基于改进 YOLOv5s+DeepSORT 的集装箱码头移动目标识别跟踪算法研究

陈东红[1]，汪承志[1]，李元洖[1]，王逸飞[1]，赵桑岚[1]，刘　臻[1]，冯冬颖[2]
（1. 重庆交通大学 河海学院，重庆 400074；2. 赤峰市巴林右旗水利局，内蒙古 赤峰 024000）

摘要：过去基于深度学习的检测器性能较差，尺度变化、背景变化和视觉遮挡降低了原始图像定位的准确性。为此，提出一种改进的 YOLOv5s+DeepSORT 模型，以提高对码头环境的适应性。为增强多尺度加载对象的鲁棒性，将多尺度卷积嵌入 YOLOv5s，同时增加高效金字塔分割注意网络(EPSA)，实现了更强大的特征融合多尺度表示，模型平均精度(mAP)从 90.05%提高至 90.90%。通过分布式排序损失优化原始分类损失函数，减轻了加载对象内部不成比例和码头图像序列中背景变化的影响，提高多目标跟踪精度(MOTA)4.8%。在自建数据集上的实验显示，平均准确率为 90.9%，检测准确率为 92.2%。

关键词：港口码头；深度学习；移动荷载；YOLOv5s；DeepSORT
中图分类号：U656.1+35　　**文献标志码**：A　　**文章编号**：1002-4972(2025)07-0172-10

Container wharf mobile object recognition and tracking algorithm based on improved YOLOv5s+DeepSORT

CHEN Donghong[1], WANG Chengzhi[1], LI Yuanhao[1], WANG Yifei[1], ZHAO Sanglan[1], LIU Zhen[1], FENG Dongying[2]
(1. College of River and Ocean Engineering, Chongqing Jiaotong University, Chongqing 400074, China;
2. Water Conservancy Bureau of Balin Right Banner, Chifeng City, Chifeng 024000, China)

Abstract: Due to the poor performance of deep learning-based detectors in the past, scale variations, background variations, and visual occlusions reduce the accuracy of raw image localization. Therefore, an improved YOLOv5s+DeepSORT model is proposed to enhance adaptability to dock environments. To enhance the robustness of multi-scale loading objects, multi-scale convolution is embedded in YOLOv5s, and an efficient pyramid segmentation attention(EPSA) network is added to achieve more powerful feature fusion multi-scale representation. The mean average precision(mAP) is improved from 90.05% to 90.90%. By optimizing the original classification loss function through distributed sorting loss, the impact of imbalanced loading objects and background changes in dock image sequences is reduced, resulting in a 4.8% improvement in multiple object tracking accuracy (MOTA). Experiments on self built datasets show an average accuracy of 90.9% and a detection accuracy of 92.2%.

Keywords: wharf; deep learning; moving load; YOLOv5s; DeepSORT

近年来，为实现在图像或视频中识别并定位各种对象，目标检测[1]逐渐成为计算机视觉中的一项关键任务。当前，目标检测技术主要分为基于区域提议的方法、单阶段检测器[2]、无锚框方法以及基于 Transformer 的方法，而单阶段检测器由于速度快、效率高、架构简单且易于实现和部署，在实际情况中优于其他方法。YOLO 算法可以直接从输入图像生成预测结果，支持端到端训练，适合实时和资源受限设备，调优超参数少，现代版本在小目标检测[3]和密集场景中表现出色。Han

收稿日期：2024-09-26
作者简介：陈东红（1999—），女，硕士研究生，研究方向为港口、海岸及近海工程。

等[4]利用 EfficientVit 替代原有的骨干网络，采用高效解耦的检测头分别处理分类和回归任务，将 CIoU 损失与 Wasserstein 损失相结合作为定位损失，提高了 9.6%的检测精度，然而，在实时能力和检测速度方面仍有改进的空间。Ren 等[5]提出一种轻量级检测算法，集成了分布移动卷积层和压缩激励注意力机制，取代了原有的部分卷积和 C3 模块，同时使用跳跃连接在 Ghost 模块上进行多尺度特征融合，改进后的模型比原算法在平均精度上提高了 1.0%，但在实现轻量级的同时忽略了对检测速度的影响。Li 等[6]提出一种集成注意力机制的 CAC3 模块，改进了颈部双向特征金字塔网络，改进模型在检测被困人员不同比例和姿势时的模型平均精度（mean average precision，mAP）比 YOLOv5s 模型分别提高 7.4%和 24.9%，但模型的抗干扰能力仍待提高。Wang 等[7]通过在骨干网中引入感受场扩展块，解决了检测器感受野与目标物体不匹配的问题，同时在尺度感知的特征层中将目标检测头和注意力机制连贯地结合在一起，提高平均检测精度 6.6%，增强了模型的预测能力，但是检测速度需要进一步提升。根据以上问题，下一步的研究应集中在检测精度与速度方面，探索更有效的改进方法。

