

一种光学遥感图像船舶目标检测技术

方梦梁, 黄刚

(南京邮电大学 计算机学院, 江苏 南京 210023)

摘要: 遥感图像目标检测与识别是遥感图像分析处理中的研究热点之一, 具有十分重要的科研和应用价值。基于光学遥感图像的海面船舶目标检测是其中一个重要的应用方向。传统的遥感图像船舶目标检测方法精度不足、适用范围有限; 因此, 文中引入自然图片目标检测任务中表现优异的基于深度学习的 Faster R-CNN 算法。由于光学遥感图像中海面船舶目标尺寸小以及自然图片与卫星遥感图像差异明显, 直接应用原始的 Faster R-CNN 算法检测效果较差。针对此问题, 提出一种将图像上采样与特征金字塔网络结合的改进策略, 以提高海面船舶检测性能, 尤其是小尺寸目标的召回率和准确性。通过在自制数据集上合理的对比实验验证了自然图片中的深度学习目标检测算法迁移至遥感图像处理的可行性和所提出方法的先进性。

关键词: 深度学习; 卷积神经网络; 光学遥感图像; 船舶目标检测

中图分类号: TP301

文献标识码: A

文章编号: 1673-629X(2019)08-0136-06

doi: 10.3969/j.issn.1673-629X.2019.08.026

A Ship Detection Technique for Optical Remote Sensing Images

FANG Meng-liang, HUANG Gang

(School of Computer, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Remote sensing image target detection and recognition is one of the research hotspots in remote sensing image analysis and processing, which has very important scientific research and application value. Ship detection based on optical remote sensing image is one of the applications in the field of remote sensing image analysis and processing. The traditional remote sensing image ship target detection method has insufficient accuracy and limited application range. Therefore, the deep learning-based Faster R-CNN is applied, which is excellent in natural picture target detection tasks. Due to the small size of ships on the sea surface in optical remote sensing images and the obvious difference between natural images and satellite remote sensing images, the direct application of the original Faster R-CNN leads to the poor detection. For this, the improved strategy of combining image upsampling with feature pyramid network is proposed, which significantly improves the ship detection performance, especially the recall rate and accuracy of small size targets. The feasibility of transferring the deep learning target detection algorithm in natural pictures to remote sensing image processing and the advancement of the proposed method are verified by a reasonable comparison experiment on the self-made data set.

Key words: deep learning; convolutional neural network; optical remote sensing image; ship target detection

0 引言

近年来, 光学遥感成像技术发展迅速, 光学遥感图像分辨率不断提升, 相比其他类型遥感图像如高光谱、合成孔径雷达(SAR), 高分辨率光学遥感图像有着独特的优势。在民用与军事领域, 基于光学遥感图像的研究和应用都受到广泛关注。船舶是重要的海上目标, 船舶目标自动检测是海洋环境监测、渔业管理、抢险救灾、军事侦察等任务中重要的一环, 也是遥感信息处理的重要内容。在基于深度学习的检测方法兴起以

前, 船舶目标检测依赖于手工设计特征, 往往需要专门的先验知识, 适用范围窄, 实时性差, 不适用于当前数据量巨大、分辨率高的光学遥感图像^[1]。近年来, 基于深度学习的方法利用深度神经网络自适应地分层学习对象的特征, 相比以往模式识别中人工设计的特征提取模型, 特征表达能力更强, 获取的特征语义更丰富, 具有较好的光照、几何、位置不变性, 泛化能力更强^[2]。基于深度学习的目标检测方法典型代表有 R-CNN^[3]、Faster R-CNN^[4]、YOLO^[5]和 SSD^[6]等, 这些方法在自

收稿日期: 2018-08-27

修回日期: 2018-12-28

网络出版时间: 2019-03-27

基金项目: 国家自然科学基金(61171053); 南京邮电大学基金(SG1107)

作者简介: 方梦梁(1993-), 男, 硕士研究生, 研究方向为机器学习; 黄刚, 教授, 研究生导师, 研究方向为计算机软件与大数据应用。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20190327.1620.010.html>

