

基于深度特征金字塔和级联检测器的 SAR 图像舰船检测

赵云飞, 张宝华*, 张艳月, 谷宇, 王月明, 李建军, 赵瑛

内蒙古科技大学信息工程学院, 内蒙古 包头 014010

摘要 针对 Faster R-CNN 算法检测舰船目标存在的不足, 提出基于深度特征金字塔和级联检测器的舰船检测算法。先利用小目标数据增强算法对数据进行扩充, 使检测模型学习足够的特征; 再使用深度特征金字塔网络改进原目标检测算法的特征提取网络, 抑制相干斑噪声, 有效提取舰船特征; 并根据合成孔径雷达(SAR)图像中舰船目标稀疏的特点使用级联结构调整网络。基于上述改进, 选取舰船目标检测数据集中部分图像及 2 月份渤海湾的 SAR 图像进行实验, 实验结果表明: 所提算法均取得了良好的检测效果, 证明了所提算法的有效性。

关键词 图像处理; 目标检测; 数据增强; 深度特征金字塔; 级联; 合成孔径雷达图像

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP57.121019

Ship Detection Based on SAR Images Using Deep Feature Pyramid and Cascade Detector

Zhao Yunfei, Zhang Baohua*, Zhang Yanyue, Gu Yu, Wang Yueming, Li Jianjun, Zhao Ying

School of Information Engineering, Inner Mongolia University of Science and Technology,
Baotou, Inner Mongolia 014010, China

Abstract Faster R-CNN algorithm cannot achieve accurate ship detection. Therefore, a ship detection algorithm based on a deep feature pyramid and cascade detector is proposed in this study. First, the small-target data enhancement algorithm is used for expanding the data to ensure that sufficient features are learned by the detection model. Then, the deep feature pyramid network is used for improving the feature extraction network of the original target detection algorithm, suppressing the coherent speckle noise, and effectively extracting the ship features. Further, a cascading structure is adopted to adjust the improved network according to the sparse features of the ship targets obtained from the synthetic aperture radar (SAR) images. Based on the aforementioned improvements, some images from the ship target detection dataset and the SAR images of the Bohai Bay captured in February are selected for performing the experiments. Experimental results show that, the proposed algorithm achieves good detection results, proving its effectiveness with respect to ship detection.

Key words image processing; object detection; data enhancement; deep feature pyramid; cascade; synthetic aperture radar images

OCIS codes 100.4996; 100.2000; 280.6730; 150.1135

1 引言

目前, 最为常见的船只目标检测识别方法主要

应用于可见光和合成孔径雷达(SAR)方面^[1], 利用 SAR 图像对海上舰船进行检测是 SAR 图像应用领域的一个研究热点。He 等^[2]将卷积神经网络

收稿日期: 2019-10-14; 修回日期: 2019-10-22; 录用日期: 2019-11-06

基金项目: 国家自然科学基金(61962046, 61663036, 61841204)、内蒙古杰青培育项目(2018JQ02)、内蒙古草原英才、内蒙古青年科技创新人才项目(第一层次)、内蒙古自治区自然科学基金(2015MS0604, 2018MS06018)、内蒙古自治区高等学校科学技术研究项目(NJZY145)、内蒙古自治区研究生科研创新资助项目(S20191187Z)

* E-mail: zbh_wj2004@imust.cn

(CNN)应用于目标检测,提出了 R-CNN(Region-CNN)^[3]。相关研究人员在此基础上提出了 Fast R-CNN^[4]和 Faster R-CNN^[5]等目标检测模型,均取得了良好的检测效果。杜兰等^[6]充分利用数据集的多种特征信息,在样本不足的情况下,对于 SAR 图像中的目标检测效果提升显著。Kang 等^[7]利用 CFAR(Constant False-Alarm Rate)对 Faster R-CNN 检测结果中分数较低的候选框进行检测,提高了舰船检测的准确率。

