

文章编号 1004-924X(2025)10-1672-19

超轻量化 SAR 影像小目标检测网络

杨晓敏^{1,3,4}, 杨 军^{1,2,3,4*}

(1. 兰州交通大学 测绘与地理信息学院, 甘肃 兰州 730070;

2. 兰州交通大学 电子与信息工程学院, 甘肃 兰州 730070;

3. 地理国情监测技术应用国家地方联合工程研究中心, 甘肃 兰州 730070;

4. 甘肃省地理国情监测工程实验室, 甘肃 兰州 730070)

摘要:采用卷积神经网络技术的合成孔径雷达(SAR)影像目标检测方法尽管能够实现较好的检测精度,但模型复杂度较高,限制了其在军事快速决策、海上紧急救援等领域的实际应用与部署。为此,本文提出一种用于雷达影像的超轻量化小目标检测模型。首先,设计了多分支高效层聚合模块,以增强多尺度感知并适应实际设备的各种资源和计算能力。其次,利用细节增强与共享检测头重点关注小目标信息,减轻海、陆杂波干扰造成的误检。最后,采用特征丰富度引导的剪枝和知识蒸馏指导目标的表示学习,进一步压缩模型和提升性能。实验结果表明,该网络模型以 4.186 G 计算量和 0.888 M 参数量,在 MSAR, SAR-Ship, AIR-SARShip-2.0, SSDD 和 HRSID 数据集上检测准确率分别达到 89.0%, 98.1%, 82.5%, 98.6% 和 91.5%。本文算法具有较好的鲁棒性,网络模型在最小体积下可以取得较优的检测速度和精度。

关键词: SAR 影像; 小目标检测; 超轻量化; 多分支高效层聚合; 增强共享检测头; 剪枝与知识蒸馏

中图分类号: TP751.1 **文献标识码:** A

doi: 10.37188/OPE.20253310.1672

CSTR: 32169.14.OPE.20253310.1672

Ultra lightweight SAR image small object detection network

YANG Xiaomin^{1,3,4}, YANG Jun^{1,2,3,4*}

(1. Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Electronic and Information Engineering, Lanzhou Jiaotong University,
Lanzhou 730070, China;

3. National and Local Joint Engineering Research Center of Geographical Monitoring Technology
Application, Lanzhou 730070, China;

4. Gansu Provincial Engineering Laboratory of Geographical Monitoring, Lanzhou 730070, China)

* Corresponding author, E-mail: yangj@mail.lzjtu.cn

Abstract: Although the synthetic aperture radar (SAR) image target detection method utilizing convolutional neural network technology can achieve good detection accuracy, its high model complexity limits its practical application and deployment in military rapid decision-making, maritime emergency rescue, and other fields. Therefore, this paper proposes an ultra lightweight small target detection model for radar im-

收稿日期: 2024-11-04; 修订日期: 2025-01-06.

基金项目: 国家自然科学基金项目 (No. 42261067); 2025 年度甘肃省重点人才项目 (No. 2025RCXM031)

ages. Firstly, a multi branch efficient layer aggregation module is designed to enhance multi-scale perception and adapt to various resources and computing capabilities of actual devices. Secondly, detail enhancement and shared detection heads are utilized to focus on small target information, thereby reducing false detections caused by sea and land clutter interference. Finally, feature richness-guided pruning and knowledge distillation guided representation learning are employed to further compress the model and enhance performance. The experimental results demonstrate that the network model achieves detection accuracies of 89.0%, 98.1%, 82.5%, 98.6%, and 91.5% on MSAR, SAR-Ship, AIR-SARShip-2.0, SSDD, and HRSID datasets, respectively, with a computational complexity of 4.186 G and a parameter complexity of 0.888 M. The algorithm presented in this paper exhibits good robustness, and the network model can achieve optimal detection speed and accuracy at the minimum volume.

Key words: SAR image; small object detection; ultra lightweight; multi branch efficient layer aggregation; enhance shared detection head; pruning and knowledge distillation

1 引 言

合成孔径雷达(SAR)是一种通过主动发射和接收电磁波实现微波成像的传感器,具备穿透云层、雨雪等天气条件的能力,能够实现全天候、全天时的对地观测,因此在灾害应急、空间侦察和环境监测等领域具有重要应用。近年来,随着 SAR 卫星的密集发射,生成了海量雷达影像数据。然而,由于 SAR 的成像原理较为特殊,对其影像的人工解译需要高度专业的知识,并且耗费大量时间。如在舰船目标检测中,通常需要结合船舶尾迹和海洋表面参数等进行算法开发。尽管传统的检测方法在处理速度上有所改进,但其精度有限并依赖人工设计。在面对庞大 SAR 数据及快速处理任务需求的情况下,传统方法已难以满足实时性和准确性的要求,因此,国内外专家学者纷纷将深度学习技术引入这一领域^[1-4]。卷积神经网络(Convolutional Neural Networks, CNN)是其中最具代表性的一类方法,通过学习目标的纹理、轮廓等浅层特征以及深层语义信息,实现端到端的目标检测。与传统方法相比,深度学习方法更适合处理复杂场景,逐渐成为 SAR 影像目标检测的主流技术。

然而,现阶段基于深度学习的目标检测算法通常需要强大的算力支持,在实际的 SAR 影像目标检测应用中往往需要满足体积小、易移植、高精度且高效率的要求。因此轻量化的 SAR 目标检测方法成为当前研究的重点。在文献[5]中,“轻量化”模型被定义为旨在降低计算和存储

资源消耗的模型,其显著特征为参数规模相对较小,介于 5~10 M 之间。而“超轻量化”模型则标志着计算与存储效率的更进一步优化,其参数规模大幅缩减至约 1 M,实现了资源利用的新高度。近年来,许多研究致力于设计用于光学图像的超轻量化目标检测网络^[6-8],但只有少数方法用于雷达影像^[9-10],且没有真正在检测准确性和模型体积之间取得较好的平衡。此外,大部分模型仍难以满足星载或机载设备对计算能力、存储空间和内存访问的严格限制。

针对 SAR 影像目标检测网络轻量化程度不足的问题,本文设计一种超轻量化的 SAR 影像小目标模型,在保证多场景检测精度的情况下最小化模型体积。首先设计多分支高效层聚合模块以强化特征映射学习到的特征,提升参数和计算利用率。其次,构建细节增强与共享检测头,提升小目标检测精度并缩减计算资源消耗。最后,设计特征丰富度引导的剪枝和知识蒸馏进一步压缩学生网络体积并优化知识传递。

2 相关研究工作

2.1 SAR 影像目标检测方法

传统的 SAR 影像检测方法通常采用恒虚警率(Constant False Alarm Rate, CFAR)算法^[11],该算法根据预定的虚警率和背景杂波的统计特性调整阈值实现目标检测。后来, Wang 等人^[12]结合强度和空间信息来增强 CFAR,但仍难以有效处理 SAR 影像中的复杂背景。例如,远海船

舶目标易受到海洋背景的干扰,靠岸船舶则易与码头及其他地物混淆。为了解决这一问题,Huo等人^[13]采用稳定极值区域候选法对SAR影像进行预筛选,实现在强杂波背景下的稳定检测。张等人^[14]研究了全极化顺轨干涉SAR实现慢动目标CFAR检测,利用全极化信息提高干涉合成孔径雷达对慢小目标的检测概率。然而,这些传统方法严重依赖人工设置和参数调整,难以应对多样化的目标和复杂的背景条件。此外,它们有限的检测速度和实时性也不能满足实际工程应用的要求。

与需要人工提取特征的传统算法不同,基于深度学习的算法在SAR影像目标检测任务中通过多个卷积层逐层提取目标的低层次特征(如边缘纹理)和高层次特征(如形状语义),从而提高检测的鲁棒性和准确性^[15]。例如,Guo等人^[16]基于YOLOX将自适应激活函数与主干网络中的SPP模块相结合,提高特征提取能力。Li等人^[17]基于RetinaNet^[18]提出一种视网膜结构,减少计算密集层FLOPs的同时实现了检测精度的提高。Yang等人^[19]在主干网络引入坐标注意力模块,获得更精确的语义特征和目标表示。然而,这些检测方法往往依赖于非常深的网络结构,尤其是在小目标检测场景中,大规模深度学习模型的计算代价难以满足实时响应和轻量化的要求,参数数量、浮点运算和目标检测精度之间仍然没有达到较好的平衡。

