文章编号:1673-0291(2026)04-0201-12 **DOI**:10.11860/j.issn.1673-0291.20250104

面向自动泊车的停车位关键点检测与结构匹配方法研究

张志浩,林春雨,黄书隽,赵 耀
(北京交通大学 计算机科学与技术学院,北京 100044)

摘 要:针对自动泊车系统在复杂环境下对车位感知能力的实际需求,以及现有端到端停车位检测方法在结构完整性建模和鲁棒性方面的不足,提出一种基于稀疏关键点检测和结构匹配的端到端停车位检测方法.该方法以车位关键点为基础构建双分支结构,同时完成关键点定位与匹配关系预测.首先,为提升模型对模糊区域及难匹配样本的识别能力,采用稀疏配对聚焦损失(Sparse Pairwise Focal Loss,SPF-Loss)与点位回归损失,分别从结构约束与几何精度两个方面对训练过程进行优化;然后,为增强模型的结构表达能力与环境适应性,引入结构感知CutMix(Structure-Aware CutMix,SA-CutMix)数据增强策略与注意力引导插值(Attention-Guided Interpolation,AGI)模块,以提升模型在遮挡、阴影、低光照等干扰条件下的检测稳定性;最后,在公开数据集ps2.0与自主构建的真实场景数据集CRPS-D上开展充分实验以验证所提方法的有效性.研究结果表明:所提方法在ps2.0数据集上达到99.37%的精确率和99.47%的召回率,与主流方法性能持平;在更具挑战性的CRPS-D数据集上,平均精确率(Average Precision,AP)相比现有方法提升3.47%~4.56%;多个典型复杂场景下的验证结果进一步证明方法的适应性与鲁棒性,消融实验也证实各模块的有效性,研究可为复杂环境下自动泊车系统的车位视觉感知提供可参考的技术路径.

关键词:停车位检测;关键点匹配;结构感知;数据增强;端到端网络
中图分类号:TP391.4 **文献标志码**:A

Parking slot keypoint detection and structural matching for automated parking

Zhang Zhihao, *Lin Chunyu*, *Huang Shujuan*, *Zhao Yao*
(School of Computer Science and Technology, Beijing Jiaotong University, Beijing 100044, China)

Abstract: To meet the need for reliable parking-slot perception in automated parking systems under complex conditions and to address the limitations of existing end-to-end parking-slot detection methods in modeling structural integrity and robustness, this study proposes an end-to-end parking-slot detection method based on sparse keypoint detection and structural matching. The method uses parking-slot keypoints to construct a dual-branch architecture that simultaneously performs keypoint localization and predicts matching relationships. First, Sparse Pairwise Focal Loss (SPF-Loss) and point re-

收稿日期:2025-07-07;**修回日期**:2026-04-30
基金项目:国家自然科学基金(62172032,U2441242)
Foundation items: National Natural Science Foundation of China (62172032, U2441242)
第一作者:张志浩(2001—),男,安徽亳州人,硕士生.研究方向为计算机视觉和自动驾驶.**email**:2511436264@qq.com.

引用格式:张志浩,林春雨,黄书隽,等.面向自动泊车的停车位关键点检测与结构匹配方法研究[J].北京交通大学学报,2026,50(4):201-212.
Zhang Zhihao, Lin Chunyu, Huang Shujuan, et al. Parking slot keypoint detection and structural matching for automated parking[J]. Journal of Beijing Jiaotong University, 2026, 50(4): 201-212. (in Chinese)

gression loss are adopted to optimize training in terms of structural constraints and geometric accuracy, respectively, thereby improving the model's ability to identify ambiguous regions and difficult-to-match samples. Next, the Structure-Aware CutMix (SA-CutMix) data augmentation strategy and the Attention-Guided Interpolation (AGI) module are introduced to enhance structural representation and adaptability to environmental variations, improving detection stability under disturbances such as occlusion, shadows, and low illumination. Finally, extensive experiments are conducted on the public ps2.0 dataset and the self-constructed real-world CRPS-D dataset to evaluate the proposed method. The results show that the method achieves a precision of 99.37% and a recall of 99.47% on ps2.0, comparable to those of mainstream methods. On the more challenging CRPS-D dataset, its Average Precision (AP) is 3.47%～4.56% higher than that of existing methods. Tests in several representative complex scenarios further demonstrate the adaptability and robustness of the method, while ablation experiments confirm the effectiveness of each module. The proposed method provides a viable technical approach to visual parking-slot perception for automated parking systems in complex environments.

Keywords: parking-slot detection; keypoint matching; structure awareness; data augmentation; end-to-end network

随着智能驾驶技术的快速发展,自动泊车系统逐渐成为提升驾驶便利性与安全性的关键模块.其中,停车位检测作为自动泊车感知系统的基础,其准确性直接决定泊车路径规划与运动控制的可靠性.相比传统单目摄像头,环视摄像头系统能够生成车辆周围环境的鸟瞰图视角,提供更全面的视觉感知信息,因此被广泛应用于泊车系统中.当前泊车系统通常结合多摄像头环视感知、激光雷达数据、规则约束与工程经验,实现对规则停车场景下车位的稳定检测.然而,在复杂环境(如车位密集、斜置车位、光照变化显著等)下,车位结构理解仍面临挑战,尤其在基于深度学习方法的端到端结构建模与车位关键点鲁棒匹配方面,仍缺乏统一且有效的解决方案.

