

海上船舶融合识别算法研究与改进

王小虎[✉]

(中国能源建设集团广东省电力设计研究院有限公司, 广东 广州 510663)

摘要: [目的] 目前, 我国海上风电平台对于附近船舶的监控手段主要是船舶 AIS (Automatic Identification System) 系统以及远程摄像头, 这种缺乏信息化技术的手段往往需要耗费大量的人力、物力。为了能有效预警海上风电平台附近的船舶, 文章分析了目前对于海上船舶识别任务所存在的亟待解决的问题, 提出一种结合改进型 Faster-RCNN 网络以及船舶 AIS 信息的海上船舶融合检测算法。[方法] 首先, 提出 Fast-RCNN 模型 3 个方面的改进意见, 对传统 Faster-RCNN 模型进行特征提取网络, 对主干网络以及损失函数等结构进行调整; 其次, 基于改进型 Faster-RCNN 网络对远程摄像头拍摄的图片进行船舶检测, 并结合船舶 AIS 系统相关信息对结果进行补充与校正; 最后, 根据模型训练过程保存的最优模型在验证集上进行测试, 采用查准率、查全率以及平均准确率指标对各个模型进行评价。[结果] 不同特征提取网络、分类损失函数的 Faster-RCNN 模型推理速度及精度得到了较大提升; 海上风电平台对于船舶的监控能力得到改善; 结合船舶 AIS 系统对海上船舶信息进行处理并获取其航行轨迹, 实现了对远程摄像头拍摄图片中的船舶的检测。[结论] 实验表明, 对传统 Faster-RCNN 进行特征提取网络以及分类损失函数的替换, 能够有效提升该网络在船舶识别任务中的检测精度, 并且通过融合船舶 AIS 系统能够有效获取船舶的运行轨迹。

关键词: Faster-RCNN; 风电平台; 海上船舶; AIS; 识别

中图分类号: TK89; TP751

文献标志码: A

文章编号: 2095-8676(2023)04-0131-07

开放科学(资源服务)二维码:



Research and Improvement of Offshore Ship Fusion Recognition Algorithm

WANG Xiaohu[✉]

(China Energy Engineering Group Guangdong Electric Power Design Institute Co., Ltd., Guangzhou 510663, Guangdong, China)

Abstract: [Introduction] At present in China, the ships near offshore wind power platforms are mainly monitored by means of the ship AIS system and remote cameras. Such means lacking information technology often require a lot of manpower and material resources. In order to effectively warn the ships near the offshore wind power platform, this paper analyzes the urgent problems to be solved that are encountered in the current offshore ship identification, and proposes an offshore ship fusion recognition algorithm that combines the improved Faster-RCNN network and ship AIS system. [Method] Firstly, improvement suggestions were proposed for three aspects of the Fast-RCNN model, and the structures such as the backbone network and the loss function were adjusted. Secondly, the ships in the pictures taken by the remote cameras were detected by the improved Faster-RCNN network, and the results were supplemented and corrected in combination with the relevant information from the ship AIS system. Finally, the verification sets were tested according to the optimal model saved in the model training process, and each model was evaluated using the indicators of precision, recall and average precision. [Result] The Faster-RCNN model inference speed and accuracy for different feature extraction networks and classification loss functions are improved greatly. The ability of offshore wind power platforms to monitor ships is improved. The offshore ship information was processed and the navigation trajectory was obtained in combination with the ship AIS system, realizing the detection of the ships in the pictures taken by the remote cameras. [Conclusion] Experiments show that the feature extraction network and the replacement of the classification loss function of the traditional Faster-RCNN can effectively improve the detection accuracy of the network in the ship recognition task and the ship trajectory can be effectively obtained by integrating the ship AIS system.

Key words: Faster-RCNN; wind power platform; offshore ship; automatic identification system; identification

收稿日期: 2022-08-08 修回日期: 2022-11-17

基金项目: 中电工程重大专项项目“基于物联网技术的风电控制系统研发可行性研究”(ER10381W)

2095-8676 © 2023 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI. This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

0 引言

海上风电平台一般位于水深 10 m 左右的近海,相较于陆地风电,其具有不受地形地貌影响、风能资源丰富等优点。但是由于大部分风电平台位于渔业资源丰富、经济发达的区域,这些区域通常航线繁忙、船只众多,这给风电平台的安全运行带来了极大的隐患。因此,风电平台需要对所在海域的舰艇、商船、外轮等舰船进行监控与识别,以避免这些目标在作业期间对海缆设施的损坏。如何全面统筹设计、施工、运营及日后运维阶段的船舶进行管理、指挥、调度,是海上风电领域的新课题^[1-2]。

