

基于散射点拓扑和双分支卷积神经网络的SAR图像小样本舰船分类

张翼鹏^{①②③④⑤} 卢东东^{*①②} 仇晓兰^{①②③④} 李飞^{①②③④}

^①(苏州市微波成像处理与应用技术重点实验室 苏州 215128)

^②(苏州空天信息研究院 苏州 215128)

^③(中国科学院空天信息创新研究院 北京 100094)

^④(中国科学院大学 北京 100049)

^⑤(中国科学院大学电子电气与通信工程学院 北京 100049)

摘要: 随着合成孔径雷达(SAR)图像在舰船检测和识别领域的广泛应用, 准确而高效地进行舰船分类已经成为一个亟待解决的问题。在小样本学习场景下, 一般的方法面临着泛化能力不足的问题, 因此该文引入了额外的信息和特征, 旨在增加模型对目标的理解和泛化能力。该文通过散射关键点构建拓扑结构以表征舰船目标的结构和形状特征, 并计算拓扑结构的拉普拉斯矩阵, 将散射点之间的拓扑关系转化为矩阵形式, 最后将SAR图像和拉普拉斯矩阵分别作为双分支网络的输入进行特征提取。在网络结构方面, 该文设计了一个由两个独立的卷积分支组成的双分支卷积神经网络, 分别负责处理视觉特征和拓扑特征, 并用两个交叉融合注意力模块分别对两个分支的特征进行交互融合。该方法有效地将目标散射点拓扑关系与网络的自动学习过程相结合, 从而增强模型的泛化能力并提高分类精度。实验结果表明, 在OpenSARShip数据集上, 所提方法在1-shot和5-shot任务的平均准确率分别为53.80%和73.00%。而在FUSAR-Ship数据集上, 所提方法分别取得了54.44%和71.36%的平均准确率。所提方法在1-shot和5-shot的设置下相比基础方法准确率均提升超过15%, 证明了散射点拓扑的应用对SAR图像小样本舰船分类的有效性。

关键词: 合成孔径雷达(SAR); 舰船分类; 小样本学习; 散射点拓扑; 双分支卷积神经网络

中图分类号: TN957.52

文献标识码: A

文章编号: 2095-283X(2024)02-0411-17

DOI: 10.12000/JR23172

引用格式: 张翼鹏, 卢东东, 仇晓兰, 等. 基于散射点拓扑和双分支卷积神经网络的SAR图像小样本舰船分类[J]. 雷达学报(中英文), 2024, 13(2): 411-427. doi: 10.12000/JR23172.

Reference format: ZHANG Yipeng, LU Dongdong, QIU Xiaolan, *et al.* Few-shot ship classification of SAR images via scattering point topology and dual-branch convolutional neural network[J]. *Journal of Radars*, 2024, 13(2): 411-427. doi: 10.12000/JR23172.

Few-shot Ship Classification of SAR Images via Scattering Point Topology and Dual-branch Convolutional Neural Network

ZHANG Yipeng^{①②③④⑤} LU Dongdong^{*①②} QIU Xiaolan^{①②③④} LI Fei^{①②③④}

^①(Suzhou Key Laboratory of Microwave Imaging, Processing and Application Technology, Suzhou 215128, China)

^②(Suzhou Aerospace Information Research Institute, Suzhou 215128, China)

^③(Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China)

收稿日期: 2023-09-21; 改回日期: 2023-10-28; 网络出版: 2023-11-17

*通信作者: 卢东东 ludongdong@tju.edu.cn *Corresponding Author: LU Dongdong, ludongdong@tju.edu.cn

基金项目: 国家自然科学基金(61991421, 62022082)

Foundation Items: The National Natural Science Foundation of China (61991421, 62022082)

责任编辑: 王智睿 Corresponding Editor: WANG Zhirui

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License

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

^④(University of Chinese Academy of Sciences, Beijing 100049, China)

^⑤(School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: With the widespread application of Synthetic Aperture Radar (SAR) images in ship detection and recognition, accurate and efficient ship classification has become an urgent issue that needs to be addressed. In few-shot learning, conventional methods often suffer from limited generalization capabilities. Herein, additional information and features are introduced to enhance the understanding and generalization capabilities of the model for targets. To address this challenge, this study proposes a few-shot ship classification method for SAR images based on scattering point topology and Dual-Branch Convolutional Neural Network (DB-CNN). First, a topology structure was constructed using scattering key points to characterize the structural and shape features of ship targets. Second, the Laplacian matrix of the topology structure was calculated to transform the topological relations between scattering points into a matrix form. Finally, the original image and Laplacian matrix were used as inputs to the DB-CNN for feature extraction. Regarding network architecture, a DB-CNN comprising two independent convolution branches was designed. These branches were tasked with processing visual and topological features, employing two cross-fusion attention modules to collaboratively merge features from both branches. This approach effectively integrates the topological relations of target scattering points into the automated learning process of the network, enhancing the generalization capabilities and enhancing the classification accuracy of the model. Experimental results demonstrated that the proposed approach obtained average accuracies of 53.80% and 73.00% in 1-shot and 5-shot tasks, respectively, on the OpenSARShip dataset. Similarly, on the FUSAR-Ship dataset, it achieved average accuracies of 54.44% and 71.36% in 1-shot and 5-shot tasks, respectively. In the case of both 1-shot and 5-shot tasks, the proposed approach outperformed the baseline by >15% in terms of accuracy, underscoring the effectiveness of incorporating scattering point topology in few-shot ship classification of SAR images.

Key words: Synthetic Aperture Radar (SAR); Ship classification; Few-shot learning; Scattering point topology; Dual-Branch Convolutional Neural Network (DB-CNN)

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)通过发射微波波段的电磁波,并接收和处理回波信号,能够全天时全天候地对地表或目标进行高精度成像。由于其独特的工作原理,SAR技术在航空航天、地质勘探、环境监测、海洋监视等领域发挥着重要作用^[1]。其中,SAR图像舰船分类是通过分析SAR图像中的舰船特征信息,实现对不同类型舰船的准确区分,可为海上巡航、安全监测等领域提供有力支持^[2]。

传统的SAR舰船分类算法通常需要手动提取舰船特征,并使用经典的机器学习分类器来进行舰船类型的判断。这些手动提取的特征包括舰船的几何特征(如长宽比、面积等)、纹理特征(如灰度共生矩阵等^[3])、散射强度、方向梯度直方图等。这些特征通常被认为是能够反映舰船形状、结构、材料等信息的关键特征^[4]。在特征提取之后,通常会使用一些经典的机器学习分类器,如支持向量机(Support Vector Machine, SVM)^[5]、k最近邻(k-Nearest Neighbors, k-NN)^[6]等,来对舰船进行分类。这些分类器通常需要大量的训练数据来进行训练,并且

需要进行大量的参数调整以达到最佳的识别效果。传统的SAR舰船识别算法的主要缺点是需要手动提取特征,这需要专业知识和经验,并且特征的提取往往需要花费大量的时间和精力。此外,由于传统算法缺乏鲁棒性,因此它在复杂场景下的识别效果通常较差^[7]。

近年来,基于深度学习的SAR舰船识别算法已得到广泛的研究和讨论。这些算法的出现不仅在舰船识别准确性和效率方面取得了重大提升,而且还成功地克服了传统手动特征提取方法的局限性。尤其是在对船舶尺寸、形状和方向变化的鲁棒性方面,基于深度学习的方法有着出色的表现^[8]。传统的手动特征提取方法已经逐渐被自动化的特征学习和端到端的深度学习方法取代。近年来,研究人员提出了许多基于深度学习的SAR舰船识别模型。这些模型通常使用大型数据集进行训练,通过多层次的卷积和池化操作来逐步提取特征,并在最后的分类层进行舰船类型的判断。然而,用于SAR图像分类的一般深度学习模型需要大量标记数据才能实现高性能的分类。但是获取SAR图像的标记数据既费时又昂贵,故数据集通常具有有限性和不平衡性,

严重限制了深度学习模型在实际场景中的适用性。解决这一问题的有效途径之一是利用小样本学习(Few-shot learning), 通过引入适当的采样策略、迁移学习技术以及模型架构的调整等策略, 让深度学习模型在有限数据下仍然表现出色, 从而克服数据稀缺性带来的挑战^[9]。

小样本学习是一种机器学习任务, 旨在通过限定的一小部分训练样本来学习新的类别或任务^[10]。传统的机器学习方法通常需要大量的标注数据来进行模型的训练, 而小样本学习则通过利用少量样本进行学习和泛化, 从而在面对新的、以前未见过的类别或任务时具有更强的适应性。小样本学习的方法可以分为基于数据扩充、基于元学习和基于迁移学习的方法。数据扩充是解决样本匮乏问题的最直接思路, 大部分研究通过生成模型或数据增强来实现数据的扩充^[11]。元学习通过在大量不同任务上进行训练, 使得模型能够快速适应新任务。元学习可以帮助模型学习到通用的特征提取和参数更新策略, 从而在小样本任务上表现更好^[12]。MAML (Model-Agnostic Meta-Learning)^[13]是一种经典的基于元学习的小样本学习方法, 它通过在多个不同任务上进行训练, 使模型能够学习到一种初始参数初始化方式, 使得在应用到新任务时, 只需进行少量梯度更新即可实现良好的性能。另外一些元学习方法结合了度量学习方法, 旨在通过学习如何度量样本之间的相似性来提高模型在小样本学习任务中的性能。ProtoNet (Prototypical Networks)^[14]通过计算每个类别的原型(样本的平均表示)来表示不同类别。在训练过程中, 它通过最小化查询样本与其所属类别原型之间的距离来进行优化。Relation-Net (Relation Network)^[15]引入了一个额外的神经网络来学习如何在新任务中计算样本之间的关系。它通过将两个样本的特征向量拼接起来, 然后通过神经网络来预测它们是否属于同一类别。MatchingNet (Matching Networks)^[16]使用一个神经网络来学习如何在新任务中进行样本匹配, 以便做出准确的预测。它将每个样本编码成一个向量, 并通过计算输入样本与每个类别的样本之间的相似度来进行分类。迁移学习是将已学习的知识迁移到新任务中的一种方法, 通过在较大规模的源任务上进行训练, 模型可以学习到通用的特征表示, 而这些学习到的特征可以在小样本任务中进行微调, 以提高模型性能^[17]。Baseline++^[18]旨在通过在少量标记支持集上对预训练模型进行微调并利用余弦相似度度量来增强距离度量学习过程, 从而改进基准模型。Meta-Baseline^[19]是另一种基于迁移学习的方法, 它

