问题,基于自主研发的微型 SAR 系统,通过外场试验构建了多俯仰角单基与双基圆周 SAR 数据集。其次,在目标检测方面提出基于 SAR 图像特征和注意力机制的小目标检测方法,在识别方面创新设计了 SAR 先验知识抑噪和视角正则化多视角融合模型,并结合 SAR 图像数据集验证了算法在复杂背景下的性能优势。最后,在工程应用方面,探讨了轻量化网络在数字信号处理(Digital signal processing, DSP)平台的部署方案,为实时处理提供技术路径。本文末尾则从散射机理建模、小样本学习等角度展望未来发展趋势,提出“物理机理-深度网络”协同演进的技术路线,推动低空 SAR 智能感知技术向实用化发展。

1 基于 SAR 小目标数据集的检测与识别技术发展现状

基于 SAR 小目标数据集,研究人员在车辆等典型地面 SAR 小目标检测和识别方面,开展了大量研究工作。

1.1 SAR 小目标检测技术研究现状

在 SAR 图像中进行目标检测时,常常面临复杂场景干扰的挑战。不同复杂场景中的干扰因素和目标特征的变化大大增加了检测的难度(图 1)。此外, SAR 系统的成像分辨率和检测效率在很大程度上受到环境因素和目标特征变化的影响。因此,挖掘有用信息并提高目标检测任务的准确性和效率显得尤为重要。在此背景下,人工智能技术,尤其是深度学习的迅速发展,为 SAR 图像解译带来了新的机遇。本节在总结 SAR 图像目标检测算法的基础上,梳理了传统 SAR 目标检测方法以及




图1 SAR图像检测场景展示

Fig.1 SAR image detection scene display

基于深度学习的SAR目标检测方法。

传统的SAR车辆小目标检测主要是基于散射机理分析以及统计机器学习的方法。该技术手段依附于各种各样的专业理论知识及基于先验信息的手工特征提取器。Fan等^[7]提出了GL-CFAR算法,通过建立背景-目标自适应模型来确定目标位置,实现SAR大面积场景中车辆目标的快速定位。Tang等^[8]基于单通道SAR图像复杂数据实部与虚部之差的新型特征,提出了一种用于车辆小目标的超像素的恒定虚警率(Constant false alarm rate, CFAR)检测方法,相较于其他CFAR检测器在更短时间内能检测到更多目标像素。Cui等^[9]提出了一种基于协同显著性的SAR图像车辆小目标检测算法,通过利用辅助数据和待测数据计算协同显著性,获取待测目标的显著特征以完成检测任务,与传统的CFAR算法和显著性算法相比所提检测精度均有所提高。代晓康等^[10]提出了一种结合超像素分割和Wishart分类器的非监督目标检测方法,通过区域生长和信息融合实现车辆小目标检测任务。李国令等^[11]为解决传统SAR图像目标检测算法在复杂场景下精度低、虚警多的问题,提出了一种针对特定类别的似物性推荐方法。

深度学习的出现,则进一步提高了SAR图像目标的检测精度。计科峰等^[12]研究的应用线性回归技术,深入探讨了在SAR图像中目标方位估计的性能,提供了丰富的实证数据支持。Wang等^[13]基于单阶段多框检测器目标检测框架,联合迁移学习和数据扩充策略提升在SAR图像上的目标检测性能。Wei等^[14]提出了一种基于半监督学习和注意力机制的SAR目标检测网络,对可能包含目标的区域进行精细目标检测。李庆等^[15]提出基于YOLOv5架构的大场景SAR图像车辆目标检测识别方法,有效减少训练样本数量,同时提高了模型收敛速度。为解决复杂背景下杂波带来的虚警和漏警问题,李毅等^[16]提出了基于特征分解卷积神经网络(Convolutional neural network, CNN)的SAR图像目标检测方法。该方法通过特征分解模

块分解出鉴别特征和干扰特征,最后将鉴别特征输入到多尺度检测模块进行目标检测,从而有效降低虚警和漏警,提高SAR目标检测性能。

1.2 SAR小目标识别技术的发展

与光学成像机理不同,SAR图像是主动微波成像,图像判读往往需要依靠专家的经验知识,这会导致图像解译的效率低下。

在传统的SAR图像车辆小目标识别研究中,传统方法主要依赖模板匹配。对此,美国麻省理工学院林肯实验室^[17]基于MSTAR数据集使用模板匹配方法进行了SAR目标识别研究,周雨等^[18]提出的SAR目标识别算法,通过优化特征提取和分类识别过程,显著提高了识别准确率。为降低模型复杂度,Zhou等^[19]提出通过对SAR图像中的全局散射中心进行预测和匹配,实现了对目标特征的准确提取和识别。Wang等^[20]提出的多特征融合方法,利用强度特征和幅度特征的结合,显著提升了SAR目标识别的效果。Zou等^[21]的伪彩色图像方法则通过对多方位角的SAR图像进行处理,降低了特征之间的差异性,增强了多方位角特征的关联性。

除了传统方法,基于深度学习的方法也被大量研究。Pei等^[22]提出包含多输入并行拓扑结构的CNN结构,将不同方位角SAR图像的特征逐层学习并融合。陈文婷等^[23]采用了单级卷积网络的方法,利用其自动学习特征的能力,在MSTAR数据集上取得了很高的准确率。进一步地,Chen等^[24]还提出了一种全卷积网络,该网络采用稀疏连接的策略,以减少过拟合的风险。Housseini等^[25]则提出了将CNN与卷积自编码器相结合的方法,通过这一结合,研究人员有效降低了时间复杂度,同时提升了识别精度。Wagner等^[26]提出了CNN与支持向量机的结合方案,充分发挥两者在特征信息提取和分类判别上的优势。Furukawa等^[27]通过数据增强技术训练深度残差网络,显著扩充了训练数据的规模,从而提高了识别准确率。Huang等^[28]提出一种基于多源数据的自适应跨域迁移SAR目标识别方法,并讨论了基于迁移学习的SAR ATR算法中源域数据对识别性能的影响。Zhang等^[29]提出一种基于Gabor滤波器和双向长短时记忆网络的多视角SAR识别方法。

2 无人机载圆周SAR数据集

2.1 无人机SAR小目标数据集

全天候成像的优势,使得SAR在检测地面小目标方面具有重大的应用潜力,而构建无人机地面小目标数据集,对于提升人工智能方法在复杂场景中的鲁棒性的相关工作具有关键意义。

