

基于深度学习的 SAR 图像舰船目标检测综述

侯笑晗^{**}, 金国栋^{*}, 谭力宁

火箭军工程大学核工程学院, 陕西 西安 710025

摘要 近年来,合成孔径雷达成像技术因具备全天时和全天候的目标感测能力,在海洋实时监测和管控等领域发挥着重要作用,特别是高分率 SAR 图像中的舰船目标检测成为当前的研究热点之一。首先分析基于深度学习的 SAR 图像舰船目标检测流程,并对样本训练数据集的构建、目标特征的提取和目标框选的设计等关键步骤进行归纳总结。然后对检测流程中的各部分对 SAR 图像舰船目标检测精度和速度的影响进行对比分析。最后根据当前研究现状,深入分析深度学习算法在舰船检测应用中存在的问题,探讨基于深度学习的 SAR 图像舰船目标检测的进一步研究方向。

关键词 机器视觉;深度学习;目标检测;合成孔径雷达;舰船目标;图像处理

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.0400005

Survey of Ship Detection in SAR Images Based on Deep Learning

Hou Xiaohan^{**}, Jin Guodong^{*}, Tan Lining

College of Nuclear Engineering, Rocket Army Engineering University, Xi'an, Shaanxi 710025, China

Abstract In recent years, synthetic aperture radar imaging technology (SAR) has played an important role in the real-time monitoring and control of the ocean due to its all-time and all-weather target sensing capabilities. In particular, the detection of ship targets in high-resolution SAR images has become current one of the research hotspots. First, the process of ship target detection based on deep learning in SAR images is analyzed, and the key steps such as the construction of sample training datasets are summarized, the extraction of target features and the design of target frame selection. Then, the influence of each part of the detection process on the detection accuracy and speed of the ship target in the SAR image is compared and analyzed. Finally, according to the current research status, the problems of deep learning algorithms in the application of ship detection are deeply analyzed, and the further research direction of ship target detection based on deep learning in SAR images is discussed.

Key words machine vision; deep learning; target detection; synthetic aperture radar; ship target; image processing

OCIS codes 150.1135; 150.4065; 280.3640

1 引言

合成孔径雷达 (Synthetic Aperture Radar, SAR)^[1]是一种主动式微波遥感传感器,与光学传感器相比具有全天时、全天候、多角度和远距离的监测能力,在海洋救援和海洋执法等民用领域以及海洋实时监视检测等军事领域都有着广泛的应用范围。随着高分辨率 SAR 成像技术的不断发展,大量

的 SAR 图像可用于海上船舶检测^[2-5]。SAR 图像舰船目标检测成为当前的研究热点之一,在海域实时检测中发挥着重要作用^[6],因此研究 SAR 舰船目标检测算法具有重要意义。

基于 SAR 图像的海上舰船目标提取在遥感图像目标检测领域是非常具有挑战性的问题之一。传统的舰船目标检测算法大多针对特定场景^[7-9],主要是对海杂波进行建模与仿真以及恒虚警目标的检

收稿日期: 2020-07-08; 修回日期: 2020-08-04; 录用日期: 2020-08-13

基金项目: 国家自然科学基金(61903375)

* E-mail: jinguodong_army@163.com; ** E-mail: Houxiaohan_666@163.com

测^[10-17],但检测过程中高度依赖于预先定义的特征或人工设计的特征,致使算法的鲁棒性较低,泛化性差。基于深度学习算法的卷积神经网络(Convolutional Neural Networks, CNN)^[18]借助其自主学习参数和自动提取特征的能力,可以摆脱对人工设计特征和建模的依赖,使其成为当前目标检测的主流算法之一^[19-20],在遥感图像目标检测领域有着重要的应用价值^[21-22],特别是在场景复杂多变和目标形态不一的 SAR 舰船目标检测领域中具有巨大的应用潜力,而且已经取得很大进展。

本文首先建立基于深度学习算法的 SAR 舰船目标检测流程,重点对基于深度学习算法的 SAR 舰船目标检测技术进行综述,然后总结图像增强、特征提取和边框设计三大关键技术的发展现状,最后结合现有算法存在的问题对其未来发展趋势进行展望。

2 基于深度学习算法的 SAR 舰船目标检测流程

基于深度学习算法的 SAR 舰船目标检测算法利用所给的 SAR 舰船目标数据集来训练网络,网络自动学习参数后可以识别舰船目标并给出其所在位置,检测算法主要分为两类。第一类是以 Faster R-CNN(Region-CNN)^[23]为代表的双阶段目标检测算法,采用该算法在包含目标的边框上生成候选区域并进行目标检测,该算法的检测精度高,但效率较低。双阶段目标检测算法的主要流程如图 1 所示。

第二类是单阶段目标检测算法,主要以 SSD(Single Shot MultiBox Detector, SSD)^[24]和 YOLOv3(You Only Look Once v3, YOLO v3)^[25]为代表,此类算法不需要生成候选区域,而是直接采用回归的方式进行目标检测,并且同时兼顾检测效率和精度。单阶段目标检测算法的主要流程如图 2 所示。




