

DOI: 10.19650/j.cnki.cjsi.J2513854

基于轻量化改进和模型剪枝的 SAR 图像飞机目标检测*

韩 萍¹, 白继睿¹, 周杰龙¹, 程 争²

(1. 中国民航大学电子信息与自动化学院 天津 300300; 2. 中国民航大学工程技术训练中心 天津 300300)

摘 要: 由于合成孔径雷达独特的成像机制, 现有的深度学习检测算法, 难以在精度和速度之间找到良好的平衡。因此针对边缘端应用需求, 结合剪枝方法设计了一种更轻量的 SAR 图像飞机目标检测网络 SAERFDnet。其以 YOLOv8n 模型为基线, 主干使用重参数化大核卷积进行特征提取, 颈部使用自适应多尺度离散特征融合模块, 以较浅的网络深度获得更大的有效感受野。其次, 改进网络在检测头分类分支引入可变形卷积, 使得网络更关注不同类别目标的几何特征差异, 在回归分支引入频率自适应扩张卷积, 加强对图像高频区域的目标定位能力。最后, 使用了模型剪枝技术获得了更轻量高效的模型。采用 3 个公开的实测数据集进行实验, 在 SAR-AIRcraft-1.0 数据集上的结果表明, 该方法以 0.5 M 参数量和 2 G FLOPS 的参数量和计算量达到了 96.3% mAP50 和 72.5% mAP50-95, 相比 YOLOv8n 模型参数量降低 83.3%, 计算量降低 75.3%, 同时提高了 0.7% mAP50 和 2.2% mAP50-95 的检测精度, 对比其他模型检测结果, 该方法能在保证检测精度的条件下, 有效提升 SAR 图像飞机目标检测的检测效率。此外, 在 SADD 数据集和高分三号飞机目标数据集上进行了迁移实验, 结果均表明该方法具有良好的泛化性和鲁棒性。

关键词: 合成孔径雷达(SAR); 飞机目标检测; 轻量化检测网络; 模型剪枝

中图分类号: TP75 TH39 **文献标识码:** A **国家标准学科分类代码:** 510.40

Lightweight SAR image aircraft target detection based on lightweight improvement and model pruning

Han Ping¹, Bai Jirui¹, Zhou Jielong¹, Cheng Zheng²

(1. College of Information Engineering and Automation, Civil Aviation University of China, Tianjin 300300, China;

2. Engineering Technology Training Center, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Due to the unique imaging mechanism of synthetic aperture radar (SAR), existing deep learning detection algorithms struggle to achieve an optimal balance between accuracy and speed. To address the requirements for edge applications, this paper proposes a lightweight SAR image aircraft target detection network, SAERFDnet, which integrates pruning techniques for optimization. Based on YOLOV8n, SAERFDnet utilizes re-parametrized large kernel convolutions for feature extraction, while the neck of the network incorporates an adaptive multiscale discrete feature fusion module, providing a larger effective receptive field with a shallower network depth. Additionally, a deformable convolution is introduced in detection head classification branch to enhance the network's focus on the geometric feature differences of different target classes. A frequency-adaptive dilation convolution is employed in the regression branch to strengthen the model's ability to locate targets in high-frequency image regions. Finally, model pruning is applied to further reduce the model size and improve computational efficiency. Experiments conducted on three publicly available datasets demonstrate that the proposed method achieves 96.3% mAP50 and 72.5% mAP50-95 on the SAR-AIRcraft-1.0 dataset, with 0.5M parameters and 2G FLOPS, representing a reduction of 83.3% in parameters and 75.3% in FLOPS compared to the YOLOv8n model, while improving detection accuracy by 0.7% mAP50 and 2.2% mAP50-95. Compared to other models, the proposed method effectively improves detection efficiency in SAR image aircraft target detection while maintaining high detection accuracy. Furthermore, transfer experiments on the SADD dataset and GaoFen-3 aircraft target dataset show that the proposed method exhibits excellent generalization and robustness.

Keywords: synthetic aperture radar (SAR); aircraft detection; lightweight network; model pruning

0 引言

飞机作为目标侦察中的典型目标,在军事和民用领域都具有重要的价值。对飞机图像的解译,可为情报侦察、机场管理和飞机调度等方面提供重要信息支持^[1]。合成孔径雷达(synthetic aperture radar, SAR)是一种主动式微波遥感成像雷达,具有全天候、全天时的图像采集能力,广泛应用于城市规划、目标侦察、自然灾害监视等多个领域^[2]。随着 SAR 成像分辨率和成像内容复杂度的提高,SAR 飞机图像的解译工作对飞机目标检测的精度和速度有了更高的要求。

近年来,随着深度学习方法的迅速发展,基于卷积神经网络(convolutional neural network, CNN)^[3-6]和检测变换器(detection transformers, DETR)^[7-8]的检测方法凭借优秀的特征提取能力和简洁的整体框架,成为图像解译领域的主流方法。这种以数据驱动模型的训练方式具有较强的鲁棒性,且在自主提取深层特征方面有显著优势,有效解决了传统方法需手动设计特征、运行时间长和泛化能力差等问题。由于 SAR 图像特殊的成像机制,对比光学图像检测领域,直接使用通用的神经网络算法对 SAR 图像检测效果不佳,因此通常对现有 CNN 网络进行改进^[9-12]。例如,Kang 等^[10]考虑不同姿态角引起的成像结果的多样性,以引入注意力机制的 CNN 网络为主干,借鉴传统的设计特征的想法,以图神经网络学习飞机离散的散射点之间的联系,提取关键散射点的位置和特征融合进主干网络中。Chen 等^[11]以 Transformer 为主干,颈部通过特征金字塔网络进行特征融合,在分类分支添加可变形卷积,并以预先提取的飞机强散射点区域模板监督可变形卷积学习,使得卷积核形状更佳契合飞机结构。尽管这些深度学习方法在 SAR 飞机目标检测任务中已经取得较为突出的表现,但使用复杂的骨干网络和颈部结构改进的网络算法,不仅训练成本高、参数量、计算量大,并且会导致实时性差不宜在边缘设备上部署。

现已有许多改善检测效率不足问题的轻量级神经网络机构,例如, MobileNet^[13-15], GhostNet^[16]和 Shufflenet^[17-18]等。然而,这些算法未能在检测性能和内存及计算资源利用率之间取得平衡。近年来已经有相关工作^[19-22]对 SAR 飞机目标检测算法的轻量化进行思考。例如,李泽胤等^[22]通过设计轻量化的任务动态调整检测头(task-adaptive dynamic detection head, TADD),通过特征共享和并行任务处理,提高检测的定位和分类性能。Chang 等^[23]采用混合不同轻量化卷积策略搭建特征提取模块和使用注意力机制改进网络主干,有效减少了网络参数和计算量,作为多类别的 SAR 图像目标检测模型在飞机检测任务中也获得了有竞争力的结果,但存在推理

速度较低的问题。这是由于 SAR 图像中飞机目标较小,图像结构呈现离散的亮斑状,检测时容易受到背景中廊桥等建筑物的干扰,通常需要网络拥有较强的特征提取能力。但是直接采用轻量化模块、浅化网络结构的方法减少参数量和计算量,往往会使得模型拟合难度增大,最终模型检测精度较低,运行速度下降。

针对以上问题,本研究提出一种轻量且高效的 SAR 图像飞机目标检测网络(SAR-aircraft efficient receptive field detection network, SAERFDnet)。该方法是在最新目标检测中广泛应用的 YOLOv8 架构和 ultralytics 框架的基础上设计^[24],为降低参数量、计算量并保持高检测性能,利用 SAR 飞机图像特性对 YOLOv8 进行了改进,在使用更轻量的网络结构上,通过提高有效感受野保证检测精度,对模型剪枝提升检测效率。首先,本研究浅化了网络架构,在网络骨干的 C2f 特征模块(cross stage partial bottleneck with 2 convolutions and faster implementation)中引入了大核重参数化卷积^[25]来获得更大的感受野,并命名为 URLKC2f。在网络颈部设计了一个更简单的单输出特征融合模块以替换原本复杂的 PAN 金字塔网络(path aggregation network-feature pyramid network)。考虑到飞机离散特性和单输出颈部感受野受限的问题,该颈部网络引入扩张卷积扩宽感受野,并对不同尺度特征图进行自适应特征融合。其次,设计了一个更加契合 SAR 飞机图像特征的特征自适应检测头(feature-adaptive head, FAHead)。该检测头在分类分支和回归分支上分别引入了可变形卷积^[26-27]和频率自适应扩张卷积^[28],以加强不同类别目标的区分能力和增强网络在图像高频部分对飞机的定位能力。最后,本研究还使用了模型剪枝技术,通过去除模型冗余的特征通道,能以较低的精度损失进一步压缩模型,获得更轻量的网络模型。在多类别的 SAR-Aircraft-1.0 数据集^[29]上,本研究方法与近年来的典型目标检测算法相比,在检测效率与检测精度的平衡上具有明显优势。