然场景图像的目标检测任务中取得了巨大的成功。

最近,已有一些研究将基于深度学习的目标检测方法应用到遥感图像船舶检测任务中^[7-12],但多是针对 SAR 图像,对光学遥感图像的比较;或是直接基于卷积神经网络(CNN)构造模型,没有很好地利用已有的高性能目标检测框架,在时间效率和通用性上还有改进空间。现有的深度学习目标检测方法中 Faster R-CNN 或基于此的改进算法实时性较好,对小而密集的目标检测有更高的精度。文中提出了一种基于深度学习的光学遥感图像船舶检测方法,通过图像上采样,在不改变卷积神经网络基本结构的情况下,增大卷积层输出的特征图分辨率;同时利用特征金字塔结合高层与低层的特征,在保持高层特征图语义信息不损失的同时增强其细节信息,提高了原始 Faster R-CNN 算法对小目标的检测能力,应用于光学遥感图像船舶检测中取得了较好的效果。

1 目标检测框架

1.1 Faster R-CNN 检测小目标的不足

Faster R-CNN 检测目标的主要流程为:利用多层卷积神经网络提取待检测图特征得到特征图;特征图被送入区域提议网络(region proposal network, RPN)得到一定数量的候选框;在特征图上取候选框对应的特征片,经兴趣区域池化层(RoI pooling)得到固定尺寸的特征图,使用分类器判别是否属于某个特定类;对于属于某一非背景类的候选框,用回归器进一步精调其位置。其中多层卷积神经网络提取的特征被 RPN 和 RoI pooling 共享,其质量十分关键。当前的特征提取网络可以有多种选择,如 AlexNet、GoogLeNet、VGGNet、ResNet 等。这些网络的主干都是多个卷积层和多个池化层的组合,由于池化层降低图像规模和分辨率,故层级越高图像分辨率越低;同时 CNN 的网络结构决定了层级越高的特征图感受野越大,更倾向于检测大的目标。卷积网络的这种特性,导致对小目标检测的不利。以经典的 VGG16 为例,用于 Faster R-CNN 共享特征提取时只用到 VGG16 的前 5 个卷积块,包含 4 个最大池化层,每次池化操作(2×2 下采样)图像规模减小 50%,最后特征图(Conv5_3)尺寸只有原输入图像的 1/16。当原图中目标尺度低于 16 像素时,特征图上几乎没有对应的定位和分类信息,自然难以被检测到。从感受野的角度也可以看到这种不足,多层 CNN 卷积层感受野的计算公式如下:

$$RF_k = RF_{k-1} + (f_k - 1) \times \prod_{i=1}^{k-1} S_i \quad (1)$$

其中, RF_k 为第 k 层卷积层的感受野大小; f_k 为当前层卷积核尺寸; S_i 为卷积步长。层级越高,感受野

越大,目标检测区分性越弱,不利于对小目标的检测。

从卷积神经网络提取到的各层特征来看,层级越高语义信息越丰富,特征越抽象、越全局化,但分辨率越来越低,几何细节信息和位置信息越来越少,适合大目标检测及复杂目标区分;而低层级的特征分辨率高,几何轮廓和位置信息丰富,对目标定位和小目标检测更有利。故为了提高对小目标的检测性能,常常将高低层次的特征结合起来或者在多个层级的特征图上做目标检测^[13-17],而不是只使用某一层的特征图。

1.2 光学遥感图像与自然图像的差异

在自然场景图像的目标检测中,Faster R-CNN 算法性能优异,目前基于此模型的应用及其改进算法还在不断涌现^[18],在很多场景仍然是精度最高的模型。为了保证足够高的召回率和准确度,文中提出的船舶检测方案就基于 Faster R-CNN 框架。然而,由于遥感图像和自然场景图像之间存在明显的差异,直接将现有算法用于遥感图像船舶检测的漏检率比较高,需要继续改进。

自然场景图像往往尺寸较小,背景比较干净,分辨率较高,包含的目标数量较少,最重要的是待检测目标尺寸大或者说占整幅图的比例很大。当前通用的目标检测或识别模型所针对的数据集,如 PASCAL VOC 和 ImageNet ILSVRC 都是如此,有数据显示 ImageNet 中超过 80% 的目标平均尺寸都超过 40 pixel^[19]。

光学卫星遥感图像尺寸大,视场大而分辨率相对较低,背景复杂,包含的对象数量众多,待检测目标尺寸小,有的场景中小目标密集聚集在一起难以区分;另外还存在目标旋转与衍射等现象以及云雾、海面波纹、阴影、光照与拍摄角度等影响。对大量的光学卫星遥感图像中海面船舶尺寸做了统计,尺寸分布如图 1 所示。以矩形标注框的短边来看,其中存在大量的短边尺寸不足 32 pixel 甚至小于 16 pixel 的船舶目标。