图 1 双阶段目标检测算法的流程图

Fig. 1 Flowchart of two-stage target detection algorithm

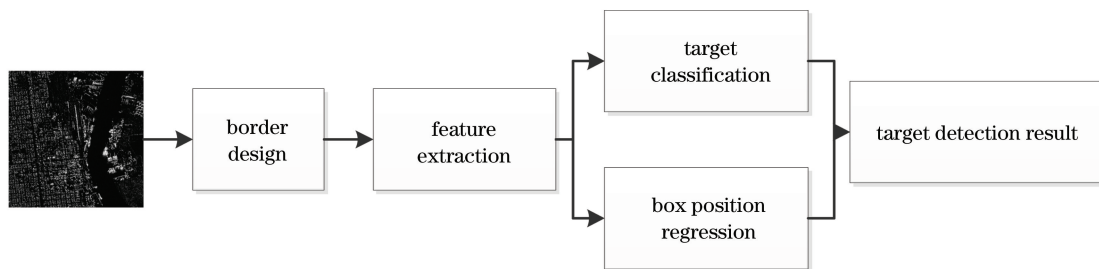


图 2 单阶段目标检测算法的流程图

Fig. 2 Flowchart of single stage target detection algorithm

上述两种主流算法在检测过程中主要包括如下三个步骤。

1) 样本训练数据集的构建

与传统算法不同,深度学习算法不需要对图像进行去噪和分割等预处理。深度学习算法中,数据集在网络收敛的过程中起着重要的作用,而

且大规模、高质量且种类丰富的数据集可在一定程度上决定网络的泛化能力。相比于可见光数据集, SAR 舰船数据并不丰富,因此 SAR 图像数据增强是 SAR 图像处理过程中十分关键的一步,主要有传统的图像处理和生成式对抗网络(GAN)两种增强方法。

2) 目标特征的提取

目标特征的提取主要是利用深度网络对图像中的高层语义信息和浅层位置信息进行提取,接着根据目标特性对所提取的特征进行处理。主要目的是加强对 SAR 图像中隐藏信息的利用率,减少 SAR 图像中干扰物的影响,从而提高舰船目标的检测率。

3) 目标候选框的设计

双阶段中候选区域的选取和单阶段中先验框的生成均需要对舰船位置边框进行设计,合理的边框设计能够有效降低目标的漏检率和虚警率。

研究人员直接将主流算框架应用在 SAR 舰船目标检测领域,但并未得到理想的检测效果,因此基于主流算法框架对 SAR 舰船目标检测算法进行研究,不断完善深度学习算法与 SAR 舰船目标检测技术的融合机制。

3 样本训练数据集的构建

深度学习算法的优势在于无须对图像进行预处理,而是将大量不同实例的数据集输入网络中并从中学习隐藏信息,从而生成概率向量。2017 年, Sun 等^[26]提出了视觉任务的性能仍然以训练数据大小的数量级线性增加的观点,证明大规模且高质量的数据对深度学习网络模型的检测能力起到至关重要的作用。由于受到 SAR 成像条件的限制,其相关数据集不如可见光数据集广泛。近年来,不同学者^[27-30]不断提出了新的 SAR 舰船数据集以满足研究需求。表 1 为现有 SAR 舰船数据集的对比。现有数据集的量级不断提升,但其船只类型多为民船,因此限制了 SAR 图像军用舰船目标检测的发展。同时,许多实验室依据特定场景建立专有舰船数据集,但无法提供完整且规范的数据,而且无法作为该领域的算法评价标准之一。

表 1 现有的 SAR 舰船数据集
Table 1 Existing SAR ship datasets

Dataset	Open SAR ship	SSDD	SAR-ship-dataset	AIR-SARship-1.0
Data information	There are 11346 slices, including ten types of ships	There are 1160 slices, including 2456 ships	There are 43819 slices, including 59535 ships	There are 31 scenes in Gaofen No. 3 SAR image
Advantage	1 st ship target dataset to provide benchmark data for researchers in this field	The dataset contains SAR images with different resolution, polarization, sea condition, large sea area and landing conditions	There has been a large-scale increase in the amount of data and the types of ships	Including ports, islands and reefs, different levels of sea conditions, the background covers variety of scenes, such as inshore and offshore
Shortcoming	The number of samples among categories is not balanced, so it is difficult to train a better classification model	The amount of data is still lacking	Most of the datasets are offshore background, the nearshore background is less, and the background is relatively simple	The types of vessels are still civilian ships

为了促进 SAR 舰船目标检测的研究、提高现有数据集的使用率,以及进一步丰富 SAR 舰船数据集的种类丰富性和舰船分布及形态的多样性,在 SAR 舰船检测中常采用传统的图像处理