2.2 轻量化SAR影像小目标检测方法

近年来,学者们致力于开发轻量化深度学习模型,在有限资源条件下实现高效的小目标检测。Quant-Det^[20]提出了轻量级分裂双向特征金字塔网络来缓解复杂背景对SAR影像的干扰。Zhou等人^[21]提出一种基于元学习的轻量级SAR影像少样本目标检测方法,从更均衡的角度提高检测的精度和速度,但仍不能满足小目标的检测精度要求。最近,谢等人^[22]提出基于改进CenterNet的轻量级无锚框方法,通过预测目标关键点的信息及检测框的相关属性,实现了SAR影像舰船的准确定位与检测。龚等人^[23]基于YOLOv5算法引入协同注意力机制和加权特征融合,以降低网络的计算复杂度并提高推理速度。Chen等人^[24]提出了一种轻量级端到端图像预处

理网络来强化上下文信息并扩大网络的有效感受野。虽然这些方法符合SAR影像检测网络的轻量化设计标准,计算量介于3~20 GFLOPs,参数量在2~30 M之间,但检测精度范围为60%~97%,难以适应在不同计算资源上的实际应用。

在采用网络剪枝与知识蒸馏进行进一步轻量化优化方面,文献[25]将通道剪枝方法^[26]引入SAR影像目标检测任务中,有效减少了模型的参数量、计算量及推理时间,但是牺牲了检测精度。Wang等人^[27]基于多目标萤火虫算法将舰船目标滤波器编码成一个概率列表,来决定是否剪枝相应的结构和参数以达到轻量化效果。郝等人^[28]采用知识蒸馏思想将教师网络的参数迁移至学生网络,在不增加任何复杂度的前提下提升学生网络的检测精度。Wang等人^[29]采用光学目标检测网络作为教师模型来指导SAR影像目标检测,在知识传递中引入教师网络的先验类别信息,提高了检测的精度和效率。文献[30-31]将剪枝和蒸馏的优势相结合,利用网络剪枝构造轻量化的网络模型,再通过知识蒸馏改善剪枝后的轻量化模型的检测精度。然而,实际应用中剪枝技术虽能压缩模型,却也导致检测精度下降,过度剪枝更会使精度骤减,难以同时满足轻量化和高精度的SAR影像小目标检测要求。

综上所述,现有的轻量化SAR影像小目标检测方法虽然降低了模型的计算复杂度和推理时间,但往往以牺牲小目标检测精度为代价。尽管复杂模型能够提取更丰富的特征,但它们依赖较深的网络结构,难以在计算资源有限的实际应用中实现高效的小目标检测。因此,如何在超轻量化与高精度之间取得更好的平衡仍是亟待解决的问题。

3 超轻量化SAR影像小目标检测方法

本文设计的超轻量化SAR影像小目标检测框架如图1所示,创新点主要包括三部分:多分支高效层聚合(Multi Branch Efficient Layer Aggregation, MELA)模块、细节增强与共享检测头(Detail Enhancement and Shared Detection Head, DESD-Head)、特征丰富度引导的剪枝和知识蒸

馏模块。首先,设计多分支高效层聚合模块和轻量型细节增强与共享检测头改进基线 YOLOv8-n 网络。然后,将模型在 SAR 影像数据集上进行特征丰富度评分,以此为依据判别模型中各通道特征的重要程度并裁剪次要通道。最后,将经过微调训练得到的剪枝后模型作为学生网络,学习复杂的教师网络并进行训练,得到超轻量化的目标检测权重模型,并在 SAR 影像目标检测模块

中使用超轻量化的权重模型实现对各尺度目标的检测。

基线 YOLOv8 算法中 C2f 模块和检测头的参数量在总体网络中占比分别高达 50.36% 和 24.97%。为了满足 SAR 影像小目标检测轻量化和高精度的双重要求,本文首先采用多分支高效层聚合模块和细节增强与共享检测头改进基线模型。改进后的网络结构如图 2 所示。




图 1 超轻量化 SAR 影像小目标检测方法框架

Fig. 1 Ultra lightweight framework for small object detection in SAR images




图 2 改进的基线网络结构框架

Fig. 2 Architecture framework of improved baseline network

3.1 多分支高效层聚合模块

本节结合多分支卷积和精简线性操作^[32]设计了兼顾轻量级、推理速度和准确性的MELA模块,其架构如图3所示。该模块精简原有架构的梯度传输路径,利用简单的 1×1 卷积、 3×3 卷积和多分支卷积(Multi Branch Convolution, MBConv)将各阶段的特征组合起来。这种操作方式可以增强不同特征映射学习到的特征,提高参数和计算利用率。




图3 MELA模块的结构

Fig. 3 Structure of MELA module

3.1.1 多分支卷积

YOLOv8中常用的BottleNeck虽然具有很好的特征提取和融合能力,但结构复杂需要较高的算力支持。为了在降低算力的同时弥补舍弃残差块所带来的性能损失,在梯度传输路径上使用多分支卷积以增强特征提取和梯度流通的能力,并且多分支卷积可在推理阶段进行融合,达到速度和精度的双重优化目标。如图4所示,多分支卷积核心思想是在训练阶段使用 3×3 卷积、 1×1 卷积和恒等映射组成多个分支,以提升模型的表达能力。而在推理阶段,这些分支通过融合操作转化为一个等效的 3×3 卷积层,以减少计算量,提高推理速度。

本文使用 $M_{k\times k}$ 表示具有C1输入通道和C2输出通道的 $k\times k$ 转换层的核, k 取值0,1和3。当 k 为0时表示此分支只有批归一化(Batch Normalization, BN)层, k 为1时表示为 1×1 分支核及




图4 MBConv的结构

Fig. 4 Structure of MBConv

BN层, k 为3时表示为 3×3 分支核及BN层。设 W^{in} 和 W^{out} 分别为MBConv的输入和输出,则MBConv可以用公式(1)表示为:

$$W^{\text{out}} = \sum_{k \in \{0, 1, 3\}} \text{BN}(W^{\text{in}} * M_{k \times k}, \mu_k, \rho_k, \lambda_k, \delta_k), \quad (1)$$

其中: $\mu_k, \rho_k, \lambda_k, \delta_k$ 分别表示各分支卷积核后BN层的累积均值、标准差、缩放参数和偏移参数,*为卷积算子。

当 k 为0时,为了便于与其他分支进行拼接,将输入 W^{in} 转换成一个恒等映射的卷积核 $W^{\text{in'}}$,保留此分支输入特征再进行批归一化处理,即

$$\text{BN}(W^{\text{in}} * M_{0 \times 0}, \mu_0, \rho_0, \lambda_0, \delta_0) = (W^{\text{in'}} - \mu_0) \frac{\lambda_0}{\rho_0} + \delta_0. \quad (2)$$

当 k 为1或3时,此分支先经过一个分支核,再进行批归一化操作,即:

$$\text{BN}(W^{\text{in}} * M_{k \times k}, \mu_k, \rho_k, \lambda_k, \delta_k) = \frac{\lambda_k}{\rho_k} W^{\text{in}} * M_{k \times k} - \frac{\mu_k \lambda_k}{\rho_k} + \delta_k. \quad (3)$$

MBConv首先将不同的输入经过多分支卷积操作后转换成相同大小的 3×3 核并相加,来扩展计算块的通道和基数。然后,将计算出的特征图按照通道维度进行拼接。此时,每组特征图中的通道数与原架构中的通道数相同,还可以引导不同组的计算块学习更多样化的特征。

在推理阶段将网络中的多个卷积层(如 3×3 和 1×1 卷积层)和批量归一化层的参数融合成一个等效的卷积层。将训练阶段的多分支结构转换为推理阶段的单分支结构,使这些复杂的计算简化为单次卷积操作,减少计算开销的同时避免

