

基于改进 R-FCN 的遥感图像舰船检测

王健林¹, 吕晓琪^{1,2*}, 张明¹, 李菁¹

¹内蒙古科技大学信息工程学院内蒙古自治区模式识别与智能图像处理重点实验室, 内蒙古 包头 014010;

²内蒙古工业大学信息工程学院, 内蒙古 呼和浩特 010051

摘要 针对传统舰船检测算法难以适应复杂多变的海洋杂波环境, 无法实现智能舰船检测的问题, 提出了一种改进的基于区域全卷积网络(R-FCN)的检测方法。针对合成孔径雷达(SAR)图像的特点, 对 R-FCN 中的特征提取网络 ResNet 进行混合尺度卷积核处理, 使特征提取网络能够抑制相干斑噪声的影响, 有效提取舰船特征。选取高分辨率 GF-3 与低分辨 Sentinel-1 卫星 SAR 图像进行测试, 均取得了良好的检测效果, 证明了本文算法的有效性。

关键词 遥感; 舰船检测; 区域全卷积网络; ResNet; 合成孔径雷达图像

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP56.162803

Remote Sensing Image Ship Detection Based on Improved R-FCN

Wang Jianlin¹, Lü Xiaoqi^{1,2*}, Zhang Ming¹, Li Jing¹

¹Inner Mongolia Key Laboratory of Pattern Recognition and Intelligent Image Processing, School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou, Inner Mongolia 014010, China;

²School of Information Engineering, Inner Mongolia University of Technology, Hohhot, Inner Mongolia 010051, China

Abstract The traditional ship detection algorithm is difficult to adapt in the complex and varied sea clutter environment, and intelligent ship detection is impossible to realize. This study proposes an improved region-based fully convolutional network (R-FCN) detection method. Aiming at the characteristics of synthetic aperture radar (SAR), the feature extraction network ResNet in R-FCN uses a mixed-scale convolution kernel. The feature extraction network can suppress the influence of the speckle noise and effectively extract the ship features. High-resolution GF-3 and low-resolution Sentinel-1 satellite SAR images are selected for the test. Consequently, good results are obtained, proving the effectiveness of the proposed algorithm.

Key words remote sensing; ship detection; region-based fully convolutional network; ResNet; synthetic aperture radar images

OCIS codes 280.5600; 280.6730; 280.4750

1 引言

近年来, 合成孔径雷达(SAR)发展迅速, 因其具有全天时、全天候、不受光照和云雾的影响的独特优势, 被广泛应用于军事和民用的各个领域中^[1]。利用 SAR 图像实现对海上舰船的快速检测, 是目前的研究热点。在传统舰船检测算法中, 恒虚警(CFAR)检测算法应用最广泛, 其核心是拟合背景杂波分布。文献[1-4]皆是研究 CFAR 的改进算

法。CFAR 在背景杂波分布均匀的情况下, 检测性能较好, 但在复杂场景下, 检测性能相对较差。

卷积神经网络^[5-8](CNN)通过对图像进行一系列的卷积计算, 能够有效提取目标特征, 实现对目标的平移不变分类, 被广泛应用于图像分类中。2014年, Girshick 等^[9]将 CNN 应用于目标检测, 提出了 R-CNN。随后在 R-CNN 的基础提出了 Fast R-CNN^[10]、Faster R-CNN^[11]和基于区域的全卷积网络(R-FCN)^[12]等目标检测框架, 在光学图像中取得

收稿日期: 2019-01-24; 修回日期: 2019-03-01; 录用日期: 2019-03-22

基金项目: 国家重点研发计划(2018YFC1407203, 2016YFA0600102)、国家自然科学基金(61771266)、内蒙古自治区高等学校科学研究项目(NJZY18150)

* E-mail: wangjl2019@126.com

了良好的检测效果。与此同时,CNN 检测算法开始被应用到 SAR 图像中。杜兰等^[13]在样本不足的情况下,充分利用数据集的多种特征信息,提高了 Faster-RCNN 在 SAR 图像中的目标检测效果。Kang 等^[14]将 Faster R-CNN 与 CFAR 相结合,利用 CFAR 检测 Faster R-CNN 检测结果中分数较低的候选框,提高了舰船检测的准确率。李健伟等^[15]构建多样舰船目标数据集 SSDD,对 Faster R-CNN 的特征提取、损失函数和其他应用细节进行了改进。

