

基于改进 YOLOv8 的 SAR 图像智能识别方法

闫晨宇¹, 耿亮^{1*}, 杜伟伟^{1,2}

(1. 北方自动控制技术研究所, 山西 太原 030006; 2. 智能信息控制技术山西省重点实验室, 山西 太原 030006)

摘要: [目的] 针对合成孔径雷达(synthetic aperture radar, SAR)图像对拍摄角度和目标姿态变化敏感,导致模型区分目标困难的问题. 本文基于 YOLOv8 提出了一种 SAR 图像车辆目标智能识别模型 DCF-SAR. [方法] 该模型首先引入可变形卷积网络(deformable convolutional network, DCN)模块,以增强模型对发生形变目标的识别能力. 其次,通过引入内容感知特征重组(content aware reassembly of features, CARAFE)上采样模块来提升模型在特征融合阶段的效率. 最后,为进一步增强模型训练效率和特征提取能力,使用 Focal 损失函数改进了原始模型的交叉熵分类损失函数,以提高模型的分类精度及其对目标区域的关注程度. [结果] 在 MSTAR 数据集上的实验结果表明,DCF-SAR 模型能够在扩展操作条件(EOC)大俯仰角变化的数据集上实现 98.79% 的识别准确度,比原始模型提高 0.12 个百分点,在标准操作条件(SOC)仅含方位角变化的 1/12 规模的数据集上实现 89.13% 的识别准确度,相比原始模型提高 10.98 个百分点. [结论] DCF-SAR 不仅在拍摄俯仰角大幅变化时表现稳健,在拍摄方位角覆盖不全面的资源受限场景中也具备较高的识别准确度.

关键词: 合成孔径雷达; 可变形卷积网络; 内容感知特征重组; Focal 损失函数

中图分类号: TP 753

文献标志码: A

文章编号: 0438-0479(2025)06-0949-09

SAR image intelligent recognition method based on improved YOLOv8

YAN Chenyu¹, GENG Liang^{1*}, DU Weiwei^{1,2}

(1. North Automatic Control Technology Institute, Taiyuan 030006, China; 2. Key Laboratory of Intelligent Information Control Technology of Shanxi Province, Taiyuan 030006, China)

Abstract: [Objective] Due to the fact that synthetic aperture radar (SAR) images are sensitive to shooting angles and target postures, it is difficult for the model to distinguish targets in SAR images. In this article, we propose an SAR image vehicle target intelligent recognition model DCF-SAR based on YOLOv8. [Method] First, in the model, a deformable convolutional network (DCN) module is introduced to enhance its ability to recognize deformed targets. Second, by introducing the content-aware reassembly of features (CARAFE) upsampling module, the efficiency of the model in the feature fusion stage can be improved. Finally, for the purpose of further enhancing the training efficiency and feature extraction ability of the model, the Focal loss function is used to improve the cross entropy classification loss function of the original model, so that the classification accuracy of the model and its attention to the target area can be improved. [Results] Experimental results on the MSTAR dataset show that the DCF-SAR model achieves a recognition accuracy of 98.79% on the extend operating condition (EOC) dataset with large depression angle variations, which is 0.12 percentage points higher than the original model. On the standard operating condition (SOC) dataset with only azimuth angle variations and at 1/12 the scale, it achieves a recognition accuracy of 89.13%, significantly improving the original model by 10.98 percentage points. [Conclusion] The DCF-SAR model is not only suitable for scenarios with large depression angle variations but also demonstrates outstanding performance on small-scale datasets with limited azimuth angle changes.

收稿日期: 2025-06-06 录用日期: 2025-07-03

基金项目: 陆军装备部“十四五”预先研究基金资助项目(804)

* 通信作者: gjane1989@126.com

引文格式: 闫晨宇, 耿亮, 杜伟伟. 基于改进 YOLOv8 的 SAR 图像智能识别方法[J]. 厦门大学学报(自然科学版), 2025, 64(6): 949-957.

Citation: YAN C Y, GENG L, DU W W. SAR image intelligent recognition method based on improved YOLOv8[J]. J Xiamen Univ Nat Sci, 2025, 64(6): 949-957. (in Chinese)



Keywords: synthetic aperture radar; deformable convolutional network; content-aware reassembly of features; Focal loss function

合成孔径雷达(synthetic aperture radar, SAR)技术是一种雷达成像技术,能以很高的空间分辨率呈现目标电磁散射的空间分布,进而获取目标的形状、尺寸以及内部结构等信息^[1].它不受云、雨、雪、雾以及黑夜或白天的影响,即使在能见度极低的气象条件下,也能拍出类似高分辨光学相机所拍出的图像.然而,SAR存在对拍摄角度和目标姿态敏感的问题,且拍出的图像不可避免地含有斑点噪声,图中的目标难以直接用肉眼识别^[2].SAR自动目标识别(SAR automatic target recognition, SAR ATR)技术一般被分为检测、鉴定、分类三个阶段^[3].目前,SAR图像目标识别任务通常指的是SAR ATR技术中的识别和分类阶段的工作,本文也主要对这一部分进行研究和讨论.

