

DOI: 10.13382/j.jemi.B2508675

# 基于激光雷达的门座式起重机钢丝绳识别方法研究\*

李欣源<sup>1</sup> 宓超<sup>2,3</sup> 沈阳<sup>3,4</sup>

(1. 上海海事大学信息工程学院 上海 201306; 2. 上海海事大学物流工程学院 上海 201306;  
3. 上海海瞩智能科技有限公司 上海 201306; 4. 上海海事大学高等技术学院 上海 201306)

**摘要:**针对干散货自动化码头门座式起重机作业中,钢丝绳与抓斗点云强空间耦合导致边界模糊、以及现场安装受限造成点云稀疏不均,致使传统分割方法难以有效识别钢丝绳的难题,提出一种基于激光雷达与改进 PointNet++ 的钢丝绳识别方法。首先,利用激光雷达获取点云,并采用基于运动学约束的动态预分割算法提取作业区域,以降低计算冗余。其次,在 PointNet++ 框架中嵌入空间-自注意力(SSA)模块,通过自注意力分支建立跨点长程依赖以增强钢丝绳轴向拓扑连续性,同时通过空间注意力分支动态加权局部几何特征以强化耦合区域的边界响应,两者协同作用从而提升了稀疏点云下耦合区域的分割精度。基于自建的门座式起重机作业点云数据集开展的实验表明,改进方法的钢丝绳分割交并比(IoU)达到 91.2%,较 PointNet++ 基准模型提升 9.4%;在雨、雾、雪等恶劣天气条件下,IoU 均保持在 89.8% 以上;在进舱、出舱、大臂回转等多种真实作业工况下,IoU 稳定在 89.4%~92.7%,显著优于对比方法,有效解决强耦合与稀疏点云场景下的钢丝绳精准分割问题,为自动化码头抓斗防摇控制与闭环定位提供了可靠的感知基础。

**关键词:** 多线激光雷达; PointNet++; 混合注意机制; 点云语义分割; 门座式起重机钢丝绳

**中图分类号:** TP391.4; TN95      **文献标识码:** A      **国家标准学科分类代码:** 510.40

## Method for identifying steel wires of gantry crane based on laser radars

Li Xinyuan<sup>1</sup> Mi Chao<sup>2,3</sup> Shen Yang<sup>3,4</sup>

(1. College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China; 2. School of Logistics Engineering, Shanghai Maritime University, Shanghai 201306, China; 3. Shanghai SMU Vision Co. Ltd., Shanghai 201306, China; 4. Higher Institute of Technology, Shanghai Maritime University, Shanghai 201306, China)

**Abstract:** To address the challenges in automated dry bulk terminal operations of gantry cranes, where strong spatial coupling between wire ropes and the grab bucket in point clouds leads to blurred boundaries, and on-site installation constraints result in sparse and uneven point clouds, making it difficult for traditional segmentation methods to effectively identify wire ropes, a wire rope recognition method based on LiDAR and an improved PointNet++ is proposed. First, point clouds are acquired using LiDAR, and a dynamic pre-segmentation algorithm based on kinematic constraints is employed to extract the operational area, thereby reducing computational redundancy. Subsequently, a spatial-self-attention (SSA) module is embedded into the PointNet++ framework. The self-attention branch establishes long-range dependencies across points to enhance the axial topological continuity of the wire rope, while the spatial attention branch dynamically weights local geometric features to strengthen the boundary response in the coupled region. Their synergistic effect improves segmentation accuracy in sparse and coupled scenarios. Experiments conducted on a self-constructed gantry crane operation point cloud dataset demonstrate that the improved method achieves a wire rope segmentation IoU of 91.2%, an improvement of 9.4% over the baseline PointNet++. Under adverse weather conditions such as rain, fog, and snow, the IoU consistently exceeds 89.8%. Across various real-world operating conditions, including entering and exiting the hatch and boom slewing, the IoU remains

stable between 89.4% and 92.7%, significantly outperforming comparative methods. This effectively solves the problem of precise wire rope segmentation in strongly coupled and sparse point cloud scenarios, providing a reliable perceptual foundation for anti-sway control and closed-loop positioning of grabs in automated terminals.

**Keywords:** multi-line lidar; PointNet++; hybrid attention mechanism; point cloud semantic segmentation; gantry crane wire rope

## 0 引言

在干散货自动化码头作业中,门座式起重机作为核心装卸装备,其效率与安全直接关乎港口运营效益。钢丝绳束作为抓斗系统的核心传力介质,其空间位姿的精准感知是抓斗闭环控制的基础,直接影响抓取效率和设备安全。钢丝绳束长度变化直接决定抓斗垂直定位精度,而平移运动诱发的摆动则影响水平稳定性,二者共同制约装卸效率与设备安全。钢丝绳束与抓斗在点云数据中呈现出强空间耦合特性,容易导致边界模糊导致的分割歧义问题,这使得复杂背景下可靠提取其姿态成为保障安全运行与提升自动化水平的技术难点。

在钢丝绳智能化检测领域,现有研究主要集中于损伤检测任务,且已在表面缺陷检测方面取得显著进展。然而,面向门座式起重机钢丝绳位姿感知的研究基础相对薄弱。因此,基于门座式起重机钢丝绳的细长线状几何特征及其在点云中的稀疏性与拓扑连续性问题,可参考现有线状结构提取方法的研究积累。