模型性能的急剧下降。

3.1.2 精简操作

YOLOv8 中采用的交叉阶段部分网络层 (Cross Sage Partial Layer, CSPLayer) 在计算中间层特征映射时存在大量冗余。因此,本文设计的 MELA 先采用普通卷积生成一些固有的特征映射,然后引入 GhostNet^[32] 中的 Ghost 卷积利用简单的线性运算来丰富特征和通道信息,在保持输出特征映射尺寸不变的前提下,MELA 模块相较于传统卷积神经网络显著减少了参数量与计算复杂度。

3.2 细节增强与共享检测头

本文设计了一个轻量型的细节增强与共享检测头处理由骨干网络提取的特征,侧重关注小目标信息,并输出目标的边界框坐标和类别得分,检测头的结构如图 5 所示。




图 5 DESD-Head 的结构细节

Fig. 5 Structural details of DESD-Head

基线解耦检测头采用的普通卷积层在搜索特征空间时没有任何侧重,然而高频的细节信息(如边缘和轮廓)对于小目标的捕获具有重要意义。此外,SAR 影像中复杂背景的普遍存在加剧了这一问题。因此,受 DEA-Net^[33] 的启发,本文首先在检测头中使用细节增强卷积 (Detail-Enhanced Convolution, DEConv) 替换部分普通卷积,从而将先验信息整合到普通卷积层,以增强表征信息和泛化能力。DEConv 包含五个并行卷

积层:香草卷积 (Vanilla Convolution, VC)、中心差分卷积 (Central Difference Convolution, CDC)、角差分卷积 (Angular Difference Convolution, ADC)、水平差分卷积 (Horizontal Difference Convolution, HDC) 和垂直差分卷积 (Vertical Difference Convolution, VDC)。然后使用重新参数化技术,将 DEConv 等效地转换为没有额外参数和计算成本的普通卷积。最后设计共享卷积,改善信息提取能力并减少需要训练的参数数量。

如图 5 中 ShareConv 模块所示,共享卷积由两组细节增强卷积和组归一化 (Group Normalization, GN) 模块线性组成。GN 模块在处理较小或单张图片时能够提供比批归一化更稳定的效果,提高了模型的鲁棒性。相比于每个膨胀率使用独立的卷积层,共享卷积层对不同膨胀率使用组归一化模块来提取多尺度的特征。低膨胀率捕捉局部细节,高膨胀率捕捉全局上下文信息,这样可减少冗余,提升模型效率。为了改善每个检测头所检测的目标尺度不一致的问题,使用 Scale 层对输入张量特征按比例缩放,使模型在训练过程中动态调整某些层的输出强度。基于此,大幅度减少了内存存储从而生成紧凑的检测头模型,可以在参数量更少、计算量更小的情况下,尽可能避免小目标检测精度的急剧下降。

3.3 特征丰富度引导的剪枝和知识蒸馏

将改进后的模型进行特征丰富度评分,根据得分判别模型中各层通道特征的重要程度并裁剪次要通道,且不需要微调训练。知识蒸馏模块将剪枝优化后的模型作为学生网络,以 YOLOv8-n, YOLOv8-s, YOLOv8-m, YOLOv8-l, YOLOv8-x 为教师网络分别指导轻量的学生网络进行训练,并在教师网络和学生网络的输出上构建特征丰富度引导的蒸馏损失,使模型参数不断更新,得到超轻量化的 SAR 影像目标检测权重模型。

3.3.1 特征丰富度评分

对于具有权重张量 $A^{(1)}, A^{(2)}, \dots, A^{(d)}$ 的深度前馈神经网络,全连接层对应的权重张量是二维矩阵,二维卷积层对应的权重张量是四维的。为了给全连接层和卷积层的特征丰富度评分一个统一的定义,本文假设每个权重张量被展开成一

个一维向量。对于每一个展开向量,将权重按照给定的索引映射以升序排序,即 $|A[x_i]| \leq |A[x_{i+1}]|$ 在 $i \leq i+1$ 时成立,其中 $A[x_i]$ 表示由索引 x 映射的权重张量 A 的第 i 项。则 A 的第 x_i 个神经元的特征丰富度评分定义为:

$$score(x_i; A) = \frac{(A[x_i])^2}{\sum_{i=1}^n (A[x_i])^2}, \quad (4)$$

其中:分子部分表示索引 x_i 处权值的平方,分母部分表示从索引 x_1 开始到末尾 x_n 平方的和。

3.3.2 特征丰富度引导的剪枝

特征丰富度评分衡量同一层所有连接的相对重要性,全局剪枝小于目标特征丰富度分数的连接,到满足所需的全局稀疏性约束为止,即对任意权重张量 A 公式(5)成立。

$$(A[x_i])^2 < (A[x_{i+1}])^2 \Rightarrow score(x_i; A) < score(x_{i+1}; A). \quad (5)$$

基于特征丰富度分数的全局剪枝和基于权重分数的全局剪枝不同,特征丰富度在每层中至少保留一个连接且易于使用。与普通的基于权重的剪枝类似,特征丰富度分数没有任何需要调优的超参数,并且很容易通过基本张量操作实现。此外,特征丰富度分数中分母所需权值的平方排序只占用很小的计算开销。

对于一个深度为 d 的神经网络,给定输入向量 u ,其输出为

$$f(u; A^{(1:d)}) = A^{(d)} \sigma(A^{(d-1)} \sigma(\dots A^{(2)} \sigma(A^{(1)} u) \dots)), \quad (6)$$

其中: σ 表示 ReLU 激活函数, $A^{(j)}$ 表示第 j 层的特征丰富度矩阵, $A^{(1:d)} = (A^{(1)}, A^{(2)}, \dots, A^{(d)})$ 表示第1层到第 d 层特征丰富度矩阵的集合。其中每一层都通过其权重矩阵对前一层的输出进行线性变换,然后运用激活函数引入非线性特征信息。

用 $\tilde{A}^{(j)}$ 表示第 j 层剪枝后的权重矩阵,则:

$$\tilde{A}^{(j)} = R \odot A^{(j)}, \quad (7)$$

其中: R 表示满足稀疏性约束的二值矩阵,当值为0时舍弃对应权重,值为1时则保留; $\odot$ 表示逐元素相乘。

为了最小化剪枝带来的性能损失,本文基于

特征丰富度并采用最小化输出损失进行网络剪枝,这一过程可表示为式(8):

$$\sup_{\|u\|_2 \leq 1} \|f(u; A^{(1:d)}) - f(u; A^{(1:j-1)}, \tilde{A}^{(j)}, A^{(j+1:d)})\|_2 \leq \frac{\|A^{(j)} - \tilde{A}^{(j)}\|_F}{\|A^{(j)}\|_F} \left(\prod_{j=1}^d \|A^{(j)}\|_F \right), \quad (8)$$

其中: $\sup_{\|u\|_2 \leq 1}$ 表示对所有 $\|u\|_2 \leq 1$ 的值取上确界;

$\|\cdot\|_2$ 表示谱范数,即取矩阵的最大奇异值; $\|\cdot\|_F$ 表示 Frobenius 范数,衡量剪枝前后特征丰富度矩阵间的相对误差; $\|f(u; A^{(1:d)}) - f(u; A^{(1:j-1)}, \tilde{A}^{(j)}, A^{(j+1:d)})\|_2$ 表示两个函数之间的 L_2 距离。

公式(8)中“ $\leq$ ”的前半部分表示剪枝前后函数输出的最大变化,后半部分表示可接受的最大变化的上界,这个上界与权重矩阵的近似误差以及模型的复杂度有关,可根据需要进行设定。此剪枝操作能够最小化剪枝后的输出与原始输出之间的失真,且不需要在修剪每个连接后重新计算。