当前关于SAR ATR技术的研究有很多.彤瑶等^[4]提出了一种联合属性散射中心重构和二维变分模态分解特征提取的SAR图像识别方法,经MSTAR数据集(https://gitcode.com/Premium-Resources/1f785/?utm_source=article_gitcode_universal&index=top&type=card)上的实验验证,该方法在同种类但不同型号的目标上有比较好的识别效果.杨慧娉等^[5]根据SAR图像中阴影也能反应目标类别的现象,提出了一种联合提取目标和阴影Zernike矩特征的SAR图像识别的方法.经MSTAR数据集上的实验验证,该方法有比较好的识别准度和鲁棒性.由于SAR图像中不可避免地存在斑点噪声且各类目标的区分度不高,存在特征提取难的问题,罗曼等^[6]为此提出了一种改进卷积神经网络的SAR图像识别方法.经MSTAR数据集上的实验验证,该方法有比较好的识别能力和抗噪声能力.针对SAR图像阴影识别中因阴影图斑离散导致识别精度低这一难题,张向阳等^[7]提出了一种融合梯度-纹理特征的超像素分割方法.经MSTAR数据集上的实验验证,该方法有效解决了图斑离散的问题,提高了模型识别SAR目标的准确度.李青等^[8]针对传统卷积神经网络在处理SAR图像时存在信息丢失导致识别准确度不高的问题,引入数据增强技术,提出了多级可逆SAR图像识别网络.经MSTAR数据集上的实验验证,该方法在解决信息丢失问题的同时提高了模型识别的准确度.

上面的这些方法和目前大部分的研究基本都是聚焦于用传统的卷积神经网络提取出图像中的纹理特征,来实现SAR图像的自动识别工作.然而在现实

情况中,SAR图像中目标的形状、纹理及强散射点分布在不同拍摄角度下会发生显著改变,以上传统模型往往难以捕捉这些变化背后的一致性特征,从而导致SAR图像识别困难的问题.为了解决这个问题,本文对YOLOv8进行了改进.首先,本文在YOLOv8的颈部网络引入可变形卷积网络(deformable convolutional network, DCN)^[9],即使SAR图像因不同拍摄角度和不同姿态发生旋转、缩放、扭曲等变化也能保证模型能识别图中目标.其次,本文将YOLOv8原来的最近邻上采样模块改为高效智能且可即插即用的内容感知特征重组(content-aware reassembly of features, CARAFE)^[10]上采样模块,提高了模型在特征融合阶段的工作效率.最后,本文使用Focal损失改进YOLOv8中的BCE分类损失函数,使模型能提取出SAR图像中更为丰富多样特征信息的同时专注于训练难以识别的目标.

1 YOLOv8 模型介绍

YOLOv8由Ultralytics公司于2023年1月10日发布.该公司发布了YOLOv8的5个版本:YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x. YOLOv8n具有体积小,运行速度快,且便于改动扩展的特点,本文在YOLOv8n的基础上进行改进,提出DCF-SAR模型. YOLOv8n主要由主干网络、颈部网络和预测分类头三个部分组成.其中主干网络使用跨阶段局部网络(CSPNet)搭建.颈部网络使用特征金字塔网络(feature pyramid network, FPN)和路径聚合网络(path aggregation network, PANet)搭建.预测分类部分采用可分开预测边界框损失和分类损失的解耦结构,这种结构可减少回归任务和分类任务之间的干扰,提升模型的检测精度和收敛速度. YOLOv8的损失函数由边界框损失和分类损失两部分组成,其中边界框损失函数由完全交并比(CIoU)损失函数和分布焦点损失(distribution Focal loss, DFL)函数组成;分类损失函数由二元交叉熵(BCE)损失函数组成.

2 本文提出的 DCF-SAR 模型

本文提出的DCF-SAR模型(DCF-SAR名称来自于改进原始模型使用的“DCN”、“CARAFE”模块与Focal改进的损失函数)的详细结构如图1所示.