南京航空航天大学(以下简称“南航”)探测与成像团队基于自主研发的多模式 MiniSAR 系统(包含单基与双基协同观测方式),构建了地面小目

标 SAR 图像数据集,将其命名为全视角静止车辆目标数据集(南航车辆 SAR 数据集)。数据集的构建过程见图 2。




图2 SAR地面小目标数据集的构建与应用

Fig.2 Construction and application of SAR ground small target dataset

构建新的地面车辆小目标数据集具有以下意义:(1)弥补样本数据瓶颈,提升算法泛化能力。由于SAR成像的复杂性,导致地面小目标在不同场景下的样本获取困难,数量较少。通过构建数据集,可提供多种成像条件下的目标样本,使得深度学习模型能够更好地学习目标样本的多视角和多尺度等特征。(2)贴近真实应用场景,增强工程实用性。通过引入不同俯仰角的SAR图像,可以使数据集更符合实际侦察任务,提高算法在复杂环境下的检测能力。

MiniSAR的单基和双基实物图如图3所示。



图3 本文使用的MiniSAR单基和双基系统实物图

Fig.3 Physical images of the MiniSAR monostatic and bistatic systems used in this paper

该数据集根据成像时间的不同分为3批,分别是2022年3月第一次录取的单基SAR成像数据;2022年7月第二次录取的单基SAR数据;以及2023年11月份第3次录取的双基SAR数据。下面将详细描述这3次数据的特点。

2.2 数据集的目标种类和成像参数

第1批单基SAR成像的时间为2022年3月,此后,本文后续将简称为“单基1.0”,其目标区域总共包含9类17个目标,分别是62LT、63APTV、63CAAV、63AT、T34-85、59-1TC、54TH、59AG和J6(详细中英文名称见表1)。图4列出了无人机在空中拍摄的目标光学图像。第2批数据仍是单基SAR数据,录取时间是2022年7月。同样地,本文后续将简称为“单基2.0”。和单基1.0数据不同的是,增加了表1中的地面雷达目标。第3批数据则是双基数据,双基数据在单基数据的基础上增加了一类高射机枪目标。

MiniSAR飞行1圈的长度约为2200m,飞行时间约为360s,则理论上每1.2s可以获取1次数据。换言之,飞行1圈可以获取300张全景图像。为获取质量更优的SAR图像样本,在单基1.0数据基础上增加了SAR系统天线的增益,从而获得单基2.0数据。与单基SAR系统的单发单收不同,双

表 1 南航车辆 SAR 数据集不同批次的种类分布和名称

Table 1 Distribution and names of different batches in the NUAA -vehicle dataset

简写	英文名称	中文名称	单基 1.0	单基 2.0	双基
62LT	62 light tank	62 轻型坦克	✓	✓	✓
63APTV	63 armored personnel transport vehicle	63 装甲运输车	✓	✓	✓
63CAAV	63C amphibious armored vehicle	63 水陆两栖装甲车	✓	✓	✓
63AT	63A amphibious tank	63A 式两栖坦克	✓	✓	✓
T34-85	Soviet T34-85 medium tank	T34 中型坦克	✓	✓	✓
59-1TC	59-1 130 mm tower cannon	T59-1 130 mm 加农炮	✓	✓	✓
54TH	54 122 mm towed howitzer	54 122 mm 牵引榴弹炮	✓	✓	✓
59AG	59 anti-aircraft guns	59 轻型高射炮	✓	✓	✓
J6	Shenyang J-6	歼-6	✓	✓	✓
Radar	Ground-to-air radar	地对空雷达		✓	✓
AMG	Anti-aircraft machine guns	高射机枪			✓



图 4 SAR 地面小目标的光学图像

Fig.4 SAR ground small targets in optical images

基 MiniSAR 接收机和发射机分置于 2 架无人机。为获取足够的双基 SAR 图像样本共飞行了 9 个架次,具体每架次的方位双基角和俯仰双基角的信息见表 2。

表 2 双基 SAR 系统在不同架次的角度信息

Table 2 Bistatic SAR system angle information for various sorties (°)

架次	发射机俯仰角	接收机俯仰角	方位双基角
1	15	45	0
2	15	60	0
3	30	45	0
4	40	45	0
5	45	45	5
6	45	45	15
7	45	45	30
8	45	45	45
9	30	30	30

图 5~7 中展示了全部 3 个批次的样本典型切片 SAR 图像。通过与 MSTAR 数据集对比,本文的单基 SAR 目标切片图像的分辨率更高,目标更加清晰,但同时也存在信噪比相对低和相对形变的




图 5 南航车辆 SAR 数据集单基 1.0 的样本切片

Fig.5 Slicing of monostatic 1.0 in NUAA SAR dataset




图 6 南航车辆 SAR 数据集单基 2.0 样本切片

Fig.6 Slicing of monostatic 2.0 in NUAA SAR dataset



图 7 南航车辆 SAR 数据集双基样本切片

Fig.7 Slicing of bistatic data in NUAA SAR dataset

问题。图 8 为 3 个批次数据试验场景的全景成像结果。

为验证本文提出的方法对于在复杂场景下检测 SAR 地面军事小目标的能力,设计了 6 组实验 (EXP 1~EXP 6)。表 3 展示了具体的实验数据集划分并且详细阐述了实验设置的具体内容。

根据表 4 实验结果,本文的模型在复杂环境下的单基 SAR 图像和双基 SAR 图像中都表现出色。检测精度可以达到 90% 以上,并且具有

良好的召回率和 F_1 -score,展现了稳定的性能。其中,评价指标包括平均精度 (mean Average precision, mAP)、平均精度 (Average precision, AP)、召回率 (Recall) 和 F_1 -分数 (F_1 -score)。此外,本文提出的方法还具有较强的扩展性,适用于检测 SAR 地面小目标、海面舰船和桥梁等不同目标。

表 3 6 组实验的训练集和测试集划分
Table 3 Division of train and test for six experiments

实验编号	训练		测试	
	数据集	数量	数据集	数量
EXP 1-1	单基 2.0(26°/31°/37°)	814	单基 2.0(45°)	295
EXP 1-2	单基 1.0(15°/31°)	345	单基 1.0(45°)	169
EXP 2	单基 2.0 全部视角	1 109	单基 1.0 全部视角	514
EXP 3-1	双基架次 1	289	双基架次 2	299
EXP 3-2	双基架次 3	294	双基架次 4	287
EXP 3-3	双基架次 5	292	双基架次 6	288
EXP 3-4	双基架次 7	299	双基架次 8	283
EXP 3-5	双基架次 8	283	双基架次 9	292
EXP 4	单基 2.0/1.0	1 623	单基所有	2 623
EXP 5	MSAR-1.0(70%)	19 914	MSAR-1.0(30%)	8 534
EXP 6	SAR-AIRcraft-1.0(82%)	13 513	SAR-AIRcraft-1.0(18%)	2 950