在现有检测方法中,多传感器融合与计算机视觉技术占据主导地位。基于视觉识别的方案依赖 YOLO 等<sup>[1]</sup>深度学习模型提取钢丝绳轮廓特征,虽具备非接触式检测优势,但在抓斗与钢丝绳的空间耦合效应、金属表面反光干扰或光照突变场景下易引发特征误识别。基于惯性的识别方案<sup>[2]</sup>则通过加速度计与陀螺仪的运动轨迹推算技术实现位姿估计,虽规避了光学环境干扰,但其依赖积分运算的位移推算机制存在零点漂移误差累积问题,难以满足长周期连续作业的精度需求。现有方法普遍面临复杂工业场景下的特征鲁棒性不足与多工况适应性缺陷,难以平衡检测精度与算法泛化能力。随着三维点云机器学习技术的快速发展,三维测量技术在工业领域得到了广泛应用。Shi 等<sup>[3]</sup>针对电力线挂点处点云缺失或被误分类的难题,提出基于空间约束与几何重建的定位法,通过区域生长分割导线、局部多项式重建缺失部位并迭代搜索交点,提取了电力线挂点坐标。Guo 等<sup>[4]</sup>针对点云缺失与投影重叠难题,提出基于模型判别的分割法,通过聚类统计自动识别导线模型并分层处理,分割了单根电力线。毛清华等<sup>[5]</sup>针对矿井提升钢丝绳空间振动测量难题,提出基于 3D 点云的在线测量方法,通过随机样本一致算法(RANSAC)与基于密度的空间聚类算法(DBSCAN)结合实现点云分割,实现振动状态在线测

量。胡益菲等<sup>[6]</sup>针对复杂场景下架空线缆识别难题,提出基于激光雷达的目标检测方法,通过物理特征约束的改进 RANSAC 与区域生长结合,识别了主导线结构。王永敏等<sup>[7]</sup>针对复杂场景下电力线快速提取难题,提出融合布料模拟与 RANSAC 的提取方法,提取了单根电力线点云。然而,上述研究方法的有效性皆高度依赖于高密度、均匀分布的点云数据,而干散货码头位姿检测场景受限于现场安装条件,所获取的点云往往较为稀疏且分布不均。同时,钢丝绳与抓斗在三维空间中紧密耦合,二者局部几何特征高度相似。这使得传统基于手工设计特征与固定阈值的分割方法难以在耦合区域建立有效判别边界,而且依赖局部点云密度的聚类算法也因数据稀疏易产生过分割或欠分割误差,难以保持钢丝绳沿轴向的拓扑连续性。因此,需要引入深度学习方法,以有效应对稀疏点云与强耦合场景下的钢丝绳识别难题。

面对门座式起重机钢丝绳的精准检测需求,在港口自动化设备三维感知体系中,基于深度学习的点云分割方法逐渐成为实现高精度几何特征提取的核心技术路径。阮剑等<sup>[8]</sup>通过 PointNet 直接处理点云数据并尊重重点的不变性,实现了高效的 3D 分类、分割和场景语义解析。Qi 等<sup>[9]</sup>提出了 PointNet++,通过在度量空间中递归应用 PointNet 并自适应结合多尺度特征,实现了鲁棒的深层次点云特征学习,显著提升复杂场景下的性能。孙国强等<sup>[10]</sup>通过 PointCNN 学习 X-变换对点特征加权和排序后应用卷积操作,实现了点云的特征学习,在多个基准任务上达到或超越最佳性能。张自强等<sup>[11]</sup>通过动态图卷积神经网络(dynamic graph CNN, DGCNN)动态构建特征空间图并使用 EdgeConv 模块捕捉局部邻域信息,实现了点云分割的高效处理。冯凯浩等<sup>[12]</sup>通过设计基于 Transformer 的逐通道点云分析网络,采用针对性的编码策略以增强通道特征区分与几何语义挖掘能力,提升了点云分类与分割性能。喻佳祺等<sup>[13]</sup>提出了基于改进 PointPillars 的点云目标检测方法,通过 SimAM 注意力机制优化体素特征输入并构建 Multi-CBAM 骨干网络,实现了对遮挡点云目标的精确检测。Zhang 等<sup>[14]</sup>提出了 Point-NN,通过非可学习组件(如 FPS、k-NN 和三角函数)实现参数无关的 3D 点云分析,并作为基础框架增强现有模型,无需训练即可超越部分全参数方法。Tran 等<sup>[15]</sup>提出了 PointCT(Point Central Transformer),通过基于中心的注意力机制整合全局特征和位置编码,实现了弱监督点云语义分割,在有限标注下提升多数据集性能。

在以上点云分割方法中,PointNet++效果最为突出,该方法通过层次化局部特征聚合与多尺度语义融合机制,构建了从局部几何结构到全局语义理解的分层表征体系,为跨领域精细化分割任务提供了可扩展的基础框架。

然而 PointNet++在应用于钢丝绳识别任务时存在局限。其最远点采样和球查询机制难以有效捕捉钢丝绳与抓斗边界区域微弱的几何特征差异,导致语义边界模糊和特征混淆。同时,该模型的局部与全局特征融合机制对细长线状结构的拓扑连续性建模能力不足,在点云稀疏时难以保持钢丝绳沿轴向的结构完整性,易造成断裂。Chang 等<sup>[16]</sup>通过参数优化与 SoftPool 池化层改进 PointNet++,增强了复杂场景下目标点云的特征捕获能力,有效解决了遮挡与姿态变化等因素导致的分割难题。Qian 等<sup>[17]</sup>通过可分离集抽象模块与各向异性约简函数改进 PointNet++,实现了点云处理精度与速度的双提升。Zhu<sup>[18]</sup>通过 GEO 和 SEP 模块改进了 PointNet++,增强了几何特征与附加信息的利用,解决了原网络信息编码不足的问题。林冬梅等<sup>[19]</sup>通过引入局部-空间特征提取网络、设计倒残差多尺度卷积网络替换编码器并采用 Focal 损失函数改进了 PointNet++,从而增强了旋转鲁棒性和边缘特征学习能力,有效提升了三维点云缺陷检测的性能。以上改进方法虽在各自应用领域取得了显著成效,但其设计主要面向具有明显几何形态特征的一般性目标,尚未针对细长线状结构在稀疏点云与强耦合场景下的特殊挑战进行专门优化。在钢丝绳识别任务中,这些方法难以有效捕捉钢丝绳与抓斗之间微弱的几何特征差异,且对细长结构沿轴向的拓扑连续性保持能力有限,在点云稀疏时易造成分割断裂。上述不足使得现有改进方法难以满足干散货码头复杂环境下钢丝绳精准识别的需求。