1 YOLOv8 目标检测算法

长期以来,YOLO 系列算法都在精度和速度的权衡上有着优异的表现^[30]。目标检测模型大多基于锚点进行设计,由于锚点的尺寸和纵横比固定,处理形状会明显变化的目标是具有挑战性的^[31]。YOLOv8 在以往 YOLO 版本成功的基础上,使用无锚框检测策略(anchor-free),减少了预测框数量,降低了非极大值抑制后处理的计算时间,更适合检测形状变化较大的物体和密集目标检测。在光学通用数据集中,YOLOv8 模型在检测精度和速度上都达到了较好的平衡。如图 1 所示,其网络架构可分为骨干(Backbone)、颈部(Neck)和检测头部(Head)3 个部分。

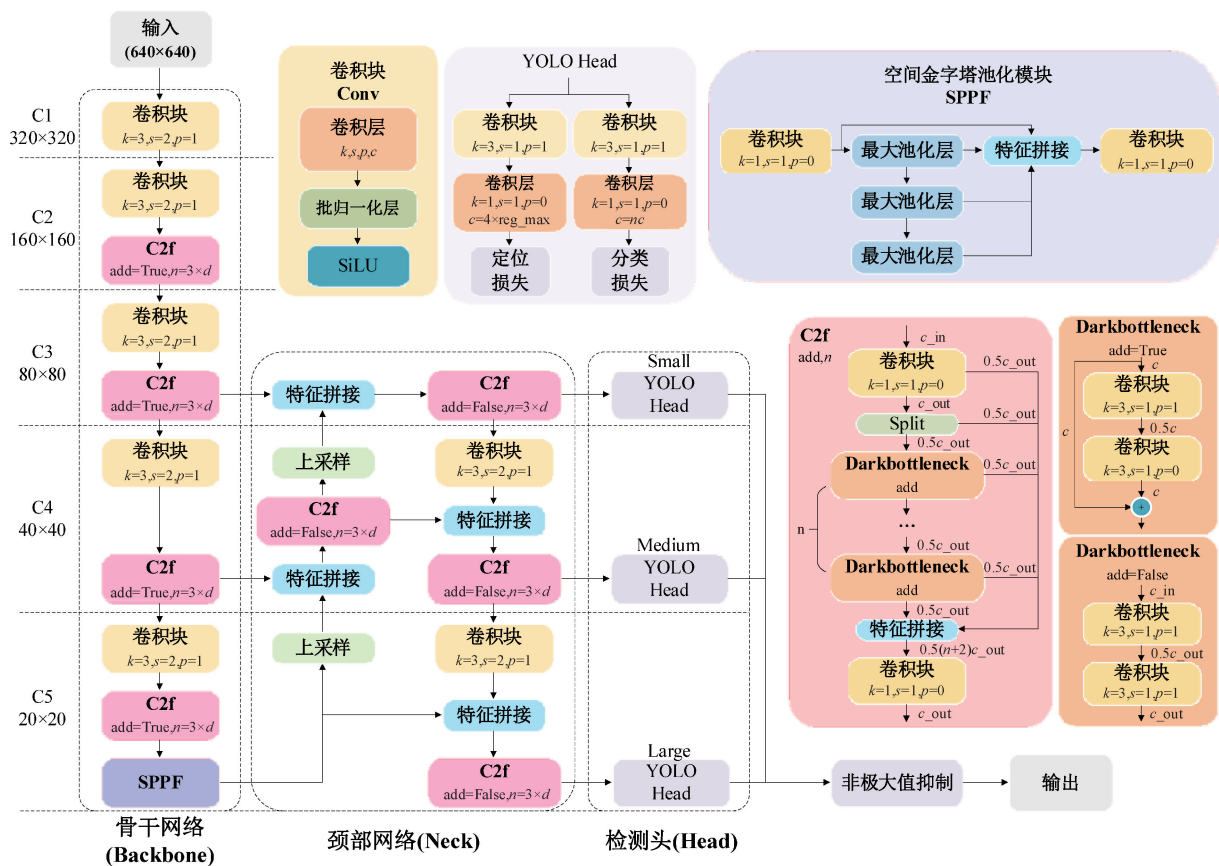


图1 YOLOv8 网络整体架构
Fig. 1 The architecture of YOLOv8

主干部分包含 5 个阶段,每个阶段由卷积块和 C2f 模块构成,其中卷积块进行下采样,C2f 模块用于特征提取,其具有更多的梯度流信息。在最后的 C5 阶段加入 SPPF 空间金字塔池化模块,用于将不同尺度的特征池化成固定大小的特征图来加快网络的计算速度。颈部使用 PAN 结构的特征融合来获取高质量的不同层次特征图。头部使用解耦头^[32],使用两条分支分别进行分类和回归,其将目标位置和类别信息分开提取,通过不同的网络分支学习,相比耦合头减少了参数数量和计算复杂度。YOLOv8 的损失函数由两部分构成,分别是分类损失 BCE Loss (binary cross entropy loss)、回归损失 CIOU Loss (complete intersection over union loss) 和 DFL (distribution focal loss)。

2 整体改进检测网络架构概述

为了在复杂的场景中快速准确的检测 SAR 图像飞机目标,如图 2 所示,本研究提出了一种轻量级检测网络 SAERFDnet 架构。

为提升现有的 SAR 图像飞机目标检测网络检测效

率的同时保证其检测精度,本研究选择 YOLOv8n 模型作为基线进行改进。首先,对于网络骨干部分,本文探究网络深度和感受野对 SAR 飞机目标检测的影响,减少了网络深度以获得更轻量的骨干,同时引入大核重参数化卷积增大感受野,提升主干的特征提取能力。其次,在网络颈部部分,本研究采用了单输入单输出的结构,以 AMDFM 模块 (adaptive multi-scale discrete feature fusion module) 替换了 PAN 特征融合金字塔进行多尺度特征的自适应融合。最后,在检测头 FAHead 部分,本研究引入了 2 种可变形卷积,分别用于分类分支和回归分支。网络的具体参数设置如表 1 所示,连接“-1”表示连接至上一层,参数包括输入通道数、输出通道数、卷积核的大小、步长和填充,其中 nc 为检测类别数,后续小节将对本文方法进行详细介绍。

2.1 重参数化大核卷积骨干网络

本研究希望在减少骨干网络参数量与计算量的同时,保证网络较高的 SAR 图像飞机目标的特征提取能力。SAR 图像飞机目标主要以离散的强散射点形态展现,特征主要为纹理、轮廓等低阶语义信息。且作为微波遥感图像目标,从感受野角度来看,飞机目标相对于整

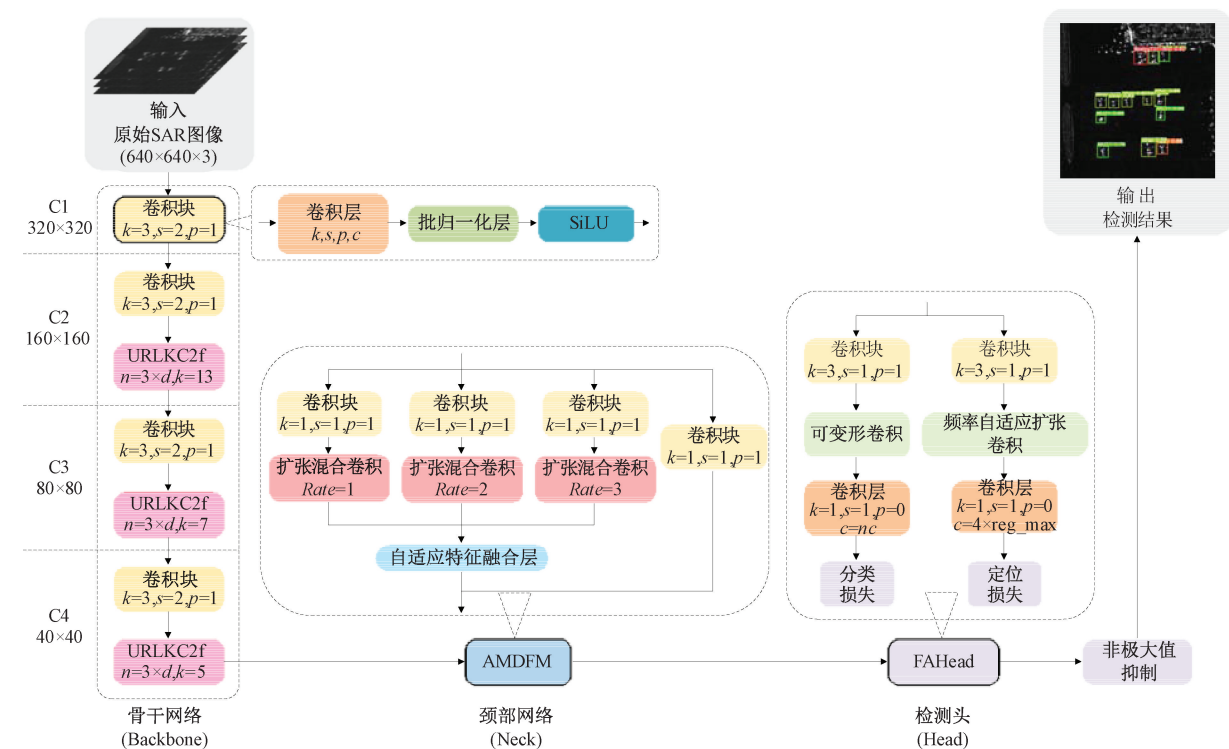


图 2 SAERFDnet 网络整体架构

Fig. 2 The overall structure of the proposed SAERFDnet

表 1 SAERFDnet 网络参数设置

Table 1 Network configuration of the proposed SAERFDnet

序号	连接	重复数	模块	参数
1	-1	1	卷积块	[3, 16, 3, 2, 1]
2	-1	1	卷积块	[16, 32, 3, 2, 1]
3	-1	1	URLKC2f	[32, 32, 13]
4	-1	1	卷积块	[32, 64, 3, 2, 1]
5	-1	2	URLKC2f	[64, 64, 7]
6	-1	1	卷积块	[64, 128, 3, 2, 1]
7	-1	2	URLKC2f	[128, 128, 5]
8	-1	1	AMDFM	[128, 128, 7]
9	-1	1	FAHead	[128, nc]