多目标跟踪旨在视频序列中同时跟踪多个目标，然后通过时间维度关联这些检测结果，维持每个目标的连续轨迹。DeepSORT 因其高精度的目标关联能力，在处理复杂环境中的连续跟踪需求时优势明显，能够与多种目标检测算法无缝集成[8-9]，展现出较高的扩展性和灵活性，适应不同应用场景的需求。通过结合卡尔曼滤波器和匈牙利算法，DeepSORT 不仅在目标定位上更加精准，还能有效应对目标遮挡和重现等挑战，进一步提升跟踪性能[10-12]。Huang 等[13]针对含遮挡的空间动态目标跟踪问题提出一种基于五帧差分与 DeepSORT 相结合的在线跟踪方法，即实现对动态目标的先识别后跟踪，虽然该跟踪算法在强光和遮挡下具有较高的有效性和优越性，但其无法适用于所有场景下的遮挡和姿态变化，不利于空间捕捉。Yang 等[14]将 DeepSORT 的重新识别网络结构替换为机器翻译接口框架，并将 DeepSORT 异物跟踪算法替换为遮挡感知空间注意力模块，多目标跟踪准确度（multi-target tracking accuracy，MOTA）与多目标跟踪精确度（multi-target tracking precision，MOTP）分别提高 6%、3.9%，但改进后的算法在提高跟踪精度的同时也面临着应用范围较小、需提高其易用性等问题。Thioanh Bui 等[15]优化了 DeepSORT 的卡尔曼滤波（Kalman filter，KF）算法，利用宽度代替了原 KF 算法中车辆预测框的长宽比，在 DeepSORT 的重新识别网络中，将原来的卷积神经网络（convolutional neural network，CNN）模型替换为改进的 ResNet36 作为特征提取的骨干网络，但该算法存在一些固有的局限性，如定位目标边界时不准确、多尺度目标检测能力差。Luo 等[16]修改了 DeepSORT 外观特征提取网络的结构，并在车辆重新识别数据集上对其进行重新训练，然而其精度受到多种因素的影响，需要通过图像增强优化算法或提高视频分辨率来缓解。因此，在下一步的研究中需要提高多目标跟踪的鲁棒性与环境的适用性。

基于上述问题，因 YOLOv5s 模型在速度和精度间平衡良好，更适合港口码头环境下的实时目标识别与跟踪，所以本文采用 YOLOv5s 作为基础模型进行研究。本文主要研究内容为：1）建立港口码头移动目标数据集；2）引入多尺度卷积 PSConv 和高效金字塔分割注意（efficient pyramid segmentation attention，EPSA）机制，提升复杂场景下的目标检测准确性；3）采用 GhostNet 模块和 D_{IoU} 指标，减少计算复杂度，提高视频序列中目标跟踪的效率和准确性。

1　数据集的建造

针对基于深度学习的目标检测模型，利用舟山港老塘山港区现场图像和网络图像建立一个 5031 幅的码头移动目标数据集，以应对码头中目标类型多样、背景杂乱、环境噪声大、动态变化实时性要求高等复杂环境问题。如图 1 所示，图

像展示了背景、分辨率、机器拍摄角度和拍摄距离的多样性，同时也考虑了拥挤场景、物体遮挡和多尺度目标等对目标识别的挑战。数据集划分为 12 类移动目标，包括集装箱装卸桥、集装箱正面吊运车、门座式起重机、牵引车、集装箱卡车、跨运车、集装箱叉车、港区火车、集装箱船、散货船、吊桥集装箱小车和桥小车[17]。图像数据标注采用 Labelimg 软件，精确标注了 8 743 个目标实例，记录目标的像素中心坐标和边界框尺寸。

图 1 数据集概况

Fig. 1 Dataset overview

2 改进的 YOLOv5s-DeepSORT 港口码头目标检测跟踪算法

2.1 目标检测网络的优化

2.1.1 PANet 中引入多尺度卷积

在码头场景中，荷载对象的大小和形状各异，存在大量复杂的交互运动，检测模型需要提高处理荷载对象尺度变化的能力。YOLOv5s 模型卷积核的感受野有限，且增大卷积核的尺寸会导致参数数量和计算成本的增加。为了提高卷积网络的效率，研究人员提出了许多解决方案，如膨胀卷积、深度可分离卷积、分组卷积和混合深度卷积等。然而，这些常见的 CNN 卷积核大小固定，限制了它们在处理多尺度特征时的效率。为了在不增加额外计算量的前提下更细致地在通道上进行多尺度特征图的计算，有研究者提出带有单一卷积核的多尺度卷积 PSConv，这种卷积在同一通道分组内以不同卷积核尺度计算。对于标准卷积层的卷积操作如下：

$$H_{c,x,y}=\sum_{k=1}^{C_{\text{in}}}\sum_{i=-(K-1)/2}^{(K-1)/2}\sum_{j=-(K-1)/2}^{(K-1)/2}f_{c,k,i,j}F_{k,x+i,y+j} \tag{1}$$

式中：$H_{c,x,y}$ 为输出特征图；F 为输入特征图；C_{in} 为输入通道数；$f_{c,k,i,j}$ 为卷积滤波器；k 为输入通道索引，表示当前遍历的输入特征图的通道编号，范围从 1 到 C_{in}；i，j 为卷积核的空间位置偏移。

此外，具有膨胀率 d 的膨胀卷积可以表示为：

$$H_{c,x,y}=\sum_{k=1}^{C_{\text{in}}}\sum_{i=-(K-1)/2}^{(K-1)/2}\sum_{j=-(K-1)/2}^{(K-1)/2}f_{c,k,i,j}F_{k,x+id,y+jd} \tag{2}$$

PSConv 与不同的膨胀率混合，以提取多尺度特征，这些膨胀率被分配到卷积核中，如下所示：

$$H_{c,x,y}=\sum_{k=1}^{C_{\text{in}}}\sum_{i=-(K-1)/2}^{(K-1)/2}\sum_{j=-(K-1)/2}^{(K-1)/2}f_{c,k,i,j}F_{k,x+iD_{(c,k)},y+jD_{(c,k)}} \tag{3}$$