对李健伟等^[8]建立的 SAR 舰船目标检测数据集(SSDD)开展实验,分析并总结该数据集与目标检测算法存在的问题:1)数据集中尺寸不一和角度不同的舰船为检测和识别带来很大困难;2)标准的 Faster R-CNN 检测算法由于后几层的感受野较大,空间信息损失严重,无法有效提取特征,从而出现漏检小目标的现象^[9];3)SAR 图像中舰船目标较为稀疏,目标与背景的准确分类在一定程度上影响目标检测精度。

针对上述问题,本文利用小目标数据增强(SDA)算法对数据进行预处理,在此基础上,利用深度特征金字塔(DFP)网络替换原特征提取网络,提取图像目标区域的语义成分与形状-空间关系特征,保留目标区域的空间信息,同时保护其他特征不丢失,为小尺寸目标的类别判定和边框定位奠定良好基础。SAR 图像中舰船目标较为稀疏,级联结构(CS)具有更大优势,实验对原 Faster R-CNN 结构进行扩展并与多任务联合优化,使得目标检测的准确度得到较明显的提升。

2 算法原理

2.1 小目标数据增强

近年来,小目标检测领域的检测算法精度较差的原因之一是训练数据中缺少对小目标的再现。SAR 图像中目标尺寸普遍较小,实验中发现真实目标(Ground-Truth object)与预测锚点(anchor)的重叠区域远远小于期望的 IoU(Intersection-over-Union)值。无论从图像本身还是从像素的角度,训练的检测模型都无法学习到足够的小目标特征信息,原因在于:1)数据集中小目标的样本数量较少,检测模型无法学习到足够的特征信息;2)图像中小目标所在区域较小,且位置缺乏多样性。

针对第一个问题,对包含小目标的样本进行过采样促使模型更加关注小目标。实验中依次改变过采样率,分别为 2、3 和 4,通过改变过采样率解决只

有少部分样本包含小目标的问题,该方法最能直接缓解数据集样本不足并能够有效改善检测模型的性能。

针对第二个问题,对包含小目标的样本进行多次复制粘贴小目标来解决。粘贴前,将目标尺寸在 $\pm 20\%$ 范围内进行缩放,在 $\pm 15^\circ$ 范围内进行旋转,与图像边界保持至少 5 pixel 的距离且不与现有目标重叠。该方法增加了小目标位置的多样性,同时保证新的小目标出现在图像中合适区域。

先在训练过程中对包含小目标的图像进行过采样,再使用复制粘贴方法有效提高了小目标位置的多样性,检测模型的准确度得到了 1.39% 的提升,平衡了检测器在小目标与大目标中的表现。

2.2 Faster R-CNN 的基本原理

基于 CNN 的目标检测框架先从待检测图像中生成尽可能多的目标区域,即候选区域的提取,在训练好的 CNN 中提取候选区域特征,最后利用这些特征对候选区域进行分类和边框回归,即位置微调。Faster R-CNN 的基本思想:提出生成候选区域的区域推荐网络(RPN),将 RPN 和 Fast R-CNN 整合为一个可以端到端学习的网络,在不损失精度的前提下提升速度^[10]。

Faster R-CNN 检测框架如图 1 所示,可以看到 Faster R-CNN 被分为两个阶段,二者共用一个特征提取模块(feature extraction),Fast R-CNN 对候选区域进行分类和边框回归。其中 a 为利用锚点机制生成大量候选区域; b 为利用 Softmax 将候选区域分为目标和背景两类; c 为在全连接(FC)层映射得到候选区域位置,该步骤属于 RPN 阶段; d 为在最后一层卷积特征图上找到候选区域的映射,再将 RPN 结果传递给 Fast R-CNN; e 为在感兴趣区域(ROD)池化层将不同尺寸候选区域的特征图映射规范到同一大小; f 为利用 Softmax 计算 ROI 池化特征得到候选区域属于各类别的概率; g 为在 FC 层实现边框回归,对候选区域位置进行微调。

