

DOI: 10.19650/j.cnki.cjsi.J2006122

基于 CReLU 和 FPN 改进的 SSD 舰船目标检测*

李晖晖¹, 周康鹏², 韩太初¹

(1. 西北工业大学自动化学院 西安 710072; 2. 中国飞行试验研究院 西安 710089)

摘要:在遥感图像中,舰船目标具有目标尺寸较小、形状细长、多个目标紧密排列、类间相似度高等特点,现有的深度学习目标检测算法对舰船小目标的检测精度不高,易发生错检、漏检情况。为了更有效地利用遥感图像信息,提高小目标检测精度,构建了舰船数据集 SDNGV,提出基于串行修正线性单元 CReLU 和特征金字塔网络(FPN)改进的单射探测器(SSD)舰船目标检测识别方法。首先,在 SSD 网络的浅层添加 CReLU,提升其浅层特征的传递效率;然后,采用 FPN 从网络的深层到浅层逐级融合 SSD 中用于检测的多尺度特征图,提升网络的定位精度和分类精度。实验表明,所提目标检测算法具有较好的检测精度,改进方法具有明显的效果,在舰船小目标的检测上有 10% 的检测精度提升。

关键词: 目标检测; 舰船检测; 深度学习; 卷积神经网络

中图分类号: TP391.4 TH39 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Ship object detection based on SSD improved with CReLU and FPN

Li Huihui¹, Zhou Kangpeng², Han Taichu¹

(1. School of Automation, Northwestern Polytechnical University, Xi'an 710072, China;

2. Chinese Flight Test Establishment, Xi'an 710089, China)

Abstract: In remote sensing images, ship objects have the characteristics of small size, slender shape, close arrangement of multiple objects and high similarity between classes. The existing deep learning object detection algorithms have low detection accuracy for small ship objects, and are prone to error detections and missed detections. In order to effectively utilize the remote sensing image information and improve the accuracy of small object detection, the SDNGV ship data set is constructed, and an improved single shot multiBOX detector (SSD) ship object detection and recognition method based on concatenated rectified linear unit (CReLU) and feature pyramid networks (FPN) is proposed. Firstly, CReLU is added to the shallow layer of the SSD network to improve the transmission efficiency of its shallow layer features. Secondly, FPN is used to fuse the multi-scale feature map used for detection in SSD step by step from the deep layer to the shallow layer of the network to improve the positioning accuracy and classification accuracy of the network. Experiments demonstrate that the proposed detection algorithm has good detection accuracy, the improved method has obvious effect, and the detection accuracy of small ship objects has 10 percent improvement.

Keywords: object detection; ship detection; deep learning; convolutional neural network

0 引言

船舶是海洋活动的重要载体,对特定海域的舰船目标检测在国防和经济发展方面具有重要的意义。而目标检测是近年来计算机视觉、模式识别、图像处理等领域研究的热点和难点^[1]。近年来,随着遥感大数据的增加,传

统的目标检测算法由于需要手工设计特征,不具有普适性,在大数据时代的目标检测任务中举步维艰。而深度学习则能够胜任大数据时代的舰船目标检测任务。在光学遥感图像中,舰船目标多以小目标为主,类间相似度高,目标紧密排列。同时,舰船检测研究主要用于进行海面监测、战略决策辅助等时效性强的任务,因此对研究要求也不仅仅局限于检测精度,更有对实时性的要求。而

现有的深度学习目标检测算法针对舰船小目标的检测缺乏行之有效的办法。针对光学遥感图像中的舰船目标检测问题,构建了源于网络、谷歌地图和视频的舰船数据集(ship data from network, google earth and videos, SDNGV);以具备高实时性的单射多包围框检测算法单射探测器(single shot multiBox detector, SSD)^[2]为基础网络,提出了基于串行修正线性单元(concatenated rectified linear unit, CReLU)^[3]和特征金字塔(feature pyramid networks, FPN)^[4]改进的 SSD 舰船目标检测识别方法,在 SSD 网络的浅层添加 CReLU,提升其浅层特征的传递效率;采用 FPN 从网络的深层到浅层逐级融合 SSD 中用于检测的多尺度特征图,提升网络的定位精度和分类精度。实验结果表明,本文算法具有较好的检测精度,保证实时检测性能的同时,在舰船小目标的检测识别上具有较好的检测精度。