表 4 EXP 1~EXP 6 的实验结果
Table 4 Experimental results of EXP 1—EXP 6 %

实验编号		地面军事小目标检测结果			
		mAP 0.5	mAP 0.75	Recall (0.5)	F_1 -score (0.5)
EXP 1	EXP 1-1	91.32	75.23	85.15	82.22
	EXP 1-2	91.13	68.98	84.40	81.01
	EXP 2	82.19	63.43	76.22	81.33
EXP 3	EXP 3-1	82.53	65.24	77.82	80.64
	EXP 3-2	84.70	70.39	81.64	84.18
	EXP 3-3	90.65	76.33	91.07	88.91
	EXP 3-4	85.83	68.35	82.87	84.63
	EXP 3-5	83.91	67.47	79.48	81.18
	EXP 4	67.91	44.20	61.82	68.32
	EXP 5	83.27	45.21	77.25	79.81
	EXP 6	92.82	65.80	91.27	87.57

3.2 基于特征增强的 SAR 图像车辆目标检测

SAR 图像小目标纹理信息的缺失导致小目标具有高度类间相似性。为应对该挑战,本文提出 SFANet 网络^[35],其整体架构如图 12 所示。具体而言,设计了空间-通道特征适配模块 (SAR-specialized feature aggregation, SAR-SFA),通过比例化聚焦空间与通道信息,增强网络对目标特征的提取与分析能力。此外,SFANet 进一步提出轻量级全局检测头 (Lightweight global detector, LGD),优化检测头的性能。同时,嵌入辅助预分类网络,利用迁移学

习提升模型分类能力。

SFANet 充分利用 YOLOv8 强大的特征提取能力和无锚框设计优势,通过集成其骨干网络来提升目标检测性能。

为提升 MiniSAR 图像中地面车辆目标的分类能力,本文提出辅助预分类方法。该方法通过将迁移学习与分类网络相结合,有效增强了目标识别能力并显著提升了整体检测性能。辅助预分类模块通过梯度反向传播机制更新网络权重,使主干网络提取的特征与数据集特征分布保持一致。这种特征对齐机制有效缓解了数据分布偏移的影响,从而提升网络的检测性能。SFA 模块主要由特征信息聚焦模块和位置信息捕获模块组成,这两个模块的协同工作显著提升了网络各分支的检测性能。

SFANet 认为应赋予丰富的特征信息更高的权重,从而避免因提取不足而导致的信息损失。在目标检测算法中,存在 3 个分支对应网络中不同的检测层,各自专门用于识别大、中、小尺度目标。考虑到空间信息 (S) 和通道信息 (C) 在特征图表示中各自独立但同样重要的角色,本文设定了它们在特征学习过程中的等效性。在检测算法 (如 YOLO 系列) 中,存在 3 个检测层。如果按照原始比例将特征信息聚焦为 2 倍,则各个分支之间的特征聚焦比例差异过大。因此,将每层的特征信息比例从每层翻倍调整为每层增加 1 倍。在这种情况下,每层特征信息被划分为 4 个部分,代表整体特征信息。




图 12 SFANet的整体结构框图

Fig.12 Overall structural diagram of SFANet

第一分支的空间信息设置为3S,通道信息为C;第二分支的空间信息为2S,通道信息为2C;第三分支的空间信息为S,通道信息为3C。与传统的检测算法不同,本研究采用的YOLOv8在第3层分支中保持通道维度为2C,与第2层分支一致,从而避免了通常的两倍通道扩展,以优化参数效率。在这个阶段,第1层分支的空间比例为0.75,通道比例为0.25。在第2层中,空间比例和通道比例均为0.50。在第3层中,空间比例降至0.33,而通道比例上升至0.67。

在特征信息聚焦模块完全聚焦特征信息后,位置信息捕获模块用于引入特征图中目标的位置信息。在位置信息捕获模块中,SFANet通过将二维池化转换为一维池化来牺牲部分感受野信息。这种方法使得网络能够沿着水平和垂直方向感知和编码特征图的位置信息。随后,将编码后的位置信息整合到特征信息中,从而增强网络定位和检测目标的能力。由于之前的特征信息聚焦模块已经充分提取了特征图信息,因此在此处牺牲部分感受野信息对最终特征信息的影响较小。

本文通过引入Swin Transformer和Ghost模块进一步优化了解耦头中的检测头,这使得语义信息的提取更加深入,使网络能够在不一致场景的深层语义信息中捕捉相似特征,从而增强地面目标的检测性能。

输入特征通过Swin Transformer块进行处理,该块利用移位窗口机制捕捉局部和跨窗口依赖关

系,从而增强特征图的全局建模能力。通过这种方式,模型可以在局部窗口内聚合信息,并将局部特征整合为全局特征。在检测层中,特征信息经过多层卷积和池化层处理,空间信息较少而语义信息高度集中。如果检测网络过于复杂且信息稀疏,则很容易导致过拟合。因此,LGD网络利用Ghost模块重构解耦头,有效地将高维特征信息的通道数转换为检测所需的通道数。由于这一阶段的计算量较大,使用Ghost替代卷积有效减少了参数数量和计算量。

为了验证所提方法的鲁棒性,在南航车辆SAR单基数据集和双基数据集上进行了实验。其中:图像分辨率缩放为 416×416 像素;评价指标包括平均精度mAP、平均精度AP、每秒帧数(Frames per second, FPS)、参数数量和GFLOPS;基线是YOLOv8。

(1) 单基数据集的检测结果。本节的方法达到了98.6%的mAP,比YOLOv8提高了1.1%。双基数据集的检测结果:SFANet在该数据集上的mAP达到了98.0%。实验结果表明,SFANet能够有效地在高质量的双基图像上和低质量的单基图像上实现稳健的检测性能。

(2) 图13可视化了SFANet在双基数据集上的部分检测结果。其中,训练集为单基2.0数据集,测试集为双基数据集。从图中可以看出,本文所提方法成功检测到所有车辆并准确识别其类别,证明了SFANet对MiniSAR地面目标的良好检测能力。