和 GAN 两种方法进行数据增强以实现样本数据集的扩充,处理流程如图 3 所示,其中 DCGAN 为深度卷积对抗生成网络, pix2pix 为像素对像素方法。

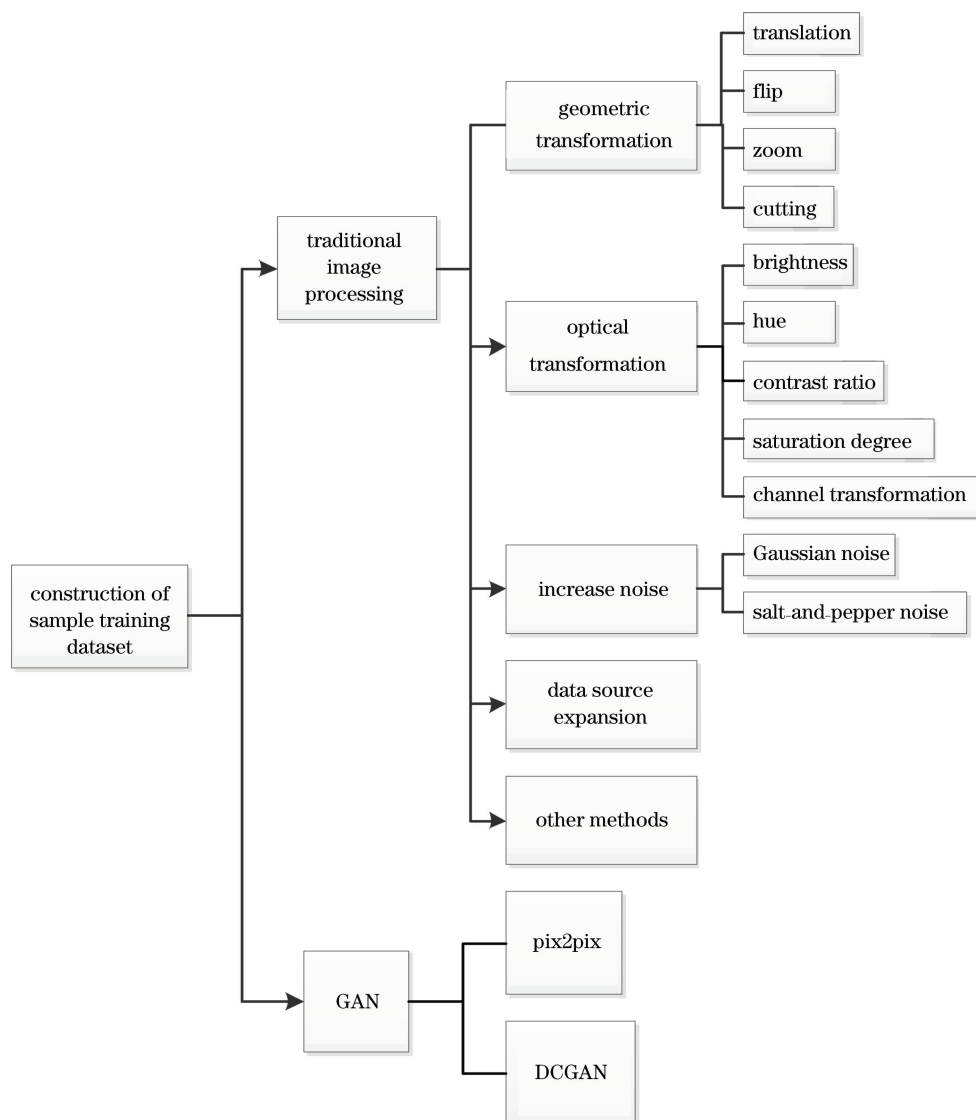


图 3 数据集扩充的处理方法
Fig. 3 Processing method of dataset expansion

3.1 传统方法

传统的图像处理方法所采用的数据增广方式主要有几何变换、光学变换、增加噪声和数据源扩充等,此外仿真也是一种重要的数据增广方式。

表 2 为传统数据增广方法的对比,其中 $G_{(i,j)}$ 表示平移前的图像, (i,j) 表示平移前的坐标, (i',j') 表示平移后的坐标, (x,y) 表示平移尺度, (W,Q) 表示旋转前的坐标, (W',Q') 表示旋转后的坐标, θ 表示旋转角度, N 表示添加的噪声, $G'_{(i',j')}$ 表示加入噪声后的图像, HSV 表示色调(H)、饱和度(S)和明度(V)。

传统的数据增广方式具有操作简单便捷的优点,是当前最常用的数据增广方式之一。文献[31]

采用了几何变换的方式在原图上填充像素并进行拉伸,控制原有数据及扩充数据的比例可以保持原有数据信息的分布,能够有效增强模型对目标的识别能力,但扩充数据引入的杂波信息会存在一定的虚警。文献[32]使用了基于三维模型与射线追踪的 SAR 舰船目标仿真成像技术,并对不同类型的舰船目标进行模拟,对得到的 SAR 图像进行切片和压缩处理以扩充数据,从而得到多类军舰样本,这为 SAR 图像舰船检测的军事化应用奠定了基础。传统的图像处理方法操作简单,但在扩充数据的同时会改变数据的原有分布。仿真成像技术局限于仿真精度,难以实现高精度的建模。