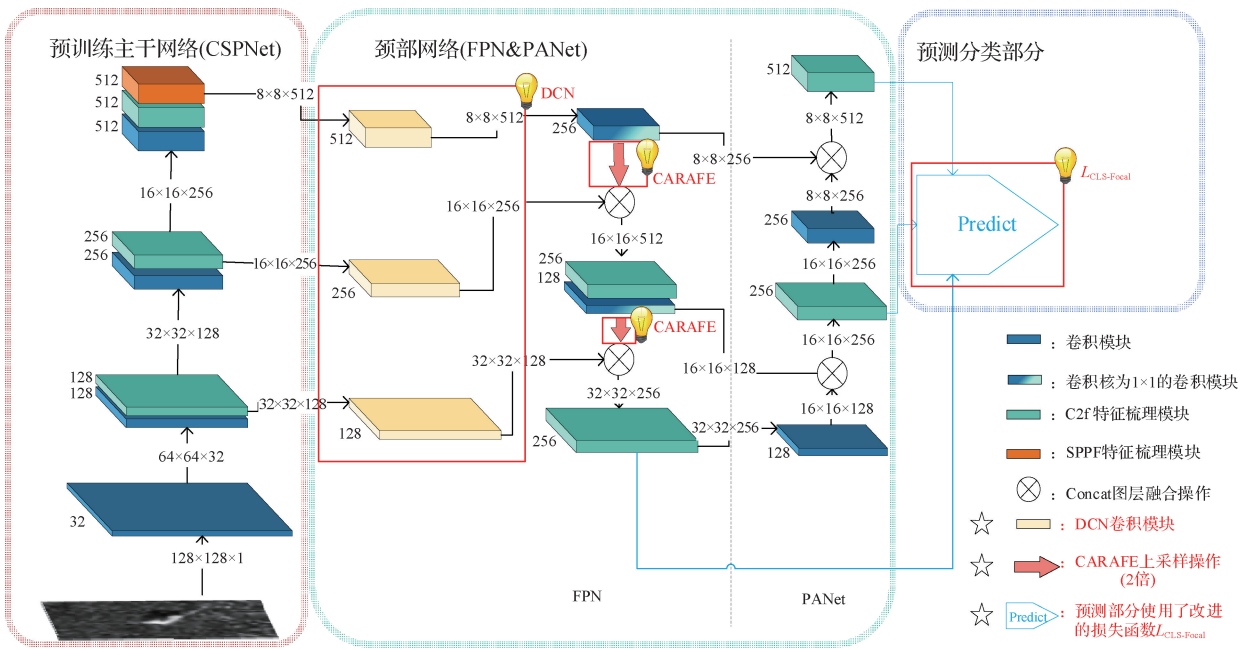


图 1 DCF-SAR 模型的结构图(带灯框代表改进点)

Fig. 1 Specific structure diagram of DCF-SAR model (the boxes with light symbol represent improvement points)

DCF-SAR 模型的改进思路为以下几方面:

- 1) 在原来颈部网络的基础上添加 DCN 模块, 以提升模型对几何形变目标的特征表征能力.
- 2) 在原来颈部网络的基础上添加 CARAFE 模块. 在维持输入图特征几何结构完整性的同时, 提升模型在特征融合阶段的效率.
- 3) 在预测分类部分使用 Focal 损失改进 BCE 损失函数, 提高模型目标分类工作的效率.

2.1 DCN

由于地面战车常处在不同的地形、不同的装备携带状态中, 而 SAR 雷达又对目标的姿态变化比较敏感, 如果在样本不够充足的情况下, 仍使用普通卷积网络, 可能会造成网络模型无法识别发生形变后的目标, 导致目标识别网络的性能变差. DCN 通过额外的一个卷积层从输入特征图中预测出每个采样点的偏移量, 生成采样位置偏移量矩阵, 进而将普通卷积网络中原来固定的卷积核采样位置分散到图中的各个地方, 使得目标检测网络可以提取到目标发生形变后的纹理特征, 认出形变后的目标. 具体的原理如图 2 和式(1)所示.