结合元学习和辅助损失函数, 使模型学习更具区分性的特征。

在SAR领域, 小样本学习已经得到了广泛的关注。Cui等人^[20]使用生成对抗网络(Generative Adversarial Networks, GAN)进行数据扩充, 通过生成合成的SAR图像来增加训练集的样本量, 从而提高目标识别性能。Ding等人^[21]结合小样本学习和数据扩充, 通过在原始图像上应用随机变换(如旋转、平移、缩放等)来生成额外的训练样本, 从而实现SAR图像分类任务中的小样本学习。Wang等人^[22]提出了一种基于深度神经网络的元学习方法, 用于小样本SAR目标识别。通过学习任务之间的相似性和共享特征, 模型可以在小样本情况下实现准确的目标识别。Pan等人^[23]采用基于度量学习的方法, 借助孪生网络实现了较高的识别准确率。Lu等人^[24]提出了一种基于迁移学习的深度卷积神经网络, 用于小样本SAR目标识别, 他们在新类别的一些示例上微调预训练的网络模型, 然后使用微调模型对新实例进行分类。Tai等人^[25]利用无连接注意模块选择性地特征从电光样本传输到SAR样本, 减少了对额外SAR样本的依赖。同时, 最近的一些研究^[26-30]提出了使用一组关键点来建模SAR目标中的局部散射区域, 以引导网络特征学习的方法。Kang等人^[26]提出一种网络旨在利用散射点关系模块来分析和关联离散散射点, 以解决SAR图像中飞机检测结果的完整性问题。散射点关系模块能够提取特征并建立散射点之间的连接, 从而克服了SAR成像中个体飞机的离散性问题。Sun等人^[27]提出一种新型统一框架, 用于在大规模SAR图像中精确定位和分类船舶, 通过捕捉船舶区域强散射点的分布特征。这种框架利用船舶分类编码器模块提取每个散射点之间的相关性和分布特征, 并结合强散射点的特征和分布信息来识别船舶类别。Sun等人^[28]提出一种新型网络模型, 用于少样本SAR飞机分类, 包括分类路径和一个利用散射提取模块引导网络学习每个目标类型的强散射点数量和分布的散射提取分支。散射提取分支采用散射提取模块来改善SAR目标特征表示, 并优化主要的分类任务, 从而在新型类别少样本识别任务上表现更好。吕艺璇等人^[29]提出的SAR图像飞机目标识别方法通过散射关联分类器指导网络学习更具有区分性的类间特征表示, 实现少样本条件下和SAR散射特性的有效结合, 提升在新类别上的泛化性能和快速识别能力。Kang等人^[30]引入了散射拓扑模块来建模散射点的空间关系和语义信息, 并通过图卷积网络(Graph Convolutional Network, GCN)来提取相关特征, 从而提升SAR图

像飞机分类的准确率。但受限于计算资源限制,基于GCN的方法通常使用9~20个散射点来构建拓扑结构。

尽管小样本学习方法在SAR图像领域取得了一些成功,但仍然存在问题需要解决。首先,SAR图像的成像机制与传统的光学图像不同,导致图像的纹理和特征表征更为复杂。SAR图像中的目标物体可能具有不同的散射特性,这需要在小样本学习中考虑如何更好地捕捉这些特征,以实现准确的分类。其次,入射角、极化等成像参数的变化会导致SAR图像呈现出显著的可变性,这使得相同目标在不同图像中可能呈现出不同的外观,从而增加了分类的难度。如何在小样本学习中充分考虑这些变化,以实现跨样本的泛化,是一个值得研究的问题。此外,SAR图像中由于成像变异性,可能导致类内差异性较高,而类间差异性较低,使得相似类之间难以区分。小样本学习方法需要在处理这种情况下,寻求更好的特征表示和分类策略,以实现更精确的目标分类。

为了应对上述问题,将SAR图像的散射特性集成到网络学习过程中是一种有效的技术途径。本文提出了一种新的网络并将散射特性集成到网络学习过程中,以提升网络的泛化能力和分类效果。本文的主要创新点归纳如下:(1)在特征提取方面,本文通过散射关键点构建拓扑结构以表征舰船目标的结构和形状特征,并计算拓扑结构的拉普拉斯矩阵,将散射点之间的拓扑关系转化为矩阵形式,最后将SAR图像和拉普拉斯矩阵分别作为双分支网络的输入进行特征提取。(2)在网络结构方面,本文设计了一个由两个独立的卷积分支组成的双分支卷积神经网络,分别负责处理不同视觉特征和拓扑特征,并用两个交叉融合注意力模块分别对两个分支的特征进行交互融合。通过上述两个方面,本方法将目标散射点拓扑关系与网络的自动学习过程相结合,从而增强模型的泛化能力并提高分类精度。

2 基于散射点拓扑和双分支卷积神经网络的SAR图像小样本舰船分类方法

2.1 问题定义

在小样本学习中, N -way K -shot是一种常见的任务设置。它用于评估模型在面对新类别时的学习能力。在这个任务中,我们有一个包含大量标记图像的基础类别数据集 C_{base} ,以及一组新颖类别 C_{novel} ,其中 $C_{\text{base}} \cap C_{\text{novel}} = \emptyset$ 。任务的目标是使用只有有限数量样本的新颖类别 C_{novel} ,来学习识别这些类别中的图像。数据集被分成两个子集:支持集和查询

集。支持集包含每个新颖类别的 K 个标记样本,用于模型学习该类别的特征。查询集则包含相同 N 个类别的未标记样本,用于评估模型在未知类别上的泛化能力。

具体而言, N -way K -shot表示支持集中有 N 个类别,每个类别有 K 个标记样本。例如,如果 $N=5$, $K=1$,那么我们的任务是从支持集中仅使用每个类别的一个样本来学习如何识别5个新颖类别。在查询阶段,我们会使用未标记的查询样本来测试模型对这些类别的分类准确性。 N -way K -shot任务的挑战在于模型需要通过有限的支持集样本来进行泛化学习,从而正确分类未知类别的查询样本。这要求模型能够从少量样本中捕捉到类别的共性特征,并将其应用于新的未见过的类别。

我们的小样本学习采用了一种特定的训练策略来提高模型对新颖类别的分类能力,具体流程如图1所示。以下是我们的训练策略的主要步骤:

步骤1 训练集:包含来自基础类别的大量标记图像。这个训练集的标签空间是与支持集和测试集完全不同的独立标签空间。

步骤2 基础分类器训练:在训练阶段,我们使用常规的图像分类方法来训练一个基础分类器 f_{θ} 。我们使用所有基础类别的标记图像,通过最小化标准的交叉熵损失来训练这个分类器。步骤2旨在让模型学习基础类别的特征和模式。

步骤3 支持集微调:为了使模型适应识别测试阶段中的新颖类别,我们将模型在支持集上进行微调。支持集包含了新颖类别中每个类别的 $N \times K$ 个标记图像。我们通过最小化损失来微调模型,使其能够更好地区分和识别支持集中的新颖类别。

步骤4 查询集测试:在微调后,我们使用经过微调的模型对查询集进行测试。查询集包含了与支持集相同的新颖类别,但是其中的图像是未标记的。我们使用微调后的模型对查询集中的每个图像进行分类,并评估模型在识别新颖类别方面的准确性。

通过这个训练策略,我们的目标是让模型通过少量样本学会泛化和识别新颖类别,从而提高在小样本学习任务中的性能。这种训练策略充分利用了支持集的信息来调整模型,以适应新颖类别的特征,从而提高模型在测试阶段的分类准确性。

2.2 模型框架

为了应对SAR目标样本数量有限、成像易变性和类间差异小等问题,本文提出了一种基于散射点拓扑的方法,将SAR目标的散射特性与卷积神经网络的自动学习过程相结合,以快速提升模型性能。该方法的整体网络结构如图2所示。