表 2 传统数据增广方法的对比

Table 2 Comparison of traditional data augmentation methods

Method	Operation method	Advantage	Shortcoming	
Geometric transformation	Translation	$G'_{(i',j')} = G_{(i+x,j+y)}$	The effect is not ideal in location-sensitive tasks	
	Rotation	$W' = W \cos \theta + Q \sin \theta$ $Q' = -W \sin \theta + Q \cos \theta$		
	Cutting	Random image clipping using a certain overlap ratio	Enrich the position and scale of objects in the image	After cropping, the output needs to be scaled to a fixed size, which may cause image distortion
	Zoom	Randomly select the expansion scale, place the original image in the lower right corner of the expansion image, and fill other blank areas with channel mean		
Optical transformation	Hue	Randomly add a real number to each point in the image with a probability of 0.5	Add images under different lights and scenes	In the case that the edge of the SAR image itself is not clear, it may cause the model to be difficult to converge
	Saturation degree	Randomly multiply each point in the image by a real number in the HSV gamut space		
Increase noise	Gaussian/salt-and-pepper noise	$G'_{(i',j')} = G_{(i,j)} + N$ $G'_{(i',j')} = G_{(i,j)} \cdot N$	Generate robustness to natural disturbances and improve the generalization ability of the model	Excessive noise affects the output of the model
Data source expansion	Change the background	Combine detected objects with other background images	Increase the richness of the dataset	The morphological characteristics of the target itself have not been changed

3.2 GAN 方法

为了解决 3.1 节的问题,提出了一种基于 GAN^[33]的图像数据增强方法。GAN 利用 CNN 来学习给定样本数据内部的统计规律,并且基于所得到的概率分布模型以产生能够欺骗判别器的新数据,从而生成更多样本,基本流程如图 4 所示, $G_{generator}$ 表示生成器, $D_{discriminator}$ 表示判别器, S 表示真实样本, $G(S)$ 为生成器生成的“虚假”图片。




图 4 GAN 的处理流程

Fig. 4 GAN processing process

为了学习真实数据 S 的分布 p_g , 将随机噪声 N

输入生成器 $G_{generator}$ 中, 将 S 和生成器的输出数据同时输入到判别器 $D_{discriminator}$ 中, 最终输出生成样本为真实样本的概率。

文献[34]提出了一种基于 pix2pix^[35] 和 GAN 的数据增广方式, 通过建立输入数据和输出数据的对应关系来生成图像, 可以使检测器的性能有一定程度的提升, 但这种方式生成的舰船目标背景简单且尺度单一, 在样本数量增加到一定程度后无法持续提高检测器的性能。李健伟等^[36] 借鉴了文献[37]的思想, 采用 GAN 与 Faster R-CNN 相结合的方法在特征图上生成不同条件下的难例样本, 并不是生成像素本身, 这可以提高多尺度且多角度舰船目标检测的鲁棒性, 但该方法只改进了训练阶段, 所以检测速率并没有得到提升。文献[38]提出了一种基于单一图像的无条件图像生成网络, 该网络采用了金字塔式多尺度 GAN 的思想, 使用该网络可以增强

样本的多样性,但每次只能训练一张图片,时间和训练成本较高。不同于传统数据增强方法,GAN 数据增强方法有助于了解数据分布的性质及其潜在结构,从而提高生成数据的多样性。

4 目标特征提取

与传统模式的最大不同之处在于,深度学习算法能够从大量数据中自动学习特征并根据特征对目标进行分类,其中特征提取是深度学习算法的核心步骤。由于 SAR 图像具有特定的成像模式,为此特征提取主要解决如下两个问题。

1) 数据集中包含多种分辨率的 SAR 舰船图像,如何在多形态、多尺度和多分辨率,以及轮廓模糊和目标像素点少的情况下提取舰船目标特征。

2) 在近岸背景下,SAR 图像舰船目标的检测过程中易受到码头、建筑物和海岸陆地的干扰,如何合理地提取特征以减少复杂背景的影响。

研究者可以采用特征融合的方式,如特征金字塔结构和密集连接等来解决问题 1)。对于问题 2),可以采用注意力机制,如卷积注意力模块或上下文融合等方法。

4.1 特征融合

CNN 中,深层特征图的分辨率较低,但含有丰富的语义信息,浅层特征图的分辨率较高,但缺乏语义信息。SAR 图像中的舰船形态多变,目标尺度差异较大,因此常采用特征融合的方式对不同特征层的信息进行融合,从而达到精准分类和定位。多层特征的融合是当前提高检测性能的常用方法之一,主要以特征金字塔网络 (Feature Pyramid Network, FPN)^[39] 和超密集连接网络为代表。

FPN 将深层语义信息传达到底层特征图中以弥补底层特征图的语义信息,从而可以较好地改善多尺度问题,总体框架如图 5 所示。




图 5 FPN 框架

Fig. 5 Framework of FPN

超密集连接网络是在保证网络中层与层之间最大程度的信息传输的前提下,直接将所有卷积层连

接起来,该网络加强了特征之间的传递,而且能够更有效地利用特征,基本结构如图 6 所示。




图 6 超密集连接网络的结构

Fig. 6 Structure of hyperdense connection network

文献[40]在网络中进行两次跨层特征的融合,可以有效解决海面和港口多尺度舰船目标的检测问题,但检测效率有所降低。文献[41]融合了相邻特征层的信息以充分利用语义和空间信息,从而进一步提高小目标的检测性能。融合后的特征层中,小物体只在很小的区域产生响应,因此对弱目标或低强度的目标进行检测易造成漏检和虚警。针对上述问题,文献[42]提高了网络的分辨率,通过融合中间层、一个缩小的浅层和一个上采样的深层来生成区域提案,从而将 RPN 的空间分辨率提高到与中间层相同的水平,这可以扩大特征图中小型船舶的响应面积。文献[43]在基础网络中部署了从浅层特征到中层特征的前向连接块和深层特征到卷积特征的反向连接块,与原特征的卷积层进行连接可用于生成增强的中间特征层。

