

基于深度学习和空间分析的港口识别

李泽明¹, 程亮^{2,3,4,5}, 朱大明^{1*}, 闫兆进^{2,3}, 季辰^{2,3}, 段志鑫^{2,3}, 景旻², 李宁²,
东野升鹏¹, 宋艳若¹, 刘家辉⁶

¹昆明理工大学国土资源工程学院, 云南 昆明 650093;

²南京大学地理与海洋科学学院, 江苏 南京 210023;

³中国南海研究协同创新中心, 江苏 南京 210023;

⁴江苏省地理信息资源开发与利用协同创新中心, 江苏 南京 210023;

⁵江苏省软件新技术与产业化协同创新中心, 江苏 南京 210023;

⁶西南林业大学地理与生态旅游学院, 云南 昆明 650051

摘要 针对港口难以自动识别的问题,在高分辨率可见光遥感影像上将深度学习和地理空间分析相结合,提出了船舶-码头-港口递进式识别模型。首先,对构建的码头样本数据集进行数据增强,并用增强后的数据集来训练 YOLO v3 算法。然后,在大幅遥感影像上利用滑动窗口进行多尺度识别,获取影像底层特征以计算出码头类别和像素坐标。最后,将码头点位转化为地理坐标,使用 Getis-Ord G_i^* 统计方法进行热点分析。并利用经典的密度聚类方法,实现了对港口位置及范围的识别与提取。在实验区中的识别对比结果表明,在 1000 m 聚合阈值下,所提模型对港口识别的比例达到 82.79%。

关键词 遥感; 光学遥感影像; 目标识别; 港口; 码头; YOLO v3; 滑动窗口

中图分类号 TP753

文献标志码 A

doi: 10.3788/LOP202158.2028002

Deep Learning and Spatial Analysis Based Port Detection

Li Zeming¹, Cheng Liang^{2,3,4,5}, Zhu Daming^{1*}, Yan Zhaojin^{2,3}, Ji Chen^{2,3}, Duan Zhixin^{2,3},
Jing Min², Li Ning², Dongye Shengkun¹, Song Yanruo¹, Liu Jiahui⁶

¹ Faculty of Land and Resources Engineering, Kunming University of Science and Technology, Kunming, Yunnan 650093, China;

² School of Geography and Ocean Science, Nanjing University, Nanjing, Jiangsu 210023, China;

³ Collaborative Innovation Center of South China Sea Studies, Nanjing, Jiangsu 210023, China;

⁴ Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application, Nanjing, Jiangsu 210023, China;

⁵ Jiangsu Center for Collaborative Innovation in Novel Software Technology and Industrialization, Nanjing, Jiangsu 210023, China;

⁶ School of Geography and Ecotourism, Southwest Forestry University, Kunming, Yunnan 650051, China

Abstract In view of the difficulty of automatic port recognition, the ship-wharf-port progressive recognition model is proposed by combining deep learning and geospatial analysis on high-resolution visible light remote sensing images. Firstly, the constructed wharf sample data set is enhanced, and the enhanced data set is used to train the

收稿日期: 2020-10-14; 修回日期: 2020-11-26; 录用日期: 2021-01-02

基金项目: 国家重点研发计划项目(2017YFB0504205)

通信作者: *634617255@qq.com

YOLO v3 algorithm. Then, the multi-scale recognition is carried out by the sliding window on the large remote sensing images, and the underlying features of the images are obtained to calculate the wharf categories and pixel coordinates. Finally, the locations of wharves are transformed into geographical coordinates, and the Getis-Ord G_i^* statistical method is used to analyze the hot spots. The classical density clustering method is used to identify and extract the locations and ranges of ports. The recognition comparison results in the experimental area show that the proportion of port basin recognition by improved model reaches 82.79% at aggregated threshold of 1000 m.

Key words remote sensing; optical remote sensing image; target detection; port; wharf; Yolo v3; sliding window
OCIS codes 280.4750; 100.4996; 100.2000

1 引言

港口是一种典型的人造目标,其由一定范围的水域和陆域组成,具有船舶进出、停泊,旅客上下,货物装卸、储存等功能。一方面,港口在交通运输中起到了非常重要的作用。另一方面,其很容易受到自然灾害影响和军事打击。因此,掌握港口的位置信息对经济发展和国防建设都有着重要的意义。