本文将 R-FCN 目标检测引入 SAR 图像舰船检测,与 Faster R-CNN 相比,R-FCN 以 ResNet 作为特征提取网络,取消全连接层,在检测器中共享 CNN,检测速度更快,检测效果更好。针对 SAR 图像中相干斑噪声强、舰船目标弱的特点,对 R-FCN 中特征提取网络 ResNet 进行改进,显著地提高了舰船的检测效果。

2 基本原理

2.1 R-FCN

R-FCN 由全卷积网络 (FCN)^[16]、区域生成网

络 (RPN)^[11] 和感兴趣区域 (RoI) 子网组成。FCN 用于提取特征,RPN 根据这些特征生成 RoI,RoI 子网根据 FCN 提取特征与 RPN 输出的 RoI 进行目标区域的定位与分类^[17]。R-FCN 的网络结构如图 1 所示。其流程如下。

- 1) 对待检测图片进行全卷积,生成特征图;
- 2) 利用 RPN 提取 RoIs,并共享到整个 R-FCN 中;
- 3) 对各 RoI 针对各类别建立 k^2 个位置敏感得分图,对相对空间位置信息进行编码;
- 4) 利用 position-sensitive RoI pool 操作,为各类别计算 k^2 个得分图;
- 5) 对 k^2 个得分图进行投票,生成 $(C+1)$ 维向量,其中 C 为目标类别,文中 $C=1$,利用 softmax 计算各类别的概率。

在计算 k^2 个得分图时,假设每个 RoI 大小为 $w \times h$,则每个小区域 (bin) 大小为 $\frac{w}{k} \cdot \frac{h}{k}$ 。在实验中, $k=3$ 时 RoI 示意图如图 2 所示。

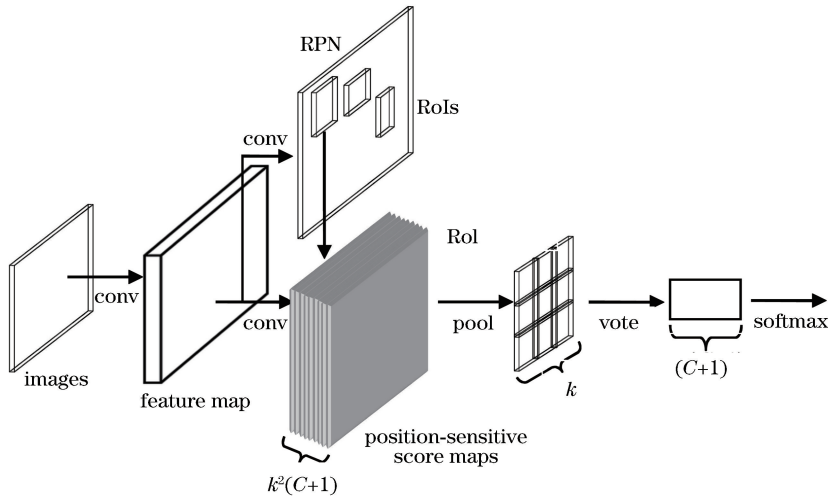


图 1 R-FCN 网络结构图

Fig. 1 Diagram of R-FCN network structure




图 2 RoI 示意图

Fig. 2 Diagram of RoI

利用下式可计算每个 bin 的得分,即

$$r_c(i, j | \Theta) = \frac{1}{n} \sum_{(x,y) \in b_{\text{bin}}(i,j)} z_{i,j,c}(x+x_0, y+y_0 | \Theta), \quad (1)$$

式中: c 为某目标类别,文中仅表示舰船类; $z_{i,j,c}$ 为 $k^2(C+1)$ 个得分图中的其中一个; Θ 为网络参数; x_0 和 y_0 为 RoI 左上角的坐标; $b_{\text{bin}}(x, y)$ 为 RoI 第 (i, j) 个空间位置 ($0 \leq i, j \leq k-1$); (x, y) 为该空间位置点的坐标; n 为该空间位置内的点数^[17]。

为确保 RoI 标注准确,在 FCN 后串联另外一个维度为 $4k^2$ 的得分图,与位置敏感得分图并行,用于修正候选框,设置位置参数为 $\{x, y, w, h\}$,其中 (x, y) 记录候选框左上角坐标, (w, h) 记录候选框区域的长与宽。

2.2 残差网络

对于卷积神经网络,网络深度的设计尤为重要,网络准确度随着网络深度的增加而增加,但会出现梯度衰减和权重减小等问题。当网络准确度达到一定程度时,增加网络深度,网络准确度反而迅速降低。针对该问题,2015 年 He^[16] 等提出了 ResNet,更好地解决了网络深度增加时出现的上述问题。图 3 为残差结构图。