层间融合和网络分辨率的提高可以有效统一多尺度表示和语义分布,从而显著提升密集小目标的检测能力。

4.2 注意力机制

相比于其他特征提取方法对输入图像的整体把握,注意力机制更关注于局部信息,在分布稀疏且像素点占比小的 SAR 图像舰船检测中发挥了重要的作用。本节主要介绍在 SAR 图像舰船检测中应用范围较广的卷积注意力模块 (Convolutional Block Attention Module, CBAM) 和上下文融合两种算法。

CBAM 通过结合通道和空间顺序来推断注意力映射,然后将注意力映射相乘为自适应特征细化的输入特征映射,框架如图 7 所示,其中 \otimes 为逐元素相乘符号。通道注意力机制能够关注有效通道,抑制无关通道,从而提高网络中信息流动的效率。空间注意力机制能够有效地关注舰船抑制图像中的其他干扰信息,从而提高检测精度。




图 7 CBAM 的框架

Fig. 7 Framework of CBAM

上下文融合算法的基本逻辑如图 8 所示。视觉系统中,背景相关信息能够为决策提高置信度,如舰船目标一般分布于海域或沿海地区。上下文融合算法是将感兴趣区域周边的像素点融入检测网络中,利用比例系数来控制周边信息和感兴趣区域的占比,使得检测网络的注意力集中于海域。

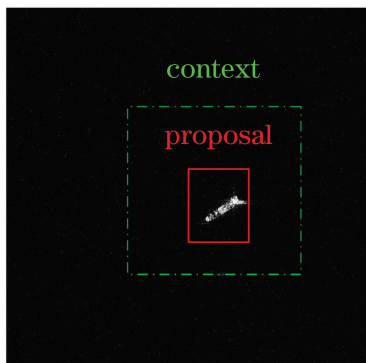


图 8 上下文融合算法的框架

Fig. 8 Framework for context fusion algorithm

文献[43]受到 He 等^[44]使用了基于像素的文本检测器对单词进行一次性预测的启发,重新设计区域注意力机制以生成识别物体区域和预测区分区域两个注意力权重图,两个独立分支互补以增强特征图的相关区域,抑制非相关区域,检测效果有所提升,但虚警率略高。文献[45]使用了 SCB(Split Convolution Block)将输入图像分为更小块以提升小目标和密集目标的注意力, SAB 可以加强目标区域的注意力,减少特征图在传输过程中的损失,但单张图片的测试时间有所增加。文献[46]使用了空间递归网络通过图像在水平和垂直方向上传递空间变化的上下文信息,可以提高对小目标的检测效果。

特征提取算法的选取需要考虑计算量和精度的平衡性,可以采用卷积分解等方式对模型进行轻量化处理,另一方面节约网络的宽度和深度可以避免过拟合。

5 目标框的设计

目标框的设计是 SAR 舰船检测的关键步骤之

一,如何设计建议框并使其更符合目标形态,而且还能提高检测准确度以及改善对密集型舰船的检测性能,是 SAR 舰船检测的难点之一。边框的设计方法主要包括方向设计和尺度设计两个。

5.1 方向设计

SAR 图像中,舰船目标是呈任意方向分布的^[47]。目标检测算法中,常使用目标最小外接垂直矩形框,但这种包围框不能准确反映舰船的方向,而且还会存在较大的冗余区域,进而引入背景噪声,所以目标最小外接矩形框对多角度舰船密集排列的检测更为合理。

文献[48]设置了 6 种旋转角度以满足角度覆盖和计算效率之间的权衡,并参考文献[49]多阶段检测策略,通过在不同的检测阶段设定递增的交并比 (IOU) 阈值,并对建议区域的连续重采样以减少拟合误差,保证旋转边界框回归的准确度。文献[50]在回归参数中加入了旋转角度以检测船头方向,构建了一个基于旋转区域的端到端船舶检测框架,能够在减少冗余噪声区域影响的同时预测船舶的靠泊方向和航行方向,但预测的准确率大大降低。以上两种方法仍限于锚框生成机制,增加参数后,锚框的生成数量也会大幅度增加,使得计算成本提高。文献[50]参考了 Centernet 模型^[51],不再设定初始锚框,而是设计网络来预测目标中心点,再对中心点处目标斜框的尺度和方向等参数进行回归分析,从而实现目标的斜框预测。摆脱锚框机制的依赖,能够更灵活地检测密集分布的目标。不同的目标边框如图 9 所示。




图 9 不同的目标边框。(a) 目标最小外接垂直框;(b) 目标最小外接矩形框

Fig. 9 Different target borders. (a) Target minimum outbound vertical border; (b) target minimum outbound rectangular border