针对钢丝绳与抓斗耦合区域边界模糊以及稀疏点云下细长结构易断裂的问题,本文提出一种基于改进 PointNet++的门座式起重机钢丝绳识别方法。该方法在 PointNet++框架中引入空间-自注意力模块,其中空间注意力分支用于增强耦合区域的边界特征,自注意力分支用于维持钢丝绳沿轴向的结构连续性,通过两者的协同实现对钢丝绳束的高精度分割与位姿估计,为自动化码头作业提供可靠的感知基础。

## 1 钢绳检测方法

### 1.1 硬件架构

本文采用适配港口门座式起重机的钢丝绳的三维感知系统,其硬件平台由双多线激光雷达与边缘计算单元构成。激光雷达采用对称式布局,部署于起重机维修平台两侧,如图1所示,通过多视角交叉扫描构建互补感知

区域,有效消除单传感器盲区并提升几何特征完整性。边缘计算单元集成于电气室核心区,承担点云数据接收、预处理及特征提取功能,实现高密度点云分割。该架构为后续钢丝绳位姿解算与安全预警提供高鲁棒性硬件基础。



图1 门座式起重机钢丝绳束识别任务激光雷达安装

Fig. 1 Laser radar installation for wire rope bunch identification task on a gantry crane

### 1.2 算法设计

#### 1) 算法架构

针对港口门座式起重机钢丝绳识别中耦合区域边界模糊导致的分割歧义问题,本文提出的基于多激光雷达与改进型 PointNet++模型的钢丝绳识别流程,如图2所示。首先,运用多激光雷达系统采集门座式起重机作业场景的三维点云数据,通过多源点云配准与动态空间预分割算法实现数据预处理,以达到在保留钢丝绳几何特征的同时有效降低冗余数据计算量的效果。其次,将预处理后的点云数据输入改进型 PointNet++模型。该模型通过嵌入空间-自注意力模块获取局部曲率敏感特征与全局拓扑连续性表征,精准识别钢丝绳及其相邻机构在高度耦合区域的几何边界。最后,采用最小二乘法对语义分割得到的钢丝绳点云束进行空间直线拟合,实现了钢丝绳空间位姿的计算,为后续的防摇控制与闭环定位提供数据支持。

#### 2) 预处理算法

本文构建了系统化的预处理流程,为深度学习模型提供优化的输入数据,以满足门座式起重机钢丝绳识别的需求。该流程采用自适应体素降采样策略压缩冗余数据密度,在显著降低计算复杂度的同时,有效保持钢丝绳细长结构的几何特征。针对粉尘遮蔽与金属反光引发的异常值干扰,该流程应用统计离群点滤波算法进行抑制,增强了点云数据的拓扑连续性。为实现作业场景点云数据的空间完整性,利用 ICP 配准算法完成了双激光雷达多源点云的空间对齐。此外,根据起重机作业区域建立了三维动态感兴趣区域,并基于空间约束预分割算法精确提取了钢丝绳长方体作业域的点云  $P_{ROI}(t)$  :




图 2 门座式起重机钢丝绳束识别流程  
Fig. 2 Wire rope bunch identification process for a gantry crane




图 3 改进的 PointNet++ 网络结构  
Fig. 3 Improved PointNet++ network structure

本文通过多阶段特征重组策略将 SSA 模块嵌入 PointNet++ 网络,如图 4 所示。

步骤 1) 输入特征矩阵  $\mathbf{F} \in \mathbf{R}^{B \times N \times (d+C)}$ , 其中  $B$  为批次大小,  $N$  为每个样本的点数,  $C$  为点集特征维度,  $d$  为每个点的特征。

步骤 2) 通过多头自注意力模块加强点云中相距较远的点之间的全局特征依赖, 生成特征向量  $\mathbf{F}' \in \mathbf{R}^{B \times N \times (d+C')}$ , 其中  $C'$  是自注意力机制输出的特征维度。

步骤 3) 通过空间注意力模块强化局部几何拓扑敏感性, 生成特征向量  $\mathbf{F}'' \in \mathbf{R}^{B \times N \times (d+C'')}$ , 其中  $C''$  是空间注意力机制输出的特征维度。

#### (1) 自注意力机制

自注意力机制<sup>[20]</sup>旨在增强点云特征的全局语义关

$$P_{ROI} = \left\{ (x_i, y_i, z_i) \in P \mid \begin{array}{l} x_{\min} \leq x_i \leq x_{\max}, \\ y_{\min} \leq y_i \leq y_{\max}, \\ z_{\min} \leq z_i \leq z_{\max} \end{array} \right\} \quad (1)$$

式中:  $P$  为原始点云;  $[x_{\min}, x_{\max}]$ 、 $[y_{\min}, y_{\max}]$ 、 $[z_{\min}, z_{\max}]$  分别表示作业域在三维坐标系下的边界阈值。