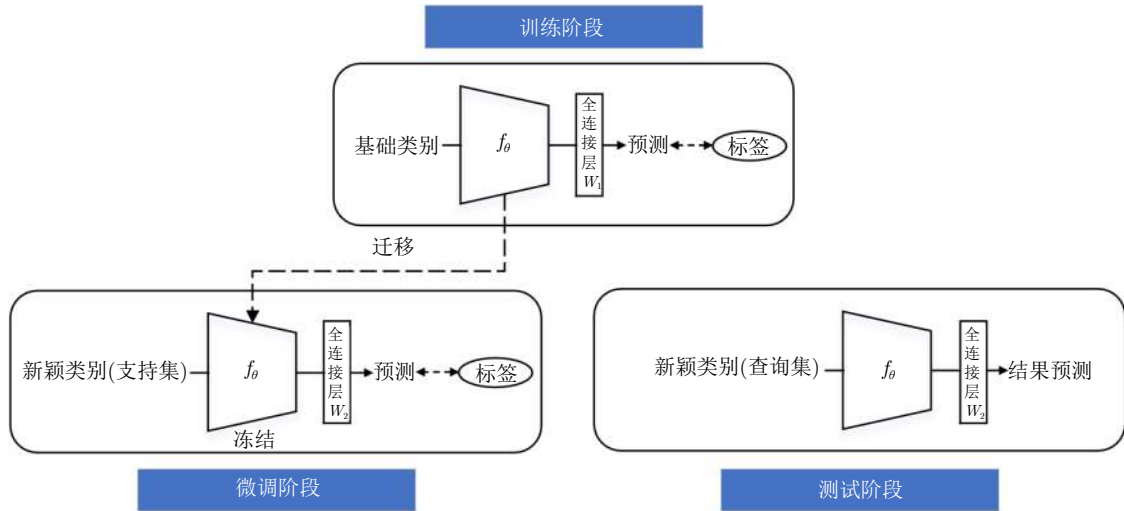


图1 训练和测试的设置

Fig. 1 Training and testing setup

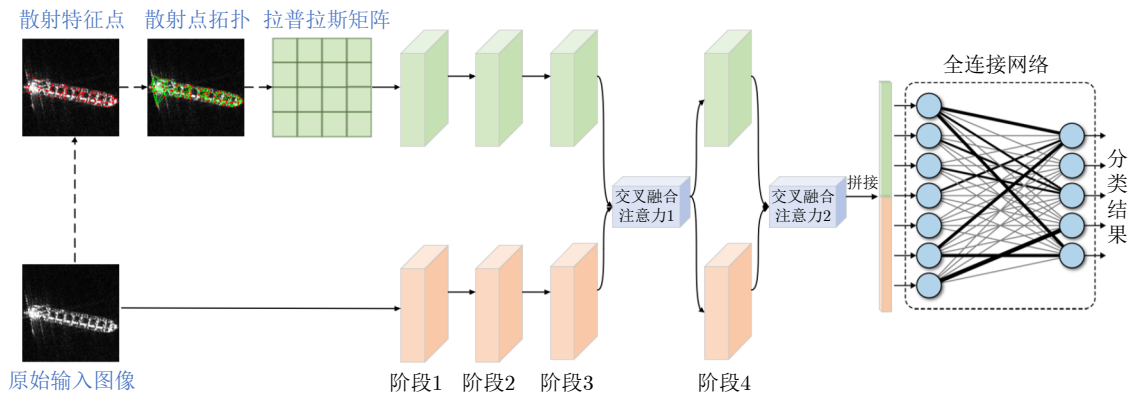


图2 整体网络架构

Fig. 2 Overall architecture of our method

该方法的基础框架是一个双分支卷积神经网络，其中每个分支采用ResNet-12^[19]作为基础架构。一个分支接受SAR图像作为输入，用于提取图像的视觉特征；另一个分支接受散射点拓扑的归一化拉普拉斯矩阵作为输入，用于捕捉目标的散射拓扑特征。这种双分支结构充分利用了图像和拓扑信息，为目标分类提供了多类别的特征表示。每个分支由4个阶段组成，每个阶段都包含一个残差块。每个残差块由3个具有 3×3 内核的卷积层、批归一化和具有0.1斜率的Leaky ReLU激活函数，以及一个步长为2的最大池化层组成。每个残差块的卷积层通道数依次为64, 128, 320和640。网络最后使用一个 5×5 的全局平均池化层，得到一个640维的特征向量。这样的层次结构使得网络能够逐步提取并组合不同层次的特征，从而实现目标多方面特征的捕捉。

为了充分融合视觉特征和拓扑特征，网络的第3阶段结束位置和第4阶段结束位置分别添加了一个交叉融合注意力模块。第1个交叉注意力模块使两个


网络分支可以在信息提取的过程中进行信息交互，使模型能够更好地进行特征学习。这两个交叉融合注意力模块使拓扑特征和视觉特征能够相互融合，相互利用有效的信息，从而显著提升模型的鲁棒性和准确性。第1个交叉注意力模块使两个网络分支能够在信息提取的过程中进行交互。这种交互促使网络从不同分支中获取互补的信息，从而丰富了模型对目标特征的理解。第2个交叉融合注意力模块进一步加强了拓扑特征和视觉特征之间的相互关联，有助于模型更好地捕捉目标的特点。通过这些交叉融合注意力模块，视觉特征和拓扑特征能够相互融合，从而加强了两者的联系。这种融合能够增强模型对目标的多方面表征，使得模型在处理样本数量有限、成像易变性和类间差异小等挑战时更具鲁棒性。通过将交叉融合注意力模块嵌入到网络中，该方法能够在特定任务中实现性能的快速提升。这意味着模型在小样本学习场景下能够更快地适应目标分类任务，从而有效地克服了数据稀缺带来的问题。

2.3 散射拓扑特征

2.3.1 散射特征点

本文采用了Harris角点检测器^[31]作为一种特征提取方法,用于从单极化SAR图像中提取散射特征点,以反映舰船的结构特征。Harris角点检测器是一种广泛应用于计算机视觉领域的技术,其原理是通过分析图像中的局部灰度变化来确定角点的位置。具体来说,对于每个像素点,Harris角点检测器计算其周围像素的梯度,并在每个点处应用一个 2×2 的卷积窗口,然后计算窗口内像素的灰度变化程度。在本文中,窗口的大小被设置为3,以便捕捉局部灰度变化。为了确保角点有更均匀的分布,我们使用了 5×5 大小的窗口对提取到的角点进行了非极大值抑制。这意味着只有每个 5×5 区域内响应值最大的点会被保留。另外,部分舰船旁瓣具有明亮的尖锐突出结构,如果提取到的角点出现在这些旁瓣上,会对舰船结构的表征产生影响,从而影响模型的效果。因此,我们引入了结构验证函数。这个结构验证函数首先提取了位于Harris角点位置附近的局部窗口。然后计算该窗口内像素的平均强度。如果平均强度超过了预定义的强度阈值,则将角点视为有效。本文中,将结构验证函数窗口设置为11,强度阈值定义为50。最后,从所有保留的角点中选择响应值最大的 m 个点(本文中设置为84),将这些被选取的点定义为散射特征点。

这些散射特征点在单极化SAR图像中的分布和相对位置能够反映舰船的结构特征。以图3为例,集装箱货船在不同箱体间呈现出明显的条纹状分布,而油船的散射特征点则集中在输油管道附件。这些散射特征点往往对应船体的关键部件和结构,它们的散射强度较大且与杂波背景的散射强度变化较显著。因此,这些点可以用来揭示舰船的结构特征,帮助识别不同类型的船只。通过Harris角点检测器提取出的响应最大的 m 个点,即散射特征点,能够在一定程度上提供有关舰船结构的重要信息。



(a) 集装箱船
(a) Container ship
(b) 油船
(b) Tanker

图3 散射特征点

Fig. 3 Scattering feature points


本文通过选择Harris角点检测器并设定适当的窗口大小,成功提取了具有显著散射强度变化的散射特征点。这些特征点的分布和相对位置提供了关于舰船特有特征的重要信息,对于舰船分类和结构分析具有重要意义。通过在单极化SAR图像中捕捉散射特征点,能够为后续的舰船分类和识别任务提供有力的特征表示,为SAR图像中的舰船目标提供更精确的分析和理解。这种方法不仅有助于增强对舰船结构的认知,还为深度学习等更高级的算法提供了重要的先验信息。

2.3.2 散射点拓扑

在SAR图像中,目标的散射点分布呈现出一定的拓扑结构,这是由于相邻的散射点之间存在着空间关系和相互作用。对这些散射点进行拓扑分析可以揭示目标的关键形状、边界以及内部结构等重要信息。在前文中,我们提到了使用Harris角点检测器提取的散射特征点,现在我们将进一步深入研究这些散射特征点,并探索它们之间的空间关系。

具体而言,我们可以为每个散射特征点寻找其 k 个最近邻的散射特征点,然后通过欧氏距离来定义它们之间的连接权重。这样,我们就能够建立起散射点之间的拓扑结构,形成一个散射点图。在这个图中,每个散射特征点作为一个节点,它们之间的连接关系则构成了图的边。这种散射点拓扑结构可以提供丰富的目标信息,对于目标的识别和分类具有重要意义。

在SAR图像目标识别中,通过分析散射点拓扑结构中的连接关系,可以获取目标的形状和边界信息。不同目标的散射点拓扑结构在连接方式上可能存在差异,这可以用来区分目标与背景之间的差异。例如,在图4中,散射点拓扑结构能够反映出集装箱船和油船的不同结构,从而有助于对它们进行分类和识别。散射点拓扑结构还可以揭示目标的内部结构特征,例如孔洞、凹凸等。通过分析连接关系,可以辨别目标内部的空洞结构,这对于特定目标类



(a) 集装箱船
(a) Container ship
(b) 油船
(b) Tanker

图4 散射点拓扑

Fig. 4 Scattering point topology

别的分类具有重要意义。散射点拓扑结构提供了一种独特的、基于空间关系的特征表示方法，能够更好地捕捉目标的形状和结构信息。这对于舰船分类和识别任务非常有帮助，尤其是在样本数量有限、成像易变性高等挑战性情境下。

2.3.3 特征变换

为了让散射点拓扑特征能够像正常图像一样被卷积神经网络(Convolutional Neural Network, CNN)处理，我们需要将拓扑结构转换为矩阵形式。拉普拉斯矩阵是一种用于表示图的重要工具，它捕获了图中节点之间的连接关系。这对于散射点拓扑结构来说同样适用。通过构建拉普拉斯矩阵，我们将散射点的拓扑结构表示为矩阵形式，这有助于将其引入到卷积神经网络中进行进一步的处理。为此，我们可以利用拉普拉斯矩阵对散射点拓扑进行表示，它包含散射点拓扑结构的重要信息。

在这种情况下，将拉普拉斯矩阵与CNN结合会有利于任务的执行。然而，在构建拉普拉斯矩阵之前，节点的排序方式可以对矩阵的构建产生重要影响。不同的排序方法可能会导致卷积后得到的拓扑特征发生一定的改变。这是因为拉普拉斯矩阵的构建过程受到节点的排列顺序的影响，不同的排列顺序会导致不同的拉普拉斯矩阵，进而影响卷积操作的结果。在CNN中，卷积操作通常是基于滤波器与输入特征之间的互相关，这意味着滤波器会对输入数据的局部结构进行敏感。如果输入数据(即拉普拉斯矩阵)的节点排列方式不同，其局部结构也会不同，从而影响卷积操作的结果。具体而言，不同的排序方式可能会引入不同的局部连接模式，这可能导致滤波器的响应模式也发生变化。因此，我们采用了一种排序策略，即按照Harris角点检测器的响应值从大到小的顺序对节点进行排序。这种排序策略有助于确保显著特征点在拉普拉斯矩阵中具有更高的重要性，从而有助于CNN捕获图中的关键结构信息。

另一个关键步骤是对拉普拉斯矩阵进行适当的预处理，以确保它符合CNN的输入要求。对拉普拉斯矩阵进行对称归一化是一个常见的步骤。这可以通过左乘和右乘度数矩阵的逆来实现，以减轻不同节点度数变化的影响。这种归一化确保了矩阵的稳定性和数值特性，使其适合神经网络的输入。归一化拉普拉斯矩阵的运用将散射点拓扑转化为一种在CNN中可以处理的形式，从而可以应用卷积操作和其他图像处理技术，以进行特征提取和分类。具体来说，我们使用以下公式来计算散射点拓扑的归一化拉普拉斯矩阵：

$$L_N = D^{-\frac{1}{2}} (D - W) D^{-\frac{1}{2}} \quad (1)$$

其中， D 表示度矩阵， W 表示考虑权值的邻接矩阵。 D 是一个对角矩阵，其中第 i 个对角元素为节点 i 与其他所有节点之间的连接权重之和，即邻接矩阵 W 第 i 行的元素之和。 W 则表示了节点之间的连接关系和对应的权值。对应权值为两个节点间在拓扑结构上的最短路径距离。归一化拉普拉斯矩阵的对角元素均为1，而其第 i 行和第 i 列反映了节点 i 与其他所有节点之间的相似性或交互程度。当节点 i 受到扰动时，拉普拉斯矩阵中的第 i 行可以反映出这个扰动在其他节点上产生的增益累积效应。因此，拉普拉斯矩阵提供了一种度量散射点拓扑结构中相邻节点之间关系的方式。通过将散射点拓扑转换为拉普拉斯矩阵形式，我们可以利用矩阵运算和特征提取方法来处理拓扑特征。在CNN中，这种转换使得我们可以将散射点拓扑作为输入数据，并应用卷积操作和其他常用的图像处理技术。这样，我们能够在CNN中对散射点拓扑进行特征提取和分类。