由于 YOLOv5s 的卷积层在通道上的常规卷积是固定的，普通卷积结构在特征图上的感受野缺乏多尺度卷积的灵活性，同时参考在 ResNet50 的残差网络中引入多尺度卷积显著提高了模型的精度，因此本文引入多尺度卷积至 YOLOv5s 的 PANet 网络结构中，替代其中部分常规卷积层。

2.1.2 改进的 EPSA 特征融合网络

在进行上一节的操作后，本文进一步在特征向量提取中引入注意力机制，增强对重要信息量的特征表达。近年来，SENet、CBAM 和 ECANet 等方法的提出大大改进了模型，但它们处理特征图尺度的方式是单一的。相比之下，EPSA 可以更好地用来处理多尺度输入张量，因此本文考虑将

该结构引入 YOLOv5s 中。

PSA(pyramid split attention，金字塔分割注意力)方法可以将输入张量分成 S 个部分，并通过不同的卷积过程控制 SPC(spatial pyramid convolution，空域金字塔卷积)模块处理每个部分，逐步扩大每个部分的卷积核(如使用大小为 $k=3$、5、7、9 的卷积核)。在使用不同卷积核大小进行卷积后，每部分的输出张量沿通道维度进行拼接。此外，PSA 使用 SE(squeeze-and-excitation，挤压-激励)模块加权机制来提炼 SPC 模块的输出，以获得跨不同尺度的特征图的注意力权重。这种策略不仅整合了来自不同层次的上下文信息，还增强了像素级别的注意力。最终在重新校准权重后输出。权重通过 softmax 函数进行归一化并应用于 SPC 模块的输出，见式(4)、(5)。

$$g_c=\frac{1}{HW}\sum_{i=1}^{H}\sum_{j=1}^{W}x_c(i,j) \tag{4}$$

$$A_{\mathrm{M}}=\mathrm{softmax}(z_i) \tag{5}$$

式中：g_c为第 c 个通道的全局平均值；H 为特征图的高度；W 为特征图的宽度；$x_c(i,j)$为特征图第 c 个通道在位置(i,j)处的像素值；softmax(z_i)表示对输入向量 Z 中的每个分量z_i 应用 softmax 函数；A_{M} 为概率分布。

整体改进模型网络结构见图 2。

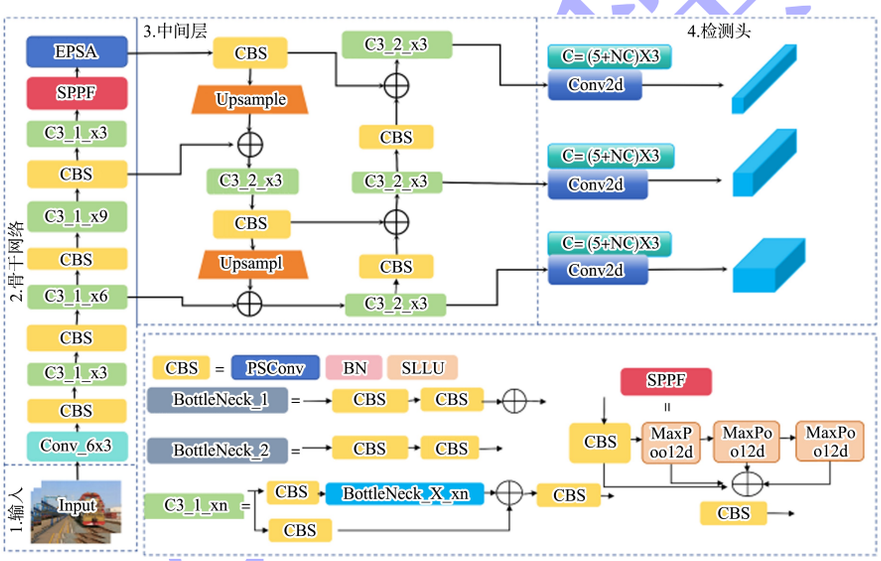

图 2　整体网络结构

Fig. 2　Overall network structure

2.2　基于 DeepSORT 的港口码头目标跟踪模型优化

2.2.1　基于 GhostNET 模块的表观特征提取网络构建

为了降低特征提取网络的复杂度并减少浮点运算，本文在表观特征网络设计中引入了 Ghost 模块。通过常规卷积生成部分特征图，基于 3×3 卷积的线性变换生成新的特征图，两部分特征图在通道维度上连接，随后通过两个 Ghost 模块与原始输入相加，生成最终输出。考虑到 DeepSORT 的原始特征提取网络基于宽残差网络构建，Ghost 模块被插入 Residual4～9 的残差层中，替换其中的二维卷积层。此外，为避免第 3 层 Maxpool 层对关键特征的过滤，采用自适应最大池化替代原有的池化层。