#### 3) 基于 SSA 改进的 PointNet++ 钢丝绳点云分割算法

尽管 PointNet++ 在局部几何特征提取方面具有优势, 但其局部-全局特征融合不足导致门座式起重机钢丝绳识别在耦合区域分割精度显著退化。为此, 本文在 PointNet++ 框架中嵌入空间-自注意力 (spatial-self-attention, SSA) 模块, 如图 3 所示, 通过协同优化局部几何与全局语义关联提升边界分割精度。在 SSA 模块中, 自注意力机制建立跨点长程依赖, 强化钢丝绳轴向连续性建模; 空间注意力机制基于局部几何特征的分布进行动态加权, 从而强化抓斗与钢丝绳交界区关键区域的几何特征表达。二者通过特征级联实现互补, 在保持线状结构整体拓扑特性的同时精准捕获局部几何差异, 有效解决边界模糊导致的语义歧义问题。

联性, 通过建模点云中各点之间的长程依赖关系, 有效捕捉钢丝绳点云沿轴向的连续性特征, 如图 5 所示。给定输入特征矩阵  $\mathbf{F} \in \mathbf{R}^{B \times N \times C}$  ( $B$  为批量大小,  $N$  为点数,  $C$  为点集特征维度), 通过线性变换生成查询矩阵  $\mathbf{Q}$ 、键矩阵  $\mathbf{K}$  与值矩阵  $\mathbf{V}$ :

$$\mathbf{Q} = \mathbf{F}\mathbf{W}_Q, \mathbf{K} = \mathbf{F}\mathbf{W}_K, \mathbf{V} = \mathbf{F}\mathbf{W}_V \quad (2)$$

式中:  $\mathbf{W}_Q$ 、 $\mathbf{W}_K$ 、 $\mathbf{W}_V$  为可学习权重矩阵。

查询矩阵和键矩阵的乘积经过缩放后, 通过 Softmax 函数计算注意力权重矩阵  $\mathbf{A}$ :

$$\mathbf{A} = \text{Softmax} \left( \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} \right) \quad (3)$$

式中: 缩放因子  $\sqrt{d}$  防止梯度消失,  $d$  为投影维度。权重矩阵  $\mathbf{A}$  的每个元素量化了任意两点之间的关联强度。更




图4 混合注意力机制特征提取模块

Fig. 4 Feature extraction module of hybrid attention mechanism




图5 自注意力机制

Fig. 5 Self-attention mechanism

新后的特征  $Z$  通过权重矩阵对值矩阵加权得到:

$$Z = A \cdot V \quad (4)$$

此操作使每个点的新特征融合了全局上下文信息,特别是强化了钢丝绳点云沿轴向的长程连续性特征。为增强特征表达能力,采用多头注意力机制,并行执行多组上述变换,每组的权重矩阵不同。各组的输出特征沿通道维度拼接后,通过线性投影融合  $F'$ :

$$F' = \text{Concat}(Z^{(1)}, \dots, Z^{(h)}) W_0 \quad (5)$$

式中:  $h$  为注意力头数量;  $W_0$  为输出投影矩阵。该机制通过动态权重分配,有效解决了传统方法在长程空间结构建模上的不足,为钢丝绳的精确识别提供了关键特征支持。

## (2) 空间注意力机制

空间注意力机制<sup>[21]</sup>旨在提升点云中抓斗与钢丝绳交界区域的局部几何特征显著性,如图6所示。给定输入特征  $F' \in \mathbb{R}^{B \times N \times C'}$  ( $B$  为批量大小,  $C'$  为点集特征维度),对通道维度进行全局平均池化与最大池化操作得




图6 空间注意力机制

Fig. 6 Spatial attention mechanism

$F_{\text{avg}}$  与  $F_{\text{max}}$ :

$$F_{\text{avg}} = \text{AvgPool}(F') \quad (6)$$

$$F_{\text{max}} = \text{MaxPool}(F') \quad (7)$$

式中:  $F_{\text{avg}}, F_{\text{max}} \in \mathbb{R}^{B \times N \times 1}$  为空间统计特征图,反映不同位置的特征分布特性。随后将两特征图沿通道维度拼接得

$F_{\text{mix}}$ :

$$F_{\text{mix}} = [F_{\text{avg}}, F_{\text{max}}] \in \mathbb{R}^{B \times N \times 2} \quad (8)$$

将之输入  $1 \times 1$  卷积层提取局部上下文信息,并经由 Sigmoid 函数生成空间注意力权重图  $M \in \mathbb{R}^{B \times N \times 1}$ :

$$M = \sigma(\text{Conv}_{1 \times 1}([F_{\text{mix}}])) \quad (9)$$

通过逐元素乘法实现特征增强:

$$F'' = F' \odot \tau(M) \quad (10)$$

式中:  $\odot$  表示逐元素乘法;  $\tau(M)$  为经过维度扩展的空间注意力权重图。该机制通过动态的空间权重分布,引导模型优先关注抓斗与钢丝绳交界区等关键耦合位置的几何特征,在有效抑制背景噪声的同时,维持细长结构的拓扑连续性,进而为复杂场景下的接触区域特征提取与边界精准分割提供关键的几何指引。

## 4) 钢丝绳束位姿计算方法

本文采用基于改进 PointNet++ 网络的点云分割方法,从原始点云中分割出钢丝绳束点云  $P = \{p_i \mid i = 1, 2, \dots, N\}$ ,其中  $p_i = (x_i, y_i, z_i)$  为三维坐标。为精确表征钢丝绳束的空间位姿,采用基于最小二乘法的空间直线拟合方法对点云进行建模。

步骤1) 针对分割后获得的钢丝绳束点云  $P$ ,采用空间直线模型描述其空间位姿  $L: p(t) = p_0 + td$ ,其中  $p_0 = (x_0, y_0, z_0)$  为直线上的一点,  $d = (d_x, d_y, d_z)$  为直线的单位方向向量,  $t \in \mathbb{R}$  为参数变量。