1 深度学习目标检测的相关工作

2012 年, Krizhevsky 等^[5]使用扩展深度的卷积神经网络(convolutional neural network, CNN)在 ImageNet 大规模视觉挑战赛分类任务中夺冠,掀起了深度学习的热潮。Girshick 等提出基于区域的 CNN 算法(region based onCNN, RCNN)^[6],奠定了深度学习目标检测这个子领域的基础,R-CNN 采用候选区域提取 CNN 特征+支持向量基(support vector machine, SVM)分类实现目标检测。Girshick^[7]提出的 Fast RCNN 是对 SPPNet^[8]的进一步改进,主要创新点是 ROI 池化层,其将不同尺度的候选框对应的特征图转换为固定大小的特征图;Fast RCNN 将深度网络和 SVM 两个阶段进行整合,使用新的网络直接进行分类和回归的计算。Ren 等^[9]提出的 Faster RCNN 采用区域生成网络(region proposal network, RPN)替换 Fast RCNN 的采用选择搜索(selective search)提取候选框的方式,实现了网络的端到端的训练。以上的深度学习目标检测算法均为候选区域提取+分类,称之为双级方式(two stage),其候选区域提取计算量大,难以满足实时性要求,因此深度学习目标检测算法有了另一分支——单级方式(one stage),典型代表为 YOLO(you look only once)^[10]和 SSD。Redmon 等^[10]提出的 YOLO 摒弃了候选框生成阶段,基于 Darknet-19 基础网络在同一个无分支的网络中进行特征提取、候选框位置回归和分类,网络结构简单,能够满足实时性的检测任务需求。Liu 等^[2]借鉴 YOLO 的网格划分思想和 Faster RCNN 的 Anchor 方法提出了 SSD 目标检测算法,在保持检测速度的同时达到了和 two-stage 深度学习目标检测算法相当的检测精度。SSD 的基础网络是 VGG-16^[11],其基于多尺度特征图预测不同大小的目标,在浅层的特征图上预测小目标,在深

层特征图上预测大目标。

在深度学习舰船目标检测方面,李建伟等^[12]将卷积神经网络应用于合成孔径雷达(synthetic aperture radar, SAR)图像舰船目标检测,研究了特征聚合、损失函数设计、迁移学习等问题,并且构建了 SAR 舰船检测数据集,包含了不同分辨率、不同尺寸、不同海况、不同传感器等条件下的舰船 SAR 图像。胡炎等^[13]基于 Faster RCNN 框架设计特征学习网络,用于多分辨率的 SAR 图像海上舰船目标检测。吴金亮等^[14]基于 Mask RCNN 框架,结合像素语义分割算法,得到候选框和其边缘轮廓数据,能够有效地解决紧密排列的舰船目标检测的问题。小目标检测一直是舰船检测研究方向的重点。陈艳浩^[15]设计了一种全局背景减法滤波器与多特征融合的红外舰船检测算法,通过抑制背景噪声来有效提高红外弱小目标的检测精度;采用传统恒虚警率(constant false-alarm rate, CFAR)算法结合高精度深度检测模型也是一个可行的研究方向。Kang 等^[16]提出了一种基于 CFAR 算法改进的 Faster RCNN 检测模型用于舰船检测,通过 CFAR 算法生成指导窗口再送入 CNN 进行舰船目标检测,有效地提高了对舰船小目标的检测精度。但 Faster RCNN 本身就有检测速度慢的缺点,无法满足实时性要求。