2.2.2　基于距离交并比的关联匹配模块优化

为在目标跟踪算法中更好地优化匹配效果，在匹配模块中引入距离交并比指标 D_{IoU}。相较于其他指标，该指标进一步将框中心点之间的距离影响纳入考量，见式(6)。

$$D_{\mathrm{IoU}}=I_{\mathrm{oU}}-\frac{d^2}{c^2} \tag{6}$$

式中：d 为预测框和检测框的中心位置间的欧式距离；c 为预测框和检测框交集的最小外接矩阵的对角线距离；I_{oU} 为交并比，可通过计算交集面积和并集面积得到。

I_{oU}、G_{IoU}(广义交并比)和 D_{IoU} 的计算结果见图 3。当预测框(外框)和检测框(内框)中的一个被包含时，I_{oU} 和 G_{IoU} 的数值均为 0.75。由于 D_{IoU} 考虑了中心距离，因此即使中心点不重合，仍能根据中心距离的远近计算出指标值。相较而言，D_{IoU} 能更准确地反映两框之间的位置关系，从而提供更准确的匹配。为了优化匹配效果，本文在关联匹配时引入 D_{IoU} 作为检测框与预测框之间对比的指标。

在关联匹配过程中，D_{IOU} 的工作流程见图 4。

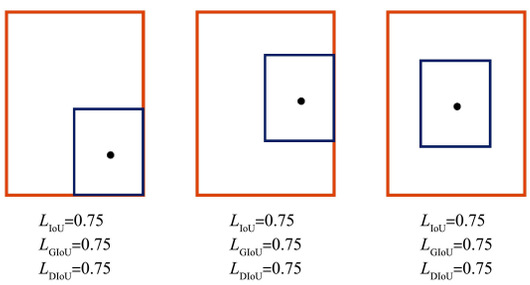

注：L 为内框中心点与外框中心点的距离。

图 3 I_{oU}、G_{IoU} 和 D_{IoU} 指标的计算举例

Fig. 3 Calculation illustration of I_{oU}, G_{IoU}, and D_{IoU}

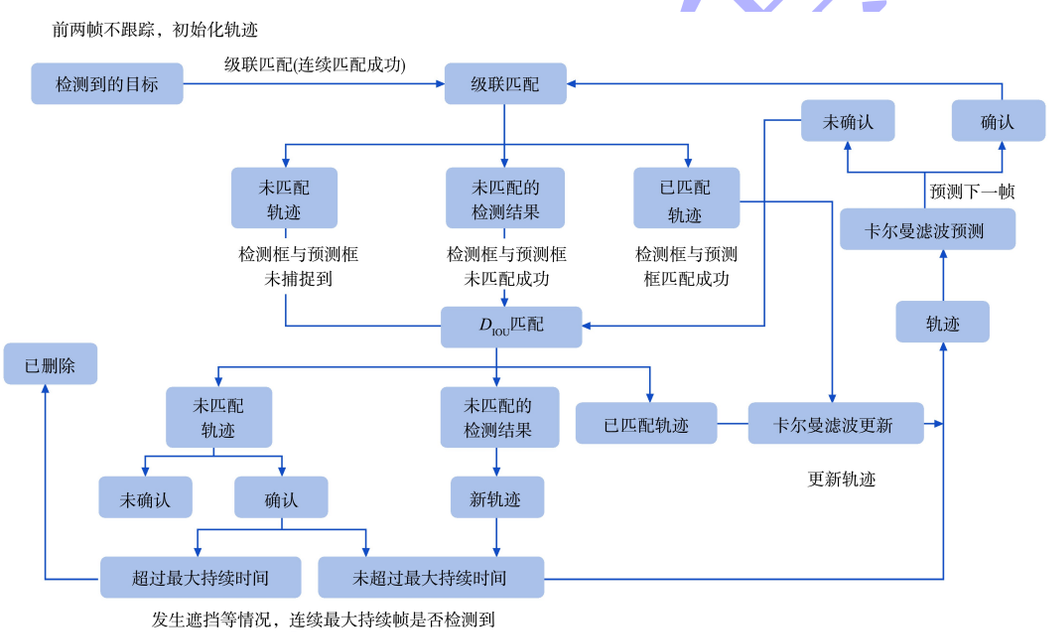

图 4 关联匹配

Fig. 4 Related matching

2.3 港口码头识别跟踪系统

通过获取的码头视频图像，使用前期研究的目标检测技术识别移动目标的类型，并运用轨迹跟踪技术获取移动目标的活动信息。如图 5 所示，整体流程包括：视频图像使用 OpenCV 加载并标准化处理后传送至改进的 YOLOv5s 网络，然后将即时处理的图像数据连接到显示窗口。显示窗口能够呈现各种荷载移动目标的边界框位置和类别置信度，从而快速识别机械的位置和类型。结合 DeepSORT 算法，配置跟踪器和检测器的参数，在目标检测模块中为每个目标分配唯一的识别 ID，并在线实时跟踪移动目标，视频中所有目标的识别信息均可记录到数据文件中，方便在线查询荷载目标的运动轨迹和数量。对于出入口的监控视频，还可以估算移动速度等信息。