图 2 展示的 DCN 具体流程为: 输入特征图(通道数为 C , 高度为 H , 宽度为 W)经额外的卷积层处理得到通道数为 $2N$ 的可变形卷积核采样区域偏移图, 偏移图的尺寸和输入特征图一样, 通道数为 $2N$, N 代表可变形卷积核中的采样点个数, 乘 2 因为每个采样点

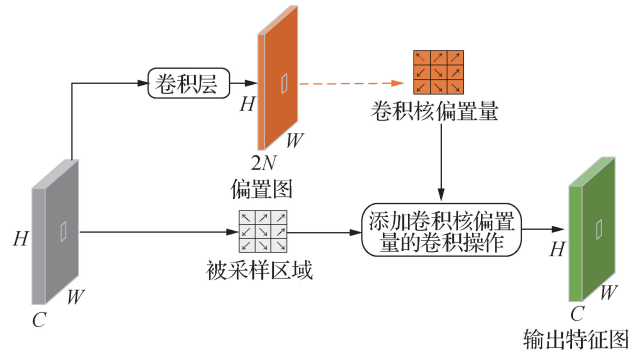


图 2 DCN 模块(3×3 卷积核)

Fig. 2 DCN module (3×3 convolution kernels)

都要学习 x 轴和 y 轴两个方向上的偏移量. 沿偏置图通道方向取出的向量排成一个矩阵就是每个卷积核各采样点的偏置量, 用采样点偏移后的卷积核对输入特征图进行可变形卷积操作, 即可得到输出特征图.

$$y(p_0) = \sum_{p_n \in R} \omega(p_n) \cdot X(p_0 + p_n + \Delta p_n) \cdot \Delta m_n. \quad (1)$$

其中: R 为采样域; $\omega(p_n)$ 为卷积核在采样点 p_n 的权重参数; $X(p_0)$ 为输入特征图在采样区域中心位置 p_0 的值; Δp_n 代表第 n 个采样点的位置偏移量, 通常为小数(使用双线性插值法对应到具体的像素点), 从而使采样网络能根据图像内容自由变形, 不再局限于规则的网格点, 由偏移量卷积网络训练学习得到; Δm_n 为第 n 个采样点的含目标权重(调制因子), 与采样点对最终

输出的重要性相关,由目标权重卷积网络训练学习得到。

由于可变形卷积模块是一种可即插即用的模块,本文在原模型 CBS 的基础上,将卷积部分替换为可变形卷积,提出用于本文模型的 DCN,具体操作如图 3 所示。




图 3 CBS 到 DCN 的改动

Fig. 3 Modification of CBS to DCN

2.2 CARAFE

CARAFE 具有可根据图像内容进行上采样,采样视野广且所需的计算资源相对比较少的特点,相比于传统的上采样技术,能得到更加关键且更加丰富的特征信息. CARAFE 上采样操作由核预测子结构和感知重组子结构两部分组成,即利用核预测模块根据输入特征图的内容动态生成上采样核,再利用感知重组模块对输入特征图的局部区域进行加权重组,从而生成高分辨率的输出特征图,具体原理如图 4 所示。




图 4 CARAFE 上采样模块

Fig. 4 CARAFE upsampling module

CARAFE 上采样的输入是:宽度为 W ,高度为 H ,通道数为 C 的特征图 X . 输出是:宽度为 σW (σ 为上采样倍数,图 4 中示例的上采样倍数为 2),高度为 σH ,通道数为 C 的重组特征图 X' .

核预测子结构由通道压缩器、内容编码器、核归一化操作组成. 通道压缩器由 1×1 卷积层搭建而成,用于压缩特征图的通道数,方便后续运算. 内容编码器用于根据特征图的内容,生成上采样核. 核归一化模块用于将每个采样核的权重调整为服从 $N(0, 1)$ 的正态分布,这样有助于保持特征图在上采样处理过程中的一致性和稳定性。

感知重组操作的表达式为

$$X'_k(i, j) = \sum_{n=-r}^r \sum_{m=-r}^r W_k(i+n, j+m) \cdot X(i+n, j+m) \quad (2)$$

其中: $X'_k(i, j)$ 为输入特征图被采样点 (i, j) 经过第 k 个内容感知重组上采样核 $W_k(i+n, j+m)$ 处理后的新像素值(每个被采样点对应的内容感知重组上采样核有 σ^2 个,可将一个被采样点变为 σ^2 个新像素值,从而将输入特征图放大 σ 倍); r 是以像素点 (i, j) 为中心的上采样范围,图 4 中为 1; $W_k(i+n, j+m)$ 由核预测子结构生成; $X(i+n, j+m)$ 为采样点 $(i+n, j+m)$ 的像素值。

由于 CARAFE 模块是一种可即插即用的模块,本文直接将原模型的最近邻上采样模块替换为 CARAFE 上采样模块。

2.3 分类损失函数的改进

分类损失函数在 SAR 图像的目标识别分类工作中有很重要的作用. 为提高模型对难以识别目标的关注程度,解决类别不平衡的问题,本文使用 Focal 损失函数对分类损失进行改进。