步骤2) 首先通过质心与主方向分析完成参数初始化,计算点云质心  $\mu$  作为基准点  $p_0$  的初始值,对中心化点云  $\{p_i - \mu\}_{i=1}^N$  构建数据矩阵并进行奇异值分解,取右奇异矩阵对应最大奇异值方向的列向量单位化后作为初始方向向量  $d_0$ 。

步骤3) 钢丝绳束位姿直线拟合的核心是通过最小化点云到直线的距离残差,求解最优参数  $(\hat{p}_0, \hat{d})$ ,优化目标为最小化所有点的距离残差平方和:

$$\min_{p_0, d} \sum_{i=1}^N \| (p_i - p_0) - ((p_i - p_0) \cdot d) d \|^2 \quad (11)$$

2 实验对比与分析

2.1 实验环境配置

本文基于自定义的门座式起重机钢丝绳作业点云数据集,旨在比较与分析相关模型的性能。实验所用的硬件和软件配置如下。软件方面,操作系统为 Ubuntu 20.04,编程框架为 Python 3.8,机器学习库使用 PyTorch 2.4.1。硬件方面,配备了 Tesla M40 24 GB 的 GPU 和 Intel Xeon E312xx (Sandy Bridge, IBRS update) 的 CPU。该点云数据集共包含 8 743 个点云样本,按 8 : 2 的比例分为训练集和测试集。

2.2 门座式起重机钢丝绳作业数据集

将改进的 PointNet++门座式起重机上钢丝绳识别模型应用于真实的散货码头装卸机械,有效地检测了钢丝绳的位置和姿态。硬件设备包括 16 线 LiDAR 和边缘计算模块。钢丝绳作业的点云数据收集过程如图 7 所示。



图 7 点云数据集收集过程  
Fig. 7 Point cloud data set collection process

每个场景被分为“钢丝绳”、“抓斗”和“其他”3 个类别进行点云分割,并使用 CloudCompare 软件对数据进行标注。

2.3 评估指标

为验证点云边界特征的有效性,本研究通过评估针对钢丝绳的点云分割模型性能来实现。本文采用精确率 (precision)、召回率 (recall) 和交并比 (IoU) 3 项核心指标构建评价体系。这些互补性指标分别量化了模型排除背景干扰、捕捉目标钢丝绳点以及预测区域与真实区域空间吻合的能力,从而综合评估分割模型的整体性能,计算公式定义为:

$$Precision = \frac{TP}{TP + FP}$$
(12)

$$Recall = \frac{TP}{TP + FN}$$
(13)

$$IoU = \frac{TP}{TP + FP + FN}$$
(14)

式中: TP 指正确分类的钢丝绳点云数量; FP 指背景点被误判为钢丝绳的数量; FN 指真实钢丝绳点未被识别

的数量。

2.4 模型对比实验与分析

本研究使用的实验环境配置中,在模型训练时设置了以下训练参数:批大小为 8,共 1 024 个采样点,采用 Adam 优化算法。初始学习率设置为 0.001,epoch 数设置为 200。

为了探索所提出的优化模型与主流点云分割网络的性能差异,使用相同的训练参数和样本训练数据进行了对比实验。训练的对比结果如表 1 所示。

表 1 不同模型的分割测试结果

Table 1 Segmentation test results of different models

| ( % )                    |           |        |      |
|--------------------------|-----------|--------|------|
| 模型                       | Precision | Recall | IoU  |
| PointNet                 | 96.8      | 83.5   | 81.3 |
| PointCNN                 | 95.5      | 78.1   | 75.4 |
| Point Transformer        | 96.2      | 80.9   | 78.4 |
| PointNet++               | 96.9      | 84.0   | 81.8 |
| RANSAC-RG <sup>[6]</sup> | 93.7      | 71.1   | 67.9 |
| 本文                       | 98.6      | 92.3   | 91.2 |

实验结果表明,在钢丝绳点云分割任务中各模型性能存在显著差异。作为点云分割领域的先驱模型,PointNet 虽然实现了 96.8%的精确率,但其 83.5%的召回率与 81.3%的 IoU 表明该模型在复杂边界特征处理和漏检控制方面存在明显不足,难以有效应对钢丝绳与抓斗的高耦合区域分割挑战。PointCNN 展现出更严重的局限性,其 78.1%的召回率和 75.4%的 IoU 均为基准模型最低值,凸显其在局部几何建模能力上的缺陷,导致细长结构特征捕捉不完整。Point Transformer 通过自注意力机制将 IoU 提升至 78.4%,但仍低于 PointNet++的 81.8%,说明其在多层次边界特征融合方面仍有优化空间,未能充分解决空间耦合效应导致的特征歧义问题。作为传统点云分割方法的代表,RANSAC-RG 的表现最差,其精确率、召回率和 IoU 分别为 93.7%、71.1%和 67.9%。该方法依赖手工设计的几何特征与固定阈值,难以在点云稀疏且强耦合的场景下准确区分钢丝绳与抓斗,导致严重的欠分割与误分割。

本文提出的改进模型通过嵌入模块 SSA,显著增强了对高耦合区域的边界分割能力,展现出全面性能优势,精确率达 98.6%,召回率提升至 92.3%,IoU 创 91.2%新高。相较于性能最优的基准模型 PointNet++,本模型 IoU 提升 9.4%;相对 PointNet、PointCNN 和 Point Transformer 则分别提升 9.9%、15.8%和 12.8%。这些数据验证了改进模型在分割精度、目标覆盖完整性和空间一致性 3 个维度的显著进步,成功克服了金属反光干扰与动态耦合效应导致的特征误识别难题,为港口自动化设备的安全监测提供了更可靠的技术解决方案。