3.3.3 特征丰富度引导的知识蒸馏

为了更好地利用每个通道中的特征知识,本文利用激活函数软对齐教师和学生网络之间相应通道。为此,首先将通道的激活函数转换为概率分布,从而使用概率距离来衡量教师和学生网络之间的差异。将教师网络和学生网络分别表示为 T 和 S ,教师和学生网络的激活映射分别表示为 φ_T 和 φ_S ,则特征丰富度引导的蒸馏损失可表示为公式(9),使用 $\xi(\cdot)$ 将激活值转换成如公式(10)的概率分布:

$$L(\xi(\varphi_T), \xi(\varphi_S)) = L(\xi(\varphi_T^c), \xi(\varphi_S^c)), \quad (9)$$

$$\xi(\varphi^c) = \frac{\exp\left(\frac{\varphi^c, m}{\Omega}\right)}{\sum_{m=1}^{W \cdot H} \exp\left(\frac{\varphi^c, m}{\Omega}\right)}, \quad (10)$$

其中: $c=1, 2, \dots, C$ 表示对通道进行索引, $\xi(\varphi_T^c)$ 和 $\xi(\varphi_S^c)$ 分别表示教师网络和学生网络在通道 c 上的输出, m 表示通道中的空间位置索引, Ω 是一个温度超参数, W 和 H 为特征图的宽度和高度, φ^c 表示第 c 个通道的输出值, φ^c, m 表示第 c 个通道在位置 m 的值。式(9)表示通过函数 ξ 处理后

的教师网络和学生网络的输出在通道 c 上是相等的。这意味着在知识蒸馏的过程中,学生网络的输出尽量模仿教师网络在每个通道上的输出分布,从而达到知识传递的目的。公式(10)将输入 φ^c 转换为归一化的概率分布,使得所有位置的概率之和为 1。通过引入温度参数 Ω 调节概率分布的平滑程度,从而影响模型的训练和推理过程。

通过应用 softmax 归一化消除大型教师网络和紧凑学生网络之间的尺度影响,从而实现知识蒸馏的目标。如果教师和学生之间的通道数量不匹配,则使用 1×1 卷积层对学生网络的通道数量进行上采样。 $L(\cdot)$ 评估了教师网络和学生网络通道特征分布的差异,其计算方法为:

$$L(\varphi_T, \varphi_S) = \frac{\Omega^2}{C} \sum_{c=1}^C \sum_{m=1}^{W \cdot H} \xi(\varphi_T^c, m) \cdot \log \left[\frac{\xi(\varphi_T^c, m)}{\xi(\varphi_S^c, m)} \right], \quad (11)$$

其中: $\xi(\varphi_T^c, m)$ 和 $\xi(\varphi_S^c, m)$ 表示教师网络和学生网络在第 c 个通道、第 m 个像素点的输出概率;

$\log \left[\frac{\xi(\varphi_T^c, m)}{\xi(\varphi_S^c, m)} \right]$ 表示教师网络和学生网络在第 c

个通道、第 m 个像素点的对数似然比; $\frac{\Omega^2}{C}$ 是归一化因子,用于平衡不同类别之间的权重。

式(11)通过最小化蒸馏损失,使得学生网络可以学习到教师网络的输出分布,从而提高密集目标检测任务的精度。若 $\xi(\varphi_T^c, m)$ 较大, $\xi(\varphi_S^c, m)$ 也同样较大,教师和学生网络之间损失最小;若 $\xi(\varphi_T^c, m)$ 很小,则蒸馏损失不太关注最小化 $\xi(\varphi_S^c, m)$ 。因此,学生网络倾向于在前景显著性区域产生相似的激活分布,而教师网络背景区域对蒸馏效果的影响较小。

3.4 SAR 影像小目标检测模块

在配置正确的环境和变量下,将待检测影像输入目标检测模块中,并利用知识蒸馏模块输出的超轻量化 SAR 影像目标检测权重模型,回归得到待检测影像中的目标类型和位置信息,实现高精度且超轻量化的 SAR 影像小目标的检测与定位。

4 实验结果分析与讨论

4.1 数据集

实验选择多个不同场景的 SAR 影像目标检测数据集,分别是 MSAR^[34], SAR-Ship^[35]、AIR-SARShip-2.0^[36], SSDD^[37] 和 HRSID^[38] 数据集。首先在 MSAR 数据集上测试主流的轻量检测网络的性能,然后选择综合性能最佳的 YOLOv8-n 模型进行特征提取与融合和检测头的轻量优化,其次在 MSAR 数据集上进行特征丰富度引导的剪枝和知识蒸馏实验,最后在 SAR-Ship, AIR-SARShip-2.0, SSDD 和 HRSID 四个船舶检测数据集上验证目标检测效果。

MSAR 数据集共包括 28 449 张影像切片,集成海丝一号和高分三号卫星数据。MSAR 数据集极化方式包括 HH, HV, VH 和 VV。该数据集含机场、港口、近岸、岛屿、远海、城区等多种场景和飞机、油罐、桥梁、船只四类目标。本研究随机选取数据集中 19 914 张影像为训练集, 2 845 张影像为验证集, 5 690 张影像为测试集。SAR-Ship, SSDD, HRSID 和 AIR-SARShip-2.0 四个数据集均只有船舶一个目标类型。本文将各数据集都按照 7:2:1 的比例分成训练集、验证集和测试集三部分。SAR-Ship 数据集由 102 张中国高分三号影像和 108 张哨兵一号影像构成,包括船舶检测切片 39 729 张,图像分辨率覆盖 1.7~25 m。该数据集包括港口、近岸、岛屿、远海场景和油轮、散货船、大型集装箱船、渔船等各类船舶目标。SSDD 数据集来自 RadarSat-2, TerraSAR-X, Sentinel-1 卫星,分辨率为 1~15 m,共有 1 160 张影像和 2 456 艘船只。HRSID 数据集的重叠比为 25% 的条件下,将 136 张分辨率为 1~5 m 的全景 SAR 影像裁剪为包含 16 951 艘船的 5 604 张 800 pixels×800 pixels 的切片。AIR-SARShip-2.0 数据集是 1.0 版本的扩展,包括从高分三号卫星获得的大小为 1 000 pixels×1 000 pixels 的 300 张影像。

根据 SAR 影像数据集特点,定义小尺寸目标为占图像总面积比例小于 5% 的目标,中尺寸目标介于 5%~20% 之间,大尺寸目标则超过 20%。本文采用的五个数据集中小目标占比大多超过 90%,具体各尺寸目标占比如表 1 所示。

表 1 数据集中各尺寸目标分布情况
Tab. 1 Object size distribution in the dataset

数据集	目标总数	小尺寸		中尺寸		大尺寸	
		目标数量	占比/%	目标数量	占比/%	目标数量	占比/%
MSAR	60 398	56 562	93.65	3 066	5.08	770	1.27
SAR-Ship	50 885	48 831	95.97	2 002	3.93	52	0.10
AIR-SARShip-2.0	2 040	2 016	98.82	23	1.13	1	0.05
SSDD	322	251	77.95	68	21.12	3	0.93
HRSID	16 950	16 858	99.46	83	0.49	9	0.05

4.2 实验环境与参数配置

本实验的硬件环境为 Intel(R) Core(TM) i9-9900K+RTX2080Ti(11 GB 显存),软件环境为 Ubuntu18.04.6+CUDA12.2+Torch2.3.1+Python3.9。训练阶段使用随机梯度下降(Stochastic Gradient Descent,SGD)优化学习率,动量为 0.937,权值衰减为 0.000 5,IoU 为 0.7,输入图像尺寸为 640×640。知识蒸馏阶段设置蒸馏损失衰减为 constant,特征损失率为 1.0,蒸馏特征层为第 15,18 和 21 层。MSAR 数据集上设置初始学习率为 0.001,最终学习率为 0.01,训练轮次为 600。其他四个船舶数据集上设置初始学习率和最终学习率均为 0.01,训练轮次为 300。

4.3 性能评价指标

本文使用浮点运算数(Floating Point Operations,FLOPs)、参数量(Params)、平均检测精度(Average Precision,AP)、所有类别平均检测精度均值(Mean Average Precision,mAP)和每秒帧率(Frames Per Second,FPS)作为模型性能的评价指标,mAP 值越大模型性能越好。为评估模型对不同尺寸目标的检测性能,用 AP_s 、 AP_m 、 AP_l 分别代表小、中、大尺寸目标的检测精度 AP 值。召回率 R (Recall)的计算如公式(12)所示,精确率 P (Precision)的计算如公式(13)所示,然后对 R 和 P 形成的 PR 曲线进行积分得到平均检