2.3.1 Focal 损失函数

Focal 损失函数可以使模型在训练阶段更加专注于区分样本数量少、难以识别的目标,具体的计算式为

$$L_{\text{Focal}}(p_t) = -\alpha_t(1-p_t)^\gamma \log(p_t), \quad (3)$$

其中: p_t 是模型预测的类别概率结果; α_t 是类别权重系数,一般取样本数量的倒数,用于调低样本数量多的目标对损失函数值的贡献,同时调高样本数量少的目标对损失函数值的贡献,从而使模型专注于训练样本数量较少的目标; γ 是专注度系数,用于调低易识别目标类别对损失函数值的贡献,同时调高不易识别目标类别对损失函数值的贡献,从而使模型专注于训练难以区分类别的目标,一般取 2。

2.3.2 本文改进的分类损失函数

本文使用 Focal 损失改进原始模型的 BCE 损失函数,具体如式(4)所示:

$$L_{\text{CLS-Focal}} = \lambda_{\text{CLS}} \sum_{i=0}^{S^2} \sum_{k=1}^n \mathbf{1}_i^{\text{obj}} \cdot [-\alpha_k(1-c_k)^\gamma \log(c_k)], \quad (4)$$

其中: λ_{CLS} 为类别损失系数,本文取 0.5; S^2 为网格单元的总个数(网格单元的数量等于最后得到特征图的像素点数); n 为样本的类别总数; $\mathbf{1}_i^{\text{obj}}$ 为指示函数,当网格单元对应预测框中含有目标时取 1,否则取 0; α_k 为第 k 类目标的权重系数,使模型更加专注于训练样本

数量较少的目标,取值为第 k 类目标训练样本数量的倒数; γ_k 为专注度系数,使模型专注于训练难以区分类别的目标,取值为 2; c_k 为预测框中目标被预测为第 k 类的概率.使用 Focal 损失对原始模型的分类损失进行改进后,提高了模型分类的准确度和模型对难以识别目标的训练关注度,进一步提高了模型的分类能力.

3 实验结果分析

3.1 实验数据集介绍

本文使用桑迪亚实验室(sandia national laboratory)公布的 MSTAR 数据集进行测试,这个数据集中的 SAR 图片由桑迪亚实验室的学者们和美国军方使用 X 波段的 SAR 雷达以 $0.3\text{ m} \times 0.3\text{ m}$ 的分辨率拍摄得到,里面收入了自行火炮、坦克、装甲车、推土机、卡车等多个类型军用地面装备的 SAR 图像.MSTAR 含有扩展操作条件(extend operating condition,EOC)和标准操作条件(standard operating condition,SOC)两类数据集.

3.2 实验效果评价指标

本文分别以查准率 R_p 、查全率 R_r 和准确率 R_a 来评价模型在 SAR 图像目标分类中的效果:

$$R_p = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (5)$$

$$R_r = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$R_a = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (7)$$

其中, N_{TP} 为真正例数, N_{TN} 为真负例数, N_{FP} 为假正例数, N_{FN} 为假负例数.

3.3 热力图对比实验

为直观地展示出添加 DCN 模块和 CARAFE 模块后对模型关注特征部分产生的效果,本文随机选取了一张 2S1 战车的测试样本图片,将模型提取到的特征进行可视化处理,以热力图的形式在图 5 中进行展示.




图 5 热力图对比
Fig. 5 Heatmap comparison

可以看出,在加入 DCN 模块后,模型生成的热力图更贴合目标及其阴影区域,但同时也引入了图像边缘的一些噪声.而在进一步引入 CARAFE 模块后,热力图不仅更加精准地聚焦于目标及影子区域,还减少了噪声的干扰.这使得模型能够更好地关注目标本身的细节特征,从而提升对不同拍摄角度与目标姿态的识别能力.

3.4 EOC 下的对比实验

为验证提出模型的性能,本文将 DCF-SAR 模型在大俯仰角变化情景下获得的 EOC 数据上进行实验,并与文献[11-16]和网络公开代码复现出的多种分类模型进行对比.大俯仰角变化情景下的 EOC 数据包含 2S1、ZSU-234、BRDM-2、T-72 这四类战车,训练集的俯仰角为 17° ,测试集的俯仰角为 30° (测试集详情如图 6 和表 1 所示).表 2 展示了本文 DCF-SAR 模型与不同模型的识别性能对比,相比于 M-Net^[11]、TSMAL^[12]、MKSF-CNN^[13]、DenseNet^[14]、SCN^[15] 和原始模型 YOLOv8n^[16],DCF-SAR 的识别准确率分别提升了 1.5、0.27、2.58、3.45、0.78、0.12 个百分点.实验结果表明,本文提出的模型可稳健地认出拍摄俯仰角发生变化的目标,在大俯仰角变化的情景下有比较好的识别能力.