目标识别是指在图像中找出感兴趣目标的位置并且判断其类别。目前,根据识别数据的不同,目标识别可分为在光学影像上的识别和在合成孔径雷达(SAR)影像上的识别。因为 SAR 图像中港口的形状轮廓等特征不容易获取,所以利用基于图像灰度值对比度的算法对在 SAR 影像上的港口进行识别。而光学影像上的形状轮廓特征容易提取,因此常常在高分辨率光学遥感影像上进行港口识别,主要有三种方式:1)根据港口海岸线封闭性来识别港口^[1-2]。2)根据水域中的防洪堤来识别港口^[3]。3)根据码头平行轮廓来识别港口^[4]。这三种方式都是用于提取光学影像上港口的形状轮廓特征的,然后利用机器学习算法加以识别。在机器学习算法识别港口时,需要提取样本中解释性强的特征,但这一过程需要人工进行,且受制于人工经验和知识,进而不能实现自动化的效果。因此,基于深度学习的目标识别的算法诞生了^[5]。

深度学习算法在目标识别领域中的应用,主要基于卷积神经网络,并且根据识别步骤分为一步法和两步法^[6]。两步法是在提取特征后利用选择性搜索方式或者区域生成网络(RPN)进行二分类得到候选区域,然后在候选区域内借助细分类及回归方式来准确识别目标,常见的两步法识别网络有 Faster R-CNN^[7]、R-FCN^[8-9]、FPN^[10]、Cascade R-CNN^[11]等。一步法是在特征图上均匀地进行密集抽样,产生大量的先验框,然后直接进行一次分类和回归操作,就可以识别出目标,常见的一步法识别网络有 YOLO^[12]、SSD^[13]、RetinaNet^[14]、CornerNet^[15]等。

通常,一步法识别速度比两步法要快很多,但识别精度也相对要低。而 YOLO v3 是一步法中的例外,其通过对网络结构和特征尺度的加强,可以在保持识别速度的同时达到较高的精度。

目前深度学习算法已被广泛应用于遥感影像飞机^[16-17]、田径场、机场^[18]、棒球场等形状大小固定、与背景相差明显的目标的识别,且能达到较高的准确率。然而,对于形状大小不固定,与背景较为融合的目标,深度学习的识别效果比较差。港口一般都是基于天然的港湾修建而成的,没有固定的形状特征。由于港口陆上部分与周围房屋和道路很难分辨,并且港口长度不一(大型港口占海岸线几千米长,小型港口只有几百米长),因此港口陆上部分很难直接识别。而码头是港口的重要组成部分,也是港口最为主要的特征,一般为呈突堤状深入港池水域或顺岸邻接水域的构筑物。由于码头在形状上较为统一,大小也不会相差太多,因此其容易被识别。一个港口通常包含多个码头,通过对识别出的码头进行聚类操作可以有效地识别港口。在实际操作中,我们发现船舶停靠的码头与无船停靠的码头特征不统一,并且有船舶停靠的码头更多。但船舶的外型颜色、数量、停泊位置和方向均不相同会导致有船舶停靠的码头较难识别。

本文主要解决在高分辨率光学遥感影像上识别有船舶停靠码头时较难识别的问题,提出了利用滑动窗口改进的多尺度 YOLO v3 算法来回归码头的位置和得分,并利用 Getis-Ord G_i^* 统计方法来分析码头识别结果的空间相关性以确定港口的位置与形状。本文的主要贡献为:1)通过对不同类型码头的样本进行标注生成了码头样本数据集,并利用旋转、翻转、裁切等样本增强方式训练出高精度的码头识别模型;2)提出了结合码头目标识别与空间分析的港口区域提取框架。主要创新为:1)根据船舶-码头-港口关系设计递进式识别模型;2)将 YOLO v3 识别结果转换为地理坐标,实现了算法与实际的结合;3)在深度学习识别基础上,用空间分析的方式提取港口。

2 港口识别模型

2.1 YOLO v3 多尺度滑窗模型

2016 年,Redmon 等^[19]提出了一种基于深度神经网络的对象识别和定位算法,即 YOLO(You Only Look Once),其只需要对图片进行一次浏览就能够识别出图中目标的类别和位置。

2018 年,Redmon 等^[20]提出了 YOLO v3 模型。在 YOLO v3 模型中,将 DarkNet-53 网络作为基础网络^[21],在减小梯度爆炸风险的同时,增强了算法对小目标的识别能力。在 YOLO v3 中,采用类似特征金字塔网络(FPN)的形式^[22],设三个尺度的特征图,每种尺度使用三个锚框进行预测,锚框是根据该尺度的像素中心生成的宽高比和大小都不同的边

界框。根据不同的锚框,利用 YOLO v3 算法对 13×13 、 26×26 和 52×52 三个尺度的特征图做检测,其对不同尺度目标的识别效果提升明显,多尺度预测得到了加强。