传统停车位检测方法多依赖于手工设计的角点、边缘等几何特征[1-3].在此基础上,文献[4]提出一种基于环视系统的检测方法,采用线段检测器(Line Segment Detector, LSD)并结合逆透视变换(Inverse Perspective Mapping, IPM),从鸟瞰图中提取车位线.文献[5]则设计面向车载广角相机的视频处理流程:首先通过张正友标定法去除图像畸变并转换为鸟瞰图,进而融合色相-饱和度-亮度(Hue-Saturation-Value,HSV)色彩空间分割、Hough变换及LSD直线检测实现车位定位.然而,传统检测方法在复杂场景下的表现有限,难以应对遮挡、光照变化以及不规则停车位等挑战.

随着深度学习技术的发展,基于学习的方法逐渐成为主流.现有基于深度学习的方法依据实现路径可大致分为基于目标检测的方法[6-8]、基于图像分割的方法[9-11],以及基于关键点与结构关系建模的方法[12-14]3类.

DeepPS[6]是首个基于深度卷积神经网络的停车位检测方案,其采用YOLOv2[15]检测车位标记点,并通过定制网络估计车位方向,最终结合几何规则推理停车位结构.在此基础上,VPS-Net[7]将空车位检测分解为车位定位与占用分类2个阶段,采用YOLOv3[16]同时完成车位分类与标记点定位,并针对车位特征设计专门的占用分类网络,从而在检测精度与结构建模方面进一步提升整体性能.文献[17]提出基于全景环视图的自动泊车空闲停车位检测算法,以改进型YOLOv8[18]为检测框架,通过增强特征提取能力并设计入口线-标记点匹配算法实现车位结构推理.文献[19]面向复杂环境下的停车位检测需求,基于YOLOv7[20]模型进行改进:在常规复杂场景下改进激活函数与上采样方式,在夜间场景中优化损失函数与网络结构并引入图像增强技术.文献[21]设计基于PP-YOLOE[22]的轻量化检测方案,通过跨阶段特征提取与多尺度感知增强以提高检测效率,并采用生成对抗网络进行数据增强.文献[23]提出2种基于YOLOv5[24]的改进方案,分别引入多头注意力机制和层次感知模块,在多尺度特征融合与远程依赖建模方面取得显著效果.文献[25]设计了双路并行多尺度标记点检测网络,采用高低双分辨率分支融合以兼顾全局布局与局部精度,采用高斯热图定位标记点,利用2个标记点的方向与相对位置关系计算车位方向.文献[26]将传统LSD直线检测与深度学习目标检测相结合,利用LSD提取的车道线几何信息辅助深度学习检测,提升了划线停车位的识别准确率与监控系统的鲁棒性.

除了基于目标检测的范式,研究者也对基于图像分割的停车位检测方法进行了探索.文献[27]采用级联式U形网络(U-shaped Network,U-Net)分别分割车位线条与角点,再通过后处理筛选有效点位以构建停车位结构.文献[28]将停车位视为整体目标,采用分割骨干网络结合特征金字塔网络(Feature Pyramid Network, FPN),实现分类、边框回归与语义分割的联合学习.文献[29]提出一种改进的Transformer与卷积神经网络(Convolutional Neural Network,CNN)混合编码-解码结构,该结构融合Transformer的全局上下文建模能力与CNN的局部特征提取能力,用于同时检测“T”形与“L”形角点及其方向与类型.文献[30]采用多重沙漏网络(Multi-Hourglass Network, MHN)进行角点与线特征的联合检测,通过多尺度策略选择最佳感受野以适应不同尺度的车位.文献[31]借鉴文本检测思想,提出一种紧凑深度神经网络,将像素分割与边界框回归相结合,实现在遮挡条件下的停车位检测与车位类型判别,并通过像素级置信度加权来提升检测准确性.

在基于关键点与结构关系建模的方法方面,DMPR-PS[12]方法通过卷积神经网络回归方向性标记点的坐标,并结合模板匹配算法判断车位入口线的有效性,从而显著提升检测的准确性与鲁棒性.为建模关键点之间的全局关系,文献[13]首次将图神经网络(Graph Neural Network, GNN)引入停车位检测任务,增强对车位拓扑结构的理解能力,有效缓解了传统方法在复杂场景中的误判问题.

近年来,基于Transformer的方法也被逐步引入停车位检测领域.文献[14]借鉴基于Transformer的端到端目标检测(DEtection Transformer,DETR)[32]框架,采用固定锚点替代传统查询机制,在保持结构感知能力的同时缩短了训练时间并提升了推理效率.此外,不断有研究探索更具通用性与适应性的检测方式,包括基于单目摄像头的停车位检测方法[33]、环视鱼眼图像下的结构识别方法[34-35],以及融合大规模视觉模型实现零样本推理能力的通用检测框架[36],进一步拓展检测任务在不同感知条件下的应用场景与技术路径.