图 3 残差结构图

Fig. 3 Residual structure

假设潜在映射为 $H(x)$,结构中的非线性层拟合残差 $F(x) = H(x) - x$,relu 为激活函数。与直接拟合 $H(x)$ 相比,残差在训练过程中,忽略共性特征,着重学习差异性,所以更容易找到残差的最优结果。更重要的是,在提高网络性能的同时训练网络所需的时间会减少。

3 本文算法

3.1 特征提取网络改进

R-FCN 设计的初衷是对光学图像进行目标检测,光学图像灰度变化平滑且目标明显,原 R-FCN 特征提取网络能有效提取图像中的目标特征。SAR 的成像机制不同于光学图像,在 SAR 图像中存在大量相干斑噪声,且舰船目标较小,这将导致原特征提取网络无法对舰船进行有效的特征提取。在设计特征提取网络时,必须充分考虑 SAR 图像与光学图像的差异性。

卷积神经网络输出的特征图的信息量与卷积过程中卷积核的大小和卷积步长有关,卷积核越大,特

征图信息量越大。并且增大卷积核能有效抑制相干斑噪声的影响。

R-FCN 采用的特征提取网络为 ResNet-50,是由图 3 中的残差块构成的 50 层网络,共包含 16 个残差块(2a, 2b, 2c, 3a, 3b, 3c, 3d, 4a, 4b, 4c, 4d, 4e, 4f, 5a, 5b, 5c),每个残差块包含一个卷积核大小为 3×3 的卷积层。本文在 ResNet-50 基础上,将部分卷积层的卷积核大小设定为 5×5 。如图 4 所示。




图 4 改进残差块结构

Fig. 4 Improved residual block structure

增大卷积核会增加训练参数,并且实验发现,修改卷积层数目会影响特征提取效果。本文将 4 个残差块(2b, 3c, 4c, 5a)的卷积核由 3×3 修改为 5×5 ,具有良好的检测效果,修改后的残差结构如图 4 所示。

3.2 图像分块

由于舰船检测是对星载 SAR 图像的海域部分进行检测,海域辽阔,反映在 SAR 图像中,图像非常大,即便是选取感兴趣区域,图像也相对较大。如果直接检测如此大的图像,不仅检测效率不高,还会出现大量漏检的情况。

针对这种情况,在 R-FCN 前加入图像分割流程,将待检测的 SAR 图像分割成小块图像,再将小块图像送入 R-FCN 中,检测后,将输出的小块图像合并成原图像。为了避免在分割过程中出现将目标船只分割的情况,本文采取如下步骤进行分割:

- 1) 设置分割后的图像大小;
- 2) 程序计算出图像的预分割线;
- 3) 检测分割线中是否包含相邻的高亮像素;
- 4) 如果包含相邻的高亮像素,分割线下移/右移;
- 5) 无高亮像素相邻,则进行图像分割。

分割示意图如图 5 所示。为了确定待检测图像尺寸,本文对一幅 $1500 \text{ pixel} \times 1500 \text{ pixel}$ 的图像进行

实验,将该图像分割成不同尺寸的小图像,并进行检测,统计最终检测结果如表 1 所示,Image Size 为待检

测图像尺寸; $N_{\text{detection}}$ 为最终舰船检测数目; N_{miss} 为漏检总目; A_{time} 为每幅小图像的平均检测时间。




图 5 分割示意图

Fig. 5 Splitting diagrams

表 1 不同尺寸图像的舰船检测结果统计表

Table 1 Statistic table of ship detection results of images with different sizes

Parameter	Value						
Image size /(pixel×pixel)	156×156	256×256	500×500	800×800	1000×1000	1200×1200	1500×1500
$N_{\text{detection}}$	29	29	29	29	28	26	25
N_{miss}	0	0	0	0	1	3	4
A_{time}/s	0.09	0.09	0.11	0.11	0.13	0.14	0.16

从表 1 可以看出,不同尺寸的图像检测时间相差不大,但原图像分割后的图像尺寸越小,待检测的图像数目越多,原图像检测总耗时成倍增长。当检测图片尺寸约为 1000 pixel×1000 pixel 时,检测效果好,且检测总耗时较少。

4 实验与结果分析

4.1 实验

实验所采用的数据集包括样本集、验证集和测试集。样本集包括正样本和负样本,正样本是各种形态的舰船。利用公开的 Sentinel-1 卫星数据,获取 20 景世界各主要港口、航道的卫星数据,从中截取舰船样本 2126 个,从 opensar 官网上多位专家上传的 Sentinel-1 舰船样本中选取 5000 只舰船样本,二者共同组成数据集。样本图像统一尺寸为 156 pixel×156 pixel,并对图像中的目标用矩形框进行标注。