幅图像为中小型目标,使用过深的下采样去提取低分辨率的语义信息并不是必须的。为解决以上问题,本研究采用了 4 层下采样的骨干网络,以 URLKC2f 改进网络特征提取层,以获得更好的有效感受野,其结构如图 3 所示。

C2f 结构能获得丰富的梯度信息流,同时加快推理速度。其中,本研究引入了使用重参数化的大核卷积块的代替原有瓶颈层,它通过大核重参数化卷积提取特征,使用 SE 注意力 (squeeze-and-excitation attention) 增强通

道间的空间聚合能力,使用具有 GELU 激活函数 (gaussian error linear unit) 的前馈神经网络层 FFN (feed-forward neural network) 学习更加复杂的非线性映射关系,最后使用 Drop path 减少模块的复杂度提高泛化能力。

卷积的重参数化使得 URLKC2f 在推理时具有更高的检测效率,重参数化卷积的重参数化过程通过使用不同扩张率的小卷积核和大卷积核等价转换实现,增强了大核的提取稀疏特征的能力,即特征图上的像素可能与相邻像素更远处的像素更具相关性,同时契合飞机目标在 SAR 图像中的成像情况,提升有效感受野大小,同时推理阶段中 BN 层 (batch normalization) 参数会等效合并至上层中。以卷积核大小 7 为例,重参数化过程如图 3 中右半部分所示,本研究的重参数化设置如表 2 所示。

表 2 URLKC2f 的扩张重参数化模块参数设置

Table 2 Re-parameterization parameter settings for dilated re-param block in URLKC2f

重参数化后 卷积核大小	进行重参数化的 各个卷积核大小	各个卷积核的 扩张率
13	[5, 7, 3, 3, 3]	[1, 2, 3, 4, 5]
7	[5, 5, 3, 3]	[1, 2, 3, 4]
5	[3, 3]	[1, 2]

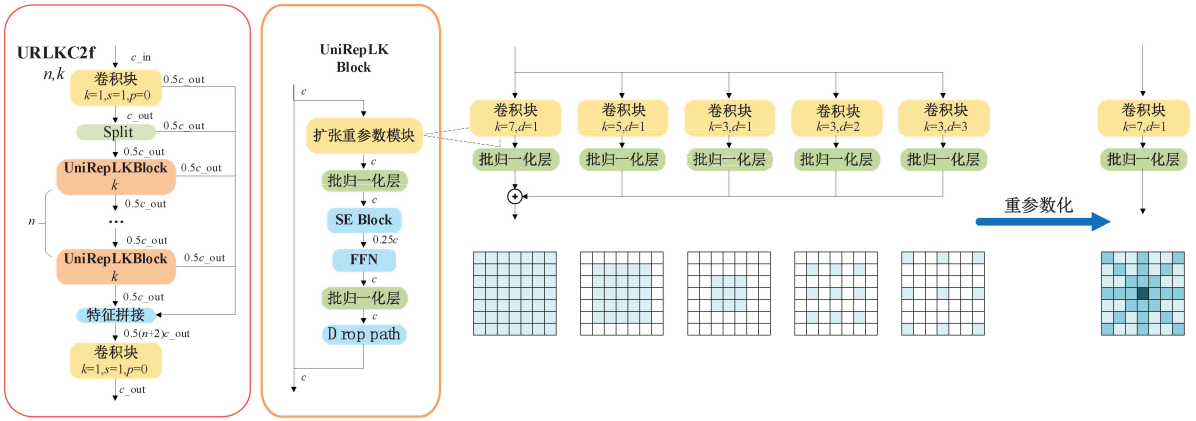


图3 URLKC2f 模块

Fig.3 URLKC2f module

2.2 改进的单输入单输出颈部网络

特征融合的主要作用是将多个不同的特征图融合为更优质的特征表示,以提高模型性能。近年来,特征金字塔网络已成为神经网络中不可或缺的组成部分。它的主要优势在于多尺度特征融合和对不同层次的对象进行分而治之的检测,将复杂的多尺度检测问题按对象尺度划分为多个子问题进行优化。然而,它复杂的横向连接方式显著增加了内存和计算负担,从而降低了目标检测的效率。且经过本研究研究发现,对于 SAR 图像飞机目标检测来说高层语义特征具有更多来自复杂背景信息的干扰,通过特征金字塔融合会导致检测精度降低。因此,本研究设计了一种简单高效的网络颈部,以保证 SAR 图像飞机目标检测的准确和快速。本研究使用了单输入单输出颈部结构,以权衡准确率和检测效率。并结合 RFB 模块^[33]的思想,设计了自适应多尺度离散特征融合模块 AMDFM,弥补单输出感受野的不足。

AMDFM 的结构如图 4 所示,卷积块被用作基本组件,以 C4 特征图作为输入,4 个分支上通过卷积核为 1 的卷积块进行通道维度变换。

其中一个作为残差连接至输出,其余 3 个分支输入 3 个不同扩张率的扩张混合卷积(mix-dilated convolution, MDConv)。最后将三支输入自适应特征融合模块 ASFF,通过对不同尺度特征图赋予可学习权重,将 3 个 MDConv 分支的输出与权重相乘后相加完成自适应多尺度特征融合,AMDFM 输出 y_{out} 可表示为:

$$y_{out} = w_1 \times x_1 + w_2 \times x_2 + w_3 \times x_3 \quad (1)$$

其中, x_1, x_2, x_3 为 3 个分支的输入,权重参数 w_1, w_2, w_3 由 Softmax 函数定义。

其中的扩张混合卷积的结构如图 5(a) 所示,通过普通卷积和扩张卷积串联、拼接和通道混洗的操作,获得离中心点更广泛区域特征之间的联系,以此更好的学习

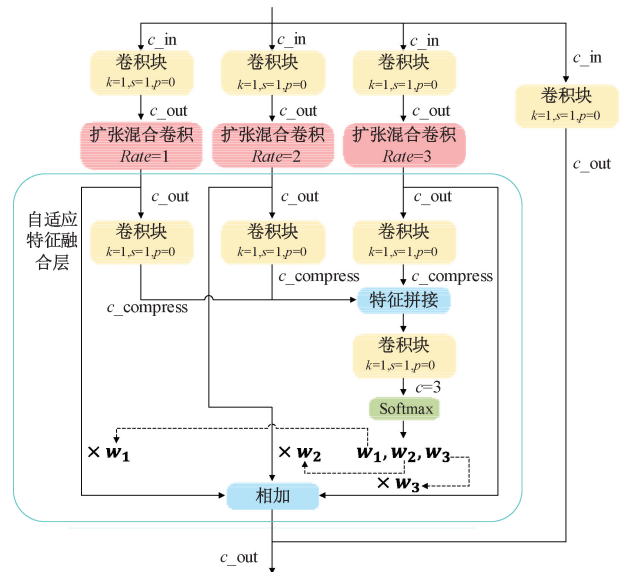


图4 AMDFM 模块

Fig.4 AMDFM module

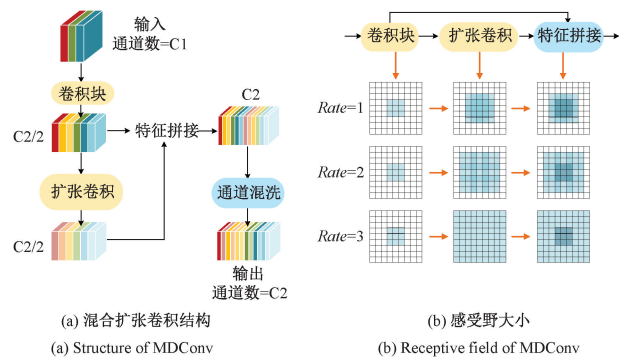


图5 混合扩张卷积

Fig.5 MDConv

SAR 飞机目标的空间位置信息和散射特性。如图 5(b) 所示,通过调节扩张率,MDConv 可以获得不同感受野融

合的效果,且对 C4 输入特征图数据利用是连续的,不会损失信息,其参数数量和计算量与卷积块一致。

2.3 特征自适应检测头

网络的头部负责整合提取的特征以获得检测结果,解耦头将类别预测和位置预测分离开的设计,有效的缓解了分类任务误差和回归误差的互相影响问题。2个不同网络的分支通常使用同样的设计架构,但在不