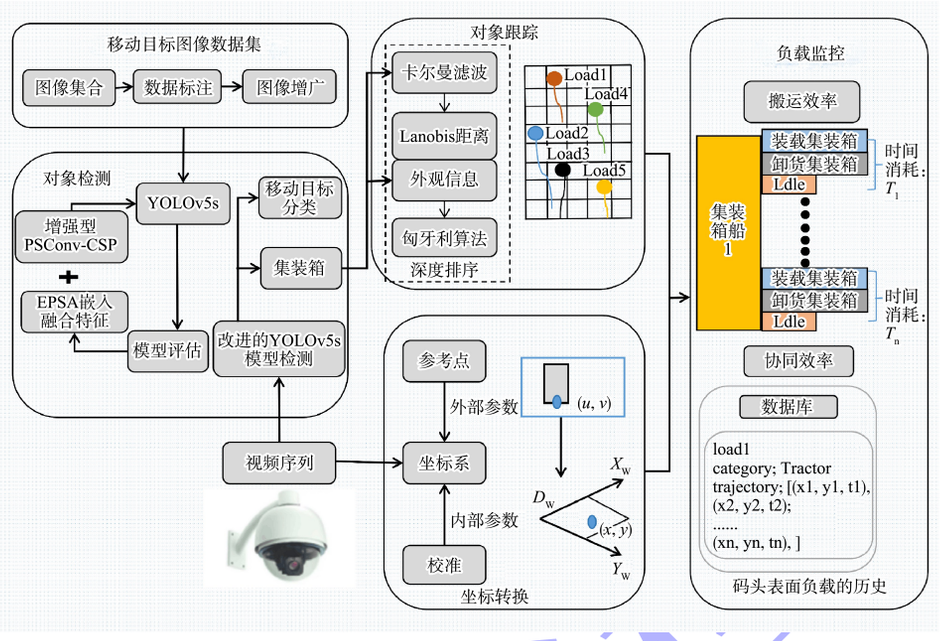

图 5　负载目标检测与识别的整体框架

Fig. 5　Overall framework for target detection and recognition with load

3　结果与讨论

3.1　目标检测改进模型评价

本文比较改进模型和其他模型的检测结果。以 YOLOv5s 为基准模型，在加入 PSConv 后，mAP@0.5 达到 91.0%，平均消耗时间为 2.6 ms，由于 PSConv 单元包含更多参数，比基准模型慢 0.2 ms。此外，在引入 EPSA 后，mAP@0.5 从 90.05% 提高至 90.90%，mAP@0.5:0.95、召回率 R 与召回率和精确率的调和平均数 F_1 相较于基准模型分别提高 1.4%、1.8%与 0.8%，见表 1。

表 1　不同模型的检测准确性

Tab. 1　Detection accuracy of different models

模型	mAP @0.5/%	mAP@0.5:0.95/%	精确率 P/%	R/%	F_1/%	推断时间/ms
YOLO	90.60	74.2	89.7	87.6	88.6	2.4
YOLO+ PSConv	91.00	75.4	90.7	85.5	85.5	2.6
YOLO+EPSA	90.05	74.4	92.9	89.1	89.1	3.6
YOLO+PSConv+EPSA	90.90	75.6	92.2	89.4	89.4	3.7

为了证明提出模型的有效性，分析 6 种码头机械行为识别的准确率和召回率，见图 6。该算法在识别各类码头机械行为方面表现出色，顺利实现了预期目标。其中，改进后的模型对港区火车、集装箱正面吊运车以及集装箱叉车的识别精度较高，分别达到 99.3%、96.3% 和 96.5%。然而，牵引车准确率较低，仅为 82.5%。在 $P-R$ 曲线中，改进后的模型在牵引车和集装箱装卸桥的检测精度上分别比原模型提升 4%和 3%，表明改进后的模型在码头目标的识别精度上有了方向性的提升。