图 1 为 YOLO v3 网络结构图。其中,DBL(DarkNetConv2D_BN_Leaky)是 YOLO v3 中的基本单元,由二维卷积(Conv)、归一化、非线性激活函数组成。res 是网络的残差结构,用以提升网络深度,如图中的 res1, res2 等,由零填充、DBL 和 res_unit 组成, res 后面的数字表示这个块里所含的 res_unit 数量。其中, res_unit 部分由张量经过两次 DBL 后的值与原值相加而成。concat 将两个输入的张量进行拼接,改变张量的维度。y1、y2、y3 是网络输出的三个尺度的特征图。

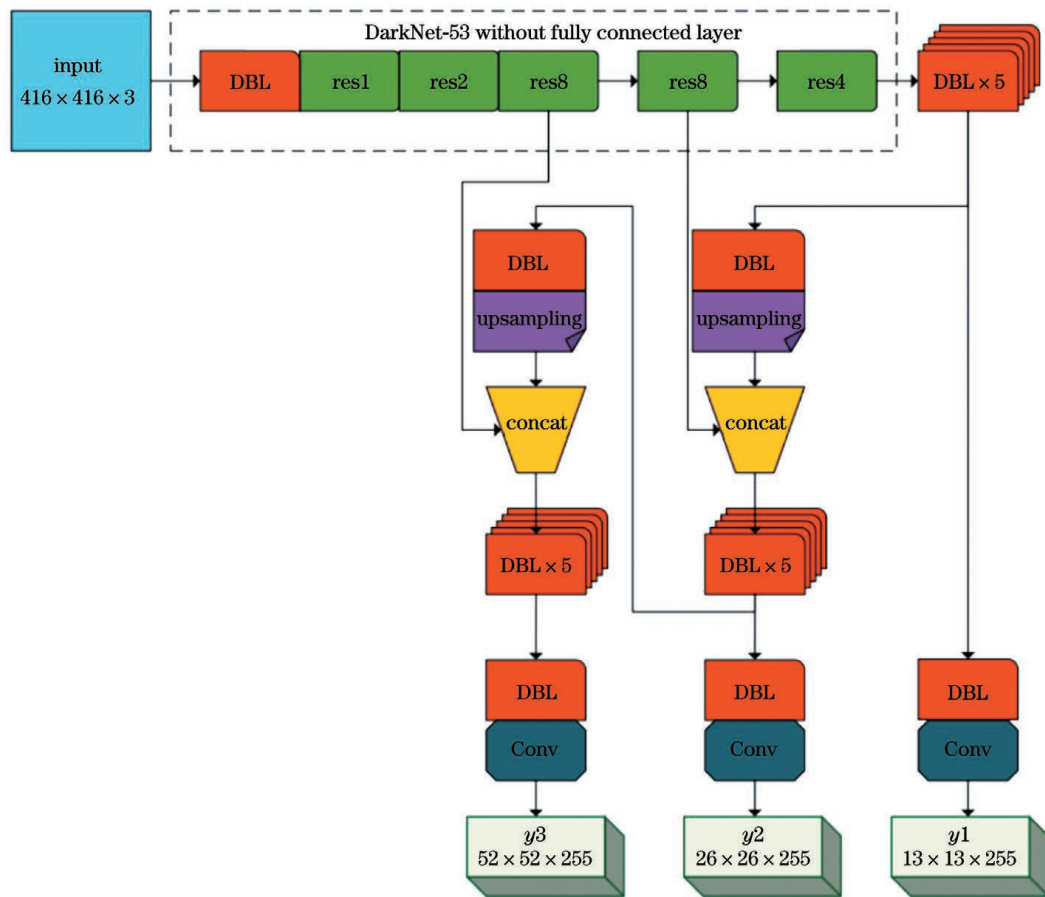


图 1 YOLO v3 网络结构图

Fig. 1 Structural diagram of YOLO v3 network

为了使 YOLO v3 模型适用于码头目标的识别,对其进行了修改。锚框是对训练数据集中的标注框进行聚类分析处理后统计出的一组初始候选框。YOLO v3 模型中原本的锚框是在 COCO 数据集上对标注框进行聚类处理后得到的,每个特征图

尺度对应 3 个锚框,共计 9 个锚框。由于 YOLO v3 网络中原本的锚框架构不适用本研究所采用的训练数据集,因此使用 K-means 算法对数据集标注框进行聚类处理以得到新的锚框。表 1 为锚框调整前后对比。