图 6 大俯仰角变化下的样本图像
Fig. 6 Sample images under large pitch angle changes

表 1 大俯仰角变化下的 EOC 数据集
Tab. 1 EOC dataset under large pitch angle changes

类别	训练集数量	测试集数量
2S1	299	288
ZSU-234	299	288
BRDM-2	298	287
T-72	299	288

表 2 大俯仰角变化下的模型识别性能对比

Tab. 2 Comparison of model recognition performance under large pitch angle changes

方法	$R_a/\%$
M-Net ^[11]	97.29
TSMAL ^[12]	98.52
MKSFF-CNN ^[13]	96.21
DenseNet ^[14]	95.34
SCN ^[15]	98.01
YOLOv8n ^[16]	98.67
DCF-SAR	98.79

3.5 SOC 下不同比例数据实验

本文采用 SOC 中的 8 类数据集,进行不同比例数据下的实验. 8 类数据包括:轮式装甲运输车(BTR-60)、自行火炮(2S1)、装甲侦察车(BRDM-2)、军用推土机(D7)、坦克(T-62)、军用卡车(ZIL-131)、自行高炮(ZSU-23-4)和桑迪亚实验室雷达测试标准使用样块(SLICY)(图 7),训练集和测试集的数据分别在俯仰角不变的情况下仅小幅变化拍摄方位角得到. 训练集拍摄的俯仰角为 17°(训练集详情如表 3 所示),测试集拍摄俯的仰角为 15°(测试集详情如表 4 所示).




图 7 MSTAR 8 类数据集

Fig. 7 8 types MSTAR data sets

表 3 MSTAR 的 8 类数据训练集

Tab. 3 8 types data train set of MSTAR

类别	BTR-60	2S1	BRDM-2	D7	T-62	ZIL-131	ZSU-23-4	SLICY
数量	297	299	298	299	299	299	299	298

表 4 MSTAR 的 8 类数据测试集

Tab. 4 8 types data test set of MSTAR

类别	BTR-60	2S1	BRDM-2	D7	T-62	ZIL-131	ZSU-23-4	SLICY
数量	247	273	240	256	261	251	241	254

3.5.1 与原始模型的性能对比

为验证本文提出模型的效果,在表 5 和表 6 中分别列出了原始模型与本文模型在特定数据集上的分类混淆矩阵,该数据集仅通过小幅改变拍摄方位角构建,其规模约为完整训练集的 1/12. 通过对表 5 和 6,可以看出,本文模型与原始模型相比,识别各类战车的准度、鲁棒性与泛化能力均有显著的提升.

3.5.2 DCF-SAR 模型与其他模型的性能对比

表 7 给出了本文复现出的 M-Net、TSMAL、

MKSFF-CNN、MoFFL、SCN 等模型,以及原始模型与本文提出的 DCF-SAR 模型在不同比例的数据集上的识别准确率对比结果. 可以看出,本文提出的分类模型在 1/2、1/4、1/8、1/12 比例的样本数据量中,识别准确度分别比表现最优秀的模型性能提升了 2.16, 2.89, 2.78, 10.98 个百分点.

除此之外,从图 8 可以看出,在仅含方位角变化的 1/12 规模数据集上,DCF-SAR 模型相较于其他对比模型,展现出更高的识别准度与更快的训练收敛速度.

表 5 原模型的混淆矩阵(在 1/12 比例训练集中的识别结果)

Tab. 5 The confusion matrix of the original model (1/12 scale training set)

真实类别	预测类别								$R_p/\%$	$R_r/\%$
	BTR-60	2S1	BRDM-2	D7	T-62	ZIL-131	ZSU-23-4	SLICY		
BTR-60	212	2	14	6	3	1	5	4	77.37	85.83
2S1	13	201	13	8	15	1	8	14	77.91	73.62
BRDM-2	2	13	186	17	2	1	15	4	78.15	77.50
D7	2	5	7	201	11	23	3	4	77.91	78.52
T-62	25	5	3	1	199	4	22	2	77.43	76.25
ZIL-131	1	26	3	6	20	181	1	13	82.65	72.11
ZSU-23-4	9	5	5	9	1	6	192	14	75.29	79.67
SLICY	10	1	7	10	6	2	9	209	79.17	82.28

表 6 DCF-SAR 模型的混淆矩阵(在 1/12 比例训练集中的识别结果)

Tab. 6 Confusion matrix of DCF-SAR model (1/12 scale training set)