5.2 尺度设计

基于深度学习算法的通用检测算法中,锚框的设计是以光学图像为基础,而 SAR 图像中的目标具有低密度和少像素点等特征,因此需要对锚框尺寸

和长宽比进行改进。文献[52]采用了 K-means++ 算法对训练数据进行重新聚类,得到的合理先验框可以使网络的训练更有实际意义。文献[53]使用了 SSDKmeans 算法聚类生成锚框以提升复杂背景下的小目标检测效果。参与聚类算法的锚框数与聚类效果在一定范围内呈线性相关,具体算法中需权衡锚框数量和计算量,尽可能在不增加计算成本的同时提升检测效果。

目标框的设计算法需要权衡计算量和参数量,并通过损失函数来设计精确的回归参数。

6 存在的问题及进一步研究方向

相比于传统算法,深度学习算法在 SAR 图像舰船检测中可以取得很大的突破,但在实际应用中尚未达到期望值,主要存在的问题如下。

1) 现有深度学习算法常采用迁移学习的方法,该方法在光学图像数据集中可以取得较好的效果,但 SAR 图像的成像机理与光学图像不同,而

且预训练模型中的许多参数并不十分适用于 SAR 图像的训练,因此如何合理地训练并提高收敛的速度及准确性在 SAR 单通道目标检测中值得研究。

2) 舰船目标的所处背景复杂多变,对背景的单一化融合处理并不能很好地提升检测器的性能。由于舰船本身呈多角度且多形态分布,而且现有算法大多集中处理多尺度的问题,但如何在复杂背景下提取舰船的多变形态特征是目前的研究难点之一。

3) 现有检测算法中常采用锚框机制对特征图上的所有点进行均匀采样,但在目标稀疏的 SAR 图像中会引入大量无舰船目标的背景区域,导致正负样本不均衡,从而占据计算资源和计算时间,因此需重新考虑边框的生成和设计方法以更适合舰船目标的特性。

SAR 舰船目标检测中各算法的对比如表 3 所示。

表 3 SAR 舰船目标检测中各算法的对比

Table 3 Comparison of algorithms in SAR ship target detection

Category	Method	Advantage	Shortcoming
	Characteristic pyramid	The problem of multi-scale detection is improved	The lower sampling rate is large, which makes the edge of the object difficult to predict, increases the difficulty of returning to the boundary, and multiple up-sampling operations increase the difficulty of detection
Target feature extraction	Super dense connection	The problem of gradient disappearance has been solved to some extent; a large number of features are reused and the number of channels of the feature graph is small	Multiple data replication is required, and certain video memory optimization techniques are needed
	CBAM	Improve the accuracy of detection	The speed has an impact
	Context fusion	Integrate background information, model the relationship between objects, and improve the understanding of the scene	Introduce non-target information
Target border design	Direction design	Fit the multi-angle characteristics of warship	Additional parameters need to be redesigned
	Scale design	The anchor frame is more in line with the characteristics of the dataset itself	The more the number of anchor involved in the clustering process, the higher the accuracy, but at the same time, it will increase the amount of computation

针对表 3 存在的问题并结合深度学习算法的发展, SAR 舰船目标检测技术的进一步发展趋势有如下几个方面。

1) 从头训练

现有深度学习算法在训练过程中使用预训练模型并根据数据特性对参数进行微调, 但 He 等^[54]提出的微调方式并不能有效防止过拟合, 其预训练和微调的时间与随机初始化训练的时间大致相同。在 SAR 图像舰船目标检测精度高和位置敏感的检测任务中, 微调的训练方式会影响检测器的性能。采用随机初始化的方法对 SAR 图像特有的数据集进行从头训练, 能够有效提高目标检测的精度。

2) 与其他领域技术融合

相比于 SAR 图像舰船检测领域, 深度学习算法在人脸识别和自动驾驶等领域的研究范围更广泛, 而且相关技术在 SAR 图像舰船检测领域中也有很好的发展前景。针对舰船形状来优化卷积方式, 从而可以提取更纯净的特征。

3) 摆脱锚框技术的应用

基于锚框机制的目标检测算法生成锚框会占用大量的内存空间和计算资源, 根据图像特征来自动预测位置和形状并生成稀疏高效的预测框, 但无锚框的目标检测技术在 SAR 图像舰船识别领域更为适用, 因此摆脱锚框可成为 SAR 图像检测的进一步研究方向。

7 结束语

基于深度学习算法的 SAR 舰船目标检测技术是 SAR 图像领域中的重要研究方向之一, 该技术不仅能够提高对大数据信息的处理和获取速度, 并且可以摆脱对人工的依赖, 从而提升主动学习算法的准确性。随着深度学习技术的不断发展, 基于深度学习算法的 SAR 舰船目标检测技术可以展现出巨大的应用潜力和市场前景, 这将成为 SAR 图像处理过程中不可或缺的技术之一。

参 考 文 献

- [1] Tang X, Shen J, Lu X Y. ACSI-SAR algorithm for clutter mitigation based on median canceller [J]. *Command Information System and Technology*, 2013, 4(4): 60-64, 79.
唐雄, 沈健, 卢晓勇. 基于中值对消的 ACSI-SAR 杂波抑制算法[J]. *指挥信息系统与技术*, 2013, 4(4): 60-64, 79.
- [2] Cozzolino D, di Martino G, Poggi G, et al. A fully

convolutional neural network for low-complexity single-stage ship detection in Sentinel-1 SAR images [C] // 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 23-28, 2017, Fort Worth, TX, USA. New York: IEEE, 2017: 886-889.