表 1 锚框调整前后对比

Table 1 Comparison of anchor boxes before and after adjustment

Scale of feature map	Original anchor boxes	New anchor boxes
52×52	10×13; 16×30; 33×23	31×97; 31×30; 47×156
26×26	30×61; 62×45; 59×119	57×49; 85×93; 130×43
13×13	116×90; 156×198; 373×326	164×162; 293×300; 511×511

此外,对 YOLO v3 模型的预训练策略进行了优化。为了使网络初始化效果好,选用具有不同分辨率的遥感影像来建立训练数据集,使模型对不同分辨率的遥感图像都具有稳定的识别效果。在训练过程中使用了多尺度训练技术,将不同尺寸的图像随机分配给网络进行训练,让模型可以适应不同尺寸的遥感图像。

虽然 YOLO v3 模型中增加了多尺度预测,但是其对小目标的识别依然不够准确。为此,本文提出了在 YOLO 框架中加入滑窗,实现更多尺度的识别来增加 YOLO 识别小目标的能力。首先,将输入的原始图片直接作为第一尺度,以识别较大的码头目标。然后,在 YOLO v3 模型中,设定滑动窗口尺寸为 416 pixel×416 pixel,并对图片进行滑窗操作(作为第二尺度),以识别较小的码头,滑动的步长小于滑动窗口的尺寸,设置窗口之间的重叠率为 10%,防止窗口边缘的目标由于切割被忽略。最后,利用非极大值抑制(NMS)方法对两个尺度的预测框进行聚合,并剔除重复的检测框。

2.2 聚类及热点分析

Getis-Ord G_i^* 统计是一种空间自相关方法,其根据距离加权矩阵来探测高值和低值聚集的区域。高值聚集区域为热点,低值聚集区域为冷点。首先,利用 Getis-Ord G_i^* 统计计算要素和一定距离内要素的局部总和。然后,将局部总和与所有要素的总和进行比较。最后,分析属性值在局部空间上的聚集程度。Getis-Ord G_i^* 统计指数(G_i^*)的表达式为

$$G_i^* = \frac{\sum_{j=1}^n W_{ij}(d) X_j}{\sum_{j=1}^n X_j}, \quad (1)$$

式中: n 是要素总数; i 是当前空间单元, $i \in n$; X_j 是第 j 个空间单元的要素属性值,且 $j \neq i$; W_{ij} 是距离 d 内的空间权重矩阵,若第 i 个和第 j 个空间单元之间的距离位于给定的临界距离 d 之内,矩阵对应元素为 1,否则为 0。对 G_i^* 进行标准化, $Z(G_i^*)$

表达式为

$$Z(G_i^*) = \frac{G_i^* - E(G_i^*)}{\sqrt{\text{Var}(G_i^*)}}, \quad (2)$$

式中: $E(G_i^*)$ 为数学期望; $\text{Var}(G_i^*)$ 为变异系数。当 $Z(G_i^*)$ 正显著时,表示空间单元 i 周围的值相对较大,此时为热点区域,反之为冷点区域。以热点区域的点要素为中心设置一定距离的搜索半径,搜索半径内的点如果超过三个,就连接成多边形要素,生成聚类多边形。

2.3 码头样本数据集

首先,使用遥感数据集 TGRS-HRRSD-Dataset 和 DIOR-Dataset 对 YOLO v3 模型进行预训练,得到初步训练模型。然后,利用标注的码头样本数据对模型进行针对性训练。TGRS-HRRSD-Dataset 是用于研究高分辨率遥感图像目标识别的数据集^[23]。DIOR-Dataset 是一种用于光学遥感图像中目标识别的大规模基准数据集^[24],由 2.3463×10^4 幅图像和 1.90288×10^5 个目标实例组成。

因为在码头中,停靠的船舶数量、船舶停靠方向、船舶颜色都会影响识别效果,所以需要尽可能涵盖各种场景下码头特征的样本,来保证模型的普适性。为保证样本覆盖全面,在 19 级 Google 卫星影像上各区域随机标注各式码头样本 1450 张。图 2 展示了不同数据集中的码头标注,图中码头均已被框出。图 2(a)为 DIOR 数据集中的标注效果,图 2(b)为 TGRS-HRRSD 数据集中的标注效果。图 2(c)、2(d)为在 19 级 Google 影像上的标注效果。码头数据集总计包含 3764 张遥感影像,其中 150 张用于测试,3614 张用于训练。

3 实验、分析与讨论

3.1 码头识别实验设计

为了验证本文用深度学习算法训练得到的码头识别模型在高分辨率遥感影像上对码头识别的有效性,设计相关实验对模型的性能进行了验证。

实验使用 DarkNet 网络和 TensorFlow 深度学



图 2 不同数据集中的码头标注。(a)DIOR;(b)TGRS-HRRSD;(c)(d)19 级 Google 遥感影像

Fig. 2 Wharf marking at different datasets. (a) DIOR; (b) TGRS-HRRSD; (c)(d) level 19 Google remote sensing image