真实类别	预测类别								$R_p/\%$	$R_r/\%$
	BTR-60	2S1	BRDM-2	D7	T-62	ZIL-131	ZSU-23-4	SLICY		
BTR-60	229	3	3	0	5	2	5	0	92.34	92.71
2S1	0	246	0	10	6	9	2	0	93.18	90.11
BRDM-2	0	8	195	12	4	6	4	11	88.64	81.25
D7	2	3	5	230	0	4	8	4	77.97	89.84
T-62	2	1	3	20	224	10	0	1	82.96	85.82
ZIL-131	9	1	2	9	14	206	0	10	81.75	82.07
ZSU-23-4	0	1	0	13	15	12	196	4	87.89	81.32
SLICY	6	1	12	1	2	3	8	221	88.05	87.01

表 7 DCF-SAR 模型与其他模型的识别效果对比

Tab. 7 Comparison of recognition effect between DCF-SAR model and other models

方法	$R_a/\%$			
	1/2	1/4	1/8	1/12
M-Net ^[11]	92.58	87.03	66.13	45.08
TSMAL ^[12]	95.17	81.59	79.32	68.76
MKSFF-CNN ^[13]	93.78	90.38	74.89	53.37
DenseNet ^[14]	92.25	87.32	82.31	69.99
SCN ^[15]	91.42	86.48	78.31	42.83
原始模型 ^[16]	96.21	93.82	89.57	78.15
DCF-SAR 模型	98.37	96.71	92.35	89.13

3.5.3 消融实验

为证明使用 DCN 和 CARAFE 技术与本文提出损失函数的有效性,本文在仅有拍摄方位角变化的数




图 8 DCF-SAR 模型与其他模型在不同周期下的识别准确度对比(1/12 原数据集)

Fig. 8 Comparison of recognition accuracy between DCF-SAR model and other models at different periods (1/12 original dataset)

数据集上进行消融实验,数据集的规模约为原数据集的 1/12. 实验结果如表 8 所示. 可以看出,随着 DCN, CARAFE 技术与 Focal 改进损失函数的使用,模型的识别准确率在逐渐上升. 单独使用 DCN 技术将模型的识别准确率提高了 5.06 个百分点,因此,使用 DCN 技术可以帮助模型认出发生形变的目标,提高模型在样本数量有限情景下的识别性能. 单独使用 CARAFE 技术将模型的识别精确度提高了 3.52 个百分点,因此,使用 CARAFE 技术可以更加充分地提取出 SAR 图像中目标的特征信息,从而提高模型的识别性能. 单独使用本文提出 Focal 改进的损失函数将模型的识别精确度提高了 4.37 个百分点,因此,本文提出的损失函数可以更加全面高效的提升模型的训练效率,从而达到提高模型识别性能的效果. 整体来看,三种方法都使用时模型的识别性能最优,识别准确率达到 89.13%.

表 8 DCN、CARAFE 模块与 Focal 改进损失函数对识别准确率的影响

Tab. 8 Influence of DCN, CARAFE module and Focal Inner SIoU loss function on recognition accuracy

DCN	CARAFE	Focal 改进的损失函数	$R_a/\%$
			78.15
✓			83.21
	✓		81.67
		✓	82.52
✓	✓		85.09
✓		✓	86.22
	✓	✓	87.73
✓	✓	✓	89.13

4 总结与展望

为提升图像分类模型在 SAR 图像上的识别性能,本文通过引入可变形卷积网络(DCN)、CARAFE 模块以及 Focal 损失函数对 YOLOv8n 模型进行改进,构建 DCF-SAR 图像地面车辆目标识别模型. 在 MSTAR 数据集上的实验结果表明,DCF-SAR 模型能够在 EOC 大俯仰角变化的数据集上实现 98.79% 的识别准确率,在 SOC 仅含方位角变化的 1/12 规模数据集上实现 89.13% 的识别准确率. 和其他模型相比,不仅在拍摄俯仰角大幅变化时表现稳健,在拍摄

方位角覆盖不全面的资源受限场景中也具备较高的识别能力.

未来工作将聚焦于优化模型架构,通过引入轻量化卷积操作、动态量化技术等高效计算策略,以显著降低模型运行量,提升运行效率. 此外,还将探索并行计算与分布式训练方法,充分利用硬件资源,进一步加快模型的训练与推理速度,推动模型在实际应用中的广泛部署.