小目标检测困难是卷积神经网络降维致使的原始图像信息损失造成的。因此,深度学习领域小目标检测方法主要是通过提高浅层网络信息利用来实现,因为卷积神经网络存在池化层下采样的缘故,浅层网络会包含更多原始图像信息,如图 1 所示,两个相近的舰船目标在经过 4 次下采样后,较小的目标已经无法用肉眼辨认,对神经网络而言亦是难以检测的。因此,如何将浅层网络特征直接用于检测或有效保留浅层特征,是小目标检测问题的关键。如解卷积网络单射探测器(deconvolutional single short detector, DSSD)^[17],通过反卷积将深层特征拼接至浅层特征,以实现小目标检测精度的提升。

2 舰船数据集 SDNGV

深度学习目标检测最基本的要求是需要一个规模适中的数据集。本文基于光学遥感图像构建了 SDNGV,数据来源于网络爬虫、YouTube 视频截图和 Google Earth 截图,Google Earth 截图的地点有直布罗陀海峡、新加坡港、长江入海口以及日本和美国的军港等。本文按照 Pascal VOC^[18]数据集的格式构建了 SDNGV,按照图片数目 7:3 的比例分成了 SDNGV 训练集和 SDNGV 验证集,包含了不同分辨率、不同尺寸、不同海域的光学图像。SDNGV 数据集共包含 2 914 张图片,10 类舰船共 7 457 个目标,数据集分布如表 1 所示。SDNGV 的舰船目标尺度分布和舰船数量 NoS(number of ships)、图像数量 NoI(number



图 1 舰船目标下采样

Fig.1 Schematic diagram of ship object down-sampling

of images) 分布如图 2、3 所示。图 4 和 5 所示为数据集中原始图像数据和标注数据。

表 1 SDNGV 数据集类别分布表

类别	训练集	验证集
运输船	1 875	769
驱逐舰	1 422	527
民船	660	292
航空母舰	428	168
游艇	188	134
客船	184	67
潜艇	184	63
战舰	121	98
海监船	97	50
渔船	104	26
总计	5 263	2 194

3 基于 CReLU 和 FPN 改进的 SSD 目标检测算法

在深度学习舰船目标检测中小目标的检测精度差、易发生漏检误检的主要原因是在于卷积神经网络在特征提取过程中会进行多次下采样以实现特征的降维,这就不可避免地导致了原始图像信息的损失,由于舰船小目标本身包含的特征信息就很少,这一问题尤为明显。




图 2 数据集 SDNGV 中目标尺寸分布情况

Fig.2 Object size distribution in SDNGV data set




图 3 数据集 SDNGV 中 NoI 和 NoS 对应关系

Fig.3 Corresponding relationship between NoI and NoS in SDNGV data set




图 4 SDNGV 数据集原始图像数据

Fig.4 Raw image data in SDNGV data set

如图 6 所示,左侧为舰船目标的真实位置,右侧为检测结果。在图 6 中可以看出,对舰船小目标的检测出现了误检、错检和定位偏差的问题。因此,提高网络特征信息利用率是解决舰船小目标的一个可行方法。针对这一问题,提出 CReLU 和 FPN 改进的 SSD 目标检测方法,CReLU 可通过一个额外的分支向深层网络传递更多的特征信息;FPN 结合浅层网络的目标特征和深层网络的语义信息,以提高网络信息的利用,达到检测精度提升的目的。



图 5 SDNGV 数据集标注数据

Fig.5 Schematic diagram of the annotated data in SDNGV data set




图 6 现有目标检测算法效果

Fig.6 Effect of existing object detection algorithms

3.1 CReLU 激活函数

Shang 等^[3] 基于对现有 CNN 模型的统计提出了 CReLU,指出这一现象:在 CNN 网络的浅层,网络的参数分布有更强的负相关性。随着网络加深,这种负相关性逐渐减弱。结论是:在 CNN 网络的浅层,网络有对正负相位的信息同时学习的趋势,但是,修正线性单元 (rectified linear unit, ReLU)^[19] 会抑制负响应。这使得 CNN 网络浅层的特征存在冗余,即网络浅层的卷积核存在冗余。而 CReLU 通过将特征图取反并通过 ReLU 函数的方法,将这些负响应的也作为卷积层的输出,将冗余特征转化为可用特征。