实验过程中,先利用 ImageNet 初始化网络参数,再利用制作好的样本集进行训练。训练时设置初始学习率为 0.005,权重衰减率为 0.0005,动量设置为 0.9,迭代次数为 20000。由于舰船目标小,将 R-FCN 中目标候选框规模修改为[2, 4, 8, 16, 32],以更合适舰船目标尺寸。设置候选框阈值为 0.8,将评分大于 0.8 的候选框保留,作为输出结果。

待检测图片从未制作成数据集的图像中选取,由于舰船密集区域检测难度更大,实验着重测试舰船集中的图像。共选取图像 16 幅,包括 10 幅

Sentinel-1 图像和 6 幅 GF-3 图像,图像尺寸为 1000 pixel×1000 pixel。

实验一,用本文算法、原 R-FCN 算法和文献[15]中的 Faster R-CNN 算法对 Sentinel-1 图像进行检测,部分检测结果如图 6 所示。

根据表 1 可知,缩小待检测图像尺寸能减少漏检数目。实验二,针对图 6(c)右侧强噪声图像出现较多漏检情况,为了减少图像总耗时,实验截取图像大小为 500 pixel×500 pixel。为了测试算法,实验二仅对漏检船只较多的区域进行检测,检测结果如图 7 所示。

实验三,由于算法训练样本仅采用了 Sentinel-1 卫星图像,为检测算法对其他卫星图像的检测效果,实验对 GF-3 卫星图像进行检测,部分检测结果如图 8 所示,图 8(a)为待检测图像,图 8(b)为改进 R-FCN 检测结果。

4.2 结果分析

上述实验检测结果如表 2 所示,其中 N_{target} 为真实目标数; $N_{\text{detection}}$ 为算法检测到的目标数; N_{false} 为检测虚警数; N_{miss} 为漏检数; P_{Precise} 为算法检测精度; R_{Recall} 为算法检测召回率。

从表 2 可以看出,原 R-FCN 对舰船检测结果较差,存在大量漏检情况,召回率仅为 20.16%,同时,存在较多的虚警情况,精确率为 78.12%;改进的 R-FCN 更适用于 SAR 图像舰船检测,检测效果大为提升,舰船漏检总数从 99 降为 9,召回率提高到 92.74%,检测虚警从 7 降为 3,精确率提高到 97.46%。此外,从表 2




图 6 Sentinel-1 图像舰船检测结果图。(a)待检测图片一;(b)待检测图片二;(c)待检测图片三;(d)原 R-FCN 对图 6(a)检测结果;(e)原 R-FCN 对图 6(b)检测结果;(f)原 R-FCN 对图 6(c)检测结果;(g)改进 Faster R-CNN 对图 6(a)检测结果;(h)改进 Faster R-CNN 对图 6(b)检测结果;(i)改进 Faster R-CNN 对图 6(c)检测结果;(j)改进 R-FCN 对图 6(a)检测结果;(k)改进 R-FCN 对图 6(b)检测结果;(l)改进 R-FCN 对图 6(c)检测结果

Fig. 6 Ship detection results of Sentinel-1 images. (a) Picture 1 to be tested; (b) picture 2 to be tested; (c) picture 3 to be tested; (d) original R-FCN detection result of Fig. 6(a); (e) original R-FCN detection result of Fig. 6(b); (f) original R-FCN detection results of Fig. 6(c); (g) detection result of improved Faster R-FCN for Fig. 6(a); (h) detection result of improved Faster R-FCN for Fig. 6(b); (i) detection result of improved Faster R-FCN for Fig. 6(c); (j) detection result of improved R-FCN for Fig. 6(a); (k) detection result of improved R-FCN for Fig. 6(b); (l) detection result of improved R-FCN for Fig. 6(c)

可以看出,本文算法的准确率和召回率均高于文献[15]中的 Faster R-CNN 算法。

从图 7 可以看出,在强噪声环境下,将图像尺寸缩小为 $500 \text{ pixel} \times 500 \text{ pixel}$,漏检数目降为 1,但原图像可分为 4 个 $500 \text{ pixel} \times 500 \text{ pixel}$ 的图像,相

对于整幅图像,所耗时间成倍增长。从图 8 和表 2 可以看出,尽管在训练中没有 GF-3 图像样本,但本文算法对 GF-3 卫星图像仍有 97.37% 精确率和 90.24% 的召回率,证明本文算法具有一定的普适性。