量;Value代表值向量。

为充分获取SAR图像的细节和目标的多视角特征,本节设计了MJT-Network的第1部分:利用CNN提取SAR图像的目标单一特征和基于注意力机制的多视角联合特征。通常,CNN具有归纳偏置的特性,在提取图像的局部特征方面具有显著优势。同时,该方法通过注意力机制充分获取同一目标不同视角间的特征。和周期重访的SAR卫星或者高空巡航的大型机载SAR相比,MiniSAR借助于圆周飞行模式具备灵活的拍摄方式,从而可以较容易获得多视角的SAR图像。从理论上来看,多视角的图像特征应该满足一致性和互补性的要求。因此,本文通过间隔统计量合理地确定了具备互补性的视角类别,又分别在每个子视角中内部分配SAR图像,这个过程保证了新形成的多视角数据集具备一致性和互补性。

一般而言,丰富的特征需要一个特征提取性能较强的模型去解析,传统基于CNN的深度学习方法不能胜任。但是,Transformer编码器则能够利用自注意力的优势来提取目标的更多特征。该编码器利用多头注意力机制和MLP周期循环12次,构成一个具有全局注意力特征提取性能模型。该模型通过建立不同视角之间的联系,且可以将特征映射到多个不同的子空间,从而增强模型的表达能力。

目标多视角的优势除了获取不同视角之间的相互特征,还可以在决策层进一步融合。本网络对

模型的Loss进行了重新设计,提出自适应聚合损失函数 $Loss_{Aggregation}$ 的计算方法,有

$$Loss_{Aggregation} = \frac{1}{Batch} \sum_{i=1}^{Batch} \sum_{j=1}^{N_{view}} \omega_j \cdot Loss_{i,j} \quad (2)$$

式中: $Loss_{Aggregation}$ 表示总损失值,Batch表示批次的大小, N_{view} 表示目标视角的数量, ω_j 表示第j视角的权重, $Loss_{i,j}$ 表示第i个小批次中第j个视角下的损失值。先获得同一目标的所有视角下每个类别置信度,然后通过叠加置信度作为Loss交叉熵的输入,得到每个视角的Loss。

$$\omega_j \leftarrow \omega_j - \alpha \cdot \frac{\partial Loss}{\partial \omega_j} \quad (3)$$

式中: α 为学习速率, $\frac{\partial Loss}{\partial \omega_j}$ 为权值 ω_j 的偏导数。该式表示权值 ω_j 的更新方法。该式的含义是每次计算损失时,根据损失值的变化来更新权重值。

4.1.2 实验结果

为验证MJT-Network识别形变SAR图像目标的准确率,本文基于MSTAR和南航车辆SAR数据集分别设计了2组实验。传统的验证方法是把同一条件下生成的SAR图像,划分为训练集和测试集来进行验证。

为进一步验证本文提出的算法鲁棒性,本文划分的训练集和测试集是在不同条件下生成的同一目标图像。具体的训练集和测试集分配如表5所示。其中,表5第5行中每个单元格中的第1个元素代表该列数据集的子集,第2个元素表示该子集中的俯仰角。

表 5 7次实验的训练和测试数据划分数量

Table 5 Number of training and testing data partitions for seven experiments

视角数量	MSTAR						南航车辆SAR数据集							
	EXP 1		EXP 2		EXP 3		EXP 4		EXP 5		EXP 6		EXP 7	
	训练	测试	训练	测试	训练	测试	训练	测试	训练	测试	训练	测试	训练	测试
	SOC/ 15°	SOC/ 17°	EOC/ 17°	EOC/ 30°	EOC/ 30°	EOC/ 45°	2.0/ 45°	1.0/ 45°	2.0/ 31°	1.0/ 31°	2.0/ 37°	1.0/ 31°	2.0/ 26°	1.0/ 15°
1	2 426	2 747	1 195	1 199	1 199	1 203	2 606	1 515	2 562	1 741	2 656	1 741	2 061	1 331
2	3 837	4 154	2 057	1 758	2 057	2 121	5 068	2 519	3 968	2 928	4 539	2 928	3 895	2 165
3	10 759	11 932	5 365	5 032	5 032	5 673	12 066	6 276	10 326	7 292	11 367	7 292	9 843	5 769
4	7 432	7 500	3 798	3 550	3 550	4 275	9 853	4 472	7 622	5 269	8 328	5 269	7 813	4 169
5	3 382	3 244	1 842	1 658	1 658	2 021	5 127	2 118	3 842	2 471	4 044	2 471	3 843	1 955

表6中的EXP 1表明了提出的算法识别无形变的SAR图像是有效的。虽然单视角的识别结果低于当前部分SAR图像识别算法,例如模型较小的神经网络^[37],但是经过5个视角融合后,其识别准确率已经达到领先水平。进一步地,EXP 2表明,当图像出现轻微形变时,本文的网络开始体现出优势,其单视角的识别结果已经和先进算法的识

别准确率处于同一水平,甚至多视角的识别结果超越一般方法。EXP 3表明本文提出的算法对提高识别形变SAR图像(MSTAR EOC 45°)的准确率有较大的帮助。

EXP 4~EXP 7的实验结果也表明了识别南航车辆SAR数据集难度更高。因此,单视角南航车辆SAR数据集的SAR图像识别准确率均低于

表 6 在实验 1~7 上不同视角数量的实验结果

Table 6 Experimental results with different numbers of views presented in EXPs 1—7

%

视角数量	MSTAR			南航车辆 SAR 数据集			
	EXP 1	EXP 2	EXP 3	EXP 4	EXP 5	EXP 6	EXP 7
1	97.83	95.85	82.68	76.32	78.56	76.65	63.24
2	98.81	96.96	88.59	79.07	82.21	80.57	68.20
3	98.97	97.37	93.40	85.44	87.44	84.15	72.70
4	99.44	98.28	96.01	90.21	92.71	89.57	76.98
5	99.78	99.27	98.37	93.86	94.60	93.57	80.46

MSTAR。南航车辆 SAR 数据集的高俯仰 45° 图像的五视角识别准确率为 93.86%，相对形变更小的 31° 数据的识别准确率则为 94.60%。这说明俯仰角越高图像目标形变越严重，则识别准确率越低。南航车辆 SAR 数据集和 MSTAR 都存在这样的现象。此外，EXP 6 表明当训练和测试俯仰角度不一致时，准确率出现了下降。不同的是，理论上 EXP 7 的训练数据应该是形变最小的 SAR 图像，但是识别准确率却是几次实验中最低。本文认为这主要由两个原因导致的：(1) MiniSAR 的飞行高度低从而导致了目标被高大树木遮挡；(2) 该架次飞行轨迹是 1 个多边形而不是 1 个非常规整的圆周。