CReLU 的定义如下,式中的 ReLU 表示 ReLU 激活函数:

$$CReLU(x) = [ReLU(x), ReLU(-x)] \quad (1)$$

总体来说,CReLU 提升了网络的浅层特征的利用率,使得浅层特征能够更好地传递到网络的深层。




图 7 CReLU 在 CNN 网络中的实现

Fig.7 Realization of CReLU in CNN

3.2 特征金字塔

Lin 等^[4] 基于深度卷积神经网络固有的多尺度层级金字塔来构建具有边际额外成本的特征金字塔,提出了具有侧向连接的自深层到浅层的架构,用于在所有尺度上构建高层语义特征图,称之为特征金字塔网络,如图 8 所示。

对于深度卷积神经网络,其网络浅层特征的语义信息比较少,但是位置信息明确;网络深层特征的语义信息丰富,但是位置信息粗略。特征金字塔网络将深层网络的语义信息与浅层网络的位置信息结合起来,提升了网络的检测精度。

特征金字塔网络包含 3 部分:1)浅层到深层的线路,如图 8(a)左侧所示;2)深层到浅层的线路,如图 8(a)右侧所示;3)侧向连接 (lateral connection),如图 8(a)中的黑色虚线矩形框,放大后如图 8(b)所示。




图 8 特征金字塔网络

Fig.8 Feature pyramid network

浅层到深层的线路其实就是网络的前向过程。随着网络的加深,特征图会从大到小的递减,而其通道数会增加,以保证特征的平移不变性。抽取网络的最后几个尺度的特征图形成特征金字塔。

深层到浅层的线路一般采用反卷积或者上采样进行。侧向连接用于将上采样的特征图和 1×1 卷积核生成的宽度、高度和通道数一致的特征图进行融合(对应元素相加)。在融合之后还会采用 3×3 卷积核对融合特征图进行卷积,其目的是消除上采样的混叠效应。

3.3 网络结构

基于 CReLU 和 FPN 改进的 SSD 目标检测算法的结构如图 9 所示,网络架构设计遵循的主要原则是在 backbone 中降低特征信息损失;对于检测的卷积层,通过融合深层特征来提升预测效果。第一点实现是在 VGG-16 网络中加入 CReLU,保留浅层特征;第二点实现则是在 SSD 网络中添加 FPN 结构,实现多尺度信息融合,具体过程是将深层网络逐层反卷积并于前一层网络深度拼接,将高层语义信息传递给浅层检测网络。

在图 9 所示的网络结构中,VGG-16 Through Conv4_3 layer 表示 VGG-16^[11] 中前 13 个卷积层和 4 个池化层。Top2_CReLU 的实现如图 9 中红色特征图所示,VGG-16 中生成的前 2 个卷积层生成的特征图进行 CReLU 操作。FPN 的浅层到深层的线路由 SSD 网络实现,图 9 中的 $2 \times \text{up}$ 实现 FPN 的深层到浅层的上采样、Conv 1×1 和 $\oplus$ 实现 FPN 的侧向连接。 $2 \times \text{up}$ 表示上采样,由反卷积操作实现,使得深层的特征图反卷积之后的大小和通道数与邻近的上一层特征图的大小和通道数一致;Conv 1×1 表示 1×1 大小的卷积核,使得卷积输出的特征图和反卷积输出的特征图具有数据一致性,以及两个特征图的宽、高和通道数一致; $\oplus$ 实现反卷积输出的特征图和侧向连接输出的特征图对应元素的线性叠加。图 5 中,Conv: $3 \times 3 \times 1\ 024$ 表示大小为 3×3 ,卷和个数为 1 024,移动步长默认为 1 的卷积核;Conv: $3 \times 3 \times 512\text{-s}2$ 表示大小为 3×3 ,卷和个数为 512,移动步长为 2 的卷积核;Detections 表示预设的生成候选框的目标个数;NMS 表示非极大值抑制;Output 表示输出的检测信息。