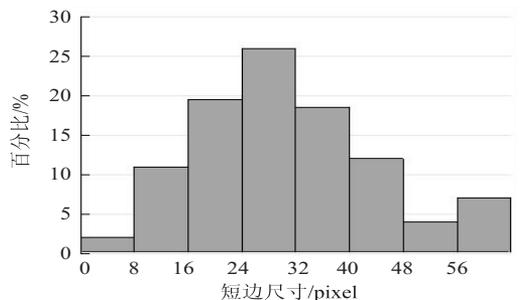


图 1 光学遥感图像数据集中船舶目标尺寸分布

当前深度学习目标检测的典型算法都是针对自然场景图像的通用模型,即便是应用到含大量小尺寸目标的其他自然场景图像检测任务上,如小人脸检测^[19],效果也明显不足。由于自然图片与光学遥感图像的显著差异,尤其大量小尺寸船舶目标的存在,直接

用 Faster R-CNN 框架进行遥感图像船舶检测的效果较差。经自然图片数据集如 ImageNet 预训练的模型迁移到遥感图像船舶检测时更需要专门数据集进行充分训练,模型的改进应该关注提高对小目标的检测能力。

2 改进方法

基于前面分析,为改善特征提取网络输出的特征图缺失底层细节特征、分辨率过小的不足,在不改变现有 Faster R-CNN 基本架构的前提下提高其对小目标的检测性能,使其适用于光学遥感图像船舶检测,提出了两种改进策略:通过输入图像上采样提高特征提取网络输出的特征图分辨率,并利用特征金字塔融合高低层的特征,在经特征融合后的多个层次的特征图上进行检测。系统主流程如图 2 所示。

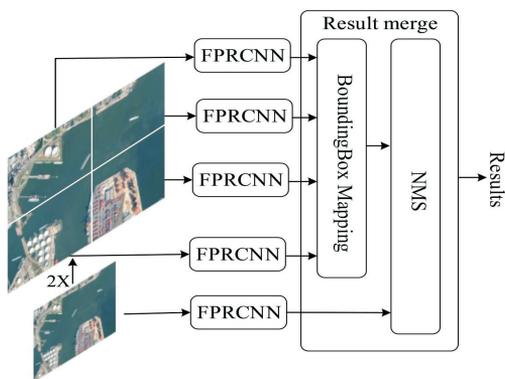


图 2 方案整体框架

文中专注于光学遥感中的民船检测,且不细分类型诸如游艇、游轮、货船、军用舰船等,相当于只检测一类目标,将分类网络最后一个全连接层输出维度改为 2,模型类别数量改为 2,对应判别两种类型:船舶、背景。特征提取网络采用中型的网络 VGG16。由于太浅的网络提取的特征不足,目标检测效果差,在复杂图像分类与检测等任务上已很少被使用,而更深的网络如 ResNet、DenseNet 等结构复杂,最终的特征图感受野更大,对小目标检测识别不利。已有的一些研究^[14]表明,在存在大量密集小目标的场合,更复杂的网络检测结果并没有较浅的 VGG16 效果好。

2.1 提高特征图分辨率

为了进一步增加特征图分辨率以提高小目标检测性能,有的研究中用更浅层的特征提取网络或删减网络的最尾部的卷积层和池化层,然而更高层特征经过多次最大池化处理后有着更强的平移不变性和形变不变性,对于该任务中背景复杂的遥感图像检测很重要。为了不删减 VGG16 卷积层、保留 Conv5 特征,同时提高其特征图分辨率,将图像 2 倍上采样后再送入网络,相当于特征提取网络中各层的特征图分辨率提高到原

来的 2 倍,比如 Conv5_3 输出的特征图由原图尺寸的 1/16 增大到 1/8,其细节特征更丰富,提高了小目标的区分度。为保证图像有较高的质量,插值方式选择双三次插值法(bicubic interpolation)。