尽管已有方法在检测精度和系统集成方面取得了一定进展,但当前端到端停车位检测框架仍普遍面临以下问题:首先,关键点之间的结构关系建模尚不充分,导致在复杂拓扑场景下车位边界容易出现重构错误;然后,环境变化引发的样本异质性显著,低光照、遮挡或背景干扰等因素常使模型难以准确感知局部关键点特征;最后,现有训练策略与损失函数多聚焦于点位回归的几何精度,忽视点与点之间的拓扑一致性约束,因而无法有效引导模型学习构建更具结构感知能力的表示.

针对上述端到端检测框架在结构关系建模、样本异质性适应及拓扑一致性约束方面的不足,提出一种基于关键点关系驱动的端到端停车位检测框架,旨在无需额外后处理的前提下,直接输出结构完整的停车位实例.在检测框架设计中,引入结构建模增强机制以提升车位重构的稳定性;同时从损失函数与数据增强2个角度出发,设计结构感知的训练优化策略,以更好地适应实际场景中结构不完整、样本稀疏与干扰显著等问题.所提方法可作为鸟瞰图感知后的独立车位检测模块,与行泊一体感知系统形成互补.

1　模型框架

针对复杂环境下停车位检测中的稀疏关键点定位与结构匹配问题,所提框架引入结构感知的数据增强策略、特征插值机制与稀疏配对聚焦损失,以提升模型在低标注密度下的鲁棒性与泛化能力.该模型包含关键点检测分支与匹配分支2个主要分支,其中关键点检测分支负责提取图像中的关键点位置,匹配分支则基于检测结果构建候选点对,执行结构匹配判断并生成匹配结果,从而确定停车位的最终位置,整体网络架构如图1所示.

框架中3项核心设计包括:结构感知CutMix(Structure-Aware CutMix,SA-CutMix)策略,用于增强背景多样性并提高模型对非结构区域的鲁棒性;注意力引导插值(Attention-Guided Interpolation,AGI)模块,提升特征对关键结构位置的敏感性与表示能力;稀疏配对聚焦损失(Sparse Pairwise Focal Loss,SPF-Loss),用于缓解样本稀疏带来的训练不稳定问题.

1.1　SA-CutMix策略

在关键点检测任务中,数据分布不均衡问题与场景复杂性对模型泛化能力构成关键挑战.为提升模型对复杂背景、多样光照及遮挡干扰的适应能力,数据增强策略成为训练过程中的关键环节.CutMix[37]作为一种经典图像数据增强方法,通过在不同图像间随机裁剪并粘贴区域,同时线性混合标签信息,可显著提升模型的鲁棒性与抗过拟合能力.然而,原始CutMix未考虑空间结构语义,直接在图像中随机裁剪替换区域,这在结构化感知任务中可能引发严重问题.以停车位关键点检测为例,关键点稀疏且结构性强,具有明确的几何构型与位置分

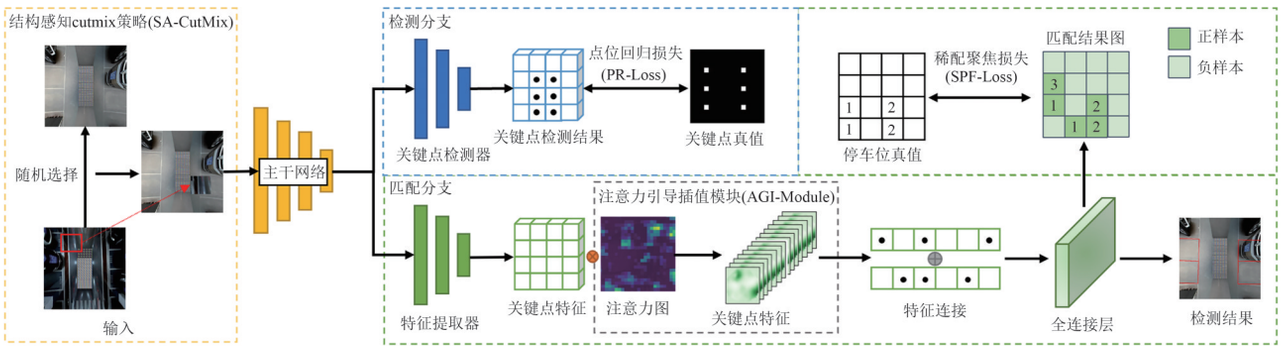


图 1　面向停车位关键点检测与匹配的端到端结构感知框架

Fig.1　Structure-aware end-to-end framework for parking-slot keypoint detection and matching

布规律.原始CutMix可能无意中裁剪关键点所在区域,打断原有空间几何关系,使模型难以学习结构先验,进而影响定位精度与稳定性.

为克服上述局限,提出SA-CutMix策略,旨在保留结构语义信息的同时引入多样化背景扰动,从而兼顾数据多样性与几何结构稳定性.SA-CutMix策略的核心思想是:仅在背景区域进行区域替换操作,避免破坏关键点区域所携带的空间结构特征,该策略的整体流程如图2所示.