2.3 深度特征金字塔提取网络

Faster R-CNN 在 PASCAL VOC 数据集上的检测效果显著,却不适用于检测 SAR 图像中舰船目标,主要原因如下。

1) 舰船在图像中包含的像元数目较少,经采样后得到特征图的空间信息损失严重,难以预测小尺寸物体类别及边框^[11]。

2) 从光学图像数据集学习到的特征不适用于 SAR 图像,因此 Faster R-CNN 的大部分特征仍需

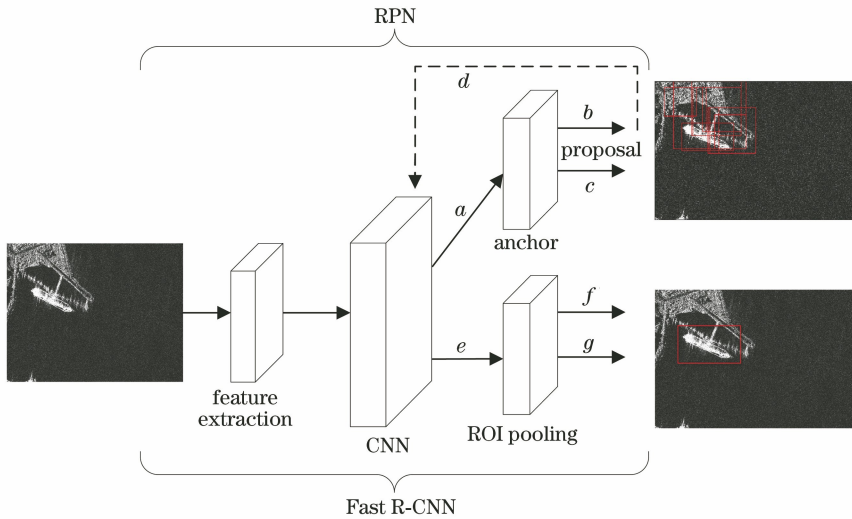


图 1 Faster R-CNN 检测框架

Fig. 1 Faster R-CNN detection framework

从 SSDD 数据集去学习,才会有更好的检测效果。

针对上述两个问题,将 Faster R-CNN 的特征提取网络替换成 DFP 网络,如图 2 所示。相比于光学图像,SAR 图像的彩色纹理特征无法体现目标的全部信息,Chen 等^[12]证实特征图能够表示对象特定的语义信息,但对于 SAR 图像,语义信息无法表

达空间结构信息。因此,使用两个 DFP 网络学习图像对的语义成分(Semantic Image Representation)和形状-空间关系特征(Shape-Spatial Relationship Image Representation)的相关性,并输出对应得分,最后利用两个 FC 层融合对应得分,并利用 Softmax 来计算最终决策。