习框架,在 2 块 11 GB 的美国英伟达公司生产的 NVIDIA 2080 Ti 显卡上完成训练及测试,CPU 为 10 核心 16 GB 内存的美国英特尔公司生产的 Intel(R) Xeon(R) E5-2620 v4。

数据增强是常用的增加训练数据量,提高模型泛化能力的方式。由于单靠标注难以达到大数据训练的目的,因此使用数据增强的方式来增加数据量。本文中采用几何变换方式来实现数据增强,使用了旋转、翻转及放缩的方式将数据增大了 64 倍。旋转方式是将图片以 45° 进行旋转并加入 $1^\circ \sim 5^\circ$ 的随机变化,数据增大了 8 倍;翻转方式是将图片以竖直方向为轴进行水平方向的翻转,数据增大了 2 倍;放缩方式是以图片中目标位置为中心,分别对目标面积占比 80%、60%、40%、20% 的区域进行裁剪,使目标在图片中所占的比例放大和缩小,数据增大了 4 倍。数据增强后,可供训练的码头数据集共计包含 2.28096×10^5 张遥感影像。

对 YOLO v3 算法的代码及配置文件中必要的参数进行调整,以改善训练效果,需要调整的参数有类别、批尺寸、学习率等。批尺寸是网络单次训练的图片数量,与显存的容量相关,本实验中的批尺寸为 32。学习率是控制网络学习速率的参数。在学习率高的情况下,虽然网络学习速度快,

梯度下降快,但是损失函数会在达到最优解时产生振荡。在学习率低的情况下,虽然梯度下降慢,网络训练时间长,可能会出现过拟合现象,但是损失函数能收敛在最优值附近。因此,将根据梯度下降调控学习率的方式应用于本实验中,设置较高的初始学习率(0.001),当连续几个梯度不再下降时,算法自动调低学习率,最低调至 0.00005,这可以使网络在训练过程中一直保持较优的学习率,更好地完成收敛。

采用准确率(p),召回率(r),F1 得分(F_1),平均精度均值(P_{mAP})等广泛用于评估深度学习模型性能的指标对 YOLO v3 模型进行评价:

$$r = \frac{A_{TP}}{A_{TP} + A_{FN}}, \quad (3)$$

$$p = \frac{A_{TP}}{A_{TP} + A_{FP}}, \quad (4)$$

$$F_1 = 2 \times \frac{p \times r}{p + r}, \quad (5)$$

式中: A_{TP} 表示正确识别码头的检测框个数; A_{FP} 表示被误识别为码头的检测框个数; A_{FN} 表示没有被检测出的码头个数。

计算 mAP 时,先设定交并比 (IoU, A_{IoU}) 阈值为 0.5,统计出标注框的个数(总码头数)为 M 和检测框的个数为 N 。初始化一个二维数组 P_{ij} ($i = 1, \dots, N; j = 1, 2$),第一列存储得分,第二列用于标记检测框是否为正确识别。初始化准确率与召回率结果矩阵 Q_{ij} ($i = 1, \dots, N; j = 1, 2$),第一列存储召回值,第二列存储召回值对应的精度值。计算每张图像中每个检测框与标注框间的 IoU 。当 IoU 小于阈值时,检测框为错误识别,此时 P_{ij} 为 0;否则检测框为正确识别,此时 P_{ij} 为 1:

$$P_{ij} = \begin{cases} 1, & A_{IoU} \geq \text{threshold} \\ 0, & A_{IoU} < \text{threshold} \end{cases} \quad (6)$$

首先,将二维数组 P_{ij} 中第一列预测分数从大到小进行排序(第二列也跟随第一列排序)。然后,计算当前时刻的精确率和召回率,并得到一组 (r_i, p_i) 。接着,将计算得到的结果赋值到 Q_{ij} 的第 i 行。最后,利用 Q_{ij} 绘制可以反应精确率与召回率关系的 PR 曲线。在预留的 150 张测试图像中,共有 396 个码头。YOLO v3 算法识别出了 376 个检测框,其中 370 个正确,6 个错误,进而可得到 $p = 98.4\%$, $r = 93.43\%$ 。图 3 为码头识别 PR 曲线,计算曲线围成的面积,可得到 $P_{mAP} = 93.07\%$ 。