图9 网络结构

Fig.9 The network architecture

3.4 损失函数

网络的损失函数是置信度损失 L_{conf} 和位置损失 L_{loc} 的加权和,定义如下:

$$L(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c)) + \alpha L_{loc}(x, l, g) \quad (2)$$

式中: N 为先验框正样本的数量; $x_{ij}^p = 1$ 表示第 i 个先验框与第 j 个类别为 p 的真实值 (ground truth, GT) 匹配,否

则, $x_{ij}^p = 0$; c 是类别置信度预测值; l 为先验框正样本对应的位置预测信息; g 为 GT 的位置参数, α 通过交叉验证设置为 1。

置信度损失 L_{conf} 采用 Softmax Loss, 定义如下:

$$L_{conf}(x, c) = - \sum_{i \in Pos} x_{ij}^p \log(\hat{c}_i^p) - \sum_{i \in Neg} \log(\hat{c}_i^0) \quad (3)$$

式中: $\hat{c}_i^p = \exp(c_i^p) / \sum_p \exp(c_i^p)$; Pos 表示正样本; Neg

负样本。

位置损失 L_{loc} 采用 Smooth L1 Loss, 定义如下:

$$L_{loc}(x, l, g) = \sum_{i \in Pos} \sum_{m \in \{cx, cy, w, h\}} x_{ij}^p \text{smooth}_{L1}(l_i^m - g_i^m) \quad (4)$$
$$\text{smooth}_{L1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & |x| > 1 \end{cases} \quad (5)$$

式中: 位置损失仅对正样本进行计算。 l_i^m 为先验框正样本对应的位置预测信息; g_i^m 为 GT 位置参数; $m \in \{cx, cy, w, h\}$ 分别表示先验框或 GT 的顶点横坐标、顶点纵坐标、宽度和高度信息。

4 实验结果

实验的硬件环境为 CPU Intel 至强系列, NVIDIA GeForce GTX1080Ti; 系统环境为 Ubuntu 16.04 LTS; 软件环境为 CUDA8.0 和 cuDNN5.1; 深度学习框架为 Caffe。

算法的衡量指标是平均精度均值 (mean average precision, mAP) 和单张图片循环检测 1 000 次的平均时间。

4.1 VOC 数据集的实验结果与分析

在 Pascal VOC 数据集上验证本文算法的有效性, 训练数据集为 VOC 2007+2012 trainval, 验证集为 VOC2007 test, 无预训练模型。实验结果如表 2 所示。

表 2 VOC 数据集的实验结果

Table 2 Experiment result of VOC data set				
网络结构	CReLU	FPN	mAP/%	检测时间/ms
SSD			73.138 4	22.155
SSD+CReLU	√		73.233 2	24.107
SSD+FPN		√	73.348 3	23.530
本文方法	√	√	73.870 8	25.443

从表 2 可以看出, 在 SSD 的基础上分别添加 CReLU、FPN、CReLU+FPN (本文), 在标准 VOC 数据集上的 mAP 相比于 SSD 方法均有提高, 而本文提出的方法最好, 提升了 0.732 4%, 其原因是 CReLU 增加了浅层特征的利用率以及 FPN 结合了深层网络的分类信息和浅层网络的位置信息, 从而提升了小目标的检测精度; 从单张图片的检测时间来看, 本文提出的方法耗时最长, 其原因是 CReLU 额外的特征图拼接操作和 FPN 中的特征图的反卷积操作增加了时间消耗。

4.2 SNDGV 数据集的实验结果与分析

在 SNDGV 上验证本文算法的有效性, 训练数据集为 SNDGV Train Set, 验证集为 SNDGV Valid Set, 无预训练模型。其实验结果如表 3 所示。

表 3 SNDGV 数据集的实验结果
Table 3 Experiment result of SDNGV data set

网络结构	mAP/%	检测时间/ms
SSD	69.235 5	22.248
DSSD	71.574 5	107.471
FSSD	70.291 2	15.535
本文方法	71.325 1	25.693