2.5 模型消融实验

为了验证预分割算法和 SSA 模块对点云分割性能的

改善,以 PointNet++为基准模型,进行了一系列消融实验。实验中逐步添加了改进模块,结果对比如表 2 所示。

表 2 消融实验结果对比  
Table 2 Comparison of ablation experiment results (%)

| 改进模型                   | Precutting | Self attention | Spatial attention | Precision | Recall | IoU  |
|------------------------|------------|----------------|-------------------|-----------|--------|------|
| Pointnet++             | ×          | ×              | ×                 | 96.9      | 84.0   | 81.8 |
| +Precutting            | √          | ×              | ×                 | 97.7      | 87.8   | 86.0 |
| +Self attention        | ×          | √              | ×                 | 97.5      | 86.8   | 85.0 |
| +Spatial attention     | ×          | ×              | √                 | 97.3      | 85.8   | 83.8 |
| +SSA                   | ×          | √              | √                 | 97.9      | 88.5   | 86.9 |
| +Precutting+SSA( Ours) | √          | √              | √                 | 98.6      | 92.3   | 91.2 |

由表 2 可知,基准模型 PointNet++的精确率、召回率和 IoU 分别为 96.9%、84.0%和 81.8%。引入预分割模块后,各项指标分别提升至 97.7%、87.8%和 86.0%,该模块通过运动学约束的空间剪裁有效降低了计算冗余,为后续分割奠定了良好的数据基础。单独引入自注意力机制使 IoU 提升至 85.0%,验证了其对于钢丝绳轴向拓扑连续性的增强作用;单独引入空间注意力机制使 IoU 提升至 83.8%,证明了其对于耦合区域边界特征的强化能力。当二者组合为 SSA 模块时,IoU 进一步提升至 86.9%,表明自注意力与空间注意力在全局建模与局部增强方面存在互补增益。将预分割与 SSA 模块共同引入后,模型性能达到最优,精确率 98.6%、召回率 92.3%、IoU 达 91.2%,较基准模型分别提升 1.7%、8.3%和 9.4%。这些结果充分验证了各改进模块的有效性及其协同增益特性。

2.6 环境鲁棒性分析

为了进一步研究改进的 PointNet++模型在真实场景中的泛化能力,针对雨、雾、雪等典型恶劣天气条件开展了工程应用测试。测试共采集 1 000 组真实场景点云样本,涵盖正常天气及雨、雾、雪等不同程度不利天气条件,每种工况 200 组样本,使用相同硬件配置的服务器进行实时分割处理。测试结果如表 3 所示。

表 3 不同天气条件模型对比  
Table 3 Comparison of models under different weather conditions (%)

| 天气 | Pointnet++ |        |      | 本文        |        |      |
|----|------------|--------|------|-----------|--------|------|
|    | Precision  | Recall | IoU  | Precision | Recall | IoU  |
| 小雨 | 96.8       | 83.3   | 81.0 | 98.6      | 92.1   | 90.8 |
| 大雨 | 96.6       | 82.8   | 80.4 | 98.5      | 91.8   | 90.5 |
| 小雾 | 96.5       | 82.2   | 79.9 | 98.4      | 91.1   | 89.8 |
| 大雾 | 97.1       | 85.0   | 82.9 | 98.7      | 92.6   | 91.4 |
| 大雪 | 96.7       | 83.2   | 80.9 | 98.6      | 92.3   | 91.1 |

实验结果表明,改进模型在所有测试天气条件下均展现出显著优于 PointNet++的分割性能。PointNet++受环境影响波动较大,IoU 介于 79.9%~82.9%,而本文模型在各工况下均保持 89.8%以上的 IoU,表现出极强的环境鲁棒性。其中,在大雾天气下两者性能差距最为明显,本文模型 IoU 达到 91.4%,较基准模型提升 8.5%。在大雨工况下,本文模型仍维持 90.5%的 IoU,验证了其对于恶劣天气干扰的有效抑制能力。综上,本文方法在实际港口复杂气象条件下具备稳定的感知能力。

2.7 工程应用对比测试

为验证本模型在港口门座式起重机真实作业场景中的性能表现,本研究在实际干散货码头环境中开展了多工况工程应用测试。测试涵盖进舱、出舱、大臂回转、进斗、出斗等核心作业流程,并区分空载与满载状态,全面评估钢丝绳在空间位姿动态变化条件下的分割鲁棒性。测试过程通过多激光雷达同步采集点云数据,以 PointNet++为基准进行实时分割性能对比。为确保评估全面性,每种工况采集 500 个样本点云序列,覆盖海侧和路侧作业区域。

如表 4 所示,空载工况下实现全面性性能提升,IoU 指标提升幅度为 7.6%至 9.0%,典型表现为大臂回转工况 IoU 从 80.4%提升至 89.4%,同时精确率提升到 98.3%至 98.9%范围,召回率提升到 90.8%至 93.7%的水平。进斗与出斗作业的 IoU 分别达 91.5%和 91.6%,均伴随精度召回率的提升。满载工况呈现更明显的效果提升,出舱作业 IoU 提升 9.1%至 92.0%,大臂回转工况提升 10.2%至 90.9%,进斗工况以 92.7%的 IoU 创峰值,同时保持 98.9%的精确率和 93.7%的召回率。

如图 8 所示,在抓斗与钢丝绳高度耦合区域,基准模型的分割结果存在边界模糊和误分割现象,而本文方法通过 SSA 模块增强几何突变特征感知,精准解耦耦合区域,实现了抓斗与钢丝绳的清晰分割。