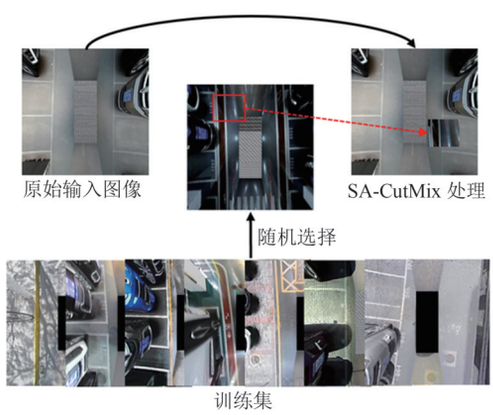


图 2　结构感知 CutMix 策略

Fig.2　Schematic of the SA-CutMix strategy

具体实现中,对于每一张训练图像,首先遍历并提取所有标注关键点的坐标信息,然后随机采样若干矩形裁剪区域作为候选替换区域.对于每一个候选区域,算法将其与关键点位置进行重叠检查:若与任何一个关键点区域发生交集,则视为包含结构语义信息,直接舍弃;仅当候选区域完全处于背景区域,不包含任何关键点时,才被标记为合法区域,并从另一张随机选取的图像中提取相同大小的图像块进行粘贴替换.为保证算法效率并避免无限采样,实际实现中设置最大尝试次数,若在设定次数内未能采样到合法区域,则跳过本轮增强.

SA-CutMix策略从结构保持与数据增强两个方面发挥作用:一方面保留了关键点对应的几何结构区域,使模型能够持续学习结构先验;另一方面引入来自其他图像的背景扰动(如不同的地面材质、纹理变化、光照条件或遮挡物体),有效扩展模型对环境变化的感知能力.

与原始CutMix相比,SA-CutMix更适用于关键点稀疏、结构约束强的任务场景.尤其在停车位检测中,关键点数量有限且排列规律显著,任何对结构区域的破坏都可能导致空间推理能力下降.SA-CutMix避免对结构的破坏,在结构稳定的前提下引入背景扰动,从而增强模型对边缘遮挡、复杂纹理与极端光照等复杂场景的适应能力.

1.2　注意力引导插值模块

在停车位关键点检测与匹配任务中,特征的精细化描述对于稀疏关键点的准确定位与结构关系的稳定建模尤为关键.传统的关键点描述符提取方法多采用直接在特征图上进行双线性插值采样的方式,尽管具备一定的连续性和可微性,但双线性插值的采样方式通常对所有空间位置赋予同等权重,未能显式区分结构区域与背景区域的重要性.在复杂场景中,如存在遮挡、强光、阴影或纹理混杂等干扰时,等权采样机制往往会削弱关键结构区域的表达能力,导致描述符判别性不足,影响后续的匹配与回归性能.

为解决网络对于关键结构关注程度不足的问题,提出一种注意力引导的特征插值模块,旨在通过引入轻量化注意力机制提升结构区域的特征表达能力,从而增强描述符对结构关系的建模效果.假设输入特征图为 $F\in R^{B\times C\times H\times W}$,首先通过 1×1 的卷积操作提取通道注意力响应,生成单通道注意力图 $A\in R^{B\times 1\times H\times W}$,并使用Sigmoid激活函数将其归一化至$[0,1]$区间,以获得每个空间位置的显著性估计,对应过程的表达式为

$$A=\sigma\left(\mathrm{Conv}_{1\times 1}(F)\right) \tag{1}$$

式中:σ为Sigmoid激活函数;$\mathrm{Conv}_{1\times 1}$为$1\times 1$的卷

积操作;B为批次大小;C为通道数;H为特征图的高度;W为特征图的宽度.

计算得到的注意力图反映当前图像中结构区域的重要性分布,可用于强调具有结构语义的显著区域并抑制冗余或噪声背景.然后,将原始特征图与注意力图进行逐元素相乘,得到加权特征图$F'=F\odot A$,注意力加权在保留空间连续性的同时增强结构敏感区域的响应,有助于提升后续插值描述符的判别性.在加权特征图F'上,继续采用双线性插值的方式对关键点位置进行特征采样.考虑到关键点位置以归一化坐标$[-1,1]$表示,具体采样过程可通过网格采样函数实现,在任意亚像素位置提取特征向量,并将结果沿空间维度展平,得到结构感知描述向量$D\in R^{B\times C\times N}$,其中$N$表示每张图像中的关键点数量.由于注意力机制已对特征图进行重加权,该描述符在稀疏标注条件下表现出更强的稳定性与区分能力.AGI模块的整体计算流程如图3所示.