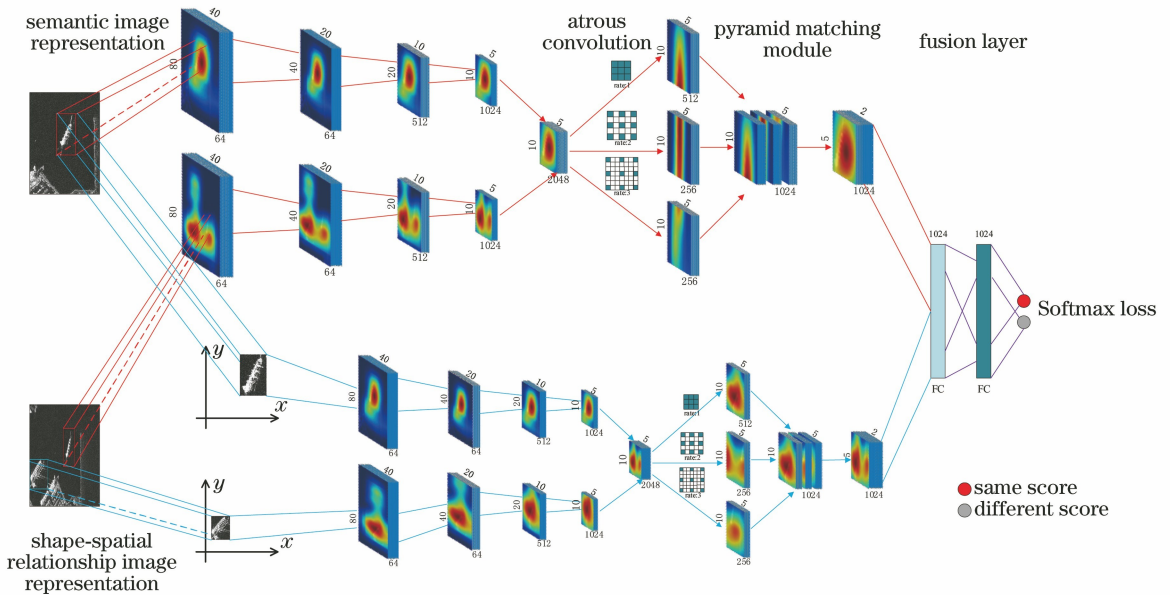


图 2 DFP 提取网络

Fig. 2 DFP extraction network

该网络结构使用两个参数共享的网络来提取目标图像的语义信息。卷积层的低层响应描绘了特定的组成成分,高层响应看似抽象,但仍保持目标与背景的对关系,这些成分对物体变化和背景变化具有很强的鲁棒性。卷积网络定义为 $f_{CNN}(\mathbf{X}; \boldsymbol{\theta})$,其

中 \mathbf{X} 为输入, $\boldsymbol{\theta}$ 为参数,语义成分的表达式为 $\{\mathbf{R}_{sc}^A, \mathbf{R}_{sc}^B\} = \{f_{CNN}(\mathbf{I}^A; \boldsymbol{\theta}_{sc}^1), f_{CNN}(\mathbf{I}^B; \boldsymbol{\theta}_{sc}^1)\}$, (1) 式中: \mathbf{R}_{sc}^A 和 \mathbf{R}_{sc}^B 分别为输入图像 \mathbf{I}^A 和 \mathbf{I}^B 的语义图像信息; $\boldsymbol{\theta}_{sc}^1$ 为语义成分共享参数。

SAR 图像中目标普遍较小且位置多变,颜色与

纹理特征不明显,提取目标的颜色、纹理特征显然不可行,所以使用另外一个金字塔匹配网络学习图像中目标的形状-空间关系特征,确定目标间的相对位置及形状大小。形状-空间关系特征表达式为

$$\{\mathbf{R}_{ssr}^A, \mathbf{R}_{ssr}^B\} = \{f_{CNN}(\mathbf{I}^A; \theta_{ssr}^1), f_{CNN}(\mathbf{I}^B; \theta_{ssr}^1)\}, \quad (2)$$

式中: \mathbf{R}_{ssr}^A 和 \mathbf{R}_{ssr}^B 分别为 \mathbf{I}^A 和 \mathbf{I}^B 的形状-空间关系特征信息; θ_{ssr}^1 为形状-空间关系特征的共享参数。

2.4 级联检测器

Faster R-CNN 用于目标检测所面临的问题: 选择前景、背景作为正、负样本时, IoU 的阈值不同会对结果产生较大影响, 阈值太小会造成正样本(前景)中存在很多负样本(背景), 阈值太大会造成正样本数量太少, 加剧正负样本数量的不均衡。级联检测器将几个级联的卷积层中前几层的输出作为后几层的输入, 界定正负样本的 IoU 阈值不断增加, 逐层优化预测结果。目的是高准确率和实时性地检测目标, VGG16 (Visual Geometry