2.4 交叉融合注意力机制

本文设置了交叉融合注意力模块，将两个卷积分支网络之间的信息进行交互和融合，使得网络可以更好地同时利用视觉特征和拓扑特征。具体结构如图5所示。

交叉融合注意力的主要目标是增强融合特征的判别能力，通过考虑不同来源特征之间的相互关系和贡献，使模型能够专注于每个特征集中最相关且信息量最大的部分。在本文中，交叉融合注意力被用于有效融合散射点拓扑特征和从卷积神经网络获得的图像特征，通过引入两个交叉融合注意力模块来促进跨特征类别学习。这些交叉注意力模块旨在捕获拓扑特征和视觉特征之间的相互信息，并增强两种特征之间的交互。如果拓扑特征能够确认目标中的视觉特征的语义意义，那么交叉注意力机制将放大目标中的视觉特征。具体而言，首先将输入的特征进行层归一化，这有助于保持一致的尺度并提高训练的稳定性。然后，通过全连接网络层将特征投射到共同的内部维度 C ，本文中 C 设置为512。视觉特征向量和拓扑特征向量分别被表示为 \mathbf{x}_V ， $\mathbf{x}_T \in \mathbb{R}^{1 \times C}$ 。然后这些特征再次投射后被表示为 \mathbf{q} ， \mathbf{k} ， \mathbf{v}_V 和 \mathbf{v}_T ，其中 \mathbf{q} 表示查询特征， \mathbf{k} 表示键特征， \mathbf{v} 表示值特征。通过计算注意力矩阵 \mathbf{A} ，将查询特征和键特征之间的相互关系和贡献考虑进来。注意力矩阵的计算使用了注意力公式，其中 \mathbf{q} 和 \mathbf{k} 的点积被除以内部维度的平方根来进行缩放，然后应用

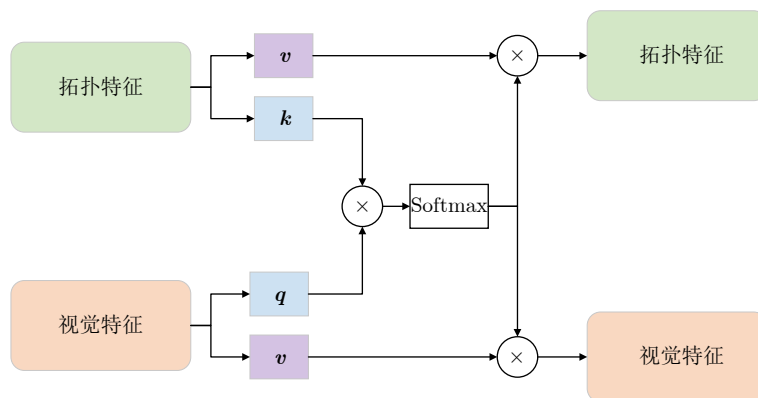


图5 交叉融合注意力机制

Fig. 5 Cross fusion attention mechanism

softmax函数来获得注意力分布。这个注意力矩阵 A 可以被用来加权求和值特征，从而得到融合后的视觉特征 x'_V 和拓扑特征 x'_T 。具体公式如下：

$$\begin{aligned} q &= x_V W_q, k = x_T W_k, v_V = x_V W_v, v_T = x_T W_v, \\ A &= \text{softmax} \left(\frac{qk^T}{\sqrt{C/h}} \right), x'_V = Av_V, x'_T = Av_T \end{aligned} \quad (2)$$

其中， $W_q, W_k, W_v \in \mathbb{R}^{C \times (C/h)}$ 是可学习的参数， C 为内部维度， h 为注意力头数量， 本文 h 设置为8。

3 实验结果与分析

3.1 实验数据

(1) OpenSARShip数据集：OpenSARShip数据集^[32]是一个专为船舶解译任务而设计的全面的Sentinel-1合成孔径雷达图像集合。该数据集由在不同海域、环境条件和季节中获取的Sentinel-1图像组成，对于海上监视和相关应用的研究具有重要价值。该数据集包含超过60,000个SAR图像切片，每个切片尺寸为256像素×256像素。这些切片中包含约20,000艘船舶，具有详细的注释，包括船舶位置、长度和宽度，以及相关的环境信息，如风速和波高。该数据集还包含各种类型的船舶，例如散货船、集装箱船、渔船、油轮、客船和拖船等。在本文实验中，我们从该数据集中选择了8个不同的类别。其中，4个样本数量较多的类别作为训练集，剩下的4个样本数量较少的类别作为测试集，详见表1。

(2) FUSAR-Ship数据集：FUSAR-Ship数据集^[33]是使用高分三号(Gaofen-3) SAR图像和相关自动识别系统(Automatic Identification System, AIS)数据构建的高分辨率SAR-AIS配对数据集。该数据集专门用于促进船舶检测、识别和海上监视的研究，通过提供具有准确的船舶位置和识别信息的高分辨率SAR图像以及相应的AIS数据。FUSAR-Ship包

表1 实验数据集设置

Tab. 1 The dataset settings in our experiment

数据集	基础类别	样本数量	新颖类别	样本数量
OpenSARShip	Cargo	8240	Dredgin	80
	Fishing	126	Passeng	38
	Tanker	1670	Pilot	14
	Tug	176	Search	24
	合计	10212	合计	156
FUSAR-Ship	Cargo	1289	HighSpeedCraft	15
	Dredger	51	LawEnforce	27
	Fishing	563	Reserved	28
	Tanker	157	Passenger	31
	Unspecified	111	Tug	44
合计	2171	合计	145	

含超过10,000个SAR图像切片，每个切片尺寸为500像素×500像素。这些图像是由高分三号卫星获取的，该卫星具有高达1 m的空间分辨率。该数据集涵盖了不同的海域、环境条件和船舶类型，增强了其在算法开发和评估中的多样性。数据集中的AIS数据提供了船舶的识别、位置、航向、速度、尺寸和其他相关属性。在本实验中，我们从该数据集中选择了10个不同的类别。其中，5个样本数量较多的类别作为训练集，剩下的5个样本数量较少的类别作为测试集，详见表1。

3.2 实验配置

在我们的实验中，我们采用了5-way 1-shot和5-way 5-shot配置在FUSAR-Ship数据集和OpenFUSAR数据集上，以及在OpenSARShip数据集上采用4-way 1-shot和4-way 5-shot配置，每个类别使用5个查询图像，如表2所示。这种配置帮助我们评估模型在不同数据集上的适应性以及在不同类别数量下的性能。

表2 实验数据设置
Tab. 2 Experimental data setting

数据集	1-shot		5-shot	
	支持集	查询集	支持集	查询集
OpenSARShip	1×4	5	5×4	5
FUSAR-Ship	1×5	5	5×5	5

为了保持一致性，我们将所有输入图像调整为固定的84像素×84像素分辨率。在训练阶段，我们设置了200次迭代来训练我们的模型。我们使用随机梯度下降(Stochastic Gradient Descent, SGD)作为优化器，并且根据配置使用了学习率为0.01，动量为0.9，阻尼为0.9以及权重衰减为0.001。为了进一步优化模型性能，我们进行了微调过程，总共进行了150个步骤。在测试阶段，我们从随机选择的 N -way K -shot任务中随机选择了100个任务，每个任务的批量大小为4。这样的测试设置使我们能够在更真实的环境中评估模型的表现。在我们的架构中，我们特别关注了散射点拓扑的特征维度和视觉特征的维度的匹配。为此，我们将两个分支网络的输入尺寸都设置为了84像素×84像素，与输入图像的分辨率相同。此外，我们将散射关键点的默认数量 m 设置为84，以确保其维度与图像特征相匹配，从而能够有效地进行特征融合和比较。最后，为了确定散射点拓扑的结构，我们将默认的最近邻节点数 k 设置为8。这有助于捕获散射点之间的局部关系和拓扑信息，从而在目标识别任务中提供更准确的特征表示。在整个实验过程中，我们使用了单个48 GB NVIDIA RTX 8000 GPU来进行模型的训练和测试。通过这些实验设置和配置，我们能够全面评估我们的模型在不同数据集、类别数量和支持集大小下的性能，为小样本目标识别任务的研究和应用提供有价值的见解。

3.3 评估指标

对于每个回合，准确率被计算为正确分类的查询图像数量与总查询图像数量之比。计算过程如式(3)所示，其中， L_q 表示总的查询图像数量。变量 p_i 和 t_i 分别代表第 i 张查询图像的预测类别和真实类别。指示函数 \mathbb{I} 在 $p_i = t_i$ 时等于1，在其他情况下等于0。

$$\text{Acc}_j = \frac{1}{L_q} \sum_{i=0}^{L_q} \mathbb{I}(p_i = t_i) \quad (3)$$

为了减少随机性的影响，实验进行多次，并且最终准确率通过所有回合准确率的平均值确定，如式(4)所示。其中，变量 L 指的是实验的重复次数。在实验中， L 设置为100，以提供更可靠的评估结果。

$$\text{Acc} = \frac{1}{L} \sum_{j=0}^L \text{Acc}_j \quad (4)$$

通过利用这个评估指标，我们可以更精确地估计模型的性能。

3.4 实验结果

在本文实验中，我们聚焦于在OpenSARShip数据集和FUSAR-Ship数据集上评估我们提出的方法，以及与一系列基础方法的性能进行比较。这些方法包括MatchingNet^[16]，ProtoNet^[14]，RelationNet^[15]，MAML^[13]，Baseline^[18]，Baseline++^[18]，NegMargin^[34]和MetaBaseline^[19]。这些方法代表了不同的范式，涵盖了度量学习、元学习、微调等不同的思路。通过对比，我们能够更全面地评估本文所提方法的优势。首先，我们考虑了MatchingNet, ProtoNet和RelationNet等基于度量学习的方法。这些方法在处理小样本学习任务时，通常通过度量学习的方式在特征空间中度量样本之间的相似性，从而进行分类。另一方面，MAML则是一种基于元学习的方法，通过训练模型使其能够快速适应新任务。Baseline和Baseline++是基于微调的方法，通常在预训练模型的基础上进行微调，以适应特定任务。NegMargin则是基于梯度的方法，着重于优化分类边界。而MetaBaseline则是将微调和元学习方法结合起来。