原模型与改进模型的类别混淆矩阵见图 7，改进后的模型在分辨外形相近的移动目标方面的细粒度能力获得显著增长。

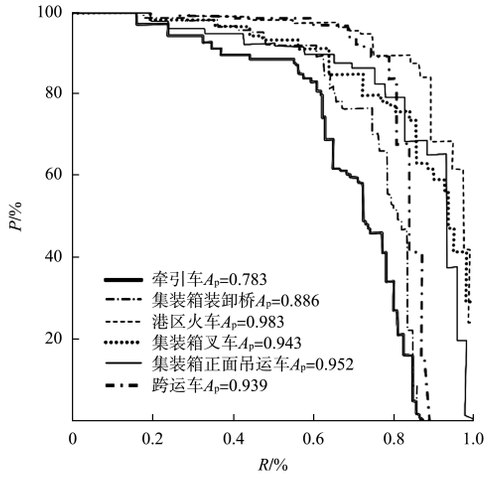

a) 原模型

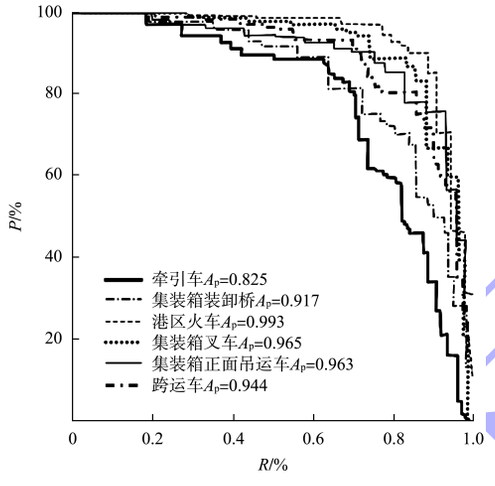

b) 改进模型

注：A_p 值即 P–R 曲线的面积；A_p 值越大，说明模型在精确率和召回率之间的平衡越好。

图 6　P–R 曲线对比

Fig. 6　Comparison of P–R curves

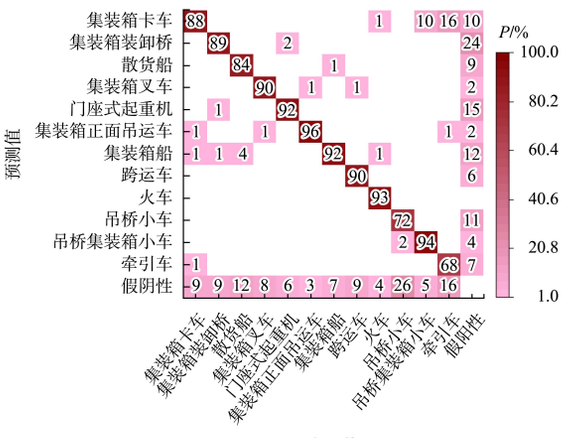

a) 原模型

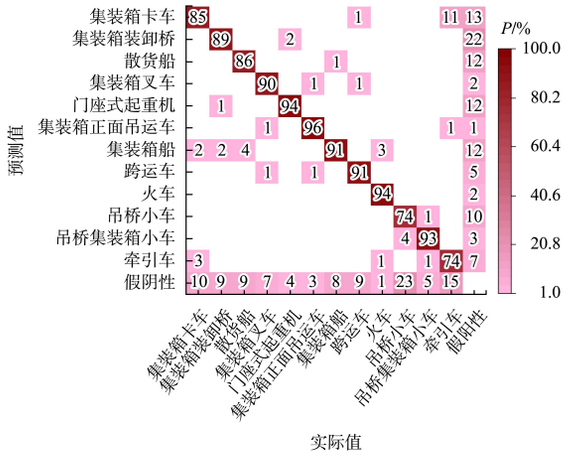

b) 改进模型

图 7　混淆矩阵对比

Fig. 7　Comparison of confusion matrix

为了验证摄像机分辨率和监控视频中不同物体尺寸对码头工程现场的影响，将提出的方法在最常见的 3 种分辨率的 1 200 张监控图像上进行评估。不同物体大小和分辨率下码头现场监控视频的 mAP 均显示该方法达到了最佳平均精度，见图 8。与原始 YOLO 相比，提出的模型根据尺寸 S 在小型（$S<32^2$）、中型（$32^2<S<96^2$）和大型（$S>96^2$）负载物体的平均精度上分别取得了 3.9%、2.4%和 1.6%的提升。所提出的方法在检测大型负载物体的性能上最接近，同时评估了不同分辨率的监控视频图像，结果显示，当监控视频的分辨率为 1 280 dpi×720 dpi 时，其平均精度略低于图像中的 YOLOv5s。因此，所提出的模型比其他方法表现更好。

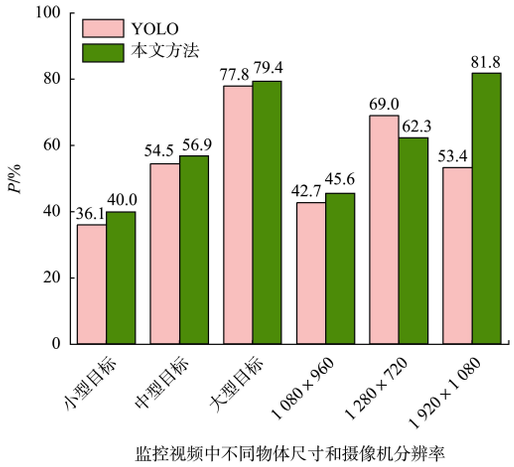

图 8　不同物体尺寸和分辨率下码头现场监控视频的 mAP

Fig. 8　The mAP of dockside surveillance video under different object sizes and resolutions

通过在卷积和通道维度上采用不同尺度的计算，见图 9，改进后的模型增强了对小尺度特征的学习能力，使得小目标检测更加有效。相比于传统模型，改进模型在检测过程中能够更有效地避免边界框回归的不准确性及漏检问题。

图 9　现场目标检测

Fig. 9　On-site object detection

3.2　整体结构结果的评价

在模型测试过程中，通过 Ghost 模块构建特征提取网络并结合 D_{IoU} 匹配指标，见图 10，MOTA 达到 67.75%，相较于其他算法精确度提升 2.19%，身份切换次数(identity switches，IDSW)降至 25，减少 7 次跟踪身份 ID 的变化，浮点计算次数减少 33.67%，结果显示该模型在提升跟踪精度的同时，计算复杂度也大幅降低。不同模型的检测结果见表 2。