输入图像尺寸的增大能提高检测准确度,但所需内存将急剧增大。为平衡准确度和占用内存,在测试和验证阶段,原始图像进入网络之前需要先进行缩放,使图像的长边达到 1 000 pixel 或者短边达到 800 pixel。同样 2 倍放大后的图像先切分为 4 等份,与原图尺寸相同,然后将这 5 块分别送入网络检测。在结果融合操作之前 5 块图像的检测步骤并行执行,缩短检测时间。各切片上的检测结果框的位置坐标是基于各自切片坐标系的,而最终检测结果应该都是在原图上标记的。另外,图片被切分后,有的目标被切分到多个切片中,可能会导致一个目标被检测多次,产生多个检测框,这些属于同一目标的检测框需要被合并。为了方便边框合并去重,将原图也送入网络进行检测。所有切片上的检测结果边框需先映射到相对于原图的坐标和尺寸,然后将所有切片上的和原图上的检测结果通过非极大值抑制方式(NMS)合并,得到最终的原图级别的检测结果。整个过程以端到端的方式完成。另外该方法在两种尺寸的图像上检测,使得网络在预定义锚框的基础上可以捕获更大尺度变化范围内的候选区域,从而提高了多尺度检测的鲁棒性。

2.2 结合特征金字塔网络融合多层特征

基于前面的分析,卷积神经网络的低层和高层特征有互补的特点,对于目标检测都很重要,尤其对于小目标检测更应该利用好低层特征。目前已有多种高低层特征融合的方式,如 HyperNet^[17]、RON^[18],但 Tsung-Yi Lin 等^[20]的实现方式操作简单、代价小、效果良好。作者利用多层卷积神经网络多层池化操作后特征图尺寸逐级减小,自然形成了多尺度多层级的类金字塔结构构造特征金字塔(feature pyramid networks, FPN),只需很小的额外计算量便巧妙融合了从低层到高层多尺度的特征,并且在各层上相对地预测候选框,结构示意图如图 3 所示。

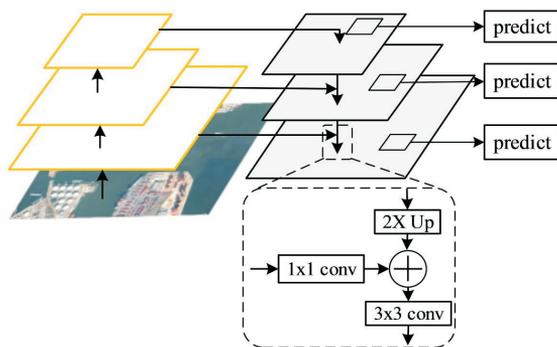


图 3 特征金字塔网络结构示意图

特征金字塔网络中的特征数据流有三个路径,分别是自底向上,自顶向下,横向连接。自底向上即卷积神经网络的前向过程,左边各框分别是取自卷积神经网络各卷积块最后的输出特征,每经过一卷积块特征图分辨率减少 $1/2$ 。自顶向下即对上一层特征图进行 2 倍最邻近上采样,然后将其与横向连接的本层特征图(经过 1×1 卷积以降低维度)通过逐元素相加方式进行融合,再采用 3×3 的卷积核对每个融合结果进行卷积操作以消除上采样的混叠效应,生成与本层原特征相同尺寸的特征图,在此称为超特征。特征金字塔每一层特征经过其上的所有层特征的累加,包含不同分辨率、不同语义强度的特征,自上至下各层特征不断丰富。FPN 具有很好的泛化能力,将其应用到一些基于深度神经网络的图像处理方法中可带来显著的性能改善甚至是速度的提升,包括目标检测、实例分割等。同时,由于该方法只是在原网络基础上加上了数个额外的跨层连接和简单的特征融合,故额外增加的时间和计算消耗很小。

将 FPN 与 Faster R-CNN 相结合,并称改进后的网络为 FPRCNN,如图 4 所示。该方法使用的特征提取网络 VGG16 有 5 个卷积块,将各卷积块的输出,即 Conv1_2, Conv2_2, Conv3_3, Conv4_3, Conv5_3 的输出分别记为 $\{C_1, C_2, C_3, C_4, C_5\}$ 。考虑到 C_1 特征图尺寸大导致内存消耗很大且语义值太低,对目标分类不利,在生成超特征时没有使用,只用 $\{C_2, C_3, C_4, C_5\}$ 自上至下生成超特征 $\{P_2, P_3, P_4, P_5\}$,与原特征一一对应,尺寸相同。