4.2 基于皮尔逊正则化的多视角 SAR 目标识别方法

由于 SAR 地面目标数据的稀缺，多视角 SAR 目标识别的准确性受到网络过拟合的限制；传统的

多视角目标识别网络在促进跨视角信息融合方面效率不高。为解决上述问题，本文提出了一种基于皮尔逊相关性正则化的多视角 SAR 目标识别算法。

4.2.1 算法分析

本文提出的 VRCNet 方法，网络架构如图 15 所示。该网络通过多维框架并行处理多视角输入。其主干架构采用 ConvNeXt，通过大核卷积操作相比于 ViT 实现了更优越的全局特征提取能力。特征融合网络由 3 个部分组成：第 1 个组件是视角相关性正则化器 (View-correlation regularizer, VCR)，它通过对主视角和相关视角的组合特征施加正则化约束，从而增强跨视角特征融合性能。第 2 个组件是交叉视角注意力 (Cross-view attention, CVA)，它通过对不同视角组合进行全局信息匹配和整合，显著提升特征融合的稳定性。第 3 个模块是视角贡献池化层 (View-contribution pooling layer, VCP)，




图 15 VRCNet 的整体结构 (以 5 视角为例)

Fig.15 Overall structure of VRCNet (taking five perspectives as an example)

它通过将视角特定的权重参数集成到标准的最大池化操作中,增强了多视角信息的利用效率。

SAR图像容易受到相干斑噪声干扰,而俯仰角和方位角的变化会导致目标形变和特征信息的丢失。因此,从物理角度考虑不同视角之间的关系,并设计正则化层来约束网络的收敛方向是至关重要的。在此基础上,本文提出了一种视角相关正则化层,该方法最大化了不同视角之间的特征相关性。

为提高正则化网络在多视角任务中的训练效率,VRCNet在多视角正则化中采用矩阵运算对视角特征进行并行计算。并且,为应用该正则化层在3个或更多的视角任务中,本文提出了一个视角转移策略。视角转移策略将特征标记为主视角特征,并通过沿着视角维度循环移动特征来生成关联视角特征。最后沿着通道维度拼接主视角特征与关联视角特征,通过正则化层约束多视角特征融合。此外,本文将视角转移策略扩展到多个并行转移分支,形成多个关联视角。根据视角数 V 计算所需的关联视角数 N ,保证了VCR策略整合了所有视角对之间的特征信息。 N 的计算公式为

$$\arg \min_N \left(V \times N > \frac{V!}{2! \times (V-2)!} \right) \quad (4)$$

式中: V 表示视角数, N 表示关联视角数。

尽管VCR促进了多视角之间的高效特征融合,但其依赖于皮尔逊相关系数进行的成对特征融合,存在一定的局限性。因此,本文设计了一种基于视角内在关系的CVA,它通过设计基于窗口的视角组合和交叉注意力来解决上述两个问题。

为进一步整合基于窗口的视角组合得到 S 组视角信息,本文使用交叉关注来计算 S 组视角之间的交互特征,从而完成多视角特征融合。通过将上述视角向量中的主视角和关联视角进行划分,窗口内的视角组合被分为查询(Query)、键(Key)和值

(Value),以进行交叉注意力的计算。

本文还提出了视角贡献池化层。视角贡献池化结合了最大池化和视角加权池化。这种设计利用最大池化确保最显著视角特征在分类中的主导地位,同时采用视角加权池化为每个视角分配实例特定的权重。VCP通过对最大池化和视角加权池化进行加权融合而形成。最大池化操作提取视角特征中的通道最大值。同时,视角加权池化通过量化每个视角的贡献重要性来为单个视角分配自适应权重,从而减轻最显著特征的垄断主导地位。

4.2.2 实验结果

为评估所提出的VRCNet在SAR目标识别方面的性能,在MSTAR和南航车辆SAR数据集上进行了实验,共设计了6个实验组(EXP 1~EXP 6)。

EXP 1使用单基2.0数据和南航车辆SAR数据集中的所有双基数据作为训练集和测试集。EXP 2使用以单基2.0数据作为训练集,而单基1.0数据作为测试集。EXP 3通过控制方位角和俯仰角,使用双基数据构建训练集和测试集。EXP 4使用双基数据,将成像质量较高的架次作为训练集,而将成像质量较低的架次作为测试集。EXP 5使用单基数据,指定单基2.0数据作为训练集,单基1.0数据作为测试集。与EXP 2不同,此实验是在控制俯仰角的情况下进行的。EXP 6使用MSTAR数据集构建一个10类SOC数据集。通过设置大俯仰角的测试集,数据进一步划分为4类EOC-1a数据集和3类EOC-1b数据集。

图16给出了VRCNet在各实验组(EXP 1~EXP 6)中的准确率、精确率和召回率,所有结果均在5视角目标识别框架下获得。在所有实验组中,准确率始终超过87%,而精确率和召回率(除了EXP 5-3、EXP 5-4和EXP 6-1)均保持在80%以上。




图16 EXP1~EXP 6的实验结果

Fig.16 Experimental results of EXP 1—EXP 6

5 基于 DSP 高效部署的双基 SAR 目标检测和识别方法

为使得 SAR 目标检测与识别实用化,需将软件程序部署到硬件系统上,其中 DSP 是重要途径。考虑到 DSP 运算资源有限,本文选择 CenterNet,利用其无锚框的特点以及简单的网络结构,实现在 DSP 上的部署。

5.1 基于矩阵分块和增强型直接内存访问缓存乒乓的通用矩阵乘法加速策略

DSP 的运行效率是部署到硬件的重要参考,本节基于数据重排和矩阵乘法的二维卷积、二维转置卷积算子的实现方案,将二维卷积、二维转置卷积运算转换成矩阵乘法,便于 DSP 的加速运算。

对于标准二维卷积,使用 im2col 算法将形状为 (IC, IH, IW) 的特征图重排为形状 $(IC \times KH \times KW, OH \times OW)$ 的矩阵,经过通用矩阵乘法 (General matrix multiply, GEMM) 操作后获得二维卷积结果。例如,在单通道的情况下,有 4×4 大小的特征图,卷积核大小为 3×3 ,补零为 0,步距为 0,按照二维卷积中卷积核在特征图中滑动相乘的情况,特征图被重排成形状 $(3 \times 3, 2 \times 2)$ 的矩阵,卷积核被重排成 $(1, 3 \times 3)$ 的矩阵。当卷积核大小为 1×1 时,可跳过 im2col 直接执行 GEMM。经过数据重排、特征图和卷积核的二维卷积被转换成了矩阵乘法。