同类别目标的分类任务和目标的回归任务中,关注到的特征可能不尽相同。因此采用不同的有效策略来关联2个分支中需求的不同 SAR 图像飞机显著特征,对于 SAR 图像飞机目标的准确检测更为有效。本研究提出了一种基于2种不同可变形卷积操作的特征自适应检测头(feature-adaptive head, FAHead),其结构如图6所示。

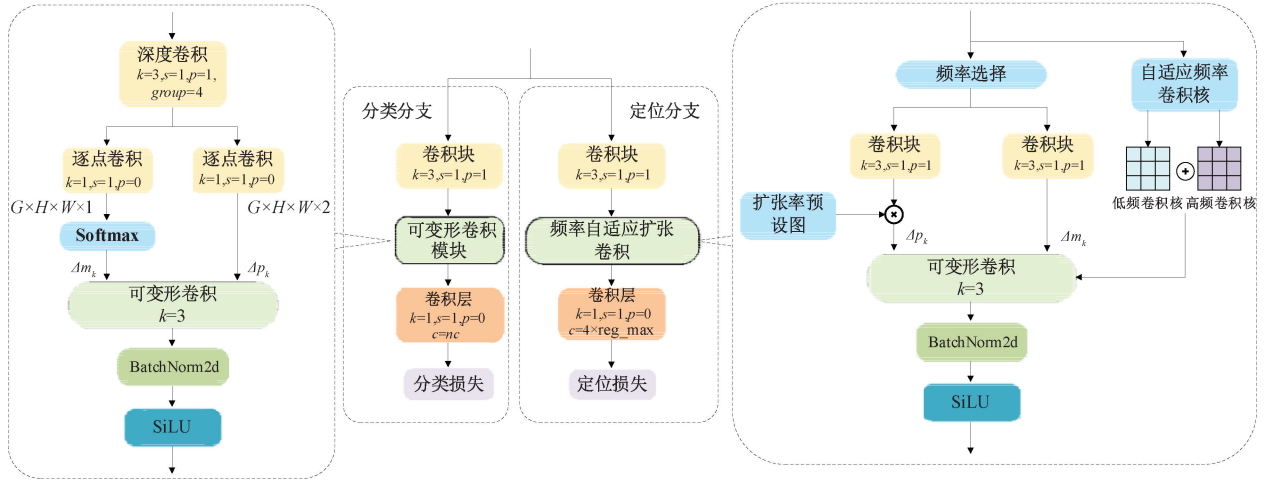


图6 特征自适应检测头结构

Fig. 6 Structure of FAHead

在分类分支中,本研究引入了轻量级的可变形卷积,以鼓励分类分支更关注不同类别飞机目标之间的差异,增强网络对不同类别飞机的识别能力。其通过深度可分离卷积的方式,使用2个逐点卷积分别获取可变形卷积需要的偏移和调制标量,以嵌入到卷积核大小为3的可变形卷积中。其输出特征可由式(2)表示。

$$y(p_0) = \sum_{g=1}^G \sum_{k=1}^K w_g \cdot x_g(p_0 + p_k + \Delta p_{gk}) \Delta m_{gk} \quad (2)$$

其中, Δp_{gk} 和 Δm_{gk} 是相对于深度卷积每组中第 k 个位置的可学习偏移量和调制标量, w_g 为每组卷积的权重值。

在回归分支中,引入了频率自适应扩张卷积,它首先通过 Freqselect 组件,采用傅里叶变换将图像特征映射到从低到高的4个频率通道,对频率通道进行空间加权平衡各个频率的功率,再送入卷积操作得到偏移和掩码。同时 AdaKern 组件将卷积核分解为低频和高频分量,以动态调整可变形卷积低频和高频部分的权重。与一般的可变形卷积不同,它的偏移量用于调整卷积的扩张率而不是卷积的采样位置。最终使得该卷积能在图像高频部分使用较大扩张率的卷积,在低频部分使用具有更小扩张率的卷积,以提升有效感受野的大小。而对于 SAR 飞机图像这一类灰度图来说,离散的飞机目标附近的频率变化相比停机坪和建筑物中心部分相对显著,且飞机目

标通常处于廊桥等建筑物边缘或停机坪空地。这些区域图像幅度的变化较大,高频分量较多,使用频率自适应扩张卷积可以更好的关注到这部分变化,从而增强飞机目标定位精度。

2.4 模型剪枝

由于嵌入式设备的内存和计算能力有限,为了使模型更适应于实时性任务,采用 DepGraph 模型剪枝方法^[34]进一步压缩模型,其流程如图7所示。

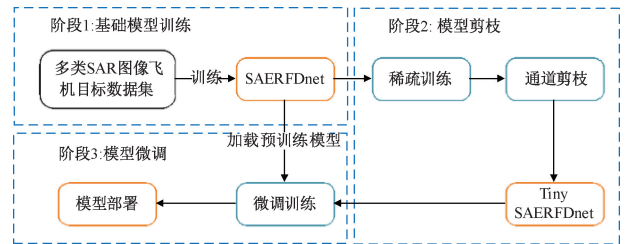


图7 剪枝流程

Fig. 7 Model pruning process

首先对通过多类 SAR 飞机目标数据对 SAERFDnet 网络进行训练。其次将训练好的 SAERFDnet 网络模型进一步稀疏训练,对主干和颈部进行通道剪枝以得到轻量模型 Tiny SAERFDnet。最后将原 SAERFDnet 模型作为与训练模型对轻量模型进行微调再训练以恢复模型

的检测精度,得到最终用于部署的模型。

1) Depgraph 剪枝算法

DepGraph 是一种通用的结构化剪枝方法,为解决剪枝算法和网络模型结构的强绑定关系,它首先通过对网络参数分组,分析网络模型层间依赖关系,然后构建依赖图来移除网络层冗余的通道和参数。

对网络模型进行依赖图建模主要可分为 2 类,考虑到一个参数组 $L = \{l_1^-, l_1^+, l_2^-, l_2^+, \dots, l_n^-, l_n^+\}$, 其中每个 l 代表一个参数化层。上标“-”和“+”分别表示层的输入和输出。通过关注层输入和输出之间的依赖关系,构建了一个层依赖关系模型如式(3)所示。

$$(l_1^-, l_1^+) \leftrightarrow (l_2^-, l_2^+) \leftrightarrow \dots \leftrightarrow (l_n^-, l_n^+) \quad (3)$$

其中,包括层内依赖关系 l_i^-, l_j^+ 和层间依赖关系 l_i^-, l_j^+ , 层间依赖由层和层直接连接导致,由于一个层的输出和下一层的输入对应的是同一个中间特征,因此两者需要被同时剪枝;层内依赖由于单个层的输入和输出可能存在如卷积层和全连接层的非耦合形式,也可能存在如逐元素运算和 BN 层的耦合形式,因此前者可以独立的进行剪枝,而后者需要同时剪枝。图 8 表示了 2 个具有残差连接的标准卷积模块的依赖性分析。

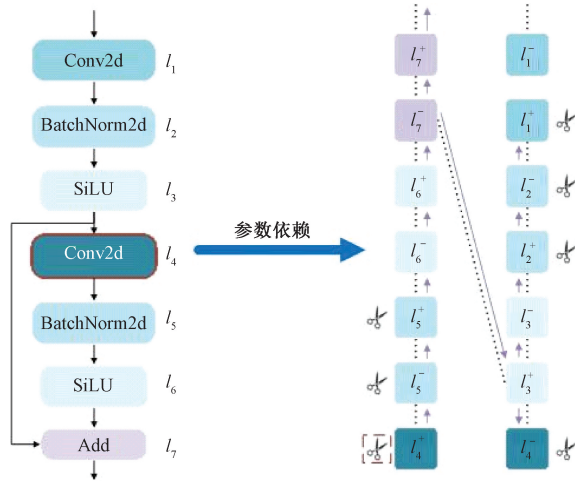


图 8 依赖图分析流程

Fig. 8 Dependency graph analysis

当从输出 l_4^+ 开始时,递归搜索所有其他节点,并将它们分组到一个组中进行修剪。批归一化层 l_2, l_5 的输入和输出是耦合的,形成层内依赖关系。相反,层 l_4 的输入和输出是独立的,但由于残差连接 l_7 , 它们仍然可以被分组到同一个参数集中。同样,本研究可以通过依赖图自动对整个网络模型的参数进行分组,最后按组移除通道完成剪枝,以确保跨层修剪的一致性,从而提高了剪枝效率和模型压缩精度。

2) 稀疏训练与剪枝

在通过依赖图对参数进行分组后,采用了一种稀疏

训练的方法来对同一组内参数进行联合优化,对重要性分数施加正则化,促使部分参数趋近于 0,标识为不重要的可剪枝部分,以确保在剪枝过程中零化的组能被安全的从网络模型中删除。对于 K 个可修剪维度中的每个参数 ω , 正则化可定义为:

$$R(g, k) = \sum_{k=1}^K \gamma_k \cdot I_{g,k} = \sum_{k=1}^K \sum_{\omega \in g} \gamma_k \|\omega[k]\|_2^2 \quad (4)$$