在这个背景下，我们的方法在OpenSARShip数据集和FUSAR-Ship数据集上进行了1-shot和5-shot实验，并与上述基础方法进行了比较，如表3所示。结果表明，我们的方法在1-shot和5-shot任务上表现出卓越的性能，取得了最高的识别精度。具体来说，在OpenSARShip数据集上，我们的方法在1-shot和5-shot任务的平均准确率分别为53.80%和73.00%。这些指标显著超过其他方法的平均准确率。在1-shot任务中，最接近我们方法性能的是NegMargin方法，其平均准确率为36.15%。而在5-shot任务中，最接近我们方法性能的是Baseline方法，其平均准确率为43.40%。在FUSAR-Ship数据集上，我们的方法在1-shot和5-shot任务中分别达到了54.44%和71.36%的性能指标，也明显高于其他次优方法的31.96%和37.32%。

除了对比主流小样本学习外，考虑到类似的工作在飞机目标识别领域已有开展，我们还对比了基于图卷积网络(GCN)提取拓扑结构特征的方法。在基于图卷积的方法中，散射点的数量被设置为20。除在FUSAR-Ship数据集上的1-shot设置下本文方法准确率比基于GCN的方法准确率略低，在其他设置下表现均明显优于基于GCN的方法。这说明了本

表3 本文方法和其他方法性能的对比(%)
Tab. 3 Comparison of performance of our method and other methods (%)

方法	OpenSARShip		FUSAR-Ship	
	1-shot	5-shot	1-shot	5-shot
MatchingNet ^[16]	30.20 \pm 1.66	33.30 \pm 1.70	31.88 \pm 1.96	34.00 \pm 1.44
ProtoNet ^[14]	32.00 \pm 1.97	37.35 \pm 2.19	30.64 \pm 2.01	35.40 \pm 1.68
RelationNet ^[15]	29.64 \pm 2.04	30.60 \pm 1.73	31.12 \pm 1.53	31.12 \pm 1.53
MAML ^[13]	29.60 \pm 2.13	33.10 \pm 1.87	31.32 \pm 1.81	32.40 \pm 1.71
Baseline ^[18]	35.85 \pm 2.00	43.40 \pm 2.04	31.68 \pm 1.56	37.32 \pm 2.00
Baseline++ ^[18]	35.35 \pm 2.09	40.90 \pm 1.84	31.96 \pm 1.79	35.64 \pm 1.83
NegMargin ^[34]	36.15 \pm 2.15	41.05 \pm 1.86	30.68 \pm 1.91	35.68 \pm 1.89
MetaBaseline ^[19]	32.51 \pm 2.03	38.60 \pm 1.86	30.32 \pm 1.88	34.52 \pm 1.83
基于GCN的方法	47.50 \pm 2.47	71.05 \pm 2.48	55.76 \pm 2.28	68.04 \pm 1.64
本文方法	53.80 \pm 2.28	73.00 \pm 2.21	54.44 \pm 2.02	71.36 \pm 1.75

注: 表3—表6中数值的下标表示标准差。

文方法的有效性。此外, 在OpenSARShip数据集上, 本文方法的优势更加明显。这反映出了本文方法在低分辨率下的稳定性, 因为OpenSARShip数据集相对于FUSAR-Ship数据集具有较低的分辨率。本文方法相对于基于图卷积的方法提取了更多的散射特征点, 并构建了更复杂的拓扑结构, 这使得本文方法对目标具有更好的鲁棒性。这说明拓扑结构的复杂性和数量可以帮助模型更好地捕捉目标的结构和关系, 从而提高了识别性能。

除了性能指标之外, 我们还通过混淆矩阵实验结果对比展示了我们的方法与Baseline在OpenSAR-Ship数据集上的分类效果, 如图6所示。从实验结果中可以清楚地看出, 我们的方法在不同类别上都取得了更好的分类效果, 这进一步验证了我们的方法在目标分类任务中的有效性和优越性能。综上所述, 通过与多种基础方法的比较和详细的实验结果分析, 我们的方法在小样本学习任务中表现出了强大的性能, 不仅在OpenSARShip数据集上, 也在FUSAR-Ship数据集上取得了明显的优势。这为小样本目标分类任务提供了一种有效的解决方案, 并在实际应用中具有潜在的推广前景。

3.5 模型分析

3.5.1 散射点拓扑参数 k 分析

我们研究了不同最近邻数量(k 值)对散射点拓扑方法性能的影响, 并结合了表格、折线图和可视化进行了详细分析。我们使用了OpenSARShip数据集和FUSAR-Ship数据集, 并考察了不同 k 值下的实验结果。

首先, 我们在两个数据集上对不同 k 值进行实验, 通过观察准确率和方差的变化趋势来评估模型

性能, 如表4所示。实验结果表明, 随着 k 值的增加, 模型的准确率呈现出一定的提升趋势。这表明增加更多的最近邻点有助于为模型提供更多的上下文信息, 从而帮助模型更好地区分不同类别的舰船。然而, 这种提升趋势并不是线性的, 而是在一定范围内逐渐增加并趋于稳定。这与模型能够从不同数量的邻居节点中获得的信息量有关。同时, 我们还观察到在准确率提升初期, 增长速度可能较快, 但会伴随着剧烈的波动, 这可能是因为模型在此阶段对噪声等变化较为敏感。

我们还通过折线图的方式绘制了准确率随 k 值变化的曲线, 进一步展示了这一趋势, 如图7所示。特别是在OpenSARShip数据集的4-way 1-shot任务中, 当 k 值超过5后, 准确率的提升速度减缓, 逐渐趋于平稳。类似的趋势也可以在其他设置和数据集中出现。方差的增加可能意味着模型对不同样本的泛化能力下降, 即模型在不同实验中的表现不够稳定, 可能受到噪声或随机性的影响。

需要注意的是, 在两个数据集中, 取得准确率峰值的 k 值并不相同。OpenSARShip数据集在 k 约为5时达到峰值, 而FUSAR-Ship数据集在 k 约为3时达到峰值。这可能与两个数据集的分辨率有关, 分辨率较低的OpenSARShip数据集和分辨率较高的FUSAR-Ship数据集可能对全局特征和局部特征的依赖程度不同。基于实验结果, 我们可以推测全局特征对于分辨率较低的图像可能更加有效, 而局部特征对于分辨率较高的图像更加有效。此外, FUSAR-Ship数据集的准确率曲线波动较大, 这可能与高分辨率图像中的噪声增加有关。因此, 随着 k 值的增加, 引入噪声的概率也会增加。

同时, 通过观察可视化的散射点拓扑在不同

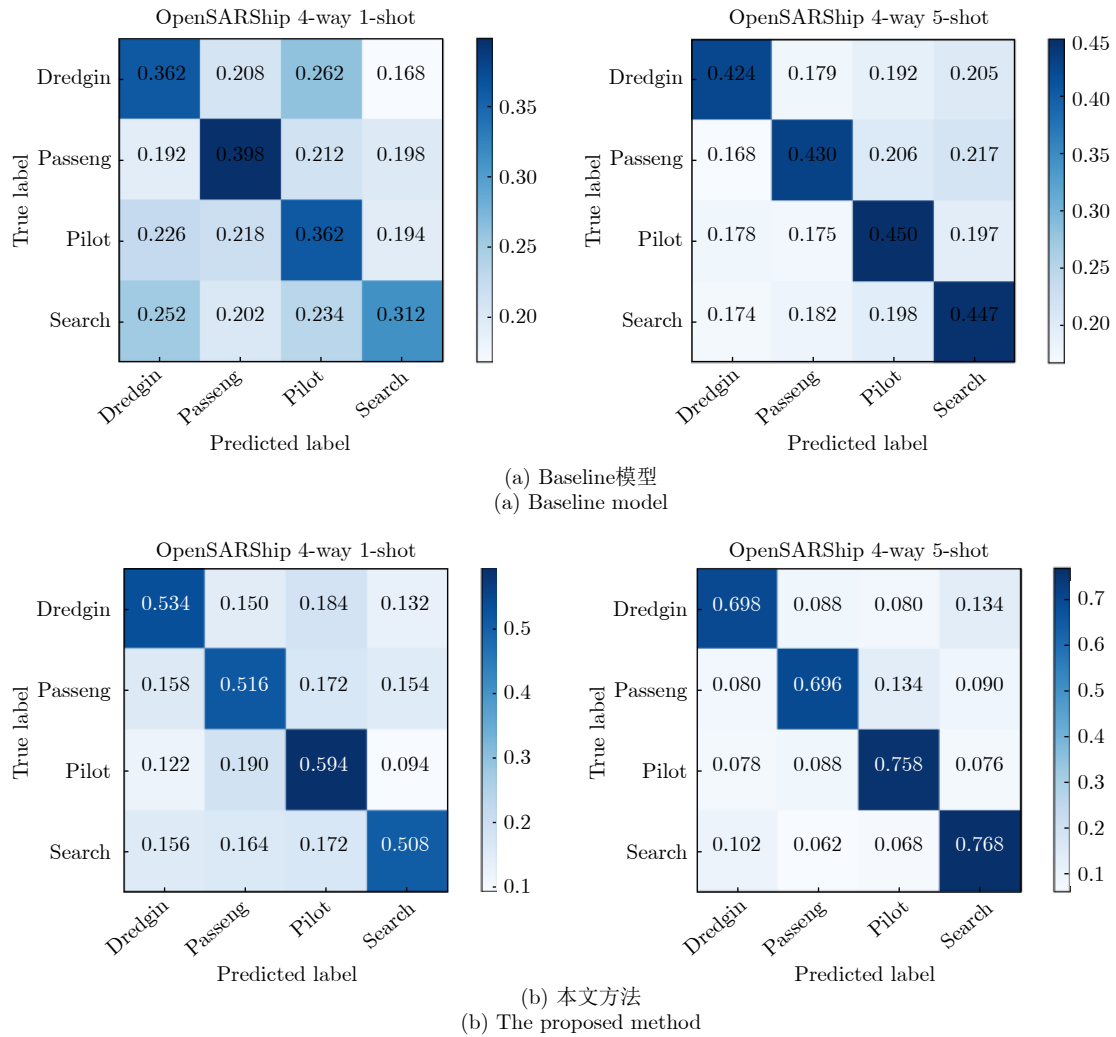


图6 本文方法和Baseline模型在OpenSARShip数据集上的混淆矩阵实验结果对比

Fig. 6 Comparison of experimental results of the proposed method and Baseline model on the OpenSARShip dataset