- [3] Kang M, Leng X, Lin Z, et al. A modified Faster R-CNN based on CFAR algorithm for sar ship detection [C] // 2017 International Workshop on Remote Sensing with Intelligent Processing, May 18-21, 2017, Shanghai, China. New York: IEEE, 2017: 16981074.
- [4] Wang Y Y, Wang C, Zhang H. Combining single shot multibox detector with transfer learning for ship detection using Sentinel-1 images [C] // 2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA), November 13-14, 2017, Beijing, China. New York: IEEE, 2017: 17413066.
- [5] Tings B, Bentes C, Velotto D, et al. Modelling ship detectability depending on TerraSAR-X-derived Metocean parameters [J]. *CEAS Space Journal*, 2019, 11(1): 81-94.
- [6] Mazzarella F, Vespe M, Santamaria C. SAR ship detection and self-reporting data fusion based on traffic knowledge [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(8): 1685-1689.
- [7] Lang H T, Wu S W, Xu Y J. Ship classification in SAR images improved by AIS knowledge transfer [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 25(3): 439-443.
- [8] Gao G, Gao S, He J, et al. Ship detection using compact polarimetric SAR based on the notch filter [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5380-5393.
- [9] 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.
- [10] Smith M E, Varshney P K. Vi-CFAR: a novel CFAR algorithm based on data variability [C] // Proceedings of the 1997 IEEE National Radar Conference, May 13-15, 2017, Syracuse, NY, USA. New York: IEEE, 2017: 5716383.
- [11] Gao G, Liu L, Zhao L, 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] Farrouki A, Barkat M. Automatic censoring CFAR detector based on ordered data variability for nonhomogeneous environments[J]. IEE Proceedings-Radar, Sonar and Navigation, 2005, 152(1): 43-51.
- [13] El-Darymli K, Gill E W, McGuire P, et al. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review [J]. IEEE Access, 2016, 4: 6014-6058.
- [14] Huang X, Yang W, Zhang H, et al. Automatic ship detection in sar images using multi-scale heterogeneities and an a contrario decision [J]. Remote Sensing, 2015, 7(6): 7695-7711.
- [15] Souyris J C, Henry C, Adragna F. On the use of complex SAR image spectral analysis for target detection: assessment of polarimetry [J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(12): 2725-2734.
- [16] Ouchi K, Tamaki S, Yaguchi H, et al. Ship detection based on coherence images derived from cross correlation of multilook SAR images[J]. IEEE Geoscience and Remote Sensing Letters, 2004, 1(3): 184-187.
- [17] Kaplan L M. Improved SAR target detection via extended fractal features[J]. IEEE Transactions on Aerospace and Electronic Systems, 2001, 37(2): 436-451.
- [18] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [C] // Proceedings of the 25th International Conference on Neural Information Processing Systems, December 3-8, 2012, Lake Tahoe, NV, USA. New York: Curran Associates Inc, 2012: 1097-1105.
- [19] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Cambridge: MIT Press, 2016: 16.
- [20] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [21] He J L, Wang Y H, Liu H W, et al. A novel automatic PolSAR ship detection method based on superpixel-level local information measurement [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(3): 384-388.
- [22] Bengio Y, Courville A, Vincent P. Representation learning: a review and new perspectives [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1798-1828.
- [23] Ren S 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, 2017, 39(6): 1137-1149.
- [24] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [EB/OL]. (2016-12-29) [2020-07-07]. <https://arxiv.org/abs/1512.02325>.
- [25] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2020-07-07]. <https://arxiv.org/abs/1804.02767>.
- [26] Sun C, Shrivastava A, Singh S, et al. Revisiting unreasonable effectiveness of data in deep learning era [C] // 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 843-852.
- [27] Huang L Q, Liu B, Li B Y, et al. Open SARShip: 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.
- [28] 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. New York: IEEE, 2017: 17413068.
- [29] 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.
- [30] 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.
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.
- [31] Du L, Liu B, Wang Y, et al. Target detection method based on convolutional neural network for SAR image [J]. Journal of Electronics & Information Technology, 2016, 38(12): 3018-3025.
杜兰, 刘彬, 王燕, 等. 基于卷积神经网络的 SAR 图像目标检测算法 [J]. 电子与信息学报, 2016, 38(12): 3018-3025.
- [32] Hua Q L, Huang B, Chen X F, et al. Ship target recognition algorithms based on complex domain CNN [J]. Command Information System and Technology, 2019, 10(6): 71-75.
化青龙, 黄斌, 陈雪峰, 等. 基于复数域 CNN 的舰船目标识别算法 [J]. 指挥信息系统与技术, 2019,