其中, $g = \{\omega_1, \omega_2, \dots, \omega_{|g|}\}$ 是根据依赖关系划分的参数组, $I_{g,k} = \sum_{\omega \in g} \gamma_k \|\omega[k]\|_2^2$ 代表了第 k 个可修剪参数的重要性。 γ_k 是这些参数在稀疏训练中的收缩强度,定义为:

$$\gamma_k = 2^{\alpha(I_g^{\max} - I_{g,k}) / (I_g^{\max} - I_g^{\min})} \quad (5)$$

其中,归一化分数 α 是一个可调整的稀疏因子,用于控制收缩的强度的大小。稀疏训练使神经网络能够加速推理速度,而不会显著降低模型性能。此外,它确保了不同层之间的一致性,并为结构化修剪提供了更好的支持。经过稀疏训练后,根据相对分数识别并删除不重要的参数,定义如式(6)所示。

$$\hat{I}_{g,k} = N \times I_{g,k} / \sum [TopN(I_g)] \quad (6)$$

3 实验与分析

3.1 实验数据集介绍

SAR-AIRcraft-1.0 实测数据集^[30] 其数据采集自高分三号卫星,极化方式为单极化,空间分辨率为 1 m,成像模式为聚束式。图片尺寸 800×800, 1 000×1 000, 1 200×1 200 和 1 500×1 500 这 4 种大小,总共 4 368 幅图像,16 463 个飞机目标实例,包括 A220、A320/321、A330、ARJ21、Boeing737、Boeing787 和 other 共 7 个类别。从图 9 可以看出,图像场景复杂,飞机目标散射点高度分离。本文将数据集以 6:2:2 的比例随机分为训练集、验证集和测试集进行消融实验和对比实验。

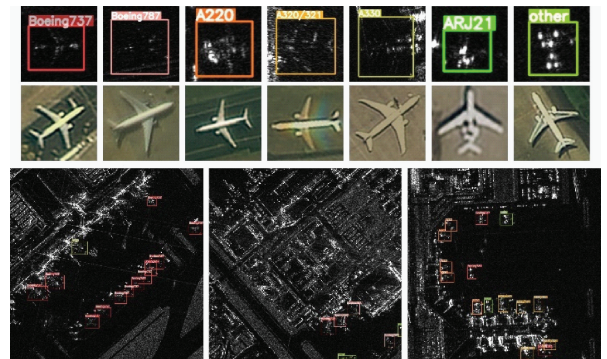


图 9 SAR-AIRcraft-1.0 数据集图像示例

Fig. 9 Image example of SAR-AIRcraft-1.0 dataset

此外,还使用额外的公开数据集进行了泛化实验。SADD 实测数据集^[35]由德国 TerraSAR-X 卫星收集。它包括分辨率为 0.5~3.0 m 的单偏振 SAR 图像。图像大小为 224 pixels×224 pixels,包括 2 966 幅 SAR 图像,其中包含飞机样本图像,没有飞机负样本图像。

高分三号飞机目标数据集^[36]是由中国高分三号卫星收集的,其数据由 C 波段分辨率 1 m 的单极化 SAR 图像组成。数据集中共包含 2 000 张图像切片,拥有更大场景图像,图像尺寸有 600 pixels×600 pixels、1 024 pixels×1 024 pixels 和 2 048 pixels×2 048 pixels 这 3 种像素。主要包括多个常见机场的不同时段的场景,包括 A220、A320/321、A330、ARJ21、Boeing737、Boeing787 和 other 共 7 个类别。

在实验中,数据集以 6:2:2 的比例随机分为训练集、验证集和测试集,用于消融实验和比较实验。

3.2 实验参数设置

1) 数据增强设置

训练图像大小缩放为 640 pixels×640 pixels,并在训练前对图像进行平移、缩放、裁剪、翻转、Mosaic 在线数据增强,以增强模型的泛化性。

此外,本研究在消融实验中还通过随机增强图像的相干斑噪声对 SAR 图像进行在线数据增强,基于 Gamma 分布模拟 SAR 图像乘性噪声增强,模拟强干扰状态的成像图像,以提升模型的鲁棒性。通过加噪数据增强后图像如图 10 所示。在线数据增强的概率设置为 50%。

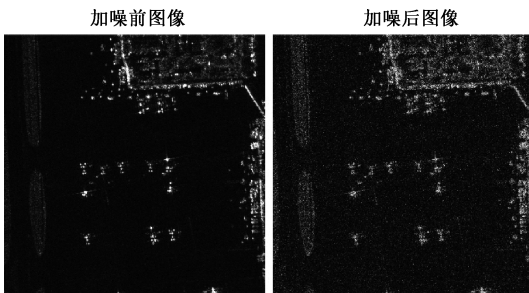


图 10 加强相干斑噪声图像示例

Fig. 10 Example of enhancing coherent speckle noise image

2) 训练参数设置

由于对网络进行了修改,消融实验中的所有权重都是随机初始化的。模型训练的优化器是 SGD,动量因子为 0.937,初始学习率为 0.01,权重设置为 0.000 5。根据数据集的不同,SAR-AIRcraft-1.0 数据集运行 300 个 epoch,SADD 数据集运行 200 个 epoch,稀疏训练和 Fine-tune 训练均为 300 个 epoch。其目的是确保收敛并防止过拟合。之后在测试集上评估模型的性能,并保留性能最佳的模型作为最终的训练结果。

在测试过程中,IoU 阈值为 0.5,置信度阈值为 0.2。所有实验都是在 PyTorch 2.0.1 版本的 Windows 系统上进行的,使用一个具有 12 GB 内存的 GTX 3060 GPU。

3.3 评价准则

为了更好地验证本研究算法的有效性,采用常见的目标检测任务的评价指标:准确率 (precision, P)、召回率 (recall, R) 和平均精度均值 (mean average precision, mAP) 来衡量算法的检测性能。并通过模型参数量、每秒浮点运算次数 (floating point operations per second, FLOPS) 和每秒帧数 (frames per second, FPS) 来衡量模型复杂度。

准确率 P 和召回率 R 计算公式如 (7) 所示。

$$\begin{cases} P = \frac{TP}{TP + FP} \\ R = \frac{TP}{TP + FN} \end{cases} \quad (7)$$

其中, TP 是正确检测的目标个数, FP 是错误检测的目标个数, FN 是未检测到的目标个数。

mAP 用于度量模型在不同置信度阈值下的准确率-召回率曲线下的面积。它的值越大,模型的性能越好。多类任务中,本研究使用各类的平均 mAP 来度量,其中 mAP50 是 IoU 阈值设置为 0.5 的情况下得到的 mAP, mAP50-95 是 IoU 阈值从 0.5~0.95 的平均 mAP。具体计算公式如 (8) 所示。

$$\begin{cases} AP = \int_0^1 p(r) dr \\ mAP = \frac{1}{N} \sum_{i=1}^N AP_i \end{cases} \quad (8)$$

模型参数量用于衡量模型的空间复杂度和其对于的内存资源开销,FLOPS 用于衡量模型的时间复杂度,是模型计算量的参考指标。FPS 用于衡量算法的整体检测速度,它表示在每秒内显示的图像帧数,值越大代表检测速度越快。

3.4 实验结果和分析

1) 消融实验与分析

为验证所提方法的性能,本部分基于 SAR-AIRcraft-1.0 数据集对本研究的 SAERFDnet 网络架构进行了一系列消融实验。

(1) 网络深度对检测结果影响的定性分析:使用 YOLOv8n 训练了一个基础模型,将各阶段的特征图叠加归一化后输出,3 个检测头前特征图对应了 C3、C4 和 C53 个阶段经过相互特征融合后的特征图。对分别为 800、1 000、1 500 分辨率的不同场景输入图像下的检测头前特征图进行对比,如图 11 所示,图像越明亮的地方代表特征的响应越多,可以认为提取到的特征越多。

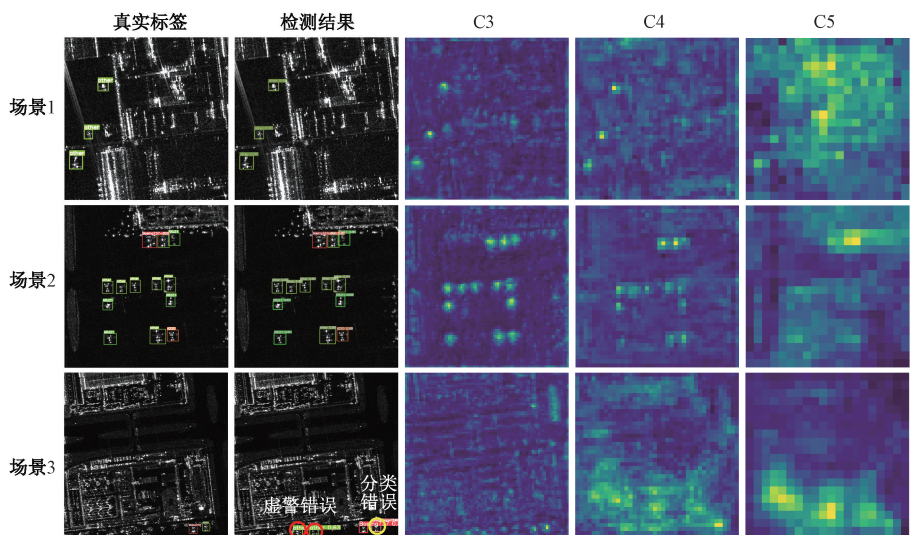


图 11 通道特征图可视化

Fig. 11 Visualization of channel feature map

可以发现,相比之下 C3 对应的特征图中飞机目标的响应最明显,其次是 C4。而 C5 阶段特征图中背景的响应通常多于飞机目标。在场景 3 中,虚警和分类错误已在图中用不同颜色的圆圈进行标识,特征图 C4、C5 的背景响应远远多于 C3。这说明浅层特征在 SAR 图像飞机目标检测任务中表现更好,且高层语义信息中过多的背景响应通过特征融合可能会降低检测精度。