表4 不同最近邻数量k对模型的影响(%)

Tab. 4 The effect of different nearest neighbor number k on the model (%)

k	OpenSARShip		FUSAR-Ship	
	1-shot	5-shot	1-shot	5-shot
1	38.85 \pm 2.61	52.85 \pm 2.24	47.64 \pm 1.73	60.76 \pm 1.75
2	37.25 \pm 2.23	48.00 \pm 2.24	59.48 \pm 1.92	63.04 \pm 1.78
3	41.50 \pm 2.22	59.75 \pm 2.14	51.32 \pm 2.34	73.44 \pm 1.61
4	47.45 \pm 2.49	67.45 \pm 2.31	49.68 \pm 2.18	66.36 \pm 1.95
5	49.80 \pm 2.30	74.82 \pm 2.22	53.40 \pm 2.16	71.84 \pm 1.76
6	51.75 \pm 2.41	69.50 \pm 2.28	50.76 \pm 2.03	66.56 \pm 1.84
7	49.05 \pm 2.60	72.30 \pm 2.45	49.76 \pm 1.91	70.12 \pm 1.79
8	53.80 \pm 2.28	73.00 \pm 2.21	54.44 \pm 2.02	71.36 \pm 1.75
9	50.35 \pm 2.63	72.40 \pm 2.16	49.28 \pm 2.34	71.12 \pm 1.64
10	51.00 \pm 2.27	70.05 \pm 2.20	50.36 \pm 2.13	71.16 \pm 1.77

k值下的结构变化，我们可以更好地理解上述规律潜在的原因，如图8所示。随着k值的增加，散射点拓扑从多个非连通子图逐渐形成一个完整的连通

图，这意味着更多的全局特征被引入。然而，随着全局特征引入的增加，也会引入更多噪声信息，从而导致准确率的剧烈波动。在达到一定阈值后，引入更多上下文信息已经无法进一步提高准确率，准确率会趋于稳定。

综上所述，我们的分析表明，在选择合适的k值时，需要平衡局部特征和全局特征之间的关系。尽管较大的k值能够引入更多上下文信息，但同时也可能引入更多噪声。因此，我们需要综合考虑准确率和方差的变化，以选择最适合任务和数据集的k值。

3.5.2 散射特征点提取方法分析

在本节中，我们对8种不同的散射特征点提取方法进行了分析，以进一步对比分析它们的性能和特点。这些方法包括本文提出的方法、Sift, Shi-Tomasi, Kaze, Harris-Laplace, Fast, ORB和Brisk。通过对8种方法提取的散射关键点的散射点拓扑可视化进行分析，我们可以更好地理解这些方

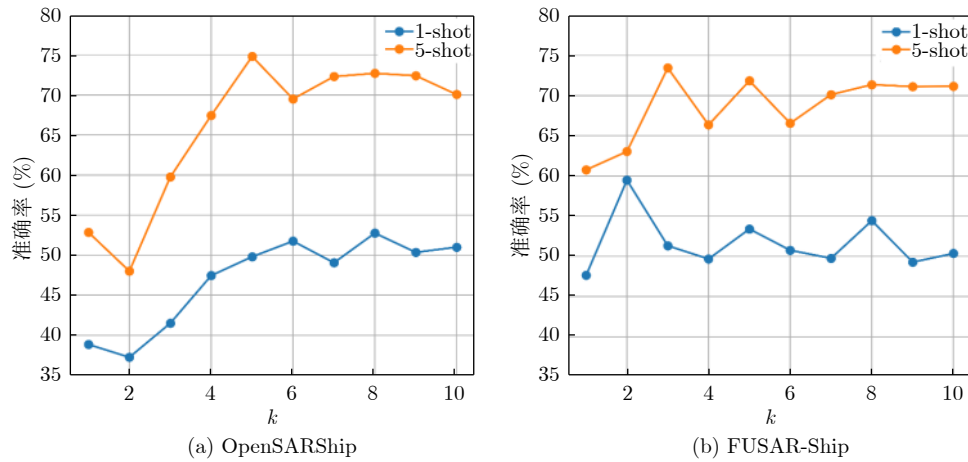

图7 散射点拓扑参数 k 对准确率的影响Fig. 7 The effect of scattering point topology parameter k on the accuracy

图8 具有不同数量散射关键点的散射点拓扑可视化

Fig. 8 Visualization of the scattering point topology with different number of scattering key points

法在散射特征点提取方面的表现,并根据图像的特点来评估不同方法的优劣势。从图9的可视化结果可以发现,不同方法提取的散射特征点在图像上的分布有所不同。本文提出的方法展现了散射特征点的广泛分布,既能够反映舰船的全局特征,也能捕捉到局部特征。此外,没有散射点提取在右下角旁瓣上,验证了本文方法的结构函数的有效性。Sift方法提取到的散射特征点同样有较好的分布,但更多的集中在边缘区域。这可能意味着Sift更适合捕捉图像的边缘特征。Shi-Tomasi方法提取的散射特征点也具有广泛的分布,能够反映舰船的结构特征,但部分散射点提取在了右下角旁瓣上。Kaze方法避免了提取到旁瓣上的散射特征点,但散射特征点分布较为集中,尤其是船的右半部分。这可能使它更适合于一些需要减少干扰的应用场景。Harris-Laplace方法有一个点提取到了旁瓣上,多集中在边缘区域,

类似于Sift和Shi-Tomasi方法。Fast方法提取的散射特征点具有较为广泛的分布,但在某些区域比较稀疏,同时有点提取到了旁瓣上。ORB方法提取的点分布非常集中,不能有效地反映舰船的特征,且有点提取到了旁瓣上。这表明它可能不适合用于具有复杂结构的目标。Brisk方法提取到的点主要集中在边缘区域,也有点提取到了旁瓣上。它可能适用于需要强调边缘特征的场景。综上所述,不同的散射特征点提取方法在散射点的分布和性能方面存在差异,其适用性受到具体应用场景和需求的影响。在选择合适的方法时,应综合考虑所处理图像的特点以及需要捕捉的特征信息。对于提取舰船目标的散射特征点而言,本文方法表现出色,因为它能够同时捕捉全局和局部特征,而其他方法则在不同方面具有各自的优点和限制。因此,合理选择散射特征点提取方法对于散射点拓扑的构建十分重要。

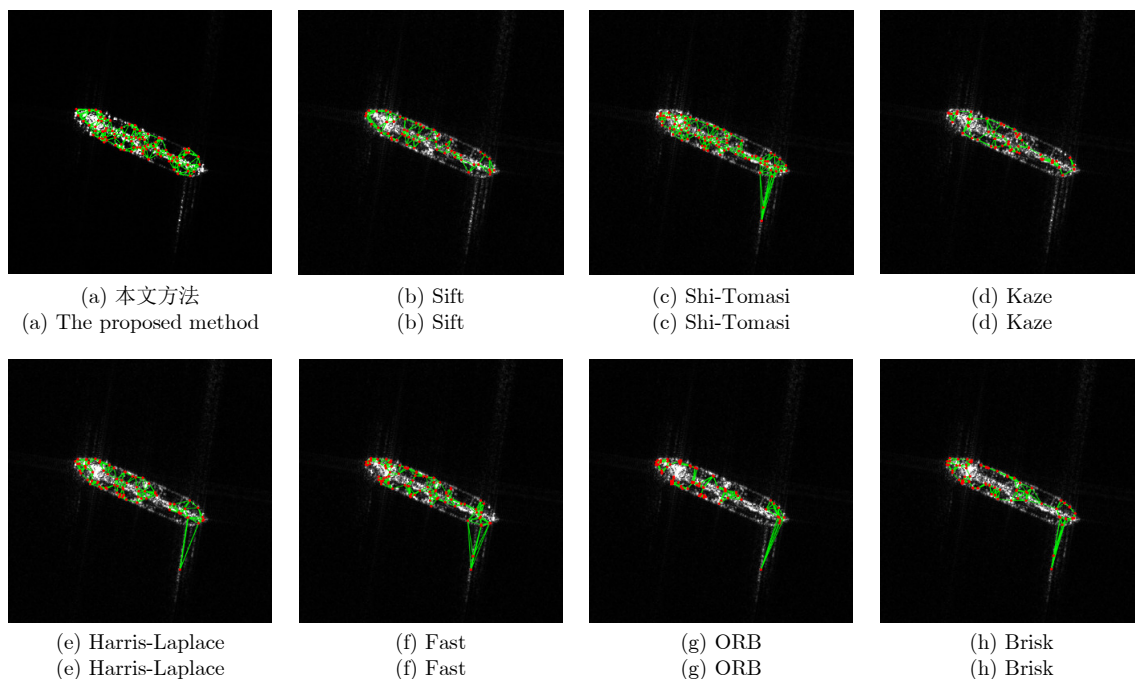


图9 不同方法提取散射关键点的散射点拓扑可视化

Fig. 9 Visualization of scattering point topology using different methods to extract scattering key points

3.5.3 散射点拓扑特征有效性分析

本文采用了一种双分支卷积网络的架构，其中两个分支分别接受视觉特征和拓扑特征作为输入。这样的架构旨在探究拓扑特征在舰船目标识别中的有效性。为了验证拓扑特征本身的有效性，进行了一系列消融实验，对比了不同输入配置下的模型性能，具体实验结果如表5所示。

首先，当两个分支都接受视觉特征作为输入时，相对于仅有一个分支接受视觉特征输入，模型的性能有所提升。这种改进在OpenSARShip数据集的1-shot和5-shot设置下分别提高了6.35%和26.20%的准确率，在FUSAR-Ship数据集上的1-shot和5-shot设置下分别提升12.20%和25.60%的准确率。当两个分支都提供视觉特征时，观察到的模型精度的提高与特征多样化的原则一致。结合来自两个分支的视觉信息使网络能够捕获更广泛的视觉模式和关系，从而显著提高准确性。这凸显了利用网络架构设计进行功能集成的重要性。

当一个分支接受视觉特征而另一个分支接受拓扑特征时，模型的性能进一步提升。在OpenSAR-Ship数据集的1-shot和5-shot设置下，准确率分别提高了11.60%和3.40%。在FUSAR-Ship数据集上的1-shot和5-shot设置下分别提升10.56%和8.44%的准确率。结果表明散射点拓扑特征对于网络特征学习具有有效性。这种方法利用了这两种特征类型的互补性。视觉特征捕获详细的空间信息，而拓扑特