Group 16)^[13] 因其拓展性强、泛化性好, 被广泛应用于在很多领域, 以 VGG16 为例介绍级联的设计原理。

图 3 为级联检测器的内部网络结构, 该网络主要由两级级联的全 CNN 组成^[14], 此时利用全局平均池化(GAP)层代替 FC 层, 因其能够强化特征图与类别的关系, 且没有参数需要优化, 使训练更快并减轻过拟合。第一阶段将特征候选区域输入到前三层进行训练, 由于网络较浅, 特征提取与表达能力较差, 因此在最大池化层后添加一个分类器, 设定得分阈值为 0.4 (阈值是多次实验得到的最优参数), 将得分超过 0.4 的特征图送到下一层卷积层中继续提取特征, 小于 0.4 直接丢弃。第二阶段将第一阶段得到的候选区域经过另外 5 层的 CNN 提取特征并进行分类, 过程与第一阶段类似。最后对剩余候选区域继续卷积, 提取更好的特征, 并进行非极大值抑制(NMS)以抑制冗余框, 再执行分类、回归和定位任务, 最终输出目标边框及类别。




图 3 级联检测器

Fig. 3 Cascade detector

3 实验结果与分析

实验环境: 利用 Pytorch 框架在 SSDD 数据集上训练检测器, 操作系统为 Ubuntu 16.04, 计算机处理器为 IntelR Xeon (R) CPU E5-1650v4 @ 3.60 GHz 和两块 NVIDIA GTX1080ti GPU (12 G 内存), 利用 CUDA9.0 和 CuDNN7.0 加速。

在数据集 SSDD 上进行 5 种方法的实验, 方法有 Faster R-CNN、经过 SDA 改进的 Faster R-CNN、基于 DFP 改进后的 Faster R-CNN、基于 CS 改进的 Faster

R-CNN 及结合上述方法改进后的检测模型。上述方法的检测结果如表 1 所示, 其中 N_{target} 表示真实目标数, $N_{detection}$ 表示算法检测到的目标数, N_{false} 表示检测虚警数, N_{miss} 表示漏检数, Precision 表示算法检测精度, Recall 表示算法检测召回率。

从表 1 可以看到, 对于标准的 Faster R-CNN, 在未经过任何改进的情况下, 检测结果较为可观, 算法的检测精度为 95.83%, 召回率为 82.31%, 但由于特征提取不充分, 存在不少漏检的舰船。经 SDA 后, 虽漏检的舰船和检测的虚警数未得到较大改善,

表1 舰船检测结果

Table 1 Ship detection results

Algorithm	N_{target}	$N_{\text{detection}}$	N_{false}	N_{miss}	Precision /%	Recall /%
Faster R-CNN	158	141	9	17	95.83	82.31
Faster R-CNN+SDA	158	145	7	13	97.22	82.78
Faster R-CNN+ DFP	158	146	5	12	96.74	83.83
Faster R-CNN+CS	158	149	5	9	97.21	84.13
Ours	158	154	2	4	98.52	84.59

但由于算法学习到更多特征,检测精度在一定程度上得到提升。利用 DFP 替换特征提取网络后,算法的检测精度相比于 Faster R-CNN 提高了 0.91 个百分点,提升效果并不显著,但召回率提升了 1.52 个百分点,反映目标被检测到的概率在增加,同时也说明这项改进对该算法模型有效。通过 CS 对检测网络改进后,与 DFP 替换特征提取网络类似,检测到的目标数、检测精度及召回率的提升并不明显,但有小幅度的增长就说明该方法行之有效。相比上述某一

项的改进,实验将上述方法进行整合,经 SDA 及对整个 Faster R-CNN 进行微调后,有效提升了检测到的目标数,漏检数由 17 降到 4,虚警数由 9 降到 2,整体检测精度提升了 2.69 个百分点,检测召回率提升了 2.28 个百分点,达到了 98.52% 和 84.59%,相比于传统算法,所提算法避免了预处理和背景杂波拟合等复杂过程,证明所提算法具有一定的普适性。

从数据集中选出不同尺寸的图像,及 2 月份渤海湾的 SAR 图像样张,如图 4 所示。




图 4 不同尺度和角度舰船检测结果。(a)(b)(c)大面积海域;(d)(e)(f)港口区域;(g)(h)(i)存在航迹干扰

Fig. 4 Ship detection results of different scales and angles. (a)(b)(c) Large areas of sea;