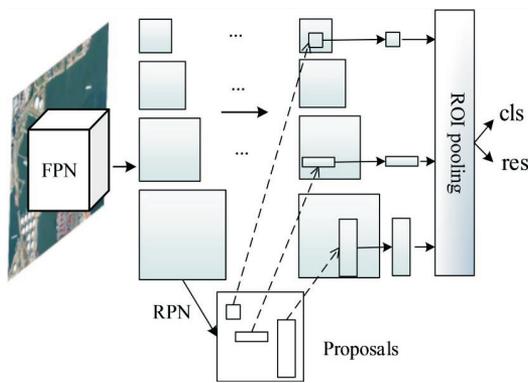


图 4 FPRCNN 结构示意图

各个区域建议网络 RPN 在特征金字塔各个特征图 $\{P_2, P_3, P_4, P_5\}$ 上独立进行候选框 RoI 的生成,不同尺度的 RoI 使用不同特征层对应的特征片作为 ROI Pooling 层的输入。根据 RoI 尺寸选择特征映射的具体公式为:

$$k = \lfloor k_0 + \log_2(\sqrt{wh}/224) \rfloor \quad (2)$$

其中, w 和 h 为 RoI 的宽和高; $k_0 = 5$, k 对应 FPN 中的 P_k 层。

所以,若某个 RoI 尺寸为 $56 * 56$,则 $k = 3$,将选择从特征金字塔中的 P_3 上提取特征片,随后的步骤与原始 Faster R-CNN 一样,即 RoI 池化、类别判定与边框回归。

由于特征金字塔各层固有的多级尺度,且该方法在各层上运行 RPN 做区域建议操作,不需要像原 Faster R-CNN 一样为了实现多尺度检测而在单个尺度的特征图检测时 RPN 网络需要设置多种不同的锚框尺寸,只需在每个层级上的 RPN 设置单一尺寸的锚框。另外根据图 1 对遥感图像中船舶尺寸的统计数据,改小 RPN 中锚框的尺寸,故分别对 $\{P_2, P_3, P_4, P_5\}$ 上的 RPN 设置锚框尺寸为 $(16^2, 32^2, 64^2, 128^2)$ 。鉴于遥感图像中船舶目标具有方向多变、高长宽比的特点,将锚框的长宽比设为 5 类 $\{1:1, 1:2, 1:3, 1:4, 1:6, 2:1, 3:1, 4:1, 6:1\}$,这种尺寸设置更有利于对船舶这一特定目标检测。为缩短模型训练和检测时间,各个层级上的分类器和回归器共享相同的卷积参数。

3 实验数据与模型训练

文中专注于检测光学遥感中的船舶目标,由于没有专门的公开数据集,自己制作了数据集。从 NWPU VHR-10 和 DOTA 数据集中选取了部分图片,另外从 Google Earth 上获取了 100 张遥感图像,原图像总共 400 张,尺寸都剪裁至 $1\ 000 \times 1\ 000$ 左右。为了扩充训练样本,并考虑到实际场景遥感图像中的目标存在视角变化。方向变化的影响,故对图像进行了旋转和翻转操作。对于每个训练样本,以顺时针方向旋转 3 个角度 $\{90^\circ, 180^\circ, 270^\circ\}$;随后对所有图像进行水平翻转,同时这些图像的原始标注数据做相应转换,例如原始图像某标注框坐标为:左上 $[x_{l0}, y_{l0}]$,右上 $[x_{r0}, y_{r0}]$,左下 $[x_{ll}, y_{ll}]$ 和右下 $[x_{rl}, y_{rl}]$,做顺时针 90° 旋转后坐标变为:左上 $[x_{ll}, y_{rl}]$,右上 $[x_{l0}, y_{l0}]$,左下 $[x_{rl}, y_{rl}]$ 和右下 $[x_{r0}, y_{r0}]$,以此类推。从 Google Earth 采集的图像通过人工标注,旋转和翻转及坐标转换操作通过编程自动完成,训练样本扩充到原来的 8 倍。取其中 2 000 张包含船舶目标的作为正样本,训练集与测试集比例为 7:3。所有正样本都人工标注其中船舶目标的边界框。

为了方便训练,把标注好的数据做成 PASCAL VOC 格式。由于基于 TensorFlow Object Detection API 构建网络,按 TensorFlow 框架要求,还需将 PASCAL VOC 格式数据集转换成 TFRecord 格式。