表 4 多工况真实场景模型测试对比

Table 4 Comparison of multi-condition real-world scenario model tests

(%)

| 状态 | Pointnet++ |        |      | 本文        |        |      |
|----|------------|--------|------|-----------|--------|------|
|    | Precision  | Recall | IoU  | Precision | Recall | IoU  |
| 空载 | 进舱         | 97.2   | 85.4 | 83.3      | 98.7   | 92.5 |
|    | 出舱         | 97.3   | 85.9 | 83.9      | 98.7   | 92.8 |
|    | 大臂回转       | 96.6   | 82.7 | 80.4      | 98.3   | 90.8 |
|    | 进斗         | 97.2   | 85.5 | 83.5      | 98.7   | 92.6 |
|    | 出斗         | 97.4   | 86.0 | 84.0      | 98.7   | 92.7 |
| 满载 | 进舱         | 97.4   | 86.4 | 84.4      | 98.8   | 93.3 |
|    | 出舱         | 97.1   | 84.9 | 82.9      | 98.8   | 93.0 |
|    | 大臂回转       | 96.7   | 83.0 | 80.7      | 98.6   | 92.1 |
|    | 进斗         | 97.5   | 86.9 | 85.0      | 98.9   | 93.7 |
|    | 出斗         | 97.1   | 84.8 | 82.7      | 98.7   | 92.9 |




图 8 分割结果可视化

Fig. 8 Visualisation of segmentation results

综上所述,本文方法在门座式起重机各类作业场景中均展现最优工况适应性,尤其在动态大臂回转与高负载抓斗工况实现显著突破。面对高粉尘、强反光等恶劣环境仍保持稳定感知能力,为港口自动化设备的精准控制与安全运行提供了可靠技术支撑。

3 结 论

作为干散货自动化码头装卸作业的关键设备,门座式起重机钢丝绳空间位姿的精准感知对抓斗防摇控制与闭环定位至关重要。针对传统视觉和惯性方法在金属反光、粉尘及动态耦合干扰下精度不足的问题,本文提出了一种基于多激光雷达的门座式起重机钢丝绳识别方法。本文所设计的感知方法利用起重机运动学约束的动态空间预分割算法降低计算量;通过改进 PointNet++网络通过嵌入 SSA 模块,增强了钢丝绳与抓斗耦合区域的分割能力,并基于分割结果采用空间直线拟合算法解算位姿。实际工况验证表明,该方法在粉尘遮蔽、金属反光等复杂干扰环境下保持稳定的感知能力,在空载、满载及大臂回转等多种动态工况中均表现出良好的适应性。本方法为

港口门座式起重机的安全监控与效率优化提供了技术支持。

参考文献

[ 1 ] Jiang H, Cheng K. YOLOOI: YOLO with robustness to outliers and illumination [ C ]//2024 2nd International Conference on Computer, Vision and Intelligent Technology (ICCVIT), 2024:1-9.

[ 2 ] Brzeczek J S. Examination of aircraft's cable control systems tension [ J ]. Advances in Science and Technology Research Journal, 2019, 13(2): 65-71.

[ 3 ] Shi S S, Yang L, Chen K Y, et al. A method of power line hanging point location based on LiDAR data [ C ]//2019 IEEE 3rd Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2019:1900-1905.

[ 4 ] Guo T, Xu L G, Chen Y R, et al. Research on point cloud power line segmentation and fitting algorithm [ C ]//2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2019: 2404-2409.