从表 3 的 mAP 来看, 本文提出的算法相比于 SSD 提高了 2.089 6%。其原因是 CReLU 增加了浅层特征的利用率以及 FPN 结合了深层网络的分类信息和浅层网络的位置信息, 从而提升了小目标的检测精度; 而 CReLU 和 FPN 的额外计算增加了检测所用时间。表 3 中的 DSSD 输入尺寸为 321, backbone 采用 ResNet-101, 与 DSSD 对比, 本文的方法在保证 mAP 与之相近的同时, 检测时间仅为其的 1/4, 具有更高的实时性; FSSD 模型输入尺寸为 300, backbone 采用 VGGNet, 本文的方法的 mAP 高出 1.033 9%, 虽然检测速度低于 FSSD, 但接近 40FPS 的处理速度已经满足实时性要求。

为了进一步地分析本文提出的算法在舰船数据集上的有效性, 计算了不同像素范围内目标的召回率和正确率, 如表 4 所示。

表 4 SDNGV 数据集上不同像素范围内的目标的召回率和正确率 (置信度阈值 0.10)

Table 4 Recall and accuracy rates of the objects in SDNGV data set in different pixel ranges (the confidence threshold is 0.10) (%)					
网络结构	参数	像素区间			
		0~400	400~1 600	1 600~3 600	≥3 600
SSD	召回率	53.01	71.95	73.76	91.95
	正确率	52.94	74.47	65.64	76.60
本文	召回率	62.39	69.97	74.56	90.69
	正确率	63.93	74.42	77.93	81.89

从表 4 可以看出, 在 SDNGV 数据集中, 本文提出的算法对于像素在 0~400、1 600~3 600 范围内的目标来说, 其召回率和正确率均高于 SSD; 对于 400~1 600 范围内的目标, 其召回率和正确率略有下降; ≥3600 范围内的目标召回率略有下降, 而正确率高于 SSD。其原因是 FPN 从网络深层传递来的特征造成了信息混叠, 造成了目标的漏检或误检。但总体来说, 本文提出的算法在 SDNGV 数据集中对于小目标的检测精度的提升是显而易见的, 在较小的检测速度损失情况下, 检测精度提升了 10.99%。

SDNGV 数据集的部分目标检测结果如图 10 所示,从第 1 和 2 幅检测图像可以看出本文提出的算法在背景干扰严重的码头场景下能有效地对舰船目标进行检测,对地面上易混淆的干扰目标只产生了少量的误检;由第 3 和 4 幅检测图像可以看出算法在海面背景下对舰船小目标可以进行高精度的定位和检测识别。



图 10 SDNGV 数据集的部分目标检测结果

Fig.10 Partial object detection results of SDNGV data set

5 结 论

本文提出了基于 CReLU 和 FPN 改进的 SSD 舰船目标检测算法, CReLU 能够提升网络的浅层特征的利用率,而 FPN 将网络深层的分类信息和浅层网络的位置信息,这两者共同作用,可以提升网络的检测精度,并构建了舰船数据集 SDNGV。本文在 Pascal VOC 数据集和 SDNGV 数据集上进行了训练和测试,并和 SSD 算法进行了对比。在 Pascal VOC 数据集上, mAP 提升了 0.732 4%;在 SDNGV 数据集上, mAP 提升了 2.089 6%,并且在置信度为 0.10 的情况下,本文方法相比于 SSD 在 0~400 pixel 范围的小目标的检测精度的提升有 10.99%。在舰船小目标检测问题上,未来的研究应当考虑舰船数据的特点来针对性地优化检测模型。例如,如何在保持一定检测精度的基础上设计更简洁的网络结构;在数据样本不充分或难以扩充的情况下,如何在小样本上发挥深度学习的优势,并提高网络模型的泛化能力等。

参考文献

[1] 李成美,白宏阳,郭宏伟,等. 一种改进光流法的运动目标检测及跟踪算法[J]. 仪器仪表学报, 2018, 39(5): 249-256.
LI CH M, BAI H Y, GUO H W, et al. Moving object detection and tracking based on improved optical flow method[J]. Chinese Journal of Scientific Instrument, 2018, 39(5): 249-256.
[2] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector[C]. European Conference on