而对于目前普遍的海上风电平台,船舶 AIS (Automatic Identification System) 以及远距摄像头进行监控,但是 AIS 方法对于未安装或打开该系统的船只进行识别,而远距摄像头获取的图像信息需要大量的人力进行监控,这样导致整个风电平台的监控系统不够智能化,错过最佳预警时期,导致事故的发生^[3-4]。因此本文旨在设计一种融合计算机视觉与船舶 AIS 系统的海上船舶融合识别算法,该算法基于改进型 Faster-RCNN 对远距摄像头拍摄的图片进行船舶检测,并结合船舶 AIS 系统相关信息对结果进行补充与校正,以提升海上风电平台对于过往船只的监控能力,保障其安全运行。

随着神经网络的发展,基于深度学习的图像识别算法在目标检测、图像分割等领域得到了广泛的应用,在船舶识别任务上,国内外研究者也将深度学习应用到了该领域,并取得了一定的成果。

在深度学习方面,刘硕等^[5]提出了一种基于改进型 SSD 算法对船舶进行识别,在该方法中对传统的 SSD 网络第 7 层添加了 L2 正则化,以此均衡该网络中各个卷积层的参数,提高了对于图像中船舶的检测能力;郭延华等^[6]则提出了一种基于极端尺度变化的船舶识别方法,该方法利用多尺度特征融合进行深层的语义提取,并在后续的网络中使用了先验框以及调制损失函数等策略进一步提升了背景的区分度以及模型识别效率;对于遥感图像,陈会伟等^[7]提出了一种基于超尺度自导注意力(Hyper-Scale Self-Guided Attention Networks, HSSGAN)的遥

感船舶识别网络,该网络中使用了自导注意力机制逐步细化超尺度特征图,并建立了超尺度局部与全局语义之间的联系,最后通过忽略不相关信息及聚合相关特征的方式提升整体网络的识别精度。

在船舶 AIS 方面,周雪芳等^[8]提出了一种针对复杂环境下的船舶 AIS 大数据处理算法,该算法采用分布式架构对船舶 AIS 数据进行报文解析处理,并利用云计算节点对船舶 AIS 数据进行计算并保存至分布式数据库;牟军敏等^[9]提出了一种基于 Hausdorff 距离的船舶轨迹识别方法,该方法首先利用(Douglas-Peucker, DP)算法对船舶 AIS 数据进行预处理,并基于 Hausdorff 距离设计了尺度参数的相似度测量方法,通过相似度举证对船舶轨迹进行区分,该方法对于船舶的航路识别以及海事监管都具有较大意义;杨源等^[10]建立了国内首个海上风电场智能船舶调度及人员管理系统,对海上风电场的人员、船舶进行管理、指挥、调度。

根据上文对于国内外研究者的相关研究内容,可以总结出目前对于海上船舶识别任务还有以下两个较大的问题亟待解决:(1)由于海上风电平台采用远距摄像头进行拍摄图像,导致图像中大部分船舶的尺寸较小,而目前大部分目标检测网络对于小目标的检测与识别效率较低;(2)目前大部分海上船舶识别方法采用单一的目标检测方法,导致该任务的精度存在瓶颈。针对上述问题,本文提出了一种结合改进型 Faster-RCNN 网络以及船舶 AIS 信息的海上船舶融合检测算法,首先对 Faster-RCNN 的主干网络以及损失函数等结构进行了调整,改善目前海上风电平台对于船舶的监控能力。

1 Faster-RCNN 模型与改进

RCNN(Region Convolutional Neural Network)是第 1 个将卷积神经网络(CNN)引入到目标领域的算法,在该算法中主要思想是通过大量的候选区域(Region Proposals)进行计算,并利用 SVM 分类器以及回归器获得目标的精准位置,这样的方法虽然相较于其他方法有加大的提升,但是计算量十分巨大。因此该团队提出了 Fast-RCNN 模型 3 个方面的改进:(1)将整张图片归一化处理送入网络,解决 RCNN 中