[ 5 ] 毛清华, 徐文兵, 赵文, 等. 基于 3D 点云的矿井提升

- 钢丝绳振动位移在线测量方法 [J]. 煤炭科学技术, 2025, 53(S2): 404-416.
- Mao Qinghua, Xu Wenbing, Zhao Wen, et al. Online measurement of vibration displacement of mine hoisting wire rope based on 3D point cloud [J]. Coal Science and Technology, 2025, 53(S2): 404-416.
- [6] 胡益菲, 刘天纵, 翟世雄, 等. 基于激光雷达的高空配电线缆识别方法 [J]. 河北工业大学学报, 2025, 54(5): 29-35.
- Hu Yifei, Liu Tianzong, Zhai Shixiong, et al. Lidar-based method for identifying overhead distribution cables [J]. Journal of Hebei University of Technology, 2025, 54(5): 29-35.
- [7] 王永敏, 曹迪, 陆吉, 等. 无人机 LiDAR 点云电力线快速提取算法研究 [J]. 测绘科学, 2026, 51(1): 108-116.
- Wang Yongmin, Cao Di, Lu Ji, et al. Research on fast extraction algorithm for power lines from UAV LiDAR point clouds [J]. Science of Surveying and Mapping, 2026, 51(1): 108-116.
- [8] 阮剑, 朱连海, 胡三宝. 基于 PointNet 的车身分割方法 [J]. 武汉大学学报(工学版), 2023, 56(3): 347-352.
- Ruan Jian, Zhu Lianhai, Hu Sanbao. Segmentation method of car body based on PointNet [J]. Engineering Journal of Wuhan University, 2023, 56(3): 347-352.
- [9] Qi C R, Yi Li, Su Hao, et al. PointNet ++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space [J/OL] 2017, arXiv:1706.02413.
- [10] 孙国强, 庞岩. 基于 PointCNN 的车载行道树点云分割方法 [J]. 北京测绘, 2023, 37(1): 61-66.
- Sun Guoqiang, Pang Yan. Point cloud segmentation method of vehicle-mounted street tree based on PointCNN [J]. Beijing Surveying and Mapping, 2023, 37(1): 61-66.
- [11] 张自强, 刘涛, 杜萍, 等. 典型建筑物群组模式的空间图卷积模型 DGCNN 识别方法 [J]. 武汉大学学报(信息科学版), 2024, 49(5): 868-878.
- Zhang Ziqiang, Liu Tao, Du Ping, et al. Recognition of typical building group patterns using spatial graph convolutional model DGCNN [J]. Geomatics and Information Science of Wuhan University, 2024, 49(5): 868-878.
- [12] 冯凯浩, 陶志勇, 李衡, 等. 基于 Transformer 的逐通道点云分析网络 [J]. 电子测量与仪器学报, 2025, 39(2): 49-59.
- Feng Kaihao, Tao Zhiyong, Li Heng, et al. Transformer-based channel-by-channel point cloud analysis network [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 49-59.
- [13] 喻佳祺, 杨洪刚, 王阳. 基于改进 PointPillars 的点云车辆目标检测 [J]. 国外电子测量技术, 2024, 43(9): 69-77.
- Yu Jiaqi, Yang Honggang, Wang Yang. Point cloud vehicle target detection based on improved PointPillars [J]. Foreign Electronic Measurement Technology, 2024, 43(9): 69-77.
- [14] Zhang R R, Wang L H, Guo Z Y, et al. Parameter is not all you need: Starting from non-parametric networks for 3D point cloud analysis [J/OL]. 2023, arXiv:2303.08134.
- [15] Tran A T, Le H S, Lee S H, et al. PointCT: Point central transformer network for weakly-supervised point cloud semantic segmentation [Z]. 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). 2024: 3544-53.
- [16] Chang K X, Ma W H, Xu X M, et al. A point cloud segmentation method for pigs from complex point cloud environments based on the improved PointNet++ [J]. Agriculture, 2024, 14(5).
- [17] Qian G C, Abed Al Kader Hammoud H, Li G H, et al. ASSANet: An anisotropic separable set abstraction for efficient point cloud representation learning [J/OL]. 2021, arXiv:2110.10538.
- [18] Zhu L H. GeoSep-PointNet++: A 3D point cloud semantic segmentation algorithm based on geometric information enhancement and feature separation encoding [Z]. 2024 IEEE 4th International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA). 2024: 1514-1519.
- [19] 林冬梅, 樊煜杰, 陈晓雷, 等. 基于 SOP 芯片三维点云图像的引脚缺陷检测方法 [J]. 电子测量与仪器学报, 2025, 39(8): 42-53.
- Lin Dongmei, Fan Yujie, Chen Xiaolei, et al. Pin defect detection method based on 3D point cloud image of SOP chip [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 42-53.
- [20] 刘清涛, 王子俊, 张玉隆, 等. 融合自注意力与残差神经网络的 3D 打印激光在机测量误差修正方法 [J]. 电子测量与仪器学报, 2024, 38(4): 27-36.
- Liu Qingtao, Wang Zijun, Zhang Yulong, et al. Method for correcting laser in-machine measurement errors integrating self-attention and residual neural network in 3D printing [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 27-36.
- [21] 曲彦霖, 王悦, 张倩, 等. 一种基于空间特征注意力机制的点云分析方法 [J]. 激光与光电子学进展,

2023, 60(24): 240-250.

Qu Yanlin, Wang Yue, Zhang Qian, et al. Point cloud analysis method based on spatial feature attention mechanism [J]. Laser & Optoelectronics Progress, 2023, 60(24): 240-250.

## 作者简介



**李欣源**, 现为上海海事大学信息工程学院计算机科学与技术专业的本科生, 作为核心成员参与了上海海事大学大学生创新训练项目“基于多源传感器信息融合的门座式起重机抓斗位姿检测系统”, 主要研究方向为计算机科学与技术。

E-mail: 202310310047@stu.shmtu.edu.cn

**Li Xinyuan** is currently an undergraduate student majoring in Computer Science and Technology at the College of Information Engineering, Shanghai Maritime University. As a core member, she has participated in Shanghai Maritime University College Students' Innovative Entrepreneurial Training Plan Program, focusing on the project "Detection System for Grab Position and Orientation of Portal Cranes Based on Multi-Sensor Information Fusion". Her main research interests include Computer Science and Technology.



**宓超**, 2007 年于上海海事大学获得学士学位, 2010 年于上海海事大学获得硕士学位, 2019 年于上海海事大学获得博士学位, 现为上海海事大学物流工程学院教授/博导, IEEE Senior Member, 中国工程机械学会青年工作委员会委员, 中国创造学会科创

产业促进专业委员会委员, 主要研究方向为港航装备智能化。

E-mail: chaomi@shmtu.edu.cn

**Mi Chao** received his B. Sc. degree from Shanghai Maritime University in 2007, M. Sc. degree from Shanghai Maritime University in 2010, and Ph. D. degree from Shanghai Maritime University in 2019, respectively. He is currently a professor and Ph. D. supervisor at the Logistics Engineering College, Shanghai Maritime University. He is an IEEE Senior Member, a member of the Youth Work Committee of China Construction Machinery Society, and a member of the Science and Technology Innovation Industry Promotion Committee of China Creativity Studies Association. His main research interests include intelligent port and waterway equipment.



**沈阳**(通信作者), 2009 年于上海海事大学获得学士学位, 2012 年于上海海事大学获得硕士学位, 2022 年于上海海事大学获得博士学位, 现为上海海事大学高等技术学院副教授/硕导, 主要研究方向为港航物流智能化。

E-mail: yangshen@shmtu.edu.cn

**Shen Yang** (Corresponding author) received his B. Sc. degree from Shanghai Maritime University in 2009, M. Sc. degree from Shanghai Maritime University in 2012, and Ph. D. degree from Shanghai Maritime University in 2022, respectively. He is currently an associate professor and M. Sc. supervisor at the Advanced Institute of Technology, Shanghai Maritime University. His main research interests include intelligent port and logistics.