- 10(6): 71-75.
- [33] Goodfellow I, Pouget-abadie J, Mirza M, et al. Generative adversarial nets[C]// Proceedings of the 27th International Conference on Neural Information Processing Systems, December 8-13, 2014, Montreal, Quebec, Canada. New York: Curran Associates Inc, 2014: 2672-2680.
- [34] Yang L, Su J, Li X. Application of SAR ship data augmentation based on generative adversarial network in improved SSD[J]. Acta Armamentarii, 2019, 40(12): 2488-2496.
杨龙, 苏娟, 李响. 基于生成式对抗网络的合成孔径雷达舰船数据增广在改进单次多盒检测器中的应用[J]. 兵工学报, 2019, 40(12): 2488-2496.
- [35] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks[EB/OL]. (2018-11-26) [2020-07-07]. <https://arxiv.org/abs/1611.07004>.
- [36] Li J W, Qu C W, Peng S J, et al. Ship detection in SAR images based on generative adversarial network and online hard examples mining [J]. Journal of Electronics & Information Technology, 2019, 41(1): 143-149.
李健伟, 曲长文, 彭书娟, 等. 基于生成对抗网络和线上难例挖掘的 SAR 图像舰船目标检测[J]. 电子与信息学报, 2019, 41(1): 143-149.
- [37] Wang X L, Shrivastava A, Gupta A. A-Fast-RCNN: hard positive generation via adversary for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 3039-3048.
- [38] Li S Y, Fu G Y, Cui Z M, et al. Data augmentation in sar images based on multi-scale generative adversarial networks [J]. Laser & Optoelectronics Progress, 2020, 57(20): 201018.
李诗怡, 付光远, 崔忠马, 等. 基于多尺度生成对抗网络的 SAR 图像样本增广[J]. 激光与光电子学进展, 2020, 57(20): 201018.
- [39] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 936-944.
- [40] Yang L, Su J, Huang H, et al. SAR ship detection based on convolutional neural network with deep multiscale feature fusion [J]. Acta Optica Sinica, 2020, 40(2): 0215002.
杨龙, 苏娟, 黄华, 等. 一种基于深层次多尺度特征融合 CNN 的 SAR 图像舰船目标检测算法[J]. 光学学报, 2020, 40(2): 0215002.
- [41] Dai W X, Mao Y Q, Yuan R, et al. A novel detector based on convolution neural networks for multiscale SAR ship detection in complex background [J]. Sensors, 2020, 20(9): 2547.
- [42] Miao K, Ke F J, Xiang G L, et al. Contextual region-based convolutional neural network with multilayer fusion for SAR ship detection[J]. Remote Sensing, 2017, 9(8): 860.
- [43] Chen S Q, Zhan R H, Zhang J. Regional attention-based single shot detector for SAR ship detection[J]. Journal of Engineering, 2019, 2019(21): 7381-7384.
- [44] He P, Huang W, He T, et al. Single shot text detector with regional attention[C]//Single shot text detector with regional attention, October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 17453216.
- [45] Gao F, Shi W, Wang J, et al. Enhanced feature extraction for ship detection from multi-resolution and multi-scene synthetic aperture radar (SAR) images[J]. Remote Sensing, 2019, 11(22): 2694.
- [46] Bell S, Zitnick C L, Bala K, et al. Inside-outside net: detecting objects in context with skip pooling and recurrent neural networks[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 2874-2883.
- [47] Ding J, Xue N, Long Y, et al. Learning RoI transformer for detecting oriented objects in aerial images[EB/OL]. (2018-12-01)[2020-07-07]. <https://arxiv.org/abs/1812.00155v1>.
- [48] Pan Z R, Yang R, Zhang A Z. MSR2N: multi-stage rotational region based network for arbitrary-oriented ship detection in SAR images[J]. Sensors, 2020, 20(8): 2340.
- [49] Cai Z, Vasconcelos N. Cascade R-CNN: delving into high quality object detection [C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 6154-6162.
- [50] Zhang X H, Yao L, Lü Y F, et al. Center based model for arbitrary-oriented ship detection in remote sensing images[J]. Acta Photonica Sinica, 2020, 49(4): 0410005.
张筱晗, 姚力波, 吕亚飞, 等. 基于中心点的遥感图像多方向舰船目标检测[J]. 光子学报, 2020, 49

(4): 0410005.

- [51] Zhou X Y, Wang D Q, Krähenbühl P. Objects as points [EB/OL]. [2020-07-07]. https://www.researchgate.net/publication/332463177_Objects_as_Points.
- [52] Hu C H, Chen C, He C, et al. SAR detection for small target ship based on deep convolutional neural network[J]. Journal of Chinese Inertial Technology, 2019, 27(3): 397-405, 414.
胡昌华, 陈辰, 何川, 等. 基于深度卷积神经网络的 SAR 图像舰船小目标检测[J]. 中国惯性技术学报, 2019, 27(3): 397-405, 414.
- [53] Chen P, Li Y, Zhou H, et al. Detection of small ship objects using anchor boxes cluster and feature pyramid network model for SAR imagery[J]. Journal of Marine Science and Engineering, 2020, 8(2): 112.
- [54] He K M, Girshick R B, Dollár P. Rethinking ImageNet pre-training [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea. New York: IEEE, 2018: 4917-4926.