对于二维转置卷积,在推理之前预先将卷积权重合并为 $(IC, OC \times KH \times KW)$ 的矩阵,并转置成 $(OC \times KH \times KW, IC)$,执行 GEMM 后使用 Col2im 算法将形状为 $(OC \times KH \times KW, IH \times IW)$ 的矩阵重排成形状为 (OC, OH, OW) 的张量。图 17 展示了单通道的 Col2im 算法示例,将形状 $(3 \times 3, 2 \times 2)$ 的矩阵的每一列重排成 $(3, 3)$ 的矩阵,对这 2×2 个矩阵赋予不同偏移后累加求和获得 1 个 $(4, 4)$ 的矩阵。由于矩阵的数据按行在内存中连续存储,所以该矩阵等价于 1 个形状为 $(4, 4)$ 的张量。Col2im 算法可以视作 Im2col 算法的逆过程。在 DSP 中,在 L2 缓存中的运算效率远高于在双倍数据速率内存 (Double data rate memory, DDR) 中。但是 L2 缓存




图 17 Col2im 数据重排算法原理

Fig.17 Principle of Col2im data rearrangement algorithm

大小有限,于是将矩阵乘法分块,将 1 次矩阵乘法分解成若干次子矩阵在 L2 缓存中进行矩阵乘法和矩阵加法是更加高效的做法。如图 18 所示,将 1 次矩阵乘法分解成若干组子矩阵乘法;将参与运算的 1 对子矩阵从 DDR 中搬运进 L2 缓存;在 L2 缓存中的子矩阵进行矩阵乘法;执行矩阵加法累加当前组每 1 对子矩阵乘法的结果,获得输出的子矩阵;将输出的子矩阵从 L2 中搬运回 DDR 中,完成一组子矩阵乘法的乘法。图中: $M \times N$ 代表输出矩阵的尺寸, $M_1 \times N_1$ 代表输出子矩阵的尺寸, $M_1 \times K_1$ 代表权重子矩阵的尺寸, $K_1 \times N_1$ 代表输入特征图子矩阵的尺寸。




图 18 矩阵乘法分块原理

Fig.18 Matrix multiplication block principle

利用增强型直接内存访问 (Enhanced direct memory access, EDMA) 可以显著提高数据在 DDR 和 L2 之间搬运的效率。为进一步提高内核的运行效率,使用 EDMA 搬运数据时可以应用缓存乒乓的策略。在内核进行子矩阵乘法的同时让 EDMA 异步进行上一次计算结果和下一次的计算用到的数据的搬运,以此最大程度提高运算效率。为防止正在参与计算的数据和搬运的数据产生冲突,L2 应当划分为两份用于缓存计算中用到的子矩阵,两份缓存存在同一时间分别用于计算和数据搬运。EDMA 缓存乒乓的原理:将两份缓存分为命名为缓存乒乓和缓存乒乓,每块缓存中包含矩阵乘法的输入矩阵 A、输入矩阵 B 和输出矩阵 C,在两块缓存中分别标注了 1 组子矩阵在 DDR 中的起始地址。每次数据搬运通过配置 3 个 EDMA 通道的寄存器分别用于将矩阵 A 的子矩阵从 DDR 搬入 L2、矩阵 B 的子矩阵从 DDR 搬入 L2 和矩阵 C 的子矩阵从 L2 搬回 DDR。

5.2 多核并行策略

多核并行模型有 fork-join 和 OpenMP,并行方式有任务级并行和数据级并行两种。Fork-join 适合任务级并行,按照上一节划分的 1 组子矩阵乘法为任务单元,按照任务划分,实现多核并行。

图 19 给出了基于 fork-join 的子矩阵乘法 4 核并行策略示意,每一块颜色代表图 18 中的子矩阵




图 19 子矩阵乘法任务 fork-join 并行策略

Fig.19 Schematic diagram of fork-join parallel strategy for submatrix multiplication task

乘法任务,包括子矩阵的数据搬运、子矩阵乘法和子矩阵加法等操作。

各核同步标志分配在 DDR 中不被 Cache 缓存的区域。在进行同步操作之前需将各核同步标志的值初始化为 0。采用计数器记录同步次数。通过核 0 来监控其他各核的同步标志,检测到其他核的同步标志都更新后,再更新核 0 的同步标志。其他核更新自己的同步标志,通过检测核 0 的同步标志来判断同步是否完成。

5.3 SIMD 和流水优化

以型号 TMS320C6678 的 DSP 为例,使用其支持的内联函数对上述的 GEMM 算法进行单指令多数据(Single instruction multiple data, SIMD)指令级优化。使用内联函数 DMPYSP 和 DADDSP 配合流水优化实现单周期 4 个 FP32 乘法运算和加法运算;内联函数 AMEMD8 配合流水优化实现单周期指令 128 位(4 个 FP32)数据的传输。理论上经过 SIMD 指令级优化的 GEMM 算法效率能提高到原来的 4 倍。

考虑到使用内联函数优化的 GEMM 需要对数据进行内存对齐,对 GEMM 中的矩阵形状有要求,要求 M 、 K 和 N 均为 2 的倍数。为了适应一般的矩阵形状且尽可能保留 SIMD 指令优化,根据 M 、 K 和 N 的值进行分情况处理,对于每种情况分别进行 SIMD 和流水优化。

结合上述方法,得到最终的二维卷积、二维转置卷积算子的加速方法如图 20 所示。

5.4 实验结果

本次实验选用是型号为 TMS320C6678^[38],集成了 8 个 C66 的 DSP 内核,主频为 1 GHz,每个内核配有 512 KB 的 L2 高速缓存,8 核共享 4 MB 的 SRAM 高速内存,包含 1 GB 的 64 位 DDR3 外存接口。

使用南航车辆 SAR 数据集用作训练和测试,训练集和测试集的比例为 5:1。使用以 ResNet18




图 20 二维卷积、二维转置卷积算子加速方法

Fig.20 Acceleration of 2D convolution and 2D transposed convolution operator

为 Backbone 的 CenterNet 作为目标检测网络,使用双线性插值将 1024×1024 的图片转换为 224×224 输入网络进行训练。在服务器中训练 500 个 epoch 后得到权重,将 BN 层和卷积层进行融合以精简推理过程,并略微减少权重的参数量和推理时间。将权重文件转换成适用于自建推理框架的格式后导入 DSP,并将测试集中的图片输入 DSP 用于推理。