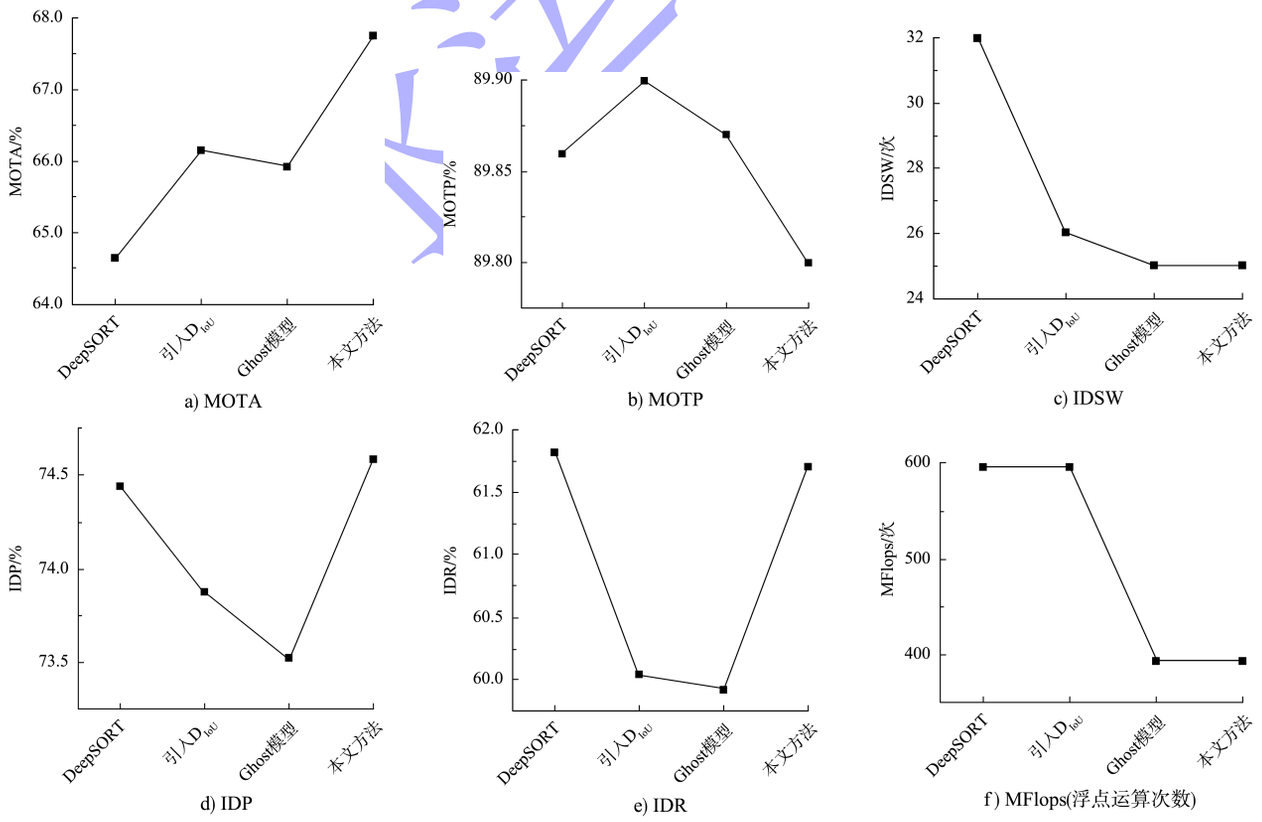

图 10　DeepSORT 改进模块的指标结果

Fig. 10　Performance metrics of improved modules in DeepSORT

表 2 不同模型的检测结果

Tab. 2 Detection results of different models

算法	MOTA/%	MOTP/%	IDSW/次	身份精准率 IDP/%	身份召回率 IDR/%
YOLOv5s+DeepSORT	65.46	89.86	32	74.44	61.82
YOLOv5s+本文方法	67.75	89.80	25	74.58	61.77
改进 YOLOv5s+DeepSORT	70.26	89.97	18	76.61	67.46

测试结果显示，改进的 YOLOv5s 与改进的 DeepSORT 跟踪算法结合后，其 MOTA、IDSW、IDP 和 IDR 指标分别达到 70.26%、18、76.61%和 67.46%，见表 2。该算法较原算法的跟踪准确率提高 4.8%，表明算法在减少漏检、误检等方面取得了显著优化，增强了在复杂港口环境中的准确性和鲁棒性，并减少了 44%的 IDSW 变化，IDR 和 IDP 指标均有提升，进一步证明了该算法在港口码头荷载目标整体跟踪性能上显著增强。

4 结论

1）引入多尺度卷积增强卷积核的粒度，并有效提升了其跨尺度特征提取的能力；结合金字塔分割注意机制，利用特征向量通道中的多尺度注意力，显著提高了目标识别精度。与其他模型相比，增强模型对港口火车、集装箱叉车和集装箱前叉车的识别精度分别为 99.3%、96.5%和 96.3%。

2）基于 Ghost 模块构建宽残差卷积层，可有效减少浮点运算次数；引入 D_{IoU} 指数在匹配阶段合并质心距离，增强预测框与检测框的对齐度，提高了匹配过程的合理性。性能指标如下：MOTA 为 67.75%，MOTP 为 89.80%，IDSW 为 25 次，IDP 为 74.58%，IDR 为 61.77%。

3）改进的 YOLOv5s+DeepSORT 算法与原方法相比，跟踪精度提高 4.8%，IDSW 减少 44%，IDP 和 IDR 分别增加 2.23%和 5.64%。该算法能够更高效、稳定地跟踪码头场景中的多个移动目标，满足码头环境中多目标识别与监控的应用需求。

参考文献：

[1] 马鸽, 李洪伟, 严梓维, 等. 基于多注意力的改进 YOLOv5s 小目标检测算法[J]. 工程科学学报, 2024, 46(9): 1647-1658.
MA G, LI H W, YAN Z W, et al. Improved small target detection algorithm based on multiattention and YOLOv5s for traffic sign recognition [J]. Chinese journal of engineering, 2024, 46(9): 1647-1658.

[2] 方莉, 赵志峰, 严铮, 等. 基于单阶段半监督目标检测的工人检测算法[J]. 微电子学与计算机, 2025, 42(2): 20-30.
FANG L, ZHAO Z F, YAN Z, et al. Construction worker detection algorithm based on one-stage semi-supervised object detection[J]. Microelectronics & computer, 2025, 42(2): 20-30.

[3] 许博强, 弓家伟, 田雨卉, 等. 基于 YOLO-v5 模型的车辆荷载实时检测算法[C]//2024 世界交通运输大会(WTC2024)论文集(桥梁工程、隧道工程与轨道交通). [出版地不详]: [出版者不详], 2024: 279-284.
XU B Q, GONG J W, TIAN Y H, et al. Real-time vehicle load detection algorithm based on YOLO-v5 Model[C]// Proceedings of the 2024 World Transportation Congress (WTC2024) (bridge engineering, tunnel engineering and rail transit). [s. l.]: [s. n.], 2024: 279-284.