候选区域大量的冗余计算问题; (2) 在整幅图上提取候选区域, 并且该候选区域的前几层特征不需要重复计算, 这大大减少了训练时间; (3) 把类别判断和位置精调统一用深度网络实现, 降低了网络训练过程的存储空间^[11]。而 Faster-RCNN 则是该团队的又一力作, 在推理速度以及精度方面均有较大提升, 因此本文采用该网络模型作为深度学习船舶图像识别方法的基础网络, 下面对该网络进行详细的介绍。

1.1 Faster-RCNN 概述

Faster-RCNN 的网络结构可以分为 4 个部分, 如图 1 所示。第一部分, 卷积层(Conv layers), 即特征提取网络, 在原网络中采用 VGG16 进行特征提取, 用于后续 RPN 层的输入^[12]。第二部分, 区域候选网络(Region Proposal Network, RPN), 该网络结构有两个任务: (1) 判断所有的 anchor 内是否有目标; (2) 修正 anchor 得到较为准确的候选区域。第三部分对感兴趣区域的池化(ROI Pooling), 用于对 RPN 网络输出的候选区域进行收集, 并结合特征提取网络的输出(feature map)送入全连接层进行分类处理。第四部分分类与回归(Classification and Regression), 利用商议结构的输出计算出具体类别。




图 1 Faster RCNN 网络结构

Fig. 1 Faster RCNN network structure

RPN 结构作为 Faster-RCNN 网络中最为重要的结构, 损失计算同样包括分类损失以及边界损失 2

个部分, 如公式 1~公式 3 所示。

$$L(\{p_i\}, \{t_i\}) = L_{\text{cls}} + \lambda L_{\text{reg}} \quad (1)$$

$$L_{\text{cls}} = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i^*, p_i^*) \quad (2)$$

$$L_{\text{reg}} = \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (3)$$

式中:

p_i ——第 i 个 anchor 预测为真实标签的概率;

p_i^* ——正样本时为 1, 负样本为 0;

t_i ——预测第 i 个 anchor 的边界框回归参数;

t_i^* ——第 i 个 anchor 对应的 GT box;

N_{cls} ——1 个 mini-batch 中所有样本数量, 即 256↑;

N_{reg} ——anchor 位置的个数, 约 2 400↑。

1.2 Backbone 网络替换

原始 Faster-RCNN 网络中采用 VGG16 作为特征提取网络(backbone), 但是由于其特殊的网络结构导致了大量冗余的网络参数, 同时在训练过程中导致出现过拟合现象, 虽然该网络在 2 只 3 次卷积后会通过最大池化下采样对网络复杂度, 但是随着网络层数的加深, 多次的池化操作会使得特征图的分辨率降低, 从而导致网络对于小目标的检测能力降低。因此在本文中采用 ResNet、ResNeXt 以及 MobileNetV2 网络对 VGG16 进行替换。

ResNet 的核心思想为残差结构, 即通过残差网络增加一个恒等映射, 跳过本层或多层运算, 同时后向传播过程中, 下一层网络梯度直接传递给上一层, 有效改善了深层网络梯度消失的问题^[13]。ResNet 共包含 5 个 stage, 其中 stage 0 由 1 个卷积层组成, 主要负责对输入的预处理, 而后续 4 个 stage 主要由多个 bottleneck 组成, 负责输入的特征提取, 最后通过 softmax 层进行展平处理。

ResNeXt 网络结合了 VGG、ResNet 和 Inception 3 个经典网络的优秀特性, 该网络的 bottleneck 是从 ResNet 网络中衍生而来, 如图 2 所示。这样的结构能够有效解决由于网络层数增加而引起的退化问题, 并且由于 cardinality 基数的使用可以在降低超参数复杂度的同时保证网络的准确度^[14]。

MobileNet 的核心思想为深度可分离卷积, 该网络折中了网络精度以及网络运行速度方面的性能。

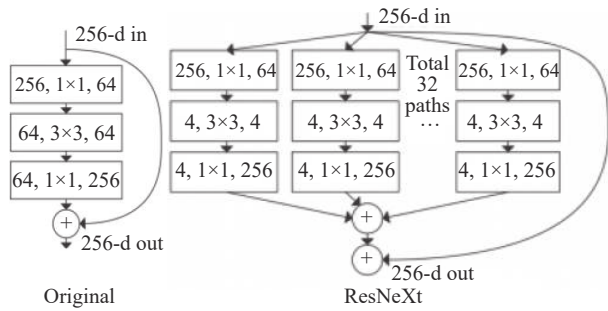


图 2 ResNet 与 ResNeXt 网络 bottleneck 结构
Fig. 2 ResNet and ResNeXt network bottleneck structure