使用 TMS320C6678 推理 CenterNet-ResNet18 的优化前后网络各部分用时情况如表 7 所示。预处理操作,对输入图片使用双线性插值转换成 224×224 的大小后做归一化处理转换为张量输入

表 7 CenterNet-ResNet18 架构运行时间

Table 7 CenterNet-ResNet18 architecture runtime ms

编号	类型	时间	
		优化前	优化后
0	预处理	11	11.23
1	Backbone	124 632	346.30
2	Neck	21 865	55.97
3	Head	31 791	65.86
4	后处理	103	23.59
总时间		178 402	502.95

网络;后处理操作,对输出的热力图进行 3×3 最大池化替代非极大值抑制操作获取目标检测结果,并解析目标的位置和大小。运用本文的优化方法将 CenterNet-ResNet18 网络在 DSP 上的推理用时从 178 s 提升到 503 ms, FPS 大约为 2, 满足机载平台对 SAR 目标检测和识别的实时性要求。

在后处理中,先解析热力图得到所有目标类别的候选目标后,再对目标偏移量和目标尺寸进行解析获得目标在原图中的位置和大小(图 21)。图 22 为对 CenterNet 网络在 TMS320C6678 上的最终实验结果,结果符合预期,完成了对微小型无人机 SAR 地面小目标检测与识别的任务。




图 21 CenterNet 输出的目标偏移量和目标尺寸

Fig.21 Target offset and target size of CenterNet output




图 22 CenterNet 在 TMS320C6678 上的检测结果

Fig.22 Results of CenterNet on TMS320C6678

6 SAR 目标检测和识别技术的未来发展与挑战

目标检测和识别一直是 SAR 研究领域的重要课题。结合本文的探索和研究,初步总结了 SAR 目标检测和识别技术未来发展与挑战:

(1) SAR 目标样本稀缺性严重制约了深度学习模型的泛化性能。为此,可结合电磁计算方法生成仿真数据,重点复现目标材质、结构细节等关键散射特征。进一步地,通过设计多模态融合网络,联合利用复图像的幅度与相位信息,可挖掘目标深层物理特征,从而突破传统幅度图像表征能力的局限性。此外,引入域自适应技术将有助于缩小仿真与实测数据之间的分布差异,为小样本条件下的模型训练提供新思路。

(2) 双基/多基 SAR 系统虽具备观测灵活性与隐蔽性优势,但其在复杂电磁环境中的稳健性仍需

提升。一种潜在的解决方案是发展蜂群 SAR 协同探测体系,通过分布式节点获取目标的多视角散射信息,并利用时-频-空三维联合处理抑制干扰。此类系统可结合强化学习动态优化节点部署策略,在强对抗条件下实现目标探测。同时,随着应用环境中目标类型的动态变化,传统封闭世界假设下的识别框架面临严峻挑战。未来需探索跨模态(如 SAR-光学)预训练与增量学习相结合的范式,使模型具备渐进式知识更新能力,这对应对突发性目标检测任务具有重要意义。

(3) 在算法实时性方面,现有检测网络的计算复杂度难以满足快速响应需求。未来研究须探索基于神经架构搜索的轻量化模型设计,通过动态卷积与自适应剪枝策略优化计算效率,并保持对多尺度目标的检测精度。值得注意的是,复杂场景下的背景杂波和目标遮挡问题仍须通过进一步构建大规模多场景数据集(如城市、丛林和沙漠等)与对抗性训练加以解决。

参考文献:

- [1] CHAN Y K, KOO V. An introduction to synthetic aperture radar (SAR)[J]. Progress in Electromagnetics Research B, 2008, 2: 27-60.
- [2] 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.
- [3] 李春升, 王伟杰, 王鹏波, 等. 星载 SAR 技术的现状与发展趋势[J]. 电子与信息学报, 2016, 38(1): 229-240.
- LI Chunsheng, WANG Weijie, WANG Pengbo, et al. Current situation and development trends of spaceborne SAR technology[J]. Journal of Electronics & Information Technology, 2016, 38(1): 229-240.
- [4] 刘寒艳, 宋红军, 程增菊. 条带模式, 聚束模式和滑动聚束模式的比较[J]. 中国科学院大学学报, 2011, 28(3): 410-417.
- LIU Hanyan, SONG Hongjun, CHENG Zengju, et al. Comparative study on stripmap mode, spotlight mode, and sliding spotlight mode[J]. Journal of University of Chinese Academy of Sciences, 2011, 28(3): 410-417.
- [5] MASSONNET D. Pre-processing of the VARAN synthetic aperture airborne radar[C]//Proceedings of International Geoscience and Remote Sensing Symposium, Remote Sensing: Moving Toward the 21st Century. [S.l.]: IEEE, 1988, 2: 715-720.
- [6] 王岩飞, 刘畅, 詹学丽, 等. 无人机载合成孔径雷达系统技术与应用[J]. 雷达学报, 2016, 5(4):