[4] HAN Y J, WANG F P, WANG W, et al. EDN-YOLO: multi-scale traffic sign detection method in complex scenes[J]. Digital signal processing, 2024, 153: 104615.

[5] REN H G, FAN A N, ZHAO J, et al. Lightweight safety helmet detection algorithm using improved YOLOv5[J]. Journal of real-time image processing, 2024, 21(4): 125.

[6] LI M Y, YANG T H, XU S B, et al. Multi-scale small target detection for indoor mobile rescue vehicles based on improved YOLOv5[J]. International journal of automotive technology, 2024, 25(6): 1431-1444.

[7] WANG S S, LIU B S, ZHU P C, et al. SAM-Y: attention-enhanced hazardous vehicle object detection algorithm [J]. IET computer vision, 2024, 18 (8): 1149-1161.

[8] 何水龙, 张靖佳, 张林俊, 等. 基于 Transformer 改进的

YOLOv5+DeepSORT 的车辆跟踪算法[J]. 汽车技术, 2024(7): 9-16.
HE S L, ZHANG JJ, ZHANG L J, et al. Vehicle tracking algorithm based on transformer's improved YOLOv5 + DeepSORT[J]. Automobile technology, 2024(7): 9-16.

[9] 付诗文, 韩星程, 王黎明, 等. 基于 YOLOv5-DeepSORT 融合的低帧率水面航行多目标跟踪算法[J]. 大连海事大学学报, 2024, 50(1): 94-101.
FU S W, HAN X C, WANG L M, et al. A multi-target tracking algorithm for low frame rate surface navigation based on YOLOv5-DeepSORT fusion [J]. Journal of Dalian Maritime University, 2024, 50(1): 94-101.

[10] HOST K, IVAŠIć-KOS M, POBAR M. Tracking handball players with the DeepSORT algorithm[C]//Proceedings of the 9th International Conference on Pattern Recognition Applications and Methods. Setúbal: Science and Technology Publications, Lda., 2020: 593-599.

[11] XIE T B, YAO X F. Smart logistics warehouse moving-object tracking based on YOLOv5 and DeepSORT[J]. Applied sciences, 2023, 13(17): 9895.

[12] ZHANG Q. Multi-object trajectory extraction based on YOLOv3-DeepSort for pedestrian-vehicle interaction behavior analysis at non-signalized intersections [J]. Multimedia tools and applications, 2023, 82(10): 15223-15245.

[13] HUANG C, ZENG Q L, XIONG F Y, et al. Space dynamic target tracking method based on five-frame difference and DeepSORT[J]. Scientific reports, 2024, 14(1): 6020.

[14] YANG D J, MIAO C Y, LIU Y, et al. Improved foreign object tracking algorithm in coal for belt conveyor gangue selection robot with YOLOv7 and DeepSORT [J]. Measurement, 2024, 228: 114180.

[15] BUI T, WANG G H, WEI G, et al. Vehicle multi-object detection and tracking algorithm based on improved you only look once 5s version and DeepSORT[J]. Applied sciences, 2024, 14(7): 2690.

[16] LUO Z B, BI Y Q, YANG X, et al. Enhanced YOLOv5s+ DeepSORT method for highway vehicle speed detection and multi-sensor verification [J]. Frontiers in physics, 2024: 1371320.

[17] 李志明. 基于深度学习的码头场景多目标感知技术研究[D]. 重庆: 重庆交通大学, 2022.
LI Z M. Research on multi-object perception technology for port scenes based on deep learning[D]. Chongqing: Chongqing Jiaotong University, 2022.

（本文编辑　王传瑜）

（上接第 134 页）

[8] 杨锦, 刘本芹, 汪磊, 等. 大水位变幅下省水船闸水位分级研究[J]. 水运工程, 2021(11): 59-65.
YANG J, LIU B Q, WANG L, et al. Study on water level classification of water-saving ship lock under large water level variation [J]. Port & waterway engineering, 2021(11): 59-65.

[9] 船闸总体设计规范: JTJ 305—2001[S]. 北京: 人民交通出版社, 2002.
Code for master design of shiplocks: JTJ 305-2001[S]. Beijing: China Communications Press, 2002.

[10] 浙赣运河水资源综合利用及航运用水保障研究报告[R]. 杭州: 浙江省水利水电勘测设计院有限责任公司, 2023.
Research report on comprehensive utilization of water resources and navigation water use guarantee for Zhe-Gan Canal [R]. Hangzhou: Zhejiang Provincial Institute of Water Conservancy and Hydropower Survey and Design Co., Ltd., 2023.

[11] 河湖生态环境需水计算规范: SL/T 712—2021[S]. 北京: 中国水利水电出版社, 2021.
Specification for calculation of ecological flow for rivers and lakes: SL/T 712-2021[S]. Beijing: China Water & Power Press, 2021.

[12] 陈雪华. 梯级泵站提水效率评估模型设计与应用探讨[J]. 陕西水利, 2019(4): 14-16.
CHEN X H. Exploration on design and application of the evaluation model for water lifting efficiency of cascade pumping station[J]. Shaanxi water resources, 2019(4): 14-16.

（本文编辑　赵娟）

水运工程