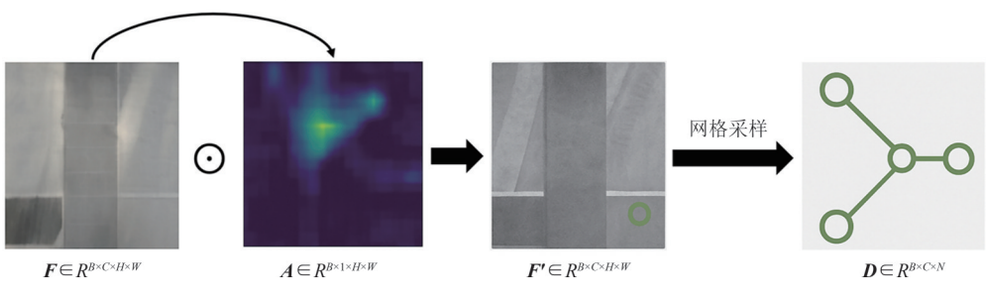


图3　注意力引导插值模块示意图

Fig.3　Schematic of the attention-guided interpolation module

与传统的直接插值方法相比,AGI模块通过显式建模区域重要性信息,引导描述符采样过程聚焦于结构显著区域,避免了背景干扰对特征表达的稀释效应.同时,AGI模块设计简单、计算开销小,易于集成到现有网络结构中并保持端到端训练流程.

1.3　损失函数设计

在端到端停车位检测任务中,模型需要同时具备精确预测图像中的车位关键点位置,以及正确判断关键点之间的结构归属关系2类能力.这2类能力分别对应空间定位与结构理解,是构建完整停车位边界的必要前提.因此,在网络训练中设计2类损失函数进行监督:点位回归损失(Point Regression Loss, PR-Loss)用于优化关键点定位精度,稀疏配对聚焦损失用于强化结构匹配判断.通过联合优化提出的损失函数,模型能够在空间定位与结构关系建模2个层面同步学习,从而获得更完整、鲁棒性更强的停车位检测能力.

1.3.1　点位回归损失

为实现像素级的关键点定位精度,设计点位回归损失,用于监督模型精确预测关键点在特征图中的空间分布.该损失直接作用于从特征图中回归得到的置信度图与偏移信息.其中,每个关键点编码为3通道张量:第1个通道表示关键点存在的置信度,后2个通道分别表示横纵坐标的相对偏移量.标签张量与对应掩膜通过3个步骤进行构建.

步骤1:置信度通道仅在真实关键点所在位置赋值为1,其余位置赋值为0.

步骤2:偏移通道记录每个关键点在其所属网格内的相对偏移量.

步骤3:训练掩膜用于标记参与损失计算的有效位置,以屏蔽空区域带来的梯度干扰.

损失计算时分别对置信度与偏移误差加权平均,将模型输出的点位预测结果与标签进行逐点比较,表达式为

$$L_{\mathrm{pr}}=\frac{1}{N_{\mathrm{mask}}}\left|\left(\hat{T}-T\right)\odot M_{\mathrm{pr}}\right|_2 \tag{2}$$

式中:L_{pr}为点位回归损失;$\hat{T},T\in R^{B\times 3\times H\times W}$分别为预测与标签张量;$M_{\mathrm{pr}}$为对应的掩膜;$\odot$为逐元素乘法;$N_{\mathrm{mask}}$为掩膜中非零位置的数量.PR-Loss的设计不仅提升了关键点位置的回归精度,还使模型在关注结构区域时具备更强的几何稳定性,进一步增强特征匹配的定位一致性.

1.3.2　稀疏配对聚焦损失

关键点匹配任务本质上可视为一个二分类问题,即判断任意2个候选关键点是否构成真实匹配对.传统方法常采用二元交叉熵(Binary Cross Entropy, BCE)损失,但在结构模糊区域(如遮挡、密集或低光照场景)中,模型难以聚焦于困难样本,容易产生误匹配.为解决结构模糊匹配问题,提出一种稀疏配对聚焦损失,引入焦点机制以增强对难匹配样本的关注,同时结合结构约束提升对稀疏边对的判别能力,从而提高整体匹配精度与鲁棒性.

具体而言,对于N个关键点预测结果,首先构建大小为$N\times N$的匹配预测矩阵$P=\{p_{ij}\}$,其中每

个元素p_{ij}表示图像对中第i个关键点与第j个关键点的匹配置信度.同时构建标签矩阵$\boldsymbol{Y}=\{y_{ij}\}$,其中$y_{ij}=1$表示正匹配对,$y_{ij}=2$表示负匹配对,$y_{ij}=0$表示无效匹配对.定义有效掩码$\boldsymbol{M}=\{m_{ij}\}$,其中对于正确匹配元素赋值$m_{ij}=1(y_{ij}>0)$,仅对于有效匹配对计算损失,利用掩码机制可以排除对模型无意义的区域干扰.