- 333-349.
- WANG Yanfei, LIU Chang, ZHAN Xueli, et al. Technology and applications of UAV synthetic aperture radar system[J]. Journal of Radars, 2016, 5(4): 333-349.
- [7] FAN Y, TIAN S, SHENG Q, et al. A coarse-to-fine vehicle detection in large SAR scenes based on GL-CFAR and PRID R-CNN[J]. International Journal of Remote Sensing, 2023, 44(8): 2518-2547.
- [8] TANG Tao, PENG Jing, XIANG Deliang. Vehicle target detection in SAR image based on complex data statistics and superpixel characteristics[EB/OL]. (2020-09-20). <https://doi.org/10.1117/12.2574442>.
- [9] CUI Y, TANG T, ZHOU X, et al. Vehicle target detection in complex scene SAR images based on co-saliency[C]//Proceedings of 2023 8th International Conference on Signal and Image Processing (ICSIP). Wuxi, China: [s.n.], 2023: 99-103.
- [10] 代晓康,殷君君,杨健.基于Wishart距离和超像素的极化SAR图像车辆检测[J].系统工程与电子技术, 2021, 43(10): 2766-2774, 2692.
- DAI Xiaokang, YIN Junjun, YANG Jian. Vehicle detection based on Wishart distance and superpixel in polarimetric SAR image[J]. Systems Engineering and Electronics, 2021, 43(10): 2766-2774, 2692.
- [11] 李国令,高飞.SAR图像特定目标检测的推荐方法[C]//第十二届全国信号和智能信息处理与应用学术会议.北京:北京航空航天大学,2018:155-160.
- LI Guoling, GAO Fei. A recommendation method for SAR specific target detection[C]//Proceedings of the 12th National Conference on Signal and Intelligent Information Processing and Applications. Beijing: Beihang University, 2018: 155-160.
- [12] 计科峰,匡纲要,郁文贤.基于线性回归的SAR目标方位角估计方法[J].现代雷达,2004, 26(11): 26-29.
- JI Kefeng, KUANG Gangyao, YU Wenxian. A method of estimating target azimuth from SAR image based on linear regression[J]. Modern Radar, 2004, 26(11): 26-29.
- [13] WANG Z, DU L, MAO J, et al. SAR target detection based on SSD with data augmentation and transfer learning[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(1): 150-154.
- [14] WEI D, DU Y, DU L, et al. Target detection network for SAR images based on semi-supervised learning and attention mechanism[J]. Remote Sensing, 2021, 13(14): 2686.
- [15] 李庆,田甜,田金文.基于YOLOv5架构的大幅面SAR图像车辆目标识别方法[J].计算机与数字工程, 2023, 51(12): 2852-2858.
- LI Qing, TIAN Tian, TIAN Jinwen. Vehicle target recognition of large-scale sar images based on YOLOv5[J]. Computer & Digital Engineering, 2023, 51(12): 2852-2858.
- [16] 李毅,杜兰,杜宇昂.基于特征分解卷积神经网络的SAR图像目标检测方法[J].雷达学报, 2023, 12(5): 1069-1080.
- LI Yi, DU Lan, DU Yuang. Convolutional neural network based on feature decomposition for target detection in SAR images[J]. Journal of Radars, 2023, 12(5): 1069-1080.
- [17] NOVAK L M, OWIRKA G J, BROWER W S. An efficient multi-target SAR ATR algorithm[C]//Proceedings of Conference Record of Thirty-Second Asilomar Conference on Signals, Systems and Computers [S.]. IEEE, 1998: 3-13.
- [18] 周雨,王海鹏,陈思喆.基于数值散射模拟与模型匹配的SAR自动目标识别研究[J].雷达学报, 2015, 4(6): 666-673.
- ZHOU Yu, WANG Haipeng, CHEN Sizhe. SAR automatic target recognition based on numerical scattering simulation and model-based matching[J]. Journal of Radars, 2015, 4(6): 666-673.
- [19] ZHOU J, SHI Z, CHENG X, et al. Automatic target recognition of SAR images based on global scattering center model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3713-3729.
- [20] WANG N, WANG Y, LIU H, et al. Feature-fused SAR target discrimination using multiple convolutional neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1695-1699.
- [21] ZOU H, LIN Y, HONG W. Research on multi-aspect SAR images target recognition using deep learning[J]. Journal of Signal Processing, 2018, 34(5): 512-522.
- [22] PEI J, HUANG Y, HUO W, et al. SAR automatic target recognition based on multiview deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(4): 2196-2210.
- [23] 陈文婷,邢相薇,计科峰.SAR图像舰船目标识别综述[J].现代雷达, 2012, 34(11): 53-58.
- CHEN Wenting, XING Xiangwei, JI Kefeng. A survey of ship target recognition in SAR images[J]. Modern Radar, 2012, 34(11): 53-58.
- [24] CHEN S, WANG H, XU F, 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.
- [25] HOUSSEINI A, TOUMI A, KHENCHAF A. Deep learning for target recognition from SAR images[C]//Proceedings of 2017 Seminar on Detection Systems

- Architectures and Technologies (DAT). [S.l.]: IEEE, 2017: 1-5.
- [26] WAGNER S A. SAR ATR by a combination of convolutional neural network and support vector machines [J]. IEEE Transactions Aerospace and Electronic Systems, 2016, 52(6): 2861-2872.
- [27] FURUKAWA H. Deep learning for target classification from SAR imagery: Data augmentation and translation invariance[EB/OL]. (2017-08-26). <https://doi.org/10.48550/arXiv.1708.07920>.
- [28] HUANG Z L, PAN Z X, LEI B. What, where, and how to transfer in SAR target recognition based on deep CNNs[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(4): 2324-2336.
- [29] ZHANG F, HU C, YIN Q, et al. Multi-aspect-aware bidirectional LSTM networks for synthetic aperture radar target recognition[J]. IEEE Access, 2017, 5: 26880-26891.
- [30] LYU J, ZHU D, GENG Z, et al. Efficient target detection of monostatic/bistatic SAR vehicle small targets in ultracomplex scenes via lightweight model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1-20.
- [31] GE Z. YOLOX: Exceeding YOLO series in 2021[EB/OL]. (2021-08-06). <https://doi.org/10.48550/arXiv.2107.08430>.
- [32] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2018: 4510-4520.
- [33] 王智睿, 康玉卓, 曾璇, 等. SAR-AIRcraft-1.0: 高分辨率 SAR 飞机检测识别数据集[J]. 雷达学报, 2023, 12(4): 906-922.
- WANG Zhirui, KANG Yuzhuo, ZENG Xuan, et al. SAR-AIRcraft-1.0: High-resolution SAR aircraft detection and recognition dataset[J]. Journal of Radars, 2023, 12(4): 906-922.
- [34] XIA R, CHEN J, HUANG Z, et al. CRTransSar: A visual transformer based on contextual joint representation learning for SAR ship detection[J]. Remote Sensing, 2022, 14(6): 1488.
- [35] ZHOU P, WANG P, ZHU D, et al. SFANet: Efficient detection of vehicle targets in SAR images based on SAR-specialized feature aggregation[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-16.
- [36] LYU J, ZHU D, GENG Z, et al. Recognition for SAR deformation military target from a new MiniSAR dataset using multi-view joint transformer approach [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 210: 180-197.
- [37] Van Der MAATEN L. Accelerating t-SNE using tree-based algorithms[J]. The Journal of Machine Learning Research, 2014, 15(1): 3221-3245.
- [38] Texas Instruments Incorporated. TMS320C66xDSP CorePac user guide[M]. Texas: Texas Instruments Incorporated, 2011: 23-26.

(编辑:刘彦东)