征提供有关数据点之间的结构关系的信息。该模型通过交互式学习利用这些不同的输入，从而能够更全面地了解与船舶相关的特征。这展示了视觉和拓扑特征之间的协同作用，以提高识别精度。

不过，当两个分支都接受拓扑特征时，模型的性能表现并不好，甚至可能出现性能下降。这表明拓扑特征虽然可以作为视觉特征的补充，但不能独立于视觉特征进行特征学习。这进一步强调了双分支架构的有效性，通过视觉特征和拓扑特征的交互学习，模型能够更全面地理解并利用特征信息，提高了对舰船目标的识别性能。

综合来看，本文提出的双分支卷积网络架构在舰船目标识别任务中取得了显著的性能提升。这种架构的有效性主要体现在两个分支输入特征的交互学习，以及拓扑特征对于视觉特征的补充作用。这些实验证明了在目标识别领域中，结合多源信息可以更好地提取和利用特征信息，从而改善模型的性能。

3.5.4 交叉融合注意力机制分析

本节将详细分析实验中引入的交叉融合注意力机制对于基于散射点拓扑和双分支卷积神经网络的SAR图像小样本舰船分类模型的影响。在实验中，通过引入两个不同的注意力机制，即注意力1和注意力2，来研究其对模型性能的影响。表6呈现了模型在不同配置下的表现。我们通过比较模型在有无注意力机制的情况下的性能差异，来评估交叉融合

表5 拓扑特征支路和视觉特征支路消融(%)

Tab. 5 Topological feature branch and visual feature branch ablation (%)

分支1	分支2	OpenSARShip		FUSAR-Ship	
		1-shot	5-shot	1-shot	5-shot
图像特征	无	35.85 \pm 2.00	43.40 \pm 2.04	31.68 \pm 1.56	37.32 \pm 2.00
图像特征	图像特征	42.20 \pm 2.21	69.60 \pm 2.16	43.88 \pm 2.31	62.92 \pm 1.87
拓扑特征	拓扑特征	35.50 \pm 2.30	44.85 \pm 1.40	21.80 \pm 1.05	28.52 \pm 1.64
图像特征	拓扑特征	53.80 \pm 2.28	73.00 \pm 2.21	54.44 \pm 2.02	71.36 \pm 1.75

表6 交叉融合注意力机制对模型的影响(%)

Tab. 6 The effect of cross-fusion attention mechanism on the model (%)

注意力1	注意力2	OpenSARShip		FUSAR-Ship	
		1-shot	5-shot	1-shot	5-shot
×	×	34.45 \pm 1.95	41.20 \pm 2.14	30.24 \pm 1.75	35.48 \pm 1.75
×	√	47.45 \pm 2.57	64.65 \pm 2.14	38.72 \pm 2.19	53.52 \pm 2.02
√	√	53.80 \pm 2.28	73.00 \pm 2.21	54.44 \pm 2.02	71.36 \pm 1.75

注：“×”表示未使用相应的注意力机制，“√”表示使用了相应的注意力机制。

注意力机制的效果。实验结果以均值和标准差的形式呈现，以便更好地理解结果的稳定性和可靠性。

从表6可以清晰地看出，通过引入注意力1和注意力2，模型在不同任务和不同阶段的性能均得到了显著的提升。引入注意力2机制后，模型的性能进一步提升。特别是在样本数较多的情况下，注意力2的作用更为显著，使得模型在OpenSARShip数据集1-shot情况下的分类准确率提升13.00%，在5-shot情况下的分类准确率提升23.45%。模型在FUSAR-Ship数据集1-shot和5-shot情况下的分类准确率分别提升8.48%和18.04%。进一步地，在同时引入注意力1和注意力2的情况下，模型的性能得到了更为显著的提升。在OpenSARShip数据集上，1-shot和5-shot的分类准确率分别提升至6.35%和8.35%。在FUSAR-Ship数据集上，相应地提升为15.72%和17.84%。这表明注意力1和注意力2的交叉融合有助于模型在不同数据集和任务上都获得更好的性能。

为了更好地理解注意力机制的影响，我们进行了卷积层输出特征图的可视化分析，如图10所示。图10(a)展示了在没有任何注意力机制的情况下，模型的第3阶段卷积层输出特征图。可以观察到，部分特征图的激活相对较弱，可能导致模型对一些关键特征的捕捉不足。引入注意力2后(图10(b))，特征图的激活明显增强，模型能够更好地聚焦于舰船的区域。图10(c)展示了在引入注意力1和注意力2后，模型的第3阶段卷积层输出特征图。可以看出，注意力1和注意力2的联合作用使得特征图的激活更加

强烈且集中，有助于更准确地地区分舰船和其他区域，目标的边缘和细节信息更加清晰可见。图10(d)展示了注意力1的输出，在融合散射点拓扑特征后，特征图从提取的空间特征变为更加抽象的特征。在这幅图中，所有的特征通道都展现出相似的右上角亮度区域，而中央区域呈现较暗的特征分布。然而，各个通道的中央暗区大小和右上角亮区大小的分布却呈现出差异，这些特征在某种程度上包含了散射点的拓扑特征。说明了注意力1对模型的特征融合和选择起到了关键作用。表明其能够有效地捕捉到图像中的散射点拓扑信息，有助于提升模型的特征学习能力。

4 结语

在本文中，针对SAR图像小样本舰船分类的挑战，我们提出了一种创新的方法，该方法结合了散射点拓扑结构和双分支卷积神经网络，以实现更准确的分类结果。通过构建散射关键点的拓扑结构并将其转化为矩阵形式，模型有效地捕捉了舰船目标的结构和形状特征，从而增强了模型的泛化能力。双分支卷积神经网络的设计使得我们能够同时处理图像和散射信息，提供了多类别的特征表示，进一步提高了分类精度。为了促进跨特征类别学习，交叉融合注意力机制被引入，通过增强不同类别特征之间的交互，使得模型能够更好地理解和利用散射拓扑特征，进而提升了特征融合的判别能力。我们在公开的SAR舰船数据集上进行了广泛实验，实验结果表明，我们的方法在两个数据集1-shot和5-shot

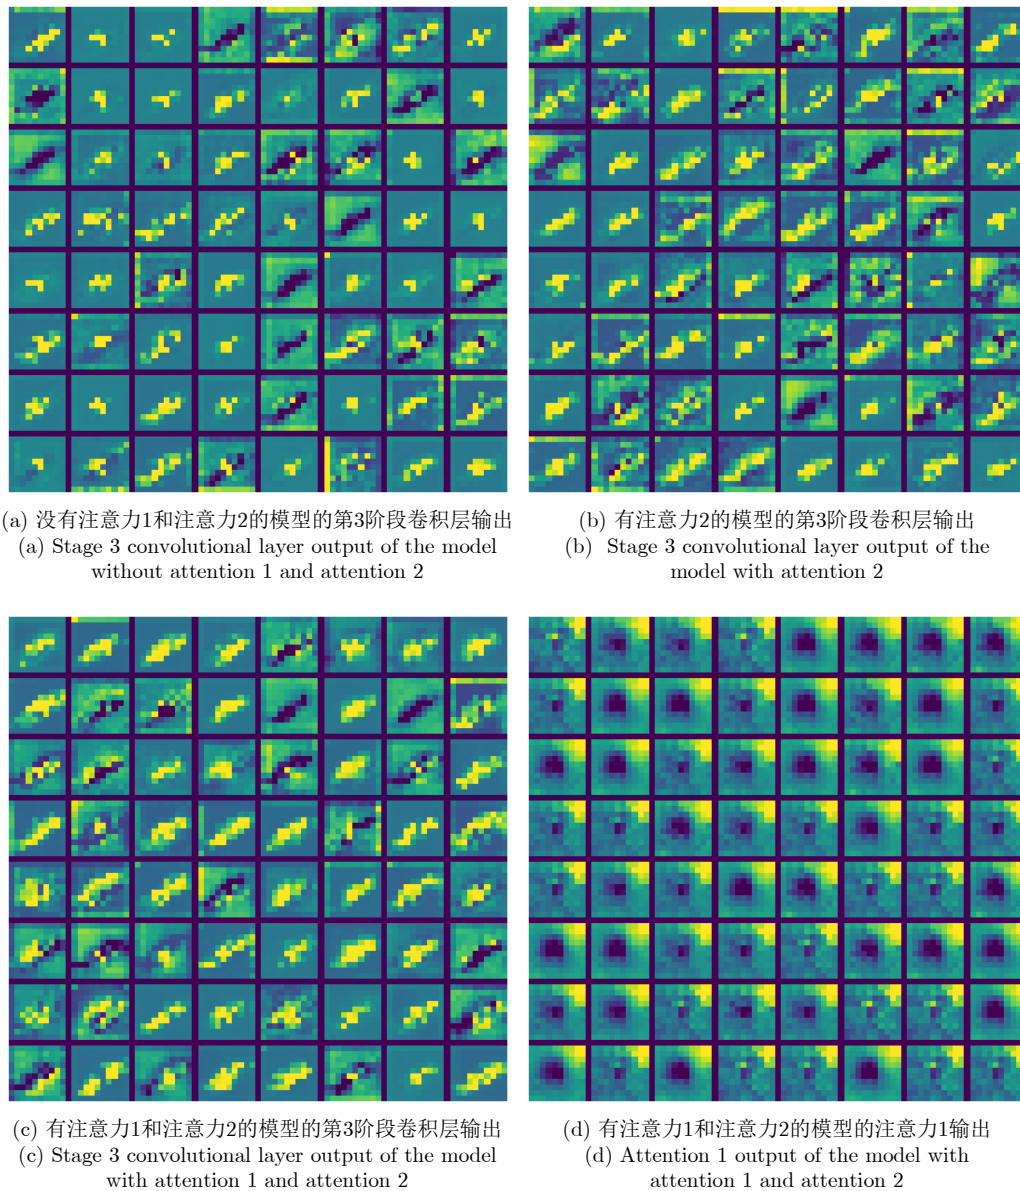


图 10 不同方法对应的视觉信息提取分支的卷积层输出特征图可视化

Fig. 10 Visualization of convolutional layer output feature maps of visual information extraction branch corresponding to different methods

设置下均显著超过其他主流基准方法，从而验证了散射点拓扑在小样本舰船分类中的有效性。此外，我们还对散射点拓扑参数进行了详细的分析，揭示了选择合适的最近邻数量(k 值)时需要平衡局部和全局特征之间的关系。交叉融合注意力机制的研究结果展示了它在增强特征融合和选择方面的关键作用，有效地捕捉了散射点拓扑信息，提高了模型的学习能力。未来，我们将进一步将本文所提方法与SAR目标检测相结合，以提升在不同视角下的泛化性能。