测精度 AP ,如公式(14)所示:

$$R = \frac{TP}{TP + FN}, \quad (12)$$

$$P = \frac{TP}{TP + FP}, \quad (13)$$

$$AP = \int_0^1 P(R) dR, \quad (14)$$

其中: TP 为真正例(True Positive),表示预测为正例,实际为正例,即算法预测正确; FP 为假正例(False Positive),表示预测为正例,实际为负例,即算法预测错误; FN 为假反例(False Negative),表示预测为负例,实际为正例,即算法预测错误。 R 为预测正确的正例数占真正的正例数的比率,即召回率; P 为预测正确的正例数占预测为正例总量的比率,即精确率。

mAP 为所有类别平均 AP 值,如公式(15)所示:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i, \quad (15)$$

其中, n 为目标类别数。

4.4 在 SSDD 数据集上测试 DESD-Head 效果

YOLO 系列检测网络的检测头在整个网络中的计算量和参数量占比都较大,将本文提出的轻量化细节增强与共享小目标检测头移植到 YOLOv8-n 和 YOLOv10-N 上,并在 SSDD 数据集上验证此检测头的效果,实验结果如表 2 所示。

表 2 SSDD 数据集上 DESD-Head 的目标检测效果
Tab. 2 Detection performance of DESD-Head on SSDD dataset

网络模型	DESD-Head	FLOPs/G	Params/M	FPS	mAP/%	AP_s /%	AP_m /%	AP_l /%
YOLOv8-n	×	8.089	3.007	265.4	98.3	63.9	75.3	73.2
YOLOv8-n	✓	6.525(↓19.33%)	2.362(↓21.45%)	274.2(↑3.21%)	98.0	64.3	73.5	74.4
YOLOv10-N	×	6.532	2.266	178.9	97.6	61.7	73.2	64.7
YOLOv10-N	✓	6.300(↓3.55%)	1.947(↓14.08%)	188.5(↑5.09%)	97.4	65.8	73.8	71.0

可以看出,与 YOLOv8-n 的解耦头和 YOLOv10-N 的分类头相比,DESD-Head 显著降低了计算量和参数量且在模型推理速度方面有了不同程度的提高。虽然 mAP 略有下降,但对小目标的检测精度分别提升了 0.4 和 4.1。验证了 DESD-Head 能够有效地平衡计算复杂度和检测精度,同时满足轻量化和检测性能的要求。

4.5 特征丰富度引导的剪枝和知识蒸馏效果

4.5.1 特征丰富度引导的剪枝轻量化效果

在基线上改进了特征聚合方式和检测头达到了一定的轻量化效果,采用特征丰富度引导的剪枝使模型更加精简。为试验最佳剪枝比例,将改进了特征聚合和检测头的网络按照 10%~

40% 的比例施加特征丰富度引导的剪枝,并与基线算法 YOLOv8-n 和剪枝前的网络进行对比。剪枝前后轻量化效果对比如表 3 所示,表中基线为 YOLOv8-n 模型。M+D 表示用 MELA 模块替换基线中的 C2f 模块,用 DESD-Head 替换基线的解耦头,下同。对改进了特征聚合方式和检测头的网络施加不同比例的剪枝后,网络大小和各项检测精度比剪枝前均有降低。剪枝率为 10% 时,模型在平均检测精度和小、中尺寸目标的检测精度上仍比基线 YOLOv8-n 模型有提升;剪枝率为 20% 时,模型对小、中尺寸目标的检测精度仍比基线 YOLOv8-n 模型高;剪枝率上升到 30% 和 40% 时,模型的各项检测精度下降较多,所以不再适合进行更高比例的剪枝。

表 3 MSAR 数据集上不同剪枝比例下轻量化效果
Tab. 3 Lightweight effect under different pruning ratios on the MSAR dataset

网络模型	剪枝比例	FLOPs/G	Params/M	mAP/%	AP _s /%	AP _M /%	AP _L /%
基线	—	8.089	3.007	84.6	70.6	80.1	69.1
M+D	0%	5.291	1.944	86.6	75.0	83.2	71.8
M+D	10%	4.724	1.041	85.8	74.1	82.3	63.5
M+D	20%	4.186	0.888	83.2	72.5	81.0	68.3
M+D	30%	3.661	0.742	78.9	69.5	78.4	58.7
M+D	40%	3.149	0.596	80.6	66.2	77.0	66.3

4.5.2 不同剪枝比例下的知识蒸馏对比试验

为验证特征丰富度引导的剪枝和知识蒸馏策略的有效性,设计了一组不同学生网络剪枝比例下的知识蒸馏对比试验。将改进剪枝后的网络作为学生网络,以 YOLOv8-n, YOLOv8-s, YOLOv8-m, YOLOv8-l 和 YOLOv8-x 分别作为教师网络进行特征丰富度引导的知识蒸馏,性能统计见表 4。各剪枝比例下检测的最优结果用加粗字体表示,第一列括号内的值表示各比例剪枝下未蒸馏网络的 mAP 值,第五列括号内的值表示经蒸馏后 mAP 的变化。

由表 4 可知,10%~30% 剪枝后的模型经特征丰富度引导的知识蒸馏优化后 mAP 大多有上升,其中经 10% 剪枝的以 YOLOv8-m 为教师网络的模型蒸馏效果最优,相对于原始学生网络 mAP 值提升 3.6,相对于 YOLOv8-n 模型 mAP 值提升了 4.8;经 20% 剪枝的以 YOLOv8-s 为教师网络的模型蒸馏提升幅度最大,相对于原始学

生网络 mAP 值提升 5.8,相对于 YOLOv8-n 模型 mAP 值提升了 4.4。在相同的剪枝比例下,不是越大的教师网络就能取得更好的蒸馏效果。随着学生模型与教师模型的差距逐渐变大,即学生模型剪枝比例为 30%,教师模型为 YOLOv8-x 后,蒸馏后 mAP 值逐渐低于蒸馏前,蒸馏效果反而变得不理想。因此,最终采用 20% 剪枝优化后的模型为学生网络, YOLOv8-s 为教师网络,经特征丰富度引导的知识蒸馏后构建超轻量化 SAR 影像小目标检测模型。

4.6 消融实验

为了全面分析本文方法在轻量化效果上的提升,在 MSAR 数据集上对算法进行了消融实验。实验结果如表 5 所示,表中模型都在相同环境和参数下运行。其中,Model-1 为本文基线模型,采用 C2f 提取和融合特征。Model-2 将 C2f 换成本文提出的 MELA 模块,相比基线模型计算量下降 25.2%、参数量下降 26.9%,但是 mAP 值只

表 4 不同剪枝比例的学生网络经蒸馏后在 MSAR 数据集上性能的提升结果

Tab. 4 Performance improvement results of student networks with different pruning ratios after distillation on the MSAR dataset

学生网络	教师网络	FLOPs/G	Params/M	mAP/%	AP _s /%	AP _m /%	AP _L /%
10% 剪枝的 M+D (mAP 85.8)	YOLOv8-n	4.724	1.041	86.1(↑0.3)	75.1	82.7	73.1
	YOLOv8-s			87.8(↑2.0)	75.1	83.7	75.9
	YOLOv8-m			89.4(↑3.6)	76.1	85.1	78.3
	YOLOv8-l			87.7(↑1.9)	74.7	84.0	76.2
	YOLOv8-x			86.9(↑1.1)	74.5	83.3	73.4
20% 剪枝的 M+D (mAP 83.2)	YOLOv8-n	4.186	0.888	86.9(↑3.7)	73.7	82.5	70.6
	YOLOv8-s			89.0(↑5.8)	75.7	85.1	78.1
	YOLOv8-m			85.7(↑2.5)	73.4	82.8	79.4
	YOLOv8-l			84.1(↑1.9)	73.3	81.2	75.0
	YOLOv8-x			83.8(↑0.6)	72.4	80.5	74.4
30% 剪枝的 M+D (mAP 78.9)	YOLOv8-n	3.661	0.742	81.1(↑2.9)	65.9	76.7	81.1
	YOLOv8-s			80.4(↑1.5)	67.0	77.9	80.4
	YOLOv8-m			80.6(↑1.7)	66.2	77.9	80.6
	YOLOv8-l			80.0(↑1.1)	65.7	76.1	79.6
	YOLOv8-x			78.5(↓0.4)	62.8	72.0	74.4
40% 剪枝的 M+D (mAP 80.6)	YOLOv8-n	3.149	0.596	80.4(↓0.2)	65.4	76.4	68.5
	YOLOv8-s			80.3(↓0.3)	65.5	77.7	70.0
	YOLOv8-m			76.9(↓3.7)	61.3	73.9	63.0
	YOLOv8-l			76.5(↓4.1)	62.6	72.3	62.9
	YOLOv8-x			75.7(↓4.9)	60.6	70.3	61.1