日本是位于亚洲东部,太平洋西岸的岛屿国

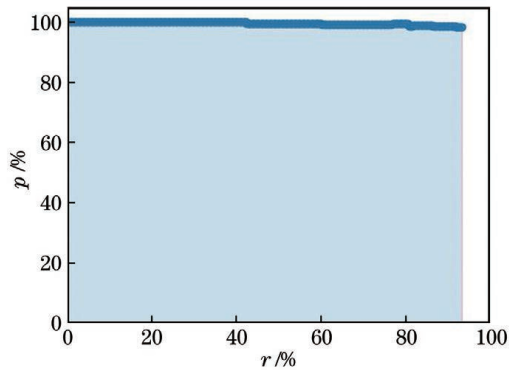


图 3 码头识别 PR 曲线

Fig. 3 PR curve of wharf recognition

家,领土面积约为 $3.7795 \times 10^5 \text{ km}^2$,海岸线总长度约为 $3.3889 \times 10^4 \text{ km}$,其中北海道、本州、四国、九州的海岸线总长度为 $1.924 \times 10^4 \text{ km}$ 。由于日本沿海岸线处港口众多,因此为了更好地验证模型在实际应用中的性能,本文将日本作为实验区域。根据船舶静止点获得靶区,沿靶区下载周围 2 km 缓冲区内的 19 级谷歌地图瓦片,并抽样图片中的 20% 进行目视判别,得到目视判别的准确率和召回率。

表 2 两种模型在实验区中的性能对比

Table 2 Comparison of performances between two models in experimental area

Model	A_{TP}	A_{FP}	A_{FN}	p	r	F_1
Original YOLO v3	125	87	563	58.96%	18.17%	27.78%
Proposed algorithm	364	137	324	72.65%	52.91%	61.23%

图 4 展示了所提模型的码头识别结果。图 4(a) 为原始图像,尺寸为 $7680 \text{ pixel} \times 9472 \text{ pixel}$ 。图 4(b) 为识别到的码头放大后的图像,可以看出所提模型对小目标的识别能力很强。图 4(c)~(h) 为码头识别结果。从图 4(c) 中可以看出,模型对于不同大小,只停靠单艘船舶的码头具有识别能力。从图 4(d) 中可以看出,模型对于较为聚集的目标有一定的识别能力,但会漏掉少数目标。从图 4(e) 中可以看出,在不同海洋颜色以及复杂场景(周围有很多建筑等)情况下,模型对码头目标的识别能力很好。从图 4(f) 中可以看出,在海面存在耀斑的情况下,虽然模型依然可以对码头目标进行识别,但是可能会将一个码头识别为两个或者多个。图 4(g)、(h) 分别显示了突堤式码头和顺岸式码头的识别情况。图 4(i)、(j) 为典型的误识别,主要为船舶、浮箱以及无船停靠的码头和部分防波堤。以上实验结果表明所提算法对有船停靠码头的检测和识别具有良好的鲁棒性和较高的检测率。

3.2 码头识别讨论分析

表 2 为在实验区中,两种模型的性能对比。可以发现,相对于原 YOLO v3 算法,所提算法对于大幅影像上码头的识别能力更强。所提算法的准确率达到 72.65%,比原 YOLO v3 算法的准确率提高了 13.69%;召回率达到 52.91%,比原 YOLO v3 算法召回率提高了 34.74%。出现该现象的原因是:1) YOLO v3 的初始分辨率为 $416 \text{ pixel} \times 416 \text{ pixel}$,而大幅遥感影像分辨率高,一幅尺寸为 $2 \text{ km} \times 2 \text{ km}$ 的影像的分辨率为 $7000 \sim 9000 \text{ pixel} \times 7000 \sim 9000 \text{ pixel}$,当该图直接进入 YOLO v3 网络时会被压缩,进而导致码头目标只占据个位数的像素,极难识别。2) 如果在原 YOLO v3 算法中将影像裁剪识别,又会导致大的码头被切割或者小的码头依然所占像素过少。因此采用多尺度滑窗的方式可以尽可能保证码头的完整性。3) 码头的大小不一,原本的锚框大小不能很好地适配不同大小的码头,使用 K-means 算法重新计算后的锚框对不同大小的码头都具有较好地检测效果。