深度可分离卷积相较于标准卷积将所有卷积核作用到所有 channel 中有所不同,它针对每一个输入的 channel 都有不同的卷积核,卷积核尺寸为 1×1。这样的卷积方式与标准卷积由相同的感受野,但是大大地减少了模型的计算量和参数量^[15]。如图 3 所示,在 MobileNetV2 中使用了倒残差结构,并且使用了 ReLU6 作为激活函数避免低维特征信息的损失。

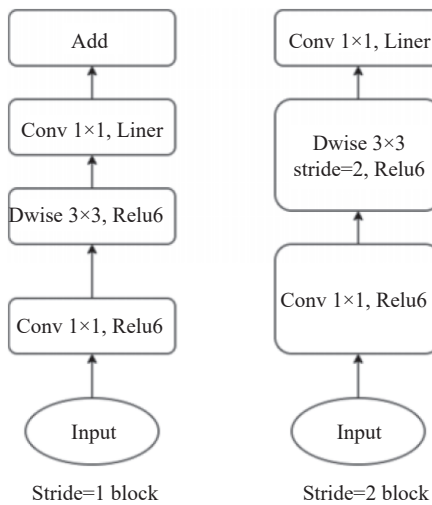


图 3 MobileNetV2 中的倒残差结构
Fig. 3 Inverted residual structure in MobileNetV2

1.3 损失函数

Lin 等^[16]在密集目标检测(Dense Object Detection)任务中发现一个主要问题是前景和背景类之间的不平衡,为了解决该问题作者提出了一种新的损失函数——焦点损失函数(Focal Loss Function),它是对交叉熵损失(Entropy Loss)的一种修正,目的是在模型能够很好地分类的例子中减少损失的权重。在船舶识别任务中,我们在 Faster-RCNN 网络最后的分类阶段使用了该损失函数。焦点损失的计算方式如

式 4 所示。

$$p_t = \begin{cases} p & \text{if } y = 1 \\ 1 - p & \text{otherwise} \end{cases} \quad (4)$$

$$L_f = -(1 - p_t)^\gamma \log(p_t) \quad (5)$$

式中:

- p_t ——与 ground truth 即类别 y 的接近程度;
- L_f ——focal loss 焦点损失;
- p ——预测概率大小。

2 船舶 AIS 信息处理

船舶 AIS 系统是一种强制安装在一定吨位以上的船只上的定位识别系统。通过计算机视觉的图像方法能够识别海上风电平台附近约 5 km 以内的船舶目标,而船舶 AIS 系统的作用距离约为 30 km,因此可以采用该系统作为海上船舶检测补充方法,设计了更加全面的雷达-光电海上船舶融合监控系统。

2.1 技术方案

- 1)使用高精度独立内部时钟的采集卡,保证信号采集的同步,以获得更精准稳定的回波位置。
- 2)使用基于 SWEEP 的处理方法,结合先跟踪后探测、非恒定自适应门限等算法实现了快速的全量程全自动跟踪^[17]。目标跟踪器每个天线周扫对目标实际位置参数进行更新,同时基于位置预测推算算法,软件内部每 1/8 周扫就对目标参数进行更新,几乎达到了对目标跟踪的实时处理。因此,多个雷达、多个跟踪器可以在近似同一时间得到近似相同的目标参数。

3)为了弥补雷达盲区,相邻雷达覆盖区域均有重叠。对于传感器目标会存在目标重合问题,需要对目标进行融合,融合时可能出现非同一目标的融合而造成目标缺失,相同目标的不融合造成目标重复。本系统采用多信息源目标融合技术,根据目标的多特性判断是否为同一目标进行融合。

2.2 数据处理

数据处理模块即对雷达采集原始船舶 AIS 数据进行处理并且能够在任何杂波和噪声环境条件下可靠地检测和跟踪目标。

在目标检测和跟踪处理过程中,采用了 TBD(Track Before Detection)算法技术,TBD 技术较之以前普遍

采用的 TWS(Track while SCAN)目标检测跟踪技术相比有自己独特的优势,集中体现在信噪比小于1的强干扰背景环境下发现掌握跟踪目标的能力上。该算法的跟踪器将每圈扫描得到的上千个回波(点)都当作“候选目标”进行存储,再采用一个视频门限降低噪声等级,再在后边的几圈中对这些“候选目标”进行确认,由于海杂波、雨杂波以及系统噪声的存在,这些“候选对象”更像虚假目标。正常情况下,候选目标是真实目标的数倍,系统直到质量标准积累到或概率达到预定的标准才将其转为真实目标送至雷达显示器显示。