由于聚焦损失(Focal Loss)[38]原本针对二分类任务设计,其要求输入标签为二值形式,将标签矩阵通过二值化转换构造目标标签,将聚焦损失扩展为稀疏配对聚焦损失,表达式为

$$y'_{ij}=1(y_{ij}=1) \tag{3}$$

$$L_{\text{spf}}=\frac{1}{N_{\text{valid}}}\sum_{i,j}m_{ij}\cdot\Big[\alpha(1-p_{ij})^{\gamma}y'_{ij}\log(p_{ij}+\varepsilon)+(1-\alpha)p_{ij}^{\gamma}(1-y'_{ij})\log(1-p_{ij}+\varepsilon)\Big] \tag{4}$$

式中:L_{spf}为稀疏配对聚焦损失;$1(\cdot)$为二值化过程的指示函数;y'_{ij}为对应的二值化标签,即$y_{ij}=1$时,$y'_{ij}=1$,否则为0;α为类别权重调节因子;γ为聚焦程度调节因子;ε为防止数值不稳定引入的微小常数;N_{valid}为所有有效点对数量.

该设计不仅解决了原始多标签匹配信息与聚焦结构不兼容的问题,同时避免了无效区域带来的梯度干扰,使得模型能更加关注边界模糊、结构遮挡、复杂形状干扰等困难匹配场景,训练过程中自动对高难度匹配对赋予更大梯度,从而显著提升结构推理能力.

1.3.3 总损失函数

PR-Loss和SPF-Loss在训练过程中被共同优化,整体损失函数表达式为

$$L_{\text{total}}=\lambda_1 L_{\text{pr}}+\lambda_2 L_{\text{spf}} \tag{5}$$

式中:L_{total}为总损失函数;λ_1和λ_2为损失项的加权系数,用于平衡结构判别与点位回归的相对重要性.

2 实验结果与分析

2.1 实验数据

在公开的环视图停车位检测数据集ps2.0[6]上对本文方法进行初步评估.ps2.0数据集是视觉感知领域中广泛使用的标准之一,包含多种典型的室内与室外停车场景,覆盖了不同的光照条件和遮挡情况,具备一定的场景多样性.该数据集图像分辨率为600×600像素,对应实际物理空间尺寸为10 m×10 m.全部数据包含9 827张训练图像和2 338张测试图像,分别标注有9 476个和2 168个停车位.遵循DMPR-PS[12]的实验设置,选取其中7 780张图像作为训练集,2 290张图像作为测试集.

尽管已有多种算法在ps2.0上取得了优异的检测性能,精确率普遍超过99%,但该数据集在场景复杂性方面仍存在一定局限,难以充分反映实际自动泊车系统所面临的多样化挑战.真实停车场景中往往存在视角畸变、光照干扰、严重遮挡以及复杂的车位形态,而这些因素在ps2.0中的体现相对不足.因此,仅在ps2.0上获得的高精确率,并不能完全代表方法在真实应用中的稳定性和鲁棒性.

为进一步验证本文方法在真实复杂环境中的泛化能力,构建大规模真实场景停车位检测数据集,命名为CRPS-D(Challenging Real-world Parking Slot Detection).CRPS-D数据集涵盖地面停车场、地下车库、路边停车等多种典型城市停车场景,力求全面覆盖现实中的多样化环境.数据采集跨越不同时间段与多种天气条件,包括白天、夜晚、晴天、多云及雨天,以增强数据的环境多样性与挑战性.相较于现有主流数据集ps2.0与SNU[39],CRPS-D数据集在数据规模、场景复杂性和车位多样性方面均具有显著优势:一方面,该数据集包含更多密集分布的停车位及大量倾斜角度较大的车位;另一方面,其路面场景结构更为复杂,包含遮挡、地面标线干扰等现实因素,检测任务的难度显著提升.因此,CRPS-D可作为面向真实应用需求的高挑战性基准,为后续研究提供更具实际意义的评估基础.

CRPS-D数据集共包含35 379张图像,其中训练集29 803张,测试集5 936张.每张图像均标注有若干标记点及对应的停车位信息.标记点包含坐标、形状、类型及方向角等属性,每个停车位由一对标记点定义.数据采集设备安装于车辆侧视镜处,原始图像经鱼眼相机采集并转换为鸟瞰图视角,输出分辨率为512×512像素,对应实际空间尺寸为10×10 m.CRPS-D数据集与ps2.0数据集的示例图像如图4所示.

2.2 实验评价指标

先前研究通常采用精确率(Precision)和召回率(Recall)作为停车位检测的主要性能指标,但由于这2项指标对阈值设置较为敏感,评估结果可能存在一定的不稳定性,难以全面反映模型在不同阈值下的整体性能表现.因此,进一步引入平均精确率作为主要评估指标,以获得更稳定、全面的性能衡量.采用PASCAL VOC 2010中提出的全点插值方法计算平均精确率(Average Precision,AP),对应的表达式为



图 4　数据集示例(CRPS-D 和 ps2.0)

Fig.4　Sample images from the datasets (CRPS-D and ps2.0)

$$\mathrm{AP}=\sum_k\left(\left(\mathrm{Recall}_{k+1}-\mathrm{Recall}_k\right)\times\mathrm{Precision}_{k+1}\right) \tag{6}$$

$$\mathrm{Precision}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}} \tag{7}$$

$$\mathrm{Recall}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{8}$$

式中:AP 为平均精确率;Recall_k 和 $\mathrm{Precision}_k$ 为阈值 k 下的召回率和精确率;TP 为真阳性结果数量;FP 为假阳性结果数量;FN 为假阴性结果数量.