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] HASHIMOTO S, SUGIMOTO Y, HAMAMOTO K, *et al.* Ship classification from SAR images based on deep learning[C]. SAI Intelligent Systems Conference, Cham, Switzerland, 2019: 18-34. doi: [10.1007/978-3-030-01054-6_2](https://doi.org/10.1007/978-3-030-01054-6_2).
 - [2] 雷禹, 冷祥光, 孙忠镇, 等. 宽幅SAR海上大型运动舰船目标数据集构建及识别性能分析[J]. 雷达学报, 2022, 11(3): 347-362. doi: [10.12000/JR21173](https://doi.org/10.12000/JR21173).
- LEI Yu, LENG Xiangguang, SUN Zhongzhen, *et al.* Construction and recognition performance analysis of wide-

- swath SAR maritime large moving ships dataset[J]. *Journal of Radars*, 2022, 11(3): 347–362. doi: [10.12000/JR21173](https://doi.org/10.12000/JR21173).
- [3] 胡思茹, 马福民, 秦天奇, 等. 基于多特征组合的红外舰船目标识别技术[J]. *舰船电子工程*, 2022, 42(2): 185–189. doi: [10.3969/j.issn.1672-9730.2022.02.040](https://doi.org/10.3969/j.issn.1672-9730.2022.02.040).
- HU Siru, MA Fumin, QIN Tianqi, *et al.* Infrared ship target recognition technology based on multi feature combination[J]. *Ship Electronic Engineering*, 2022, 42(2): 185–189. doi: [10.3969/j.issn.1672-9730.2022.02.040](https://doi.org/10.3969/j.issn.1672-9730.2022.02.040).
- [4] OUCHI K. Current status on vessel detection and classification by synthetic aperture radar for maritime security and safety[C]. 38th Symposium on Remote Sensing for Environmental Sciences, Gamagori, Japan, 2016: 3–5.
- [5] 田壮壮, 占荣辉, 胡杰民, 等. 基于卷积神经网络的SAR图像目标识别研究[J]. *雷达学报*, 2016, 5(3): 320–325. doi: [10.12000/JR16037](https://doi.org/10.12000/JR16037).
- TIAN Zhuangzhuang, ZHAN Ronghui, HU Jiemin, *et al.* SAR ATR based on convolutional neural network[J]. *Journal of Radars*, 2016, 5(3): 320–325. doi: [10.12000/JR16037](https://doi.org/10.12000/JR16037).
- [6] JI Yongjie, ZENG Peng, ZHANG Wangfei, *et al.* Forest biomass inversion based on KNN-FIFS with different alos data[C]. 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, Brussels, Belgium, 2021: 4540–4543. doi: [10.1109/IGARSS47720.2021.9554712](https://doi.org/10.1109/IGARSS47720.2021.9554712).
- [7] ZHANG Xin, HUO Chunlei, XU Nuo, *et al.* Multitask learning for ship detection from synthetic aperture radar images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 8048–8062. doi: [10.1109/JSTARS.2021.3102989](https://doi.org/10.1109/JSTARS.2021.3102989).
- [8] 杜兰, 王兆成, 王燕, 等. 复杂场景下单通道SAR目标检测及鉴别研究进展综述[J]. *雷达学报*, 2020, 9(1): 34–54. doi: [10.12000/JR19104](https://doi.org/10.12000/JR19104).
- DU Lan, WANG Zhaocheng, WANG Yan, *et al.* Survey of research progress on target detection and discrimination of single-channel SAR images for complex scenes[J]. *Journal of Radars*, 2020, 9(1): 34–54. doi: [10.12000/JR19104](https://doi.org/10.12000/JR19104).
- [9] ZHANG Liangpei, ZHANG Legei, and DU Bo. Deep learning for remote sensing data: A technical tutorial on the state of the art[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2016, 4(2): 22–40. doi: [10.1109/MGRS.2016.2540798](https://doi.org/10.1109/MGRS.2016.2540798).
- [10] HOSPEDALES T, ANTONIOU A, MICAELLI P, *et al.* Meta-learning in neural networks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(9): 5149–5169. doi: [10.1109/TPAMI.2021.3079209](https://doi.org/10.1109/TPAMI.2021.3079209).
- [11] CAO Changjie, CUI Zongyong, CAO Zongjie, *et al.* An integrated counterfactual sample generation and filtering approach for SAR automatic target recognition with a small sample set[J]. *Remote Sensing*, 2021, 13(19): 3864. doi: [10.3390/rs13193864](https://doi.org/10.3390/rs13193864).
- [12] NICHOL A, ACHIAM J, and SCHULMAN J. On first-order meta-learning algorithms[EB/OL]. <https://arxiv.org/abs/1803.02999>, 2018.
- [13] FINN C, ABBEEL P, and LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]. 34th International Conference on Machine Learning, Sydney, Australia, 2017: 1126–1135.
- [14] SNELL J, SWERSKY K, and ZEMEL R. Prototypical networks for few-shot learning[C]. 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 4080–4090.
- [15] SUNG F, YANG Yongxin, ZHANG Li, *et al.* Learning to compare: Relation network for few-shot learning[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 1199–1208. doi: [10.1109/CVPR.2018.00131](https://doi.org/10.1109/CVPR.2018.00131).
- [16] VINALS O, BLUNDELL C, LILICRAP T, *et al.* Matching networks for one shot learning[C]. 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016: 3637–3645.
- [17] BENGIO Y. Deep learning of representations: Looking forward[C]. International conference on statistical language and speech processing. Berlin, Germany, 2013: 1–37. https://doi.org/10.1007/978-3-642-39593-2_1.
- [18] CHEN Weiyu, LIU Y C, KIRA Z, *et al.* A closer look at few-shot classification[C]. 7th International Conference on Learning Representations, Vancouver, Canada, 2019: 241–268.
- [19] CHEN Yinbo, LIU Zhuang, XU Huijuan, *et al.* Meta-baseline: Exploring simple meta-learning for few-shot learning[C]. 2021 IEEE/CVF International Conference on Computer Vision, Montreal, Canada, 2021: 9042–9051. doi: [10.1109/ICCV48922.2021.00893](https://doi.org/10.1109/ICCV48922.2021.00893).
- [20] CUI Zongyong, ZHANG Mingrui, CAO Zongjie, *et al.* Image data augmentation for SAR sensor via generative adversarial nets[J]. *IEEE Access*, 2019, 7: 42255–42268. doi: [10.1109/ACCESS.2019.2907728](https://doi.org/10.1109/ACCESS.2019.2907728).
- [21] 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).
- [22] WANG Ke, ZHANG Gong, XU Yanbing, *et al.* SAR target recognition based on probabilistic meta-learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(4): 682–686. doi: [10.1109/LGRS.2020.2983988](https://doi.org/10.1109/LGRS.2020.2983988).
- [23] PAN Zongxu, BAO Xianjie, ZHANG Yueting, *et al.* Siamese network based metric learning for SAR target classification[C]. IGARSS 2019–2019 IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, 2019: 1342–1345. doi: [10.1109/IGARSS.2019.8898210](https://doi.org/10.1109/IGARSS.2019.8898210).

- [24] LU Da, CAO Lanying, and LIU Hongwei. Few-shot learning neural network for SAR target recognition[C]. 2019 6th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR), Xiamen, China, 2019: 1–4. doi: [10.1109/APSAR46974.2019.9048517](https://doi.org/10.1109/APSAR46974.2019.9048517).
- [25] TAI Yuan, TAN Yihua, XIONG Shengzhou, *et al.* Few-shot transfer learning for SAR image classification without extra SAR samples[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 2240–2253. doi: [10.1109/JSTARS.2022.3155406](https://doi.org/10.1109/JSTARS.2022.3155406).
- [26] KANG Yuzhuo, WANG Zhirui, FU Jiamei, *et al.* SFR-Net: Scattering feature relation network for aircraft detection in complex SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5218317. doi: [10.1109/TGRS.2021.3130899](https://doi.org/10.1109/TGRS.2021.3130899).
- [27] SUN Yuanrui, WANG Zhirui, SUN Xian, *et al.* SPAN: Strong scattering point aware network for ship detection and classification in large-scale SAR imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 1188–1204. doi: [10.1109/JSTARS.2022.3142025](https://doi.org/10.1109/JSTARS.2022.3142025).
- [28] SUN Xian, LV Yixuan, WANG Zhirui, *et al.* SCAN: Scattering characteristics analysis network for few-shot aircraft classification in high-resolution SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5226517. doi: [10.1109/TGRS.2022.3166174](https://doi.org/10.1109/TGRS.2022.3166174).
- [29] 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).
- [30] 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).
- [31] KANG Yuzhuo, WANG Zhirui, ZUO Haoyu, *et al.* ST-Net: Scattering topology network for aircraft classification in high-resolution SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5202117. doi: [10.1109/TGRS.2023.3236987](https://doi.org/10.1109/TGRS.2023.3236987).
- [32] HARRIS C G and STEPHENS M J. A combined corner and edge detector[C]. Alvey Vision Conference, Manchester, UK, 1988: 1–6.
- [33] 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).
- [34] HOU Xiyue, AO Wei, SONG Qian, *et al.* FUSAR-Ship: Building a high-resolution SAR-AIS matchup dataset of Gaofen-3 for ship detection and recognition[J]. *Science China Information Sciences*, 2020, 63: 140303. doi: [10.1007/s11432-019-2772-5](https://doi.org/10.1007/s11432-019-2772-5).
- [35] LIU Bin, CAO Yue, LIN Yutong, *et al.* Negative margin matters: Understanding margin in few-shot classification[C]. 16th European Conference on Computer Vision, Glasgow, UK, 2020: 438–455. doi: [10.1007/978-3-030-58548-8_26](https://doi.org/10.1007/978-3-030-58548-8_26).

作者简介

张翼鹏, 硕士生, 主要研究方向为遥感图像智能解译、SAR目标检测识别。

卢东东, 硕士, 助理研究员, 主要研究方向为人工智能、遥感图像智能解译、星载/机载图像处理。

仇晓兰, 博士, 研究员, 博士生导师, 主要研究方向为SAR成像处理、SAR图像理解。

李飞, 硕士, 研究员, 硕士生导师, 主要研究方向为智能信息终端、智能信息处理。

(责任编辑: 高山流水)