2.3 显示与控制

显示及控制部分是整个系统中的主要用户管理操作界面,能够使得操作员获得系统中的所有信息,并有能力对系统功能进行控制,如图4所示。

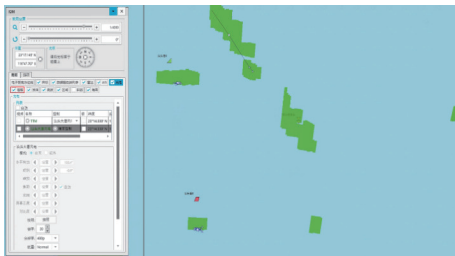


图4 显控终端示意图

Fig. 4 Schematic diagram of display and control terminal

软件系统是以 Microsoft Windows 为基础的,操作员的操作界面设计是使用了 Windows 的功能性如多重窗口,菜单,子菜单,工具栏等特点,并且所有的窗口可以自由的移动或隐藏。

3 试验过程与结果

3.1 数据集

对于海上船舶检测任务,目前大部分算法的数据集是卫星拍摄海面的 SAR 图像,由于本次任务采用光学摄像头拍摄船舶照片并且进行检测,因此这些数据集并不适用于本次船舶检测任务。针对上述问题,本文自制了一款包含约 5 000 张的光学摄像头拍摄的船舶图像,这些图像的来源包括:(1)海上风电平台拍摄的船舶图像;(2)通过爬虫技术获取的网络图像。利用 labelImg 软件完成对图像中船舶位置的标记,训练集、验证集及测试集按照 7 : 2 : 1 的比例进行划分^[18]。本文数据集部分典型示例如图5所示。



图5 船舶部分数据集

Fig. 5 Partial ship data sets

3.2 数据预处理

为了使得模型能够取得更好的效果,在训练过程中采用了多种方式进行数据增强。这些数据增强方式包括:(1)以 0.5 的概率进行水平方向的翻转;(2)随机裁剪一个 400×400 的区域,并在训练期间将其调整为 800×800 。这样的方式是为了让小目标能够占据图像的较大区域^[19]。

3.3 模型训练

本文首先采用 Pytorch 框架搭建网络,利用 GPU 平台对训练过程进行加速。在训练过程中,首先采用迁移学习的方式分别载入 MobileNetV2、ResNet50 以及 ResNetXt101 网络在 ImageNet 数据集上预训练权重,训练过程分为 2 个部分:前 5 个 epoch 的训练中,首先冻结前置特征提取网络权重(backbone),训练 RPN 以及最终预测网络部分;而在后续的 epoch 训练过程中,解冻前置特征提取网络权重(backbone),接着训练整个网络权重。同时在训练过程中,学习率采用 SGD 优化策略,anchor 尺寸设置为 (32, 64, 128, 256, 512),当训练过程的损失趋于稳定后保存对于模型并进行测试。

3.4 实验结果

根据模型训练过程保存的最优模型在验证集上进行测试,采用查准率(Precision)、查全率(Recall)以及平均准确率(Average Precision, AP)指标对各个


模型进行评价,其中查询率表示模型检测的正样本数量占真实正样本的比例,而查准率表示模型检测全目标中真实正样本的比例,而平均准确率表示 P - R 曲线的面积。针对不同特征提取网络、分类损失函数的 Faster-RCNN 网络的精度如表 1 所示。

表 1 各项参数改变对网络性能的影响
Tab. 1 Influence of various parameter changes on network performance


backbone	class loss	mAP/%	Precision/%	Recall/%
VGG16(传统结构)	entropy loss	79.44	74.23	74.04
	focal loss	81.38	76.42	76.35
ResNet50	entropy loss	80.92	75.79	75.63
	focal loss	81.26	76.37	76.28
MobileNetV2	entropy loss	83.69	79.20	79.08
	focal loss	84.83	79.89	79.63

3.5 算法效果

采用训练好的模型,对数据集中部分数据进行验证与测试,网络对于该任务的识别效果如图 6 所示,其中图 6(a)为船舶正面识别效果,图 6(b)为侧面识别效果,该模型能够对图像中的船舶进行识别并将标注位置以及概率。