在预测结果和标注标签的匹配中,将每个停车位标注为一个关键点对,记作 $S_{\mathrm{g}}=\{p_{\mathrm{g}}^1,p_{\mathrm{g}}^2\}$,其中 $p_{\mathrm{g}}^1=(x_1,y_1)$、$p_{\mathrm{g}}^2=(x_2,y_2)$ 表示地面真实停车位入口线的 2 个端点,检测结果表示为关键点对 $S_{\mathrm{d}}=\{p_{\mathrm{d}}^1,p_{\mathrm{d}}^2\}$,判断关键点对与标注关键点对是否匹配的表达式为

$$|p_{\mathrm{g}}^1-p_{\mathrm{d}}^1|^2<\delta \text{ 且 } |p_{\mathrm{g}}^2-p_{\mathrm{d}}^2|^2<\delta \tag{9}$$

式中:δ 为匹配阈值,依据图像分辨率和车位预期大小取值为 10.

2.3　实验结果

所有实验均在同一硬件平台上完成:一块 NVIDIA GeForce RTX 2080 Ti GPU 12GB 与一台配备 Intel Xeon E5-2680 v4@2.4GHz 处理器的服务器.模型训练基于 PyTorch 框架实现.

2.3.1　公开数据集测试

为验证本文方法的有效性,首先在公开数据集 ps2.0 上进行充分的对比实验.对比实验中选择了基于目标检测的 DeepPS[6]、VPS-Net[7]、SCCN[40]、One-Stage[41],基于关键点和关系建模的 DMPR-PS[12]、GCN[13],基于图像分割的 SAM-PS[36],不同方法在 ps2.0 数据集上的检测性能对比结果如表 1 所示.

由表 1 可知:在 ps2.0 数据集中,已有方法的检测精度普遍较高,精确率和召回率均达到 99% 左右,整体性能趋于饱和;本文方法在 ps2.0 数据集上的精确率为 99.37%,召回率为 99.47%,在多项指标上与现有先进方法持平,验证了该方法在标准场景下的适应性与准确性;进一步引入平均精确率作为评估指标,以衡量模型在不同阈值下的整体性能,在该指标上,本文方法达到 99.47%,表明模型兼顾检

表 1　不同方法在 ps2.0 数据集上的检测性能对比

Tab.1　Detection performance of different methods on the ps2.0 dataset　%

方法	精确率	召回率	平均精确率
DeepPS	98.99	99.13	—
DMPR-PS	99.42	99.37	—
VPS-Net	99.63	99.10	—
GCN	99.56	99.42	—
SCCN	99.35	99.17	—
One-Stage	99.63	99.63	—
SAM-PS	94.29	81.35	—
本文方法	99.37	99.47	**99.47**

测精度与鲁棒性.

然而,ps2.0数据集中的场景较为规整,泊车线条清晰,遮挡情况较少,难以覆盖真实自动泊车场景中可能遇到的复杂情况,例如严重遮挡、停车位密集、斜向车位增多等.因此,仅在该数据集上取得良好性能并不足以全面评估模型在真实环境中的实际应用潜力.

2.3.2 自建数据集测试

进一步引入具有更高挑战性和复杂度的私有数据集CRPS-D,并在该数据集上进行对比实验,以验证本文方法在复杂场景下的泛化能力与鲁棒性.考虑到目前大多数端到端停车位检测方法尚未公开训练代码或预训练模型,因此难以在统一平台和设置下在CRPS-D上实现全面复现与公平对比.在已公开的方法中,仅有图卷积网络(Graph Convolutional Network, GCN)[13]提供完整的训练框架,并支持多种主干网络(ResNet18、ResNet50、Darknet、VGG16),具备良好的可复现性与扩展性.因此,选取GCN作为对比基线,在保持数据集、损失函数、训练策略和超参数一致的前提下,基于4种主干网络在CRPS-D数据集上进行复现训练,并与本文方法进行系统的对比实验.对比结果如表2所示.

表2 本文方法与GCN*在CRPS-D数据集上的检测性能对比

Tab.2 Comparison between the detection performance of the proposed method and GCN* on the CRPS-D dataset %

主干网络	方法	精确率	召回率	平均精确率
ResNet18	GCN*	91.38	82.04	78.01
		91.56	84.54	**82.38**
ResNet50	本文方法	90.91	83.22	78.63
		91.11	84.89	**82.10**
Darknet	GCN*	91.38	83.27	79.01
		91.39	85.00	**82.93**
VGG16	本文方法	92.43	82.75	79.02
		92.21	85.54	**83.58**

注:*表示基于公开代码进行复现的结果.