参考文献:

- [1] 毛新华. 聚束式合成孔径雷达成像处理之道[M]. 北京:国防工业出版社,2024.
- [2] 保铮,邢孟道,王彤. 雷达成像技术[M]. 北京:电子工业出版社,2005.
- [3] 任浩浩. 合成孔径雷达图像目标识别方法研究[D]. 成都:电子科技大学,2021.
- [4] 彤瑶,张洋洋. 重构目标和多层次 BVMD 特征融合的 SAR 图像目标识别方法[J]. 探测与控制学报,2025,47(1):94-101.
- [5] 杨慧娉,赖小龙,刘丹,等. 一种基于区域特征的 SAR 图像目标识别方法[J]. 电光与控制,2025,32(3):76-81.
- [6] 罗曼,李新. 改进卷积神经网络的 SAR 图像识别方法[J]. 空天预警研究学报,2024,38(3):162-166,172.
- [7] 张向阳,罗小军,包佳文,等. 梯度-纹理特征超像素分割的 SAR 图像阴影识别[J]. 遥感信息,2023,38(4):106-112.
- [8] 李青,柯文字,翟懿奎,等. 多级可逆网络在 SAR 图像识别中的应用[J]. 五邑大学学报(自然科学版),2024,38(2):40-47.
- [9] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks[C]//International Conference on Computer Vision. Piscataway:IEEE,2017:764-773.
- [10] WANG J Q, CHEN K, XU R, et al. CARAFE: content-aware reassembly of features [C] // IEEE (ICCV). Piscataway:IEEE,2019:3007-3016.
- [11] SHANG R H, WANG J M, JIAO L C, et al. SAR targets classification based on deep memory convolution neural networks and transfer parameters[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2018,11(8):2834-2846.
- [12] GUO S, CHEN T, WANG P H, et al. TSMAL: target-shadow mask assistance learning network for SAR target recognition[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024,17:18247-18263.
- [13] AI J Q, MAO Y X, LUO Q W, et al. SAR target classification using the multikernel-size feature fusion-

- based convolutional neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [14] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 2261-2269.
- [15] GUO Y R, PAN Z X, WANG M M, et al. Learning capsules for SAR target recognition[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 4663-4673.
- [16] VARGHESE R, SAMBATH M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C] // 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Piscataway: IEEE, 2024: 1-6. doi:10.1109/adics58448.2024.10533619.
- [16] XIE R, HU D Y, LUO K, et al. Performance analysis of joint range-velocity estimator with 2D-MUSIC in OFDM radar[J]. IEEE Transactions on Signal Processing, 2021, 69: 4787-4800.
- [17] DEMISSIE B, BERGER C R. High-resolution range-Doppler processing by coherent block-sparse estimation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(2): 843-857.
- [18] HADI M A, TABASSUM M N, ALSHEBEILI S. Compressive sensing based high-resolution passive bistatic radar[J]. Signal, Image and Video Processing, 2017, 11(4): 635-642.
- [19] FILIP-DHAUBHADEL A, SHUTIN D. Long coherent integration in passive radar systems using super-resolution sparse bayesian learning[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(1): 554-572.
- [20] TANG G G, BHASKAR B N, SHAH P, et al. Compressed sensing off the grid[J]. IEEE Transactions on Information Theory, 2013, 59(11): 7465-7490.
- [21] YANG Z, XIE L H. Enhancing sparsity and resolution via reweighted atomic norm minimization[J]. IEEE Transactions on Signal Processing, 2016, 64(4): 995-1006.
- [22] CHEN P, CHEN Z M, MIAO P, et al. RIS-ADMM: a RIS and ADMM-based passive and sparse sensing method with interference removal[J]. IEEE Communications Letters, 2024, 28(4): 867-871.
- [23] SUI J X, WANG J, GAO J. Clutter suppression algorithm via covariance matrix reconstruction with airborne passive radar[J]. IEEE Internet of Things Journal, 2025: 1. doi: 10.1109/JIOT.2025.3588861.
- [24] LI Y C, WANG X D, DING Z G. Multi-target position and velocity estimation using OFDM communication signals[J]. IEEE Transactions on Communications, 2020, 68(2): 1160-1174.
- [25] ZHANG Z, WANG Y, TIAN Z. Efficient two-dimensional line spectrum estimation based on decoupled atomic norm minimization[J]. Signal Processing, 2019, 163: 95-106.
- [26] YANG Z, XIE L H. Exact joint sparse frequency recovery via optimization methods[J]. IEEE Transactions on Signal Processing, 2016, 64(19): 5145-5157.
- [27] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [28] NAHA A, SAMANTA A K, ROUTRAY A, et al. Determining autocorrelation matrix size and sampling frequency for MUSIC algorithm[J]. IEEE Signal Processing Letters, 2015, 22(8): 1016-1020.

(责任编辑:任滢滢)

[上接第 948 页]

(责任编辑:任滢滢)