本实验的网络训练采用迁移学习策略,共享的特征提取网络为 VGG16,已经过 ImageNet 数据集的预训练,在此基础上,继续在该遥感船舶数据上微调参

数。在训练过程中,设置初始学习速率为 0.000 1,每迭代 2 000 次学习速率减为 1/10。多次迭代,每 5 000 次保存一个模型,选择损失小的在测试集图上做检测试验。其他参数遵循原 Faster R-CNN^[3],如 NMS 的 IoU 阈值为 0.7。采用端到端(end-to-end)的方式来训练主干网络 VGG16 和 RPN 区域推荐网络。

在实际场景中,不同船舶之间体型区别及遥感图像地面采样距离(GSD)的差异导致船舶目标也存在较大的尺度变化,为了强化模型的多尺度鲁棒性,在训练阶段采用多尺度训练方式。每隔 10 轮随机改变输入的训练图像的尺寸,图像缩放到原尺寸的 1.0+0.2(1-k)倍,k 随机取值 {0,1,2,3},即原图的 {0.6,0.8,1.0,1.2} 倍,模型在原图的这 4 种缩放比例上有更充分地训练。

为方便起见,基于 Google 开源的 TensorFlow Object Detection API 构建该模型。实验平台:Ubuntu 14.04.5, Xeon E5-2690v4 CPU, NVIDIA GK110 BGL GPU。

4 实验结果分析

实验中,用准确率(precision)和召回率(recall)来评判检测效果,其中召回率描述被正确检测到的船舶数与图像中实际总数量的比率,表明所希望被检索到的船舶目标多大程度上被系统检索到了。准确率衡量正确检测数量与全部识别出目标数量的比值,即检索到的对象里有多少是真正的船舶目标。

$$\text{recall} = \frac{\text{TruePositive}}{\text{TruePositive} + \text{FalseNegative}} \quad (3)$$

$$\text{precision} = \frac{\text{TruePositive}}{\text{TruePositive} + \text{FalsePositive}} \quad (4)$$

图 5 是测试集的一个检测结果示例,可以看到图中绝大部分船舶都被成功正确地检测出,有较好的多尺度适应性。



图 5 检测结果示例

图中上部有几艘紧贴另一艘大船的船没有被检测到,推测其原因应该是本方法基于常见的水平边界框

检测,船只方向多变,候选框往往不能很好地贴合瘦长形的船只,容易出现紧靠在一起的多个候选框高度重合在 PRN 网络中被合并。故对于这种尺寸差别明显且密集紧贴的多个目标难以区分,需要继续改进。

如表 1 数据显示,无论是基于区域建议的 Faster R-CNN 还是基于回归的 SSD,基于深度学习的方法在在遥感图像船舶目标检索上的性能都超过了传统的基于手工特征的 HOG+SVM 方法,显示出了良好的泛化能力。表中“Faster R-CNN+FPN”指仅仅使用特征金字塔改进 Faster R-CNN 的方法,对比最后三行数据可看到,该方法提出的两个策略:图像上采样、特征金字塔 FPN 对提升召回率都有明显的帮助。与原始 Faster R-CNN 相比,文中方法的船舶目标召回率提高了约 11 个百分点,说明文中方法能在背景复杂、目标尺度多变的遥感图像中检测出更多的小目标。

表 1 不同方法的召回率对比

方法	AR/%
HOG+SVM	59.30
SSD	65.73
Faster R-CNN	64.54
Faster R-CNN+FPN	70.84
文中方法	75.21

表 2 是不同方法在文中数据集上检测的准确度结果对比,同样可以看到提出的两个策略对检测的准确率都有提升,改进后 Faster R-CNN 目标检测准确度提高了 8.6%。

表 2 不同方法的准确率对比

方法	AP/%
HOG+SVM	74.59
SSD	81.67
Faster R-CNN	81.40
Faster R-CNN+FPN	85.11
文中方法	88.36

综合上述结果,提出的改进方法检测光学遥感图像船舶小目标相比原始的 Faster R-CNN 在准确率、召回率上均有明显提高,也超过了传统的基于手工特征模式识别方法和 SSD 算法。