(2)网络深度与感受野大小对检测精度影响的定量分析:接下来以 YOLOv8n 模型探究骨干深度和理论感受野大小对检测效果的影响,除 YOLOv8n 模型以外,其余模型仅使用骨干网络和头部进行实验,其结果如表 3 所示。

表 3 不同深度对模型性能的影响

Table 3 The impact of different depths on model performance				
网络模型	mAP50/%	mAP50-95/%	参数量/M	FLOPS/G
YOLOv8n	95.6	70.3	3.00	8.1
C3	92.8	66.3	0.23	3.5
C4	95.5	68.8	0.76	3.7
C5	94.0	67.6	2.64	4.3
C4+URLKC2f [13,13,13]	95.8	69.7	0.77	3.4
C4+URLKC2f [5,7,13]	95.7	69.3	0.69	3.2
C4+URLKC2f [13,7,5]	95.8	69.8	0.67	3.3

可以发现当使用单个 C4 阶段特征图进行检测时, mAP50 达到了 95.5% 均高于 C3 和 C5 阶段,结合实验(1),这是因为更深阶段的分辨率更低含有更多高阶语义信息,单独使用 C3 和 C5 阶段都无法平衡低阶和高阶语义信息,而对于 SAR 图像而言低阶语义信息同样重要,C4 阶段相比于 C3、C5 在低阶和高阶语义信息方面有着更好的平衡,且使用更少的参数量和计算量。

本研究进一步考虑到深度和感受野的关系,在 C4 阶段基础上对骨干引入重参数化大核特征提取模块 URLKC2f 继续实验。大核卷积拥有更大的理论感受野,在检测精度上均高于原 C4 骨干,这是因为扩大感受野,从更大范围内捕捉到输入图像的全局特征,能更有效处理复杂的图像场景,有助于捕捉高层次的抽象特征提高检测精度。通过对不同阶段卷积核大小的改变,综合检测精度和模型大小,发现[13,7,5]的排列方式比起全使用 13 大小卷积核和[5,7,13]方式的效果要更好。这是因为递减排列的方式对于每阶段不同分辨率的卷积核感受野大小都能更契合飞机目标在特征图中的大小,这使得每阶段的有效感受野大小比递增排列更大,尽管理论感受野比其前两种方式要小的多。且使用 URLKC2f 的 C4 骨干在检测精度上已经与 YOLOv8n 模型相当,且参数量和计算量远低于 YOLOv8n 模型。

综上所述,本研究在接下来实验中采用了 4 阶段的重参数化大核卷积骨干网络。

(3)各模块的有效性分析:为了清晰的表达各个模块的贡献,接下来对模型进行了消融实验,结果如表 4 所示。

其中 YOLOv8n#为使用 C4 阶段骨干和单输出 PAN 结构颈部的网络模型,与 YOLOv8n 相比参数量和计算量分别降低 68.0% 和 41.9%。引入 URLKC2f 后,模型的

表 4 SAERFDnet 模块消融实验

Table 4 Ablation experiments of each SAERFDnet module

模型	精确率/%	召回率/%	mAP50/%	mAP50-9/%	参数量/M	FLOPS/G	FPS
YOLOv8n	86.8	96.0	95.6	71.2	3.00	8.1	131
YOLOv8n#	86.6	95.1	95.6	69.4	0.96	4.7	142
+URLKC2f	86.6	96.3	95.8	70.1	0.87	4.3	133
+AMDFM	86.1	96.8	96.1	71.2	1.09	4.6	156
+FAHead	87.3	95.7	96.2	72.1	0.99	4.1	122
+加噪数据增强后	87.4	94.1	96.1	71.9	0.99	4.1	127

检测精度上已与 YOLOv8n 模型相当,仅在 mAP50-95 上略低 0.2%,重参数化使得模型进一步减少了参数量和计算量。使用 AMDFM 模块作为颈部结构,弥补了单输入到颈部的感受野的不足,融合不同尺度感受野特征进一步提升有效感受野实现 0.3% mAP50 和 1.1% mAP50-95 的提升。最后使用 FAHead 替换原检测头,通过可变形卷积操作增强模型的分类和定位精度,实现了 0.1% mAP50 和

0.9% mAP50-95 的提升。接下来,在训练中引入相干斑噪声进行数据增强,在原测试集中精度影响不大。但通过对原测试集进行加噪检测,可视化结果如图 12 所示,其中圆圈标识代表漏检,三角标识代表虚警。可以发现,未进行加噪数据增强的模型在强干扰环境下出现了较多的漏检,而进行加噪数据增强后的模型,漏检有所减少,在强噪声干扰环境下的鲁棒性有一定提升。

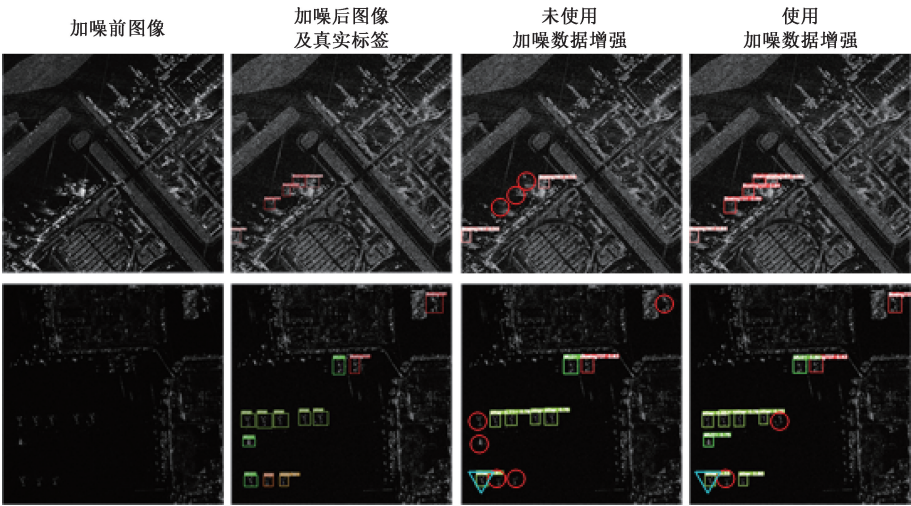


图 12 强相干斑噪声干扰图像检测结果

Fig. 12 Strong coherent speckle noise interference in image detection results

为更好理解模型有效感受野的贡献,选取了测试集中的随机 500 张图像,测试模型输出最后特征中心点和输入图像相关区域点的比例,可视化了模型的感受野大小,如图 13 所示,颜色越深表示相关性越高。

可以看到,层数较多的 YOLOv8n 模型与 YOLOv8n# 相比对有效感受野的放大作用不大。相反,本文的最终模型获得了更大的有效感受野。结合检测精度和前期实验的表现也证明了,更深的下采样能扩大感受野,但不能很好增强有效感受野的大小。

总的来看,本文提出的模型相比 YOLOv8n 模型减少了 67.0% 的参数量和 49.3% 的计算量,同时提升了 0.6% mAP50 和 1.8% mAP50-95 的检测精度。

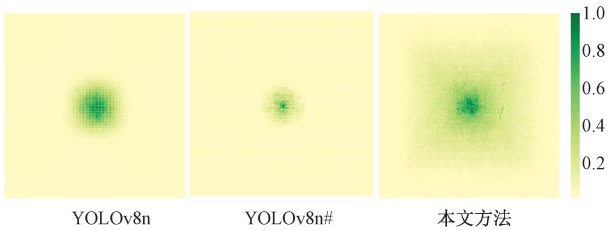


图 13 各模型有效感受野大小可视化

Fig. 13 Visualization of effective receptive field size for each model

2) 网络剪枝实验及分析

为进一步轻量化网络模型,对 SAERFDnet 网络模型

进行了模型剪枝。为了深入研究剪枝对网络模型体积和检测精度的影响,先通过调节稀疏训练的系数因子,研究不同稀疏率对网络性能的影响,再选择最佳的稀疏因子条件,调整剪枝率寻找网络的最佳压缩大小。如表 5 所

示,第 1 行为剪枝前模型的检测效果,随着稀疏率增大,当稀疏率为 0.265 左右时,减少冗余通道后的剪枝模型的检测性能有所提升,之后继续提升稀疏率效果开始下降。

表 5 SAR-AIRcraft-1.0 数据集上的剪枝实验结果
Table 5 Pruning experiment results on SAR-AIRcraft-1.0 dataset