表 5 在 MSAR 数据集上的消融实验

Tab. 5 Ablation experiments on the MSAR dataset

网络模型	MELA	DESD-Head	剪枝	蒸馏	FLOPs/ G	Params/ M	FPS/ (frames ⁻¹)	mAP/%	AP _s /%	AP _m /%	AP _L /%
Model-1	×	×	×	×	8.089	3.007	263.5	84.6	70.6	80.1	69.1
Model-2	✓	×	×	×	6.051	2.198	270.8	82.0	66.5	77.1	61.5
Model-3	×	✓	×	×	6.525	2.362	230.2	89.6	78.0	86.2	74.8
Model-4	✓	✓	×	×	5.291	1.944	231.9	86.6	75.0	83.2	71.8
Model-5	✓	✓	✓	×	4.186	0.888	250.3	83.2	72.5	81.0	68.3
Model-6	✓	✓	✓	✓	4.186	0.888	279.7	89.0	75.7	85.1	78.1

下降 2.6,这表明,MELA 模块特征学习能力略有削弱,但在轻量化需求场景中具有显著优势。Model-3 将基线模型的检测头替换成 DESD-Head,相比基线网络计算量下降 19.3%、参数量下降 21.4%,并且 mAP 值提升了 5.0,AP_s提升了 7.4,体现了该检测头在小目标检测任务中的优越性能。Model-4 将 MELA 模块与 DESD-Head 结合,计算量与参数量进一步下降,mAP 值

相比基线上升了 2.0,但略低于 Model-3。造成 mAP 降低的原因是 MELA 模块对特征传递路径的精简导致部分特征学习能力的削弱。然而,这种组合设计使模型整体计算量和参数量分别减少了 34.6% 和 35.35%,在综合性能上实现了更优的轻量化目标,因此本文选择 Model-4 进行后续实验。Model-5 基于 Model-4 进行特征丰富度引导的剪枝,剪枝率为 20%。剪枝后计算量再下

降 20.9%,但检测精度也略有降低。Model-6 在 Model-5 的基础上以 YOLOv8-s 为教师网络进行特征丰富度引导的知识蒸馏,相比基线网络检测精度提升 4.4,模型大小和每秒帧率均达到最优。综上所述,本文方法能有效减少计算量与参数量,提升目标检测精度,达到速度与精度的平衡。

4.7 不同 SAR 影像目标检测方法在 MSAR 数据集上的性能对比

为了适应 SAR 影像小目标检测在精度和效率方面的要求,在 MSAR 数据集上对比目前最轻量的 YOLO 系列和 RT-DETR 模型的目标检测效果。从模型大小、检测速度、检测精度、各尺寸目标检测效果等方面综合评价,结果如表 6 所示。每列最优结果用加粗字体表示,次优结果用下划线表示,下同。可以看出,本文方法使用更少的参数和计算资源,达到了最高的平均检测精度和

小目标检测精度。

以各模型在 MSAR 数据集上的 FPS 值为横坐标、mAP 值为纵坐标、模型计算量为圆圈半径绘制可视化对比。如图 6 所示,本文方法在 MSAR 数据集上相较于其他轻量级网络,实现了最小模型体积下的最优检测速度和精度。

表 7 展示了 MSAR 数据集上不同网络模型各类别目标检测效果对比。本文方法对飞机和船只目标的检测精度最高,分别为 97.0 和 83.7。对于受复杂背景影响的油罐和尺度差异大的桥梁,本文方法比基线 YOLOv8-n 模型分别提升了 4.4 和 2.1,但比 YOLOv7 模型分别下降了 4.9 和 0.8。然而,YOLOv7 的模型体积较大、网络层数较深。综合来看,本文方法在提升小目标检测效果的同时,保持了超轻量化特性。

表 6 不同 SAR 影像目标检测方法在 MSAR 数据集上的性能对比结果

Tab. 6 Performance comparison results of different SAR images object detection methods on MSAR dataset

网络模型	FLOPs/G	Params/M	FPS/(frame·s ⁻¹)	mAP/%	AP _s /%	AP _m /%	AP _L /%
YOLOv5-n	4.130	<u>1.761</u>	125.0	80.8	73.9	74.4	<u>80.7</u>
YOLOv7	103.223	36.501	96.2	<u>86.7</u>	<u>74.4</u>	85.9	81.6
YOLOv7-tiny	13.022	6.007	109.9	68.9	62.9	72.3	61.0
YOLOv8-n	8.089	3.007	<u>263.5</u>	84.6	70.6	80.1	69.1
YOLOv9-T	7.599	1.971	42.5	77.6	71.2	80.5	77.8
YOLOv10-N	6.532	2.266	228.2	83.1	65.7	75.7	52.7
RT-DETR(r18)	57.290	18.860	36.7	76.8	51.4	71.1	55.4
本文方法	<u>4.186</u>	0.888	279.7	89.0	75.7	<u>85.1</u>	78.1




图 6 “平均精度-FPS-模型体积”可视化对比

Fig. 6 Visual comparison of "mAP-FPS-model size"

表 7 不同方法在 MSAR 数据集上的各类别目标检测精度

Tab. 7 Detection accuracy of various types of targets using different methods on the MSAR dataset

网络模型	飞机	油罐	桥梁	船只
YOLOv5-n	93.8	83.8	74.6	71.0
YOLOv7	94.0	92.2	88.8	71.7
YOLOv7-tiny	88.4	85.9	46.9	54.4
YOLOv8-n	90.2	82.9	85.9	79.5
YOLOv9-T	88.4	<u>87.5</u>	67.9	66.5
YOLOv10-N	86.7	83.7	81.9	80.2
RT-DETR(r18)	<u>96.5</u>	79.6	77.3	54.0
本文方法	97.0	87.3	<u>88.0</u>	83.7

4.7.1 在 MSAR 数据集上的可视化结果

根据表 6 中的结果选择目标检测效果较好的 YOLOv5-n, YOLOv7, YOLOv8-n, YOLOv10-N 和本文方法进行可视化对比。如图 7 所示,其中红色框标为错检目标,明黄色框

标为漏检目标,下同(彩图见期刊电子版)。在陆地杂波和海杂波干扰的情况下,本文方法表现出优异的性能,有效地解决了在不同场景下的杂波干扰。同时,对于某些船舶,本文方法获得了更精确的位置定位。




图 7 MSAR 数据集上各方法可视化对比

Fig. 7 Visual comparison of various methods on the MSAR dataset

4.8 在多种船舶数据集上的实验结果

为验证本文方法在大范围复杂场景 SAR 影像中对目标的快速检测能力,使用在 MSAR 数据集上训练得到的超轻量权重模型对 SAR-Ship、AIR-SARShip-2.0, SSDD 和 HRSID 四种船舶数据集上的目标进行检测。如表 8 和表 9 所示,本文方法均能以更少的计算量和参数量取得最高的 mAP 和 FPS,同时在 SSDD 数据集上的 AP_s 为最高,在 HRSID 数据集上的 AP_s 仅比最高值低 2.8。

与以 ResNet-50 为主干网络的双阶段大规模检测方法^[39-42,18]相比,YOLO 系列的轻量级检测网络反而能在 SSDD 和 HRSID 数据集上取得更

好的综合效果,同时显著减少资源需求,实验结果如表 9 所示。本文方法性能的提升主要归因于设计的多分支高效层聚合模块和细节增强共享小目标检测头,显著增强了舰船目标的上下文表征能力,有效降低了 SAR 影像中海地杂波对检测性能的干扰,这与图 7 和图 9 的可视化结果一致。