3.3 地理空间分析与讨论

将实验区检测结果转换为地理坐标,然后进行热点分析,得到码头聚集点位。虽然热点分析可以有效剔除部分误识别的点位以提升港口位置识别的准确率,但是其也可能导致一些仅有一个码头的目标被剔除掉,故可知热点区域就是具有较多码头的大中型港口的位置。设置不同的聚合阈值(500、800、1000、1200、1500 m)来进行热点分析。所选阈值太小时起不到剔除误识别点位的作用,所选阈值太大会导致剔除的点位太多,不同阈值下的热点分析结果如表 3 所示。可以看出,除 500 m 阈值外,港口在热点中占的比例随阈值的增大而增大,出现该现象的原因是随着阈值增大剔除掉的错误识别点更多。在选择 500 m 阈值时之所以港口比例更高,主要是因为大型的港口会因阈值太小被分成几个热点。将不同阈值情况进行对比,可以发现,1000 m 阈值可以在剔除误识别点位的同时保留更多的港口,聚合多边形个数最多。此外,按 1000 m 阈值聚




图 4 码头识别结果。(a)原始图像;(b)局部图像;(c)停靠单艘船舶的码头识别;(d)停靠多艘船舶的码头识别;(e)复杂场景中的码头识别;(f)海面存在耀斑情况下的码头识别;(g)突堤式码头识别;(h)顺岸式码头识别;(i)(j)典型的误识别

Fig. 4 Recognition results of wharves. (a) Original image; (b) local image; (c) recognition of wharf with single ship docked; (d) recognition of wharf with many ships docked; (e) wharf recognition in complex scene; (f) wharf recognition when prescene of flares on sea surface; (g) recognition of jetty wharf; (h) recognition of along-shore wharf; (i)(j) typical misrecognitions

表 3 不同阈值下的热点分析结果

Table 3 Hotspot analysis results under different thresholds

Threshold /m	Number of hotspots	Number of ports	Proportion of ports in hotspots	Number of aggregated polygons
500	2241	1748	78.00%	438
800	1932	1468	75.98%	442
1000	1757	1353	77.01%	465
1200	1617	1261	77.98%	450
1500	1481	1157	78.12%	435

合码头点后生成的 465 个多边形,大部分可以还原出港口港池大概的形状,其他距离约束下难以还原港池形状。经目视验证后,465 个多边形中有 82.79% 可以还原港口港池的形状和位置。

港口热点及聚合多边形如图 5 所示。图 5(a) 中圆点标出了实验区的热点位置。图 5(b)~(e) 为以 1000 米距离为阈值将码头点进行聚合所生成的多边形,可以看出,虽然与原本的港池形状有所差距,但是已经基本还原出港口港池的形状和位置。

4 结 论

针对港口难以有效识别的问题,提出了一种结合深度学习目标识别和地理空间分析识别港口的方法。首先,根据港口目标的知识,分析了其特征,确定了识别的对象为码头。然后,针对码头样本不足的问题,使用样本增强方法对样本进行了扩充。同时,为有效地识别高分辨率遥感影像中有船舶停靠的码头,提出使用滑窗识别方法对 YOLO v3 网络




图 5 (a)港口热点和(b)~(e)聚合多边形

Fig. 5 (a) Port hotspots and (b)–(e) aggregated polygons

进行增强。并且,为解决滑窗识别出现冗余检测框的问题,采用 IoU 算法对检测框进行融合。接着,利用像素地理坐标转换方法将码头识别结果转换为地理坐标。最后,将码头识别地理坐标和地理热点分析相结合,在研究区域内识别出了大中型港口。对 150 张测试样本进行识别时,所提模型的精确率达到 98.4%,召回率达到 93.43%。对实验区的高分辨率遥感影像进行识别的结果表明,所提算法在码头识别实际应用中精确率达到了 72.65%。在 1000 米聚合阈值下,465 个多边形中有 82.79% 可以基本还原港池的形状和位置。

深度学习目标识别算法和空间分析算法的结合是提高目标识别准确度的一种重要方式。所提模型会受到遥感影像成像情况、背景情况以及停靠船舶数量密集程度的影响,故存在误识别和未识别的情况。后续我们将进行技术和算法的改良来解决上述问题。