剪枝率	α	稀疏率	mAP50/%	mAP50-95/%	参数量/M	FLOPS/G
-	-	-	96.2	72.1	0.99	4.1
0.3	0.005	0.047	96.2	71.8	0.68	2.7
	0.010	0.190	96.3	72.1	0.68	2.7
	0.020	0.265	96.5	72.4	0.68	2.7
	0.050	0.307	96.2	71.9	0.68	2.7
	0.100	0.325	96.2	70.8	0.68	2.7
0.4	0.020	0.265	96.4	72.2	0.56	2.2
0.5	0.020	0.265	96.3	72.5	0.50	2.0
0.6	0.020	0.265	95.7	68.4	0.48	1.8
0.7	0.020	0.265	90.7	65.4	0.42	1.7
差异化	0.020	0.265	96.1	71.0	0.47	1.8

进一步控制模型的剪枝比例进行剪枝实验,当剪枝比例高于 50%后,模型性能开始显著降低,在剪枝率 0.7 时 mAP50 和 mAP50-95 分别降低了 5.5%和 6.7%,这说明此时剪枝率已经过高,模型容量大幅下降,模型进入“过剪枝临界区”,此时剪枝后难以通过微调恢复原有特征表达能力。可以通过对不同模块设置差异化剪枝率来稳定剪枝效果,因此本文设置差异化剪枝率,其中主干为 0.7,颈部为 0.7,检测头为 0.3 进行实验,可以看到微调后精度相比全局剪枝率为 0.6 时有所提升。差异化剪枝需要更细致的剪枝策略设计,而在全局剪枝率为 0.5 附近时,模型已有不错的可部署性。最后本文选择剪枝率和稀疏因子分别为 0.5 和 0.02 时的模型,作为最终的轻量模型 Tiny-SAERFDnet。与原模型相比,Tiny-SAERFDnet 参数量减少了 49.5%,计算量减少了 51.2%,mAP50 和 mAP50-95 分别提升了 0.1%和

0.4%。结果表明,通过适当的稀疏训练并选择合适的模型压缩比例能有效提升模型的检测效率。

3) 对比实验与分析

为进一步验证所提方法的性能,将 SAERFDnet 模型与其他主流轻量级目标检测算法^[21],以及同为 SAR 图像目标检测任务的轻量级算法 MLSDNet^[23]在 SAR-AIRcraft-1.0 数据集上进行了对比实验。如表 6 所示,提出的 SAERFDnet-tiny 方法仅占用 0.50 M 的参数量和 2.0 G FLOPS 的计算量,在 SAR-AIRcraft-1.0 数据集上表现出更好的检测精度(96.3%的 mAP50 和 72.5%的 mAP50-95)和较高的检测速度(125 fps),具有更加平衡和优异的检测性能。

从测试集中选择了一些具有挑战性的检测场景进行了比较,可视化结果如图 14 所示,其中圆圈标识代表漏检,三角标识代表虚警。

表 6 SAR-AIRcraft-1.0 数据集上的对比实验结果
Table 6 Comparative experimental results of SAR-AIRcraft-1.0 dataset

模型	精确率/%	召回率/%	mAP50/%	mAP50-95/%	参数量/M	FLOPS/G	FPS
YOLOv7-tiny ^[4]	87.6	94.4	95.6	66.2	6.02	13.1	115
YOLOv8n ^[24]	86.8	96.0	95.6	70.3	3.00	8.1	131
YOLOv11n ^[37]	85.7	96.3	96.2	71.9	2.58	6.3	138
MLSDnet ^[23]	86.9	95.3	95.8	69.3	1.32	1.5	61
SAERFDnet-tiny(本文方法)	87.9	94.4	96.3	72.5	0.50	2.0	125

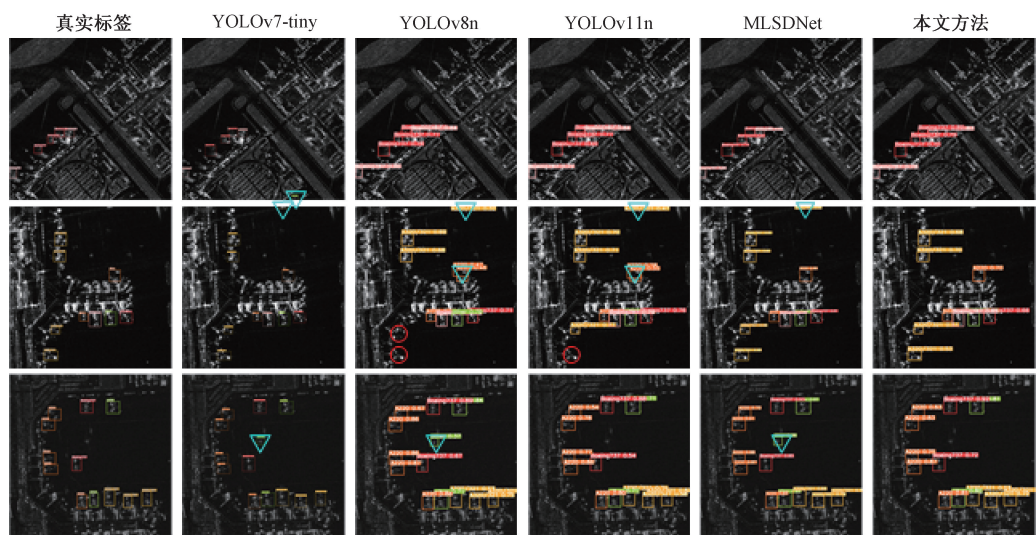


图 14 SAR-AIRCRAFT-1.0 数据集上不同算法的检测结果

Fig. 14 Detection results of different algorithms on SAR-AIRCRAFT-1.0 dataset

可以看到,在复杂场景下的多类别飞机目标检测,其他主流轻量级目标检测算法容易出现漏检和虚警,MLSDNet 改善了漏检的情况但仍然存在虚警,对比之下本文剪枝后模型具有更加优异的性能。

为了验证所提出方法的泛化能力,在 SADD 数据集和高分三号飞机目标数据集上对 SAERFDnet 算法进行了测试。检测结果如表 7 所示,剪枝后 SAERFDnet-tiny 的可视化结果如图 15 和 16 所示。

表 7 泛化性实验结果

Table 7 Generalization experiment results

数据集	剪枝率	精确率/%	召回率/%	mAP50/%	mAP50-95/%	FPS
SADD	-	96.3	95.4	97.8	65.4	128
	0.5	93.6	94.0	96.6	64.6	133
高分三号飞机目标数据集	-	92.9	95.5	97.2	80.9	111
	0.5	93.2	94.4	97.1	79.7	121

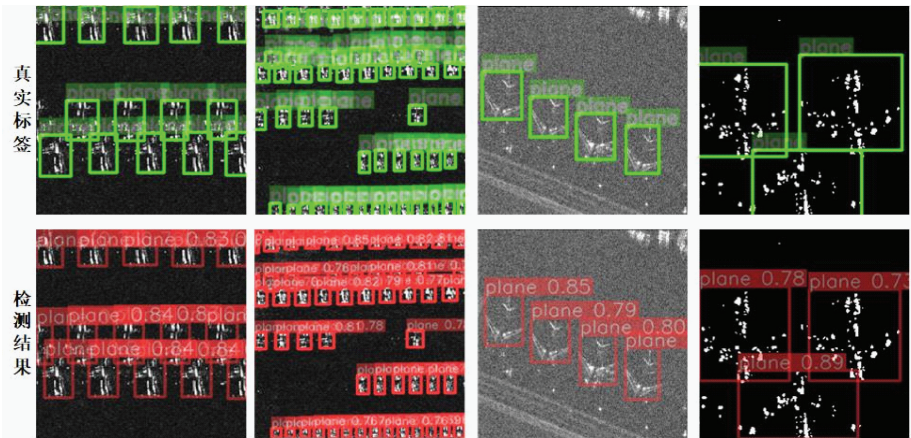


图 15 SAERFDnet-tiny 在 SADD 数据集上的检测结果

Fig. 15 Detection results of SAERFDnet-tiny on SADD dataset

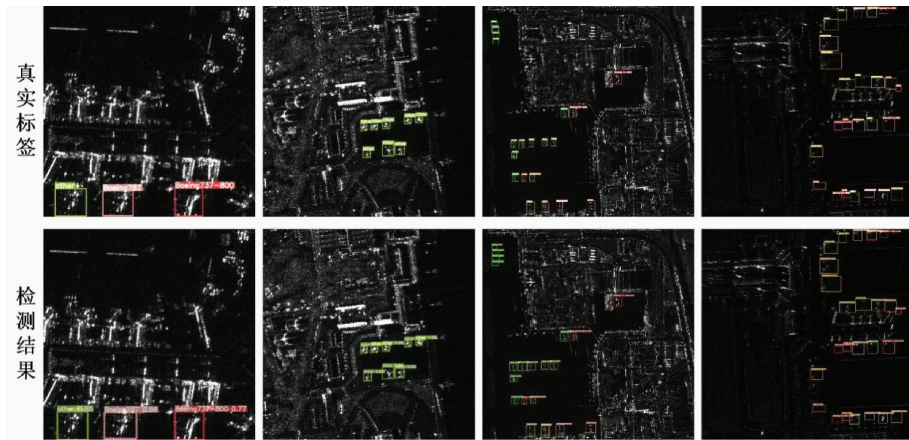


图 16 SAERFDnet-tiny 在高分三号飞机目标数据集上的检测结果

Fig. 16 Detection results of SAERFDnet-tiny on Gaofen-3 aircraft target dataset

SAERFDnet-tiny 在检测密集小目标方面也表现出优异的检测能力,在额外的 2 个数据集上的检测精度均达到了 95% mAP50 以上,表现出良好的泛化能力。