(a) 船舶正面



(b) 船舶侧面

图 6 船舶识别效果示意图

Fig. 6 Schematic diagram of ship identification effect

根据船舶 AIS 系统数据处理方法以及相关软件要求,通过对船舶 AIS 数据进行处理后得到船舶的轨迹如图 7 所示,可显示目标的历史轨迹点和线,间隔时间可调,每个历史轨迹点都有时间和位置信息。



图 7 船舶轨迹图

Fig. 7 Ship trajectory chart

4 结论

海上风电的发展风生水起,但海上风电安全管理仍有所欠缺,安全管理处于风口浪尖^[20]。根据文章的实验结果可知,本文所提出的海上船舶融合检测方法是有效的。通过对传统 Faster-RCNN 的特征提取网络以及分类损失函数进行改进,该网络在船舶识别任务上的精度得到了约 5% mAP 的性能提升,同时结合船舶 AIS 数据对其航行轨迹进行了可视化分析,有效地解决了海上风电平台对于附近船舶进行监控的需求。

参考文献:

- [1] 国家能源局. 风电场工程 110 kV~220 kV 海上升压变电站设计规范: NB/T 31115—2017 [S]. 北京: 中国电力出版社, 2017.
National Energy Board. Code for 110 kV~220 kV offshore substation design of wind power projects: NB/T 31115—2017 [S]. Beijing: China Electric Power Press, 2017.
- [2] 中华人民共和国住房和城乡建设部. 海上风力发电场设计标准: GB/T 51308—2019 [S]. 北京: 中国计划出版社, 2019.
Ministry of Housing and Urban-Rural Development of the People's Republic of China. Standard for design of offshore wind farm: GB/T 51308—2019 [S]. Beijing: China Planning Press, 2019.
- [3] XIAO F L, LIGTERINGEN H, VAN GULIJK C, et al. Comparison study on AIS data of ship traffic behavior [J]. *Ocean engineering*, 2015, 95: 84-93. DOI: 10.1016/j.oceaneng.2014.11.020.
- [4] 徐志伟. 海上风电升压站平台设计及有限元计算分析 [J]. *内蒙古电力技术*, 2022, 40(1): 44-48. DOI: 10.19929/j.cnki.nmgdljs.2022.0009.
XU Z W. Design and finite element analysis of offshore wind