5 结束语

首先将自然场景图像深度学习目标识别算法运用到了遥感图像船舶目标检测上,将通用的多类别目标检测算法 Faster R-CNN 用于单类目标的检测,把目标的检测问题转换为二分类问题(船舶和背景)。分析了高分辨率遥感图像与自然场景图像的差别及原始 Faster R-CNN 算法检测小目标的不足之处,提出图像

上采样与特征金字塔网络结合的策略。改进后的模型在遥感图像海面船舶检测任务中表现出更好的性能,表明了用于自然图像中的深度学习目标检测算法应用到遥感图像处理的可行性和优越性。该方法召回率有显著提升,但是离实际应用需求还有距离,有待继续提高;另外该方法使用传统的水平边界框做检测,导致少数密集紧贴的多个目标候选框易高度重合而被非极大值抑制方法错误地抛弃,若使用任意方向的边界框替代水平边界框可能会有改善,下一步将在这两方面做进一步研究。

参考文献:

- [1] 陈亮,王志茹,韩仲,等.基于可见光遥感图像的船只目标检测识别方法[J].科技导报,2017,35(20):77-85.
- [2] 李旭冬,叶茂,李涛.基于卷积神经网络的目标检测研究综述[J].计算机应用研究,2017,34(10):2881-2886.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of 2014 IEEE conference on computer vision and pattern recognition. Columbus, OH, USA:IEEE,2014:580-587.
- [4] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2017,39(6):1137-1149.
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of 2016 IEEE conference on computer vision and pattern recognition. Las Vegas, NV, USA:IEEE,2016:779-788.
- [6] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//European conference on computer vision. Amsterdam, the Netherlands:Springer,2016:21-37.
- [7] 黄洁,姜志国,张浩鹏,等.基于卷积神经网络的遥感图像舰船目标检测[J].北京航空航天大学学报,2017,43(9):1841-1848.
- [8] 胡炎,单子力,高峰.基于Faster-RCNN和高分辨率SAR的海上舰船目标检测[J].无线电工程,2018,48(2):96-100.
- [9] KANG M, JI K, LENG X, et al. Contextual region-based convolutional neural network with multilayer fusion for SAR ship detection[J]. Remote Sensing,2017,9(8):860-874.
- [10] LIU Y, CUI H Y, KUANG Z, et al. Ship detection and classification on optical remote sensing images using deep learning [C]//ITM web of conferences. Les Ulis France:EDP Sciences,2017:05012.
- [11] TANG Jiexiong, DENG Chenwei, HUANG Guangbin, et al. Compressed-domain ship detection on spaceborne optical image using deep neural network and extreme learning machine[J]. IEEE Transactions on Geoscience and Remote Sensing,2015,53(3):1174-1185.
- [12] SOMMER L, SCHUMANN A, SCHUCHERT T, et al. Multi feature deconvolutional faster R-CNN for precise vehicle detection in aerial imagery[C]//2018 IEEE winter conference on applications of computer vision. Lake Tahoe, NV:IEEE,2018:635-642.
- [13] 葛园园,许有疆,赵帅,等.自动驾驶场景下小且密集的交通标志检测[J].智能系统学报,2018,13(3):366-372.
- [14] HONARI S, YOSINSKI J, VINCENT P, et al. Recombinator networks: learning coarse-to-fine feature aggregation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, NV, USA:IEEE,2016:5743-5752.
- [15] ZHU Chenchen, ZHENG Yutong, LUU K, et al. CMS-RCNN: contextual multi-scale region-based CNN for unconstrained face detection[M]//Deep learning for biometrics. Berlin:Springer,2017:57-79.
- [16] KONG Tao, YAO Anbang, CHEN Yurong, et al. Hypernet: towards accurate region proposal generation and joint object detection[C]//IEEE conference on computer vision and pattern recognition. Las Vegas, NV, USA:IEEE,2016:845-853.
- [17] DAI Jifeng, LI Yi, HE Kaiming, et al. R-FCN: object detection via region-based fully convolutional networks[C]//Proceedings of the 30th international conference on neural information processing systems. Barcelona, Spain:Curran Associates Inc.,2016:379-387.
- [18] HU Peiyun, RAMANAN D. Finding tiny faces[C]//2017 IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA:IEEE,2017:1522-1530.
- [19] KONG Tao, SUN Fuchun, YAO Anbang, et al. Ron: reverse connection with objectness prior networks for object detection [C]//IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA:IEEE,2017:2.
- [20] 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. Honolulu, HI, USA:IEEE,2017:4.