4 结 论

基于 YOLOv8 架构设计了一种用于 SAR 图像飞机目标检测与识别任务的轻量级检测网络架构 SAERFDnet,采用了更少的下采样阶段和大核重参数化卷积,在避免了之前的深骨干和复杂的横向检测连接 FPN 颈部的同时获得了更好的有效感受野大小。之后结合模型剪枝技术,在显著降低网络参数和计算量的同时,保持了高水平的检测精度和速度。通过实验,SAERFDnet-tiny 在 SAR-Aircraft-1.0 数据集上,以 0.50 M 的参数量和 2.0 G FLOPS 计算量,分别取得了 96.3%/72.5% 的 mAP50/mAP50-95 检测精度和 125 fps 的实时性检测速度。相比其他典型轻量级目标检测算法,在对有部署需求的背景复杂和特征离散 SAR 图像飞机目标检测任务中具有明显优势。

参考文献

[1] 罗汝,赵凌君,何奇山,等. SAR 图像飞机目标智能检测识别技术研究进展与展望[J]. 雷达学报, 2024, 13(2): 307-330.
LUO R, ZHAO L J, HE Q SH, et al. Intelligent technology for aircraft detection and recognition through SAR imagery: Advancements and prospects[J]. Journal of Radars, 2024, 13(2): 307-330.
[2] LEE J S, POTTIER E. Polarimetric radar imaging: From basics to applications[M]. CRC Press, 2017.
[3] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region

proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
[4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
[5] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
[6] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. 2023 IEEE/CVF conference on Computer Vision Aand Pattern Recognition, 2023: 7464-7475.
[7] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. Computer Vision-ECCV 2020, 2020: 213-229.
[8] ZHAO Y, LYU W Y, XU SH L, et al. Detrs beat YOLOs on real-time object detection [C]. 2024 IEEE/ CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
[9] 胡欣,马丽军. 基于 YOLOv5 的多分支注意力 SAR 图像舰船检测 [J]. 电子测量与仪器学报, 2022, 36(8): 141-149.
HU X, MA L J. Multi-branch attention SAR image ship detection based on YOLOv5 [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 141-149.
[10] KANG Y ZH, WANG ZH R, ZUO H Y, 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: 1-17.

- [11] CHEN Y Y, CONG Y L, ZHANG L. Deformable scattering feature correlation network for aircraft detection in SAR images [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 1-5.
- [12] ZHU W B, ZHANG L, LU CH Q, et al. FEMSFNet: Feature enhancement and multi-scales fusion network for SAR aircraft detection [J]. Remote Sensing, 2024, 16(9): 1589.
- [13] HOWARD A G, ZHU M L, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. ArXiv preprint arXiv: 1704.04861, 2017.
- [14] SANDLER M, HOWARD A, ZHU M L, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [15] HOWARD A, SANDLER M, CHEN B, et al. Searching for mobilenetv3 [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.
- [16] 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, 2020: 1577-1586.
- [17] ZHANG X Y, ZHOU X Y, LIN M X, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [18] MA N N, ZHANG X Y, ZHENG H T, et al. Shufflenet V2: Practical guidelines for efficient CNN architecture design [C]. Computer Vision-ECCV 2018, 2018: 122-138.
- [19] 杨瑞君, 张浩, 叶璟. 改进 YOLOv8n 的轻量级遥感图像军用飞机检测算法 [J]. 电子测量技术, 2025, 48(1): 154-165.
- YANG R J, ZHANG H, YE J. Improved lightweight military aircraft detection algorithm for remote sensing images with YOLOv8n [J]. Electronic Measurement Technology, 2025, 48(1): 154-165.
- [20] 邝先验, 程福军, 吴翠琴, 等. 基于改进 YOLOv7-tiny 的高效轻量遥感图像目标检测方法 [J]. 电子测量与仪器学报, 2024, 38(7): 22-33.
- KUANG X Y, CHENG F J, WU C Q, et al. Efficient and lightweight target detection method for remote sensing images based on improved YOLOv7-tiny [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 22-33.
- [21] WANG J L, BAI ZH, ZHANG X M, et al. A lightweight remote sensing aircraft object detection network based on improved YOLOv5n [J]. Remote Sensing, 2024, 16(5): 857.
- [22] 李泽胤, 李栋, 房建东, 等. 改进的 YOLOv8n 遥感图像轻量化检测模型 [J]. 电子测量技术, 2025, 48(6): 130-142.
- LI Z Y, LI D, FANG J D, et al. Improved YOLOv8n lightweight detection model for remote sensing images [J]. Electronic Measurement Technology, 2025, 48(6): 130-142.
- [23] CHANG H, FU X J, DONG J, et al. MLSNet: Multiclass lightweight SAR detection network based on adaptive scale distribution attention [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 1-5.
- [24] SOHAN M, SAI RAM T, RAMI REDDY C V. A review on YOLOv8 and its advancements [C]. International Conference on Data Intelligence and Cognitive Informatics, 2024: 529-545.
- [25] DING X H, ZHANG Y Y, GE Y X, et al. Unireplknet: A universal perception large-kernel convnet for audio video point cloud time-series and image recognition [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5513-5524.
- [26] CHEN Q, WANG Y M, YANG T, et al. You only look one-level feature [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13034-13043.
- [27] WANG W H, DAI J F, CHEN ZH, et al. Internimage: Exploring large-scale vision foundation models with deformable convolutions [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 14408-14419.
- [28] GAO H, ZHU X ZH, LIN S, et al. Deformable kernels: Adapting effective receptive fields for object deformation [J]. ArXiv preprint arXiv: 1910.02940, 2019.
- [29] CHEN L W, GU L, ZHENG D ZH, et al. Frequency-adaptive dilated convolution for semantic segmentation [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 3414-3425.
- [30] 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 ZH R, KANG Y ZH, ZENG X, et al. SAR-AIRcraft-1.0: High-resolution SAR aircraft detection and recognition dataset [J]. Journal of Radars, 2023, 12(4): 906-922.
- [31] JIANG P Y, ERGU D, LIU F Y, et al. A Review of YOLO algorithm developments [J]. Procedia Computer Science, 2022, 199: 1066-1073.

- [32] SONG G L, LIU Y, WANG X G. Revisiting the sibling head in object detector[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11560-11569.
- [33] LIU S T, HUANG D, WANG Y H. Receptive field block net for accurate and fast object detection[C]. Computer Vision-ECCV 2018, 2018: 404-419.
- [34] FANG G F, MA X Y, SONG M L, et al. DepGraph: Towards any structural pruning[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 16091-16101.
- [35] ZHANG P, XU H, TIAN T, et al. SEFEPNet: Scale expansion and feature enhancement pyramid network for SAR aircraft detection with small sample dataset[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 3365-3375.
- [36] SUN X, LYU Y X, WANG ZH R, 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: 1-17.
- [37] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[J]. ArXiv preprint arXiv:2410.17725, 2024.

作者简介



韩萍(通信作者), 分别于 1986 年、1989 年和 2004 年于天津大学获得学士、硕士和博士学位。现为中国民航大学教授。主要研究方向包括图像处理和模式识别以及 SAR 和 PolSAR 图像解释。

E-mail: hanpingcauc@163.com

Han Ping (Corresponding author) received her B.Sc., M.Sc., and Ph.D. degrees all from Tianjin University in 1986, 1989, and 2004, respectively. She is currently a professor at Civil Aviation University of China. Her current research interests include image processing and pattern recognition, as well as SAR and PolSAR image interpretation.



白继睿, 2022 年于武汉科技大学获得学士学位, 目前于中国民航大学攻读硕士学位, 主要研究方向为 SAR 图像飞机目标检测。

E-mail: baijirui1999@163.com

Bai Jirui received his B.Sc. degree from Wuhan University of Science and Technology in 2022. He is currently pursuing his master's degree at Civil Aviation University of China. His research interests include SAR image and aircraft target detection.



程争, 分别于 2014 年和 2017 年在中国民航大学获得电子信息工程学士学位和电子与通信工程硕士学位。现为中国民航大学工程实训中心实验员, 主要研究方向包括图像处理和模式识别以及 SAR 和 PolSAR 图像解释。

E-mail: chengzhengcauc@163.com

Cheng Zheng received the B.Sc. degree in electronic information engineering, and the M.Eng. degree in electronic and communication engineering from the Civil Aviation University of China in 2014 and 2017, respectively. He is currently an experimentalist with the Engineering Techniques Training Center, Civil Aviation University of China. His current research interests include image processing and pattern recognition, SAR and PolSAR image interpretation.