- power booster station platform [J]. *Inner Mongolia electric power*, 2022, 40(1): 44-48. DOI: 10.19929/j.cnki.nmgdljs.2022.0009.
- [5] 刘硕, 葛愿, 李媛媛, 等. 基于改进SSD的无人船海上船舶识别算法 [J]. *传感器与微系统*, 2021, 40(2): 120-123. DOI: 10.13873/J.1000-9787(2021)02-0120-04.
LIU S, GE Y, LI Y Y, et al. Recognition algorithm of unmanned ship at sea based on improved SSD [J]. *Transducer and microsystem technologies*, 2021, 40(2): 120-123. DOI: 10.13873/J.1000-9787(2021)02-0120-04.
- [6] 郭延华, 孙磊, 马世超, 等. 一种基于极端尺度变化的船舶识别方法研究 [J]. *计算机应用与软件*, 2021, 38(1): 171-178. DOI: 10.3969/j.issn.1000-386x.2021.01.029.
GUO Y H, SUN L, MA S C, et al. A boat recognition method based on extreme scale variation [J]. *Computer applications and software*, 2021, 38(1): 171-178. DOI: 10.3969/j.issn.1000-386x.2021.01.029.
- [7] 陈会伟, 刘树美, 刘培学, 等. 超尺度自导注意力网络的遥感船舶识别 [J]. *计算机工程*, 2021, 47(10): 314-320. DOI: 10.19678/j.issn.1000-3428.0058993.
CHEN H W, LIU S M, LIU P X, et al. Remote sensing ship recognition based on hyper-scale self-guided attention networks [J]. *Computer engineering*, 2021, 47(10): 314-320. DOI: 10.19678/j.issn.1000-3428.0058993.
- [8] 周雪芳, 刘树龙, 周海龙. 复杂环境中高可用船舶AIS大数据信息处理方法 [J]. *舰船科学技术*, 2022, 44(6): 137-140. DOI: 10.3404/j.issn.1672-7649.2022.06.028.
ZHOU X F, LIU S L, ZHOU H L. High-availability ship AIS big data information processing method in complex environment [J]. *Ship science and technology*, 2022, 44(6): 137-140. DOI: 10.3404/j.issn.1672-7649.2022.06.028.
- [9] 牟军敏, 陈鹏飞, 贺益雄, 等. 船舶AIS轨迹快速自适应谱聚类算法 [J]. *哈尔滨工程大学学报*, 2018, 39(3): 428-432. DOI: 10.11990/jheu.201609033.
MOU J M, CHEN P F, HE Y X, et al. Fast self-tuning spectral clustering algorithm for AIS ship trajectory [J]. *Journal of Harbin engineering university*, 2018, 39(3): 428-432. DOI: 10.11990/jheu.201609033.
- [10] 杨源, 阳熹, 汪少勇, 等. 海上风电场智能船舶调度及人员管理系统 [J]. *南方能源建设*, 2020, 7(1): 47-52. DOI: 10.16516/j.gedi.issn2095-8676.2020.01.007.
YANG Y, YANG X, WANG S Y, et al. Scheme design of intelligent vessel dispatching and personnel management system for offshore wind farm [J]. *Southern energy construction*, 2020, 7(1): 47-52. DOI: 10.16516/j.gedi.issn2095-8676.2020.01.007.
- [11] CHEN Y, LI W, SAKARIDIS C, et al. Domain adaptive faster R-CNN for object detection in the wild [C]//Anon. Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, June 28-23, 2018. New York: IEEE, 2018: 3339-3348. DOI: 10.1109/CVPR.2018.00352.
- [12] 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. DOI: 10.1109/TPAMI.2016.2577031.
- [13] WU Z F, SHEN C H, VAN DEN HENGEL A. Wider or deeper: revisiting the ResNet model for visual recognition [J]. *Pattern recognition*, 2019, 90: 119-133. DOI: 10.1016/j.patcog.2019.01.006.
- [14] 蒋圣南, 陈恩庆, 郑铭耀, 等. 基于ResNeXt的人体动作识别 [J]. *图学学报*, 2020, 41(2): 277-282. DOI: 10.11996/JG.j.2095-302X.2020020277.
JIANG S N, CHEN E Q, ZHENG M Y, et al. Human action recognition based on ResNeXt [J]. *Journal of graphics*, 2020, 41(2): 277-282. DOI: 10.11996/JG.j.2095-302X.2020020277.
- [15] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//Anon. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, June 18-23, 2018. New York: IEEE, 2018: 4510-4520. DOI: 10.1109/cvpr.2018.00474.
- [16] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2020, 42(2): 318-327. DOI: 10.1109/TPAMI.2018.2858826.
- [17] 郭浩, 张晰, 安居白, 等. 基于船舶AIS信息的可疑船只监测研究 [J]. *交通信息与安全*, 2013, 31(4): 67-72. DOI: 10.3963/j.issn.1674-4861.2013.04.015.
GUO H, ZHANG X, AN J B, et al. Monitoring of intrusive vessels based on an automatic identification system (AIS) [J]. *Journal of transport information and safety*, 2013, 31(4): 67-72. DOI: 10.3963/j.issn.1674-4861.2013.04.015.
- [18] PURI D. COCO dataset stuff segmentation challenge [C]//Anon. 2019 5th International Conference on Computing, Communication, Control and Automation (ICCUBEA), Pune, India, September 19-21, 2019. New York: IEEE, 2019: 1-5. DOI: 10.1109/ICCUBEA47591.2019.9129255.
- [19] WU C L, CHAU K W, FAN C. Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques [J]. *Journal of hydrology*, 2010, 389(1/2): 146-167. DOI: 10.1016/j.jhydrol.2010.05.040.
- [20] 刘庆辉, 陆海强. 浅析海上风电施工安全管控 [J]. *南方能源建设*, 2020, 7(1): 128-132. DOI: 10.16516/j.gedi.issn2095-8676.2020.01.021.
LIU Q H, LU H Q. Brief analysis on safety management and control of offshore wind farm construction [J]. *Southern energy construction*, 2020, 7(1): 128-132. DOI: 10.16516/j.gedi.issn2095-8676.2020.01.021.

作者简介:



王小虎

王小虎(通信作者)

1974-, 男, 高级工程师, 电气工程及其自动化专业学士, 主要从事工电力系统二次设计工作(e-mail) wangxiaohu@gedi.com.cn。

(编辑 孙舒)