由表 8 和表 9 中的结果选择检测效果较好的 YOLOv5-n, YOLOv7-tiny, YOLOv8-n 和本文方法进行多种船舶数据集目标检测效果可视化对比。图 9 展示了不同场景下的综合对比结果,包括海岛海岸干扰场景、近海岸大场景、码头场

表 8 不同方法在 SAR-Ship 和 AIR-SARShip-2.0 数据集上的目标检测结果

Tab. 8 Object detection results of different methods on SAR-Ship and AIR-SARShip-2.0 datasets

网络模型	FLOPs/G	Params/M	SAR-Ship		AIR-SARShip-2.0	
			FPS	mAP/%	FPS	mAP/%
YOLOv5-n	4.1	1.8	259.8	97.7	257.1	67.8
YOLOv7	103.2	36.5	80.2	94.7	83.0	63.0
YOLOv7-tiny	13.0	6.0	264.5	96.8	256.5	70.3
YOLOv8-n	8.1	3.0	259.9	97.7	263.3	75.7
YOLOv9-T	10.7	2.6	69.5	94.7	70.2	74.2
YOLOv10-N	6.5	2.3	168.8	93.1	201.7	64.5
RT-DETR(r18)	56.9	18.8	58.6	95.3	60.7	51.8
CenterNet++ ^[39]	89.4	20.3	52.3	94.9	48.4	73.9
GhostNet ^[32]	8.7	3.6	204.1	91.7	199.9	49.0
Quant-Det ^[20]	9.5	3.2	213.2	95.7	208.5	77.0
本文方法	4.2	0.9	281.3	98.1	283.5	82.5

表 9 不同方法在 SSDD 和 HRSID 数据集上的目标检测结果

Tab. 9 Object detection results of different methods on SSDD and HRSID datasets

网络模型	FLOPs /G	Params /M	SSDD					HRSID				
			FPS	mAP /%	AP _s /%	AP _m /%	AP _L /%	FPS	mAP /%	AP _s /%	AP _m /%	AP _L /%
Cascade R-CNN ^[40]	152.2	55.6	9.6	93.1	54.8	67.1	57.8	10.0	87.7	67.5	67.7	28.8
Mask Scoring R-CNN ^{†[41]}	206.7	48.1	13.4	94.7	55.6	65.3	51.2	12.6	87.6	65.3	65.8	22.2
Hybrid Task Cascade ^[42]	278.5	69.3	6.3	94.5	55.9	68.4	59.2	7.8	87.7	69.0	71.2	38.1
RetinaNet ^[18]	114.8	42.7	31.9	90.2	51.2	62.6	45.4	33.7	84.7	60.9	60.9	26.8
YOLOv5-n	4.1	1.8	254.2	97.2	62.1	74.6	69.1	256.6	90.3	50.0	73.5	65.7
YOLOv7	103.2	36.5	80.9	94.5	64.2	77.5	79.4	82.8	87.7	47.7	73.4	57.9
YOLOv7-tiny	13.0	6.0	263.6	96.2	62.7	78.4	72.0	262.3	87.0	45.3	71.5	57.2
YOLOv8-n	8.1	3.0	265.4	98.3	63.9	75.3	73.2	265.2	89.8	51.0	76.8	52.3
YOLOv9-T	10.7	2.6	72.6	97.0	63.3	75.7	72.8	79.1	88.2	52.7	73.1	62.8
YOLOv10-N	6.5	2.3	178.9	97.6	61.7	73.2	64.7	167.8	89.4	53.9	77.4	52.2
RT-DETR(r18)	56.9	18.8	60.6	97.2	64.6	76.4	77.6	60.0	91.3	51.4	75.7	60.5
本文方法	4.2	0.9	279.3	98.6	64.7	74.1	74.8	282.7	91.5	66.2	77.8	64.9

景和密集目标场景等。本文方法能够在不同场

数据集上均展现出稳定且出色的目标检测

景下有效排除干扰,准确检出目标,在各种 SAR

效果。





图 8 本文方法对大场景的目标检测效果

Fig. 8 Object detection effect of the proposed method in large scale scenarios






图9 在多种船舶数据集上各方法目标检测结果可视化对比

Fig. 9 Visual comparison of object detection results using various methods on multiple ship datasets

5 结 论

针对现有SAR影像目标检测网络轻量化效果不足、精度不高的问题,提出了一种高效的超轻量化SAR影像小目标检测模型,有效降低了计算量和参数量。首先,设计了多分支高效层聚合模块,以满足实际设备在性能和成本上的多样化需求。其次,为更好地适应SAR影像数据的特点,提出了细节增强与共享的检测头,有效抑制了海洋和地面杂波的干扰。最后,结合特征丰富度引导的剪枝与知识蒸馏策略,进一步压缩模型并改进了目标分类与回归时学生和教师网络的通道信息对齐。实验结果表明,本文方法的计算量和参数量分别为4.186 G和0.888 M,符合

超轻量化标准,并且在各尺度目标检测精度方面达到了与现有最先进网络相当的性能。然而,在大场景中,长宽差异较大的目标仍易被错检,模型泛化能力有待进一步提升。后续研究将考虑采用更先进的目标检测方法,结合中间层知识蒸馏和困难目标挖掘,优化大场景下的SAR影像目标检测方案,提高轻量化方法对多尺度目标的适应性和稳健性。

作者贡献声明:

杨晓敏:提出超轻量化检测方法,设计实验和撰写论文;

杨军:指导数学模型推导、实验分析和论文撰写。

参考文献:

- [1] 徐芳,刘晶红,孙辉,等. 光学遥感图像海面船舶目标检测技术进展[J]. 光学精密工程, 2021, 29(4): 916-931.
XU F, LIU J H, SUN H, *et al.* Research progress on vessel detection using optical remote sensing image[J]. *Opt. Precision Eng.*, 2021, 29(4): 916-931. (in Chinese)
- [2] 杨军,韩鹏飞. 采用神经网络架构搜索的高分遥感影像目标检测[J/OL]. 吉林大学学报(工学版), 2023: 1-12. (2023-01-31). <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=JLGY20230130008&dbname=CJFD&dbcode=CJFQ>.
YANG J, HAN P F. Target Detection of High-Scoring Remote Sensing Images Using Neural Network Architecture Search[J/OL]. *China Industrial Economics*, 2023: 1-12. (2023-01-31). <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=JLGY20230130008&dbname=CJFD&dbcode=CJFQ>
- [3] YANG R, PAN Z R, JIA X X, *et al.* A novel CNN-based detector for ship detection based on rotatable bounding box in SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 1938-1958.
- [4] CUI Z Y, WANG X Y, LIU N Y, *et al.* Ship detection in large-scale SAR images via spatial shuffle-group enhance attention[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 379-391.
- [5] PU H, ZHU Z W, HU Q, *et al.* Ulit-BiDet: an ultralightweight object detector for SAR images based on binary neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1-21.