(d)(e)(f) port areas; (g)(h)(i) track interference

从图 4 可以看到,所提检测算法可适用于这些样本,图中数据表示目标类别,这里目标是舰船。传统检测算法对图 4(a)~4(c)大片海域的目标检测结果较好,但图 4(d)~4(f)中不可避免地存在漏检情况,这是传统检测算法的弊端,检测图 4(d)~4(f)中靠岸目标通常需对港口区域进行预处理、海陆分割和杂波建模等环节,检测效果并不好,而所提算法省去这些环节,使用端到端的学习方法,在靠岸目标、大片海域目标及目标较多的情况下都取得了

良好的检测效果。图 4(g)~4(i)为渤海湾样张的检测结果,相比于图 4(a)~4(f),2 月份渤海湾有海冰及舰船航行留下的航迹干扰,对舰船目标检测极为不利,但所提算法依然可检测到这些目标,这是所提检测算法的优势。图 4(i)左下角由于目标所占像素太小导致漏检,不过这不能代表整体情况。

4 结 论

小目标数据增强算法解决了数据集样本不足的

问题,使检测模型学习到更多特征,提升了检测器的性能。通过深度特征金字塔网络提取待检测目标的语义成分与形状-空间关系特征的相关性,与级联协同优化 Faster R-CNN 检测模型,提高各种尺寸和不同角度样本检测的鲁棒性。基于上述改进,在数据集上进行实验,实验结果表明:检测精度和召回率由原来的 95.83% 和 82.31% 提升到 98.52% 和 84.59%,同时验证了每一点改进可提升的检测效果。基于深度学习的方法解决 SAR 图像中舰船检测问题,无需对图像进行去噪和海陆分割等操作,大大提高了检测效率。

参 考 文 献

- [1] Wang W X, Fu Y T, Dong F, et al. Infrared ship target detection method based on deep convolution neural network [J]. *Acta Optica Sinica*, 2018, 38 (7): 0712006.
王文秀, 傅雨田, 董峰, 等. 基于深度卷积神经网络的红外船只目标检测方法 [J]. *光学学报*, 2018, 38 (7): 0712006.
- [2] 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.
- [3] 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, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 14632381.
- [4] Sun X D, Wu P C, Hoi S C H. Face detection using deep learning: an improved Faster RCNN approach [J]. *Neurocomputing*, 2018, 299: 42-50.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] Hou B J, Yang M H, Sun X W. Real-time object detection for millimeter-wave images based on improved faster regions with convolutional neural networks [J]. *Laser & Optoelectronics Progress*, 2019, 56(13): 131009.
侯冰基, 杨明辉, 孙晓玮. 基于改进 Faster RCNN 的毫米波图像实时目标检测 [J]. *激光与光电子学进展*, 2019, 56(13): 131009.
- [10] Feng X Y, Mei W, Hu D S. Aerial target detection based on improved Faster R-CNN [J]. *Acta Optica Sinica*, 2018, 38(6): 0615004.
冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测 [J]. *光学学报*, 2018, 38 (6): 0615004.
- [11] Ren Z J, Lin S Z, Li D W, et al. Mask R-CNN object detection method based on improved feature pyramid [J]. *Laser & Optoelectronics Progress*, 2019, 56(4): 041502.
任之俊, 蔺素珍, 李大威, 等. 基于改进特征金字塔的 Mask R-CNN 目标检测方法 [J]. *激光与光电子学进展*, 2019, 56(4): 041502.
- [12] Chen Y C, Zhu X T, Zheng W S, et al. Person re-identification by camera correlation aware feature augmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40 (2): 392-408.
- [13] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2019-10-13]. <https://arxiv.org/abs/1409.1556>.
- [14] Zhang S L, Xie L B. Salient detection based on cascaded convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2019, 56(7): 071501.
张松龙, 谢林柏. 基于级联全卷积神经网络的显著性检测 [J]. *激光与光电子学进展*, 2019, 56 (7): 071501.