图 7 检测结果
Fig. 7 Test results




图 8 GF-3 图像舰船检测结果图。(a)待检测图片一;(b)待检测图片二;(c)待检测图片三;(d)改进 R-FCN 对图 8(a) 检测结果;(e)改进 R-FCN 对图 8(b)检测结果;(f)改进 R-FCN 对图 8(c)检测结果

Fig. 8 Ship detection results of GF-3 image. (a) Picture 1 to be tested; (b) picture 2 to be tested; (c) picture 3 to be tested; (d) detection result of improved R-FCN for Fig. 8(a); (e) detection result of improved R-FCN for Fig. 8(b); (f) detection result of improved R-FCN for Fig. 8(c)

表 2 舰船检测结果统计表

Table 2 Statistical table of ship detection results

Method	Image	N_{target}	$N_{detection}$	N_{false}	N_{miss}	$P_{Precise} / \%$	$R_{Recall} / \%$
R-FCN	Sentinel-1	124	32	7	99	78.12	20.16
	GF-3	82	27	9	64	66.67	21.95
Faster-RCNN	Sentinel-1	124	106	4	12	96.23	82.25
	GF-3	82	76	4	10	94.74	87.80
Improved R-FCN	Sentinel-1	124	118	3	9	97.46	92.74
	GF-3	82	76	2	8	97.37	90.24

5 结 论

针对 SAR 图像舰船检测问题,提出了一种改进的 R-FCN 检测算法。该方法在原 R-FCN 的基础上,对特征提取网络 ResNet 进行混合尺度卷积核处理,并在算法细节上进行改进。实验结果表明,改

进后的 R-FCN 大幅提升了舰船的检测效果。本文算法基于深度学习技术,通过学习舰船特征检测舰船,避免了传统算法中的预处理、背景杂波拟合等复杂过程,具有稳健性和普适性强等特点。故用深度学习技术对 SAR 图像舰船进行检测具有广阔的应用前景。

参 考 文 献

- [1] Xing X W, Chen Z L, Zou H X, *et al.* A fast algorithm based on two-stage CFAR for detecting ships in SAR images [C] // 2009 2nd Asian-Pacific Conference on Synthetic Aperture Radar, October 26-30, 2009, Xi'an, Shaanxi, China. New York: IEEE, 2010: 56-59.
- [2] Leng X G, Ji K F, Yang K, *et al.* A bilateral CFAR algorithm for ship detection in SAR images[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12 (7): 1536-1540.
- [3] Qin X X, Zhou S L, Zou H X, *et al.* A CFAR detection algorithm for generalized gamma distributed background in high-resolution SAR images[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10 (4): 806-810.
- [4] Ji Y G, Zhang J, Meng J M, *et al.* A new CFAR ship target detection method in SAR imagery [J]. Acta Oceanologica Sinica, 2010, 29(1): 12-16.
- [5] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [6] Szegedy C, Liu W, Jia Y Q, *et al.* Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 15523970.
- [7] Zhang X Y, Zou J H, Ming X, *et al.* Efficient and accurate approximations of nonlinear convolutional networks[C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 1984-1992.
- [8] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [9] Girshick R, Donahue J, Darrell T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 580-587.
- [10] Girshick R. Fast R-CNN [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2016: 1440-1448.
- [11] 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.
- [12] Dai J F, Li Y, He K M, *et al.* R-FCN: object detection via region-based fully convolutional networks[C] // Proceedings of the 30th International Conference on Neural Information Processing Systems, December 5-10, 2016, Barcelona, Spain. USA: Curran Associates Inc., 2016: 379-387.
- [13] 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.
- [14] Kang M, Leng X G, 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 (RSIP), May 18-21, 2017, Shanghai, China. New York: IEEE, 2017: 16981074.
- [15] Li J W, Qu C W, Peng S J, *et al.* Ship detection in SAR images based on convolutional neural network [J]. Systems Engineering and Electronics, 2018, 40 (9): 1953-1959.
李健伟, 曲长文, 彭书娟, 等. 基于卷积神经网络的 SAR 图像舰船目标检测 [J]. 系统工程与电子技术, 2018, 40(9): 1953-1959.
- [16] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2015: 16541111.
- [17] Sang N, Ni Z H. Gesture recognition based on R-FCN in complex scenes [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2017, 45(10): 54-58.
桑农, 倪子涵. 复杂场景下基于 R-FCN 的手势识别 [J]. 华中科技大学学报(自然科学版), 2017, 45 (10): 54-58.