- [6] WANG Z W, LU J W, WU Z Y, *et al.* Learning efficient binarized object detectors with information compression [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(6): 3082-3095.
- [7] GE ZH, LIU S T, WANG F, *et al.* YOLOX: Exceeding YOLO series in 2021 [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, USA: IEEE, 2021: 13039-13048.
- [8] XU SH L, WANG X X, LV W Y, *et al.* PP-YOLO: An Evolved Version of YOLO [EB/OL]. 2022: *arXiv*: 2203.16250. <https://arxiv.org/abs/2203.16250.pdf>.
- [9] ZHOU L, WEI S Y, CUI Z M, *et al.* Lira-YOLO: a lightweight model for ship detection in radar images [J]. *Journal of Systems Engineering and Electronics*, 2020, 31(5): 950-956.
- [10] LI Y D, ZHANG S S, WANG W Q. A light-weight faster R-CNN for ship detection in SAR images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 19: 4006105.
- [11] GAO G, LIU L, ZHAO L J, *et al.* An adaptive and fast CFAR algorithm based on automatic censoring for target detection in high-resolution SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(6): 1685-1697.
- [12] WANG Y H, LIU H W. A hierarchical ship detection scheme for high-resolution SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(10): 4173-4184.
- [13] HUO W B, HUANG Y L, PEI J F, *et al.* Ship detection from ocean SAR image based on local contrast variance weighted information entropy [J]. *Sensors*, 2018, 18(4): 1196.
- [14] 张鹏, 张嘉峰, 刘涛. 基于相干度优化的极化顺轨干涉 SAR 慢小目标 CFAR 检测 [J]. *北京航空航天大学学报*, 2019, 45(3): 575-587.
ZHANG P, ZHANG J F, LIU T. Slow and small target CFAR detection of polarimetric along-track interferometric SAR using coherence optimization [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2019, 45(3): 575-587. (in Chinese)
- [15] 黄泽贤, 吴凡路, 傅瑶, 等. 基于深度学习的遥感图像舰船目标检测算法综述 [J]. *光学精密工程*, 2023, 31(15): 2295-2318.
- [16] GUO Q, LIU J N, KALIUZHENYI M. YOLOX-SAR: high-precision object detection system based on visible and infrared sensors for SAR remote sensing [J]. *IEEE Sensors Journal*, 2022, 22(17): 17243-17253.
- [17] LI Y X, DUA A, REN F B. Light-weight retinanet for object detection on edge devices [C]. 2020 *IEEE 6th World Forum on Internet of Things (WF-IoT)*. June 2-16, 2020. New Orleans, LA, USA. IEEE, 2020: 1-6.
- [18] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal loss for dense object detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [19] YANG X, ZHANG X, WANG N N, *et al.* A robust one-stage detector for multiscale ship detection with complex background in massive SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5217712.
- [20] YANG X, ZHANG J N, CHEN C Z, *et al.* An efficient and lightweight CNN model with soft quantification for ship detection in SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5230713.
- [21] ZHOU Z, CHEN J, HUANG Z X, *et al.* FSODS: a lightweight metalearning method for few-shot object detection on SAR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5232217.
- [22] 谢洪途, 姜新桥, 王国倩, 等. 基于改进 CenterNet 的轻量级无锚框 SAR 图像多尺度舰船检测算法 [J]. *哈尔滨工程大学学报*, 2024, 45(3): 504-516.
XIE H T, JIANG X Q, WANG G Q, *et al.* Lightweight and anchor-free frame method of multiscale ship detection based on improved CenterNet in SAR images [J]. *Journal of Harbin Engineering University*, 2024, 45(3): 504-516. (in Chinese)
- [23] 龚峻扬, 付卫红, 方厚章. SAR 图像舰船目标检测的轻量化和特征增强研究 [J]. *西安电子科技大学学报*, 2024, 51(2): 96-106.
GONG J Y, FU W H, FANG H Z. Research on

- lightweight and feature enhancement of SAR image ship targets detection[J]. *Journal of Xidian University*, 2024, 51(2): 96-106. (in Chinese)
- [24] CHEN C X, ZHANG Y M, HU R L, *et al.* A lightweight SAR ship detector using end-to-end image preprocessing network and channel feature guided spatial pyramid pooling [J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 4003605.
- [25] 陆天宇, 徐湛, 崔红元, 等. 大幅宽SAR图像嵌入式舰船实时检测系统设计[J]. *计算机工程与应用*, 2024, 60(1): 301-309.
- LU T Y, XU Z, CUI H Y, *et al.* Design of embedded real-time large size SAR image ship detection system[J]. *Computer Engineering and Applications*, 2024, 60(1): 301-309. (in Chinese)
- [26] YIN J, WANG W, GUO Z H, *et al.* DTS: dynamic training slimming with feature sparsity for efficient convolutional neural network[J]. *Journal of Real-Time Image Processing*, 2024, 21(4): 128.
- [27] WANG J L, CUI Z Y, JIANG T, *et al.* Lightweight deep neural networks for ship target detection in SAR imagery [J]. *IEEE Transactions on Image Processing*, 2023, 32: 565-579.
- [28] 郝帅, 吴瑛琦, 马旭, 等. 融合知识蒸馏和注意力机制的光伏热斑检测[J]. *光学精密工程*, 2023, 31(24): 3640-3650.
- HAO S, WU Y Q, MA X, *et al.* Photovoltaic hot spot detection method incorporating knowledge distillation and attention mechanisms[J]. *Opt. Precision Eng.*, 2023, 31(24): 3640-3650. (in Chinese)
- [29] WANG C, RUAN R, ZHAO Z C, *et al.* Category-oriented localization distillation for SAR object detection and a unified benchmark [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5211314.
- [30] CHEN S Q, ZHAN R H, WANG W, *et al.* Learning slimming SAR ship object detector through network pruning and knowledge distillation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 1267-1282.
- [31] PARK J, NO A. *Prune Your Model Before Distill It*[M]. Computer Vision-ECCV 2022. Cham: Springer Nature Switzerland, 2022: 120-136.
- [32] HAN K, WANG Y H, TIAN Q, *et al.* GhostNet: more features from cheap operations [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 1577-1586.
- [33] CHEN Z X, HE Z W, LU Z M. DEA-net: single image dehazing based on detail-enhanced convolution and content-guided attention[J]. *IEEE Transactions on Image Processing*, 2024, 33: 1002-1015.
- [34] 陈杰, 黄志祥, 夏润繁, 等. 大规模多类SAR目标检测数据集-1.0[OL]. 2022: 雷达学报. <https://radars.ac.cn/web/data/getData?dataType=MSAR>. CHEN J, HUANG ZH X, XIA R F, *et al.* Large-Scale Multi-Class Sar Image Target Detection Dataset-1.0[OL]. 2022: Journal of Radars. <https://radars.ac.cn/web/data/getData?dataType=MSAR>. (in Chinese)
- [35] WANG Y Y, WANG C, ZHANG H, *et al.* A SAR dataset of ship detection for deep learning under complex backgrounds [J]. *Remote Sensing*, 2019, 11(7): 765.
- [36] 孙显, 王智睿, 孙元睿, 等. AIR-SARShip-1.0: 高分辨率SAR舰船检测数据集[J]. *雷达学报*, 2019, 8(6): 852-862.
- SUN X, WANG Z R, SUN Y R, *et al.* AIR-SARShip-1.0: high-resolution SAR ship detection dataset[J]. *Journal of Radars*, 2019, 8(6): 852-862. (in Chinese)
- [37] LI J W, QU C W, SHAO J Q. Ship detection in sar images based on an improved faster R-CNN [C]. 2017 *SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA)*. November 13-14, 2017, Beijing, China. IEEE, 2017: 1-6.
- [38] WEI S J, ZENG X F, QU Q Z, *et al.* HRSID: a high-resolution SAR images dataset for ship detection and instance segmentation[J]. *IEEE Access*, 2020, 8: 120234-120254.
- [39] GUO H Y, YANG X, WANG N N, *et al.* A CenterNet++ model for ship detection in SAR images [J]. *Pattern Recognition*, 2021, 112: 107787.
- [40] CAI Z W, VASCONCELOS N. Cascade R-CNN: delving into high quality object detection [C]. 2018 *IEEE/CVF Conference on Computer*

- Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 6154-6162.
- [41] HUANG Z J, HUANG L C, GONG Y C, *et al.* Mask scoring R-CNN[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019. Long Beach, CA, USA. IEEE, 2019.
- [42] CHEN K, PANG J M, WANG J Q, *et al.* Hybrid task cascade for instance segmentation [C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2019: 4969-4978.

作者简介:

杨晓敏(1998—),女,陕西汉中,硕士研究生,2021年于西安科技大学获得学士学位,主要从事深度学习、遥感影像目标检测的研究。E-mail: 11220872@stu.lzjtu.edu.cn

通讯作者:

杨 军(1973—),男,宁夏吴忠人,博士,教授,博士生导师,1995年于西北师范大学获得学士学位,2002年于兰州交通大学获得硕士学位,2007年于西南交通大学获得博士学位,主要从事计算机图形学、遥感大数据智能解译、深度学习等方面的研究。E-mail: yangj@mail.lzjtu.cn