参 考 文 献

- [1] Zhang Z L, Zhang Y, Shen Z K. Port recognition in high resolution remote sensing images based on feature spectrum[J]. Acta Electronica Sinica, 2010, 38(9): 2184-2188.
张志龙, 张焱, 沈振康. 基于特征谱的高分辨率遥感图像港口识别方法[J]. 电子学报, 2010, 38(9): 2184-2188.
- [2] Zhu B, Li J Z, Chen A J. Fast knowledge based recognition of harbor target[J]. Journal of Computer Applications, 2006, 26(3): 729-732.
朱兵, 李金宗, 陈爱军. 基于知识的快速港口识别[J]. 计算机应用, 2006, 26(3): 729-732.
- [3] Chen Q, Wang N, Zhao L J, et al. Harbor detection of remote sensing images based on model[C]//2010 2nd International Conference on Future Computer and Communication, May 21-24, 2010, Wuhan, China. New York: IEEE Press, 2010: V1-322.
- [4] Liu C, Xiao Y Y, Yang J, et al. Harbor detection in polarimetric SAR images based on the characteristics of parallel curves[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(10): 1400-1404.
- [5] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [6] Duan Z J, Li S B, Hu J J, et al. Review of deep learning based object detection methods and their mainstream frameworks [J]. Laser & Optoelectronics Progress, 2020, 57(12): 120005.
段仲静, 李少波, 胡建军, 等. 深度学习目标检测方法及其主流框架综述[J]. 激光与光电子学进展, 2020, 57(12): 120005.
- [7] Zhou B, Li R X, Shang Z H, et al. Object detection algorithm based on improved Faster R-CNN [J]. Laser & Optoelectronics Progress, 2020, 57(10): 101009.
周兵, 李润鑫, 尚振宏, 等. 基于改进的 Faster R-CNN 目标检测算法[J]. 激光与光电子学进展, 2020, 57(10): 101009.
- [8] Dai J F, Li Y, He K M, et al. R-FCN: object detection via region-based fully convolutional networks [EB/OL]. (2016-05-20) [2020-10-10]. <https://arxiv.org/abs/1605.06409>.
- [9] Wang J L, Lü X Q, Zhang M, et al. Remote sensing image ship detection based on improved R-FCN [J]. Laser & Optoelectronics Progress, 2019, 56(16): 162803.
王健林, 吕晓琪, 张明, 等. 基于改进 R-FCN 的遥感图像舰船检测[J]. 激光与光电子学进展, 2019, 56(16): 162803.
- [10] Ghiasi G, Lin T Y, Le Q V. NAS-FPN: learning

- scalable feature pyramid architecture for object detection[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 7029-7038.
- [11] Cai Z W, Vasconcelos N. Cascade R-CNN: delving into high quality object detection [C] //2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 6154-6162.
- [12] Liu Y Q, Feng J K, Xing B W, et al. Water surface object detection based on deep learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181502.
刘雨青, 冯俊凯, 邢博闻, 等. 基于深度学习的水面目标检测[J]. *激光与光电子学进展*, 2020, 57(18): 181502.
- [13] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9905: 21-37.
- [14] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection [C] //2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2999-3007.
- [15] Law H, Deng J. CornerNet: detecting objects as paired keypoints[J]. *International Journal of Computer Vision*, 2020, 128(3): 642-656.
- [16] Dai W C, Jin L X, Li G N, et al. Real-time airplane detection algorithm in remote-sensing images based on improved YOLOv3[J]. *Opto-Electronic Engineering*, 2018, 45(12): 84-92.
戴伟聪, 金龙旭, 李国宁, 等. 遥感图像中飞机的改进 YOLOv3 实时检测算法[J]. *光电工程*, 2018, 45(12): 84-92.
- [17] Dong Y F, Zhang C T, Wang P, et al. Airplane detection of optical remote sensing images based on deep learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041007.
董永峰, 仇长涛, 汪鹏, 等. 基于深度学习的光学遥感图像飞机检测算法[J]. *激光与光电子学进展*, 2020, 57(4): 041007.
- [18] Chen F, Ren R L, van de Voorde T, et al. Fast automatic airport detection in remote sensing images using convolutional neural networks [J]. *Remote Sensing*, 2018, 10(3): 443.
- [19] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C] //2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [20] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-08-08)[2020-10-10]. <https://arxiv.org/abs/1804.02767>.
- [21] Li C Y, Yao J M, Lin Z X, et al. Object detection method based on improved YOLO lightweight network [J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141003.
李成跃, 姚剑敏, 林志贤, 等. 基于改进 YOLO 轻量化网络的目标检测方法[J]. *激光与光电子学进展*, 2020, 57(14): 141003.
- [22] Guo J X, Liu L B, Xu F, et al. Airport scene aircraft detection method based on YOLO v3[J]. *Laser & Optoelectronics Progress*, 2019, 56(19): 191003.
郭进祥, 刘立波, 徐峰, 等. 基于 YOLO v3 的机场场面飞机检测方法[J]. *激光与光电子学进展*, 2019, 56(19): 191003.
- [23] Zhang Y L, Yuan Y, Feng Y C, et al. Hierarchical and robust convolutional neural network for very high-resolution remote sensing object detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5535-5548.
- [24] Li K, Wan G, Cheng G, et al. Object detection in optical remote sensing images: a survey and a new benchmark [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 159: 296-307.