Computer Vision (ECCV), Springer, Cham, 2016: 21-37.
[3] SHANG W, SOHN K, ALMEIDA D, et al. Understanding and improving convolutional neural networks via concatenated rectified linear units[C]. International Conference on Machine Learning (ICML), 2016: 2217-2225.
[4] LIN T Y, DOLLÁR P, GIRSHICK R B, et al. Feature pyramid networks for object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936-944.
[5] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems, 2012: 1097-1105.
[6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.
[7] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision (ICCV), Santiago, 2015: 1440-1448.
[8] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9): 1904-1916.
[9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[C]. International Conference on Neural Information Processing Systems, MIT Press, 2015: 91-99.
[10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-Time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016: 779-788.
[11] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. International Conference on Learning Representations (ICLR), 2015: 1-14.
[12] 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.
LI J W, QU CH W, PENG SH J, et al. Ship detection in SAR images based on convolutional neural network[J]. Systems Engineering and Electronics, 2018, 40(9): 1953-1959.
[13] 胡炎,单子立,高峰,等. 基于 Faster-RCNN 和多分辨率 SAR 的海上多分辨率舰船目标检测[J]. 无线电工程,

- 2018, 48(2):96-100.
- HU Y, SHAN Z L, GAO F, et al. Ship detection based on faster-RCNN and multiresolution SAR [J]. Radio Engineering, 2018, 48(2):96-100.
- [14] 吴金亮,王港,梁硕,等. 基于 Mask R-CNN 的舰船目标检测研究[J]. 无线电工程, 2018, 48(11):947-952.
- WU J L, WANG G, LIANG SH, et al. Ship object detection based on mask R-CNN[J]. Radio Engineering, 2018, 48(11):947-952.
- [15] 陈艳浩. 基于全局背景减法滤波器与多形状特征的红外舰船检测算法[J]. 电子测量与仪器学报, 2018, 32(10): 138-146.
- CHEN Y H. Infrared ship detection algorithm based on global background subtraction filter and multi-shape feature [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(10): 138-146.
- [16] KANG M, LENG X, LIN Z, et al. A modified faster R-CNN based on CFAR algorithm for SAR ship detection[C]. IEEE International Workshop on Remote Sensing with Intelligent Processing (RSIP), 2017:1-4.
- [17] FU C Y, LIU W, RANGA A, et al. DSSD: Deconvolutional single shot detector [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 1937-1945.
- [18] EVERINGHAM M, ESLAMI S M A, VAN GOOL L, et al. The pascal visual object classes challenge: A retrospective[J]. International Journal of Computer Vision, 2015, 111(1):98-136.

- [19] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C]. Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, 2011: 315-323.

作者简介



李晖晖 (通信作者), 1996 年于昆明理工大学获得学士学位, 2003 年和 2006 年于西北工业大学分别获得硕士学位和博士学位, 现为西北工业大学副教授, 主要研究方向为计算机视觉、机器学习、人工智能。
E-mail: lihui@nwpu.edu.cn

Li Huihui (Corresponding author) received her B. Sc. degree in 1996 from Kunming University of Science and Technology, received her M. Sc. degree and Ph. D. degree in 2003 and 2006 both from Northwestern Polytechnical University, respectively. Now, she is an associate professor in Northwestern Polytechnical University. Her main research interests include computer vision, machine learning and artificial intelligence.



周康鹏, 2016 年和 2019 年于西北工业大学分别获得学士学位和硕士学位, 现为中国飞行实验研究院助理工程师, 主要研究方向为深度学习。
E-mail: zkp518625@163.com

Zhou Kangpeng received his B. Sc. degree in 2016 and M. Sc. degree in 2019 both from Northwestern Polytechnical University, respectively. Now, he is an assistant engineer in Chinese Flight Test Establishment. His main research interest is deep learning.