由表2可知:① 本文方法在4种主干网络下均优于GCN方法,尤其在平均精确率指标上提升明显.采用VGG16主干网络时,本文方法的平均精确率为83.58%,较GCN的79.02%提升4.56%;采用ResNet18、ResNet50和Darknet主干网络时,平均精确率分别提升4.37%、3.47%和3.92%.② 本文方法在不同主干网络下均具有较好的兼容性与稳定性,能够有效挖掘停车位结构信息,提升检测性能.③ 在精确率保持相对稳定的前提下,本文方法的召回率相比GCN有较为明显的增长,说明其在复杂、密集、非规则停车位分布场景中具有更强的目标捕获能力与误检控制能力,对于实际自动泊车系统在遮挡、光照变化、车位倾斜及空间紧凑等真实条件下的可靠检测具有积极意义.

为进一步评估方法的检测性能,选择典型的一阶段检测方法YOLOv8[18]、YOLOv12[42]以及基于实时旋转目标检测Transformer(Real-time oriented object DEtection TRansformer, RT-DETR)[43]作为对比对象,对比结果如表3所示.

表3 各检测方法在CRPS-D数据集上的检测性能对比

Tab.3 Comparison between the different detection methods on the CRPS-D dataset %

方法	精确率	召回率	平均精确率
YOLOv8	89.69	83.86	82.28
YOLOv12	91.28	81.93	80.42
RT-DETR	79.34	78.99	70.74
本文方法	**91.56**	**84.54**	**82.38**

由表3可知:本文方法的精确率、召回率和平均精确率分别为91.56%、84.54%和82.38%,3项指标均优于YOLOv8;与YOLOv12相比,本文方法的精确率高0.28%,同时召回率提升2.61%,平均精确率提升1.96%,表明本文方法在保持较高定位精度的同时对正样本的捕获能力更强;RT-DETR在3项指标上均显著低于本文方法,精确率低12.22%,召回率低5.55%,平均精确率低11.64%,反映出基于DETR的检测范式在当前车位检测任务中可能面临收敛困难或特征对齐不足的问题.综上所述,本文方法在CRPS-D这一复杂数据集上达到与主流一阶段检测方法相当或更优的性能,从而验证方法的有效性与竞争力.

2.3.3 消融实验

为进一步验证所提各模块设计的有效性,在自建数据集上开展消融实验.实验采用ResNet18作为主干网络,依次引入关键设计组件,包括AGI模块、SPF-Loss以及SA-CutMix策略,并在保持其他设置不变的前提下,观察各组件对模型性能的影响.消融实验结果如表4所示.

表4 模块逐步引入对模型性能的影响

Tab.4 Effects of incrementally adding modules on detection performance

实验序号	方法配置	平均精确率/%
1	主干网络	77.76
2	主干网络+AGI Module	78.94
3	主干网络+AGI Module+SPF-Loss	79.45
4	主干网络+AGI Module+SPF-Loss+SA-CutMix	**82.38**

由表4可知:在基准模型中引入AGI模块后,平均精确率提升至78.94%,模块引入带来的平均精确率增量为1.18%,表明该模块在捕捉车位关键点间的几何关系方面具备良好的建模能力;进一步加入SPF-Loss,平均精确率提升至79.45%,损失函数修改带来的平均精确率增量为0.51%,显示结构感知损失函数能有效增强模型对关键点间结构匹配的关注,从而提高整体检测精度;结合SA-CutMix数据增强策略后,平均精确率提升至82.38%,策略设计带来的平均精确率增量为2.93%,进一步提升模型的泛化能力和鲁棒性;各关键设计均能在不同程度上提升模型性能,且组合使用时效果最优,验证本文方法在结构建模、损失设计和数据增强等方面的有效性与互补性.

2.3.4　推理效率实验

为验证本文方法在实际自动泊车系统中的应用潜力,对算法的推理速度进行评估.虽然当前测试在通用GPU平台上进行,但该方法在设计之初就考虑端侧部署的轻量化需求,针对推理时间和每秒处理帧数(Frames Per Second, FPS)进行评价,推理效率实验结果如表5所示.由表5可知:在NVIDIA GeForce RTX 2080Ti平台上,本文方法处理单帧图像的平均耗时为14.86 ms,约70 FPS,优于对比方法GCN[13]和BEV-PolyNet[44];尽管车载嵌入式平台的算力低于服务器级GPU,但本文方法70 FPS的处理能力为嵌入式端的模型量化和裁剪预留充足的性能裕量.

表5　推理效率对比

Tab.5　Inference efficiency of different methods

方法	GPU型号	推理时间/ms	FPS/(帧/s)
DMPR-PS	NVIDIA TITAN Xp	12.24	81.70
GCN	NVIDIA TITAN Xp	25.56	39.12
BEV-PolyNet	NVIDIA GeForce RTX 4090	24.77	40.37
本文方法	NVIDIA GeForce RTX 2080Ti	14.86	67.29

为进一步验证本文方法在实际泊车系统中的推理速度与部署效果,以NVIDIA Jetson AGX Xavier作为边缘推理设备,进行相应的推理优化与部署.主干网络采用ResNet18,首先在PyTorch框架下完成模型训练并保存权重.然后将模型转换为ONNX格式,并利用TensorRT进行FP16精度下的推理加速.构建过程中使用默认的层融合策略与内核自动调优,并允许GPU推理时对计算图进行显存复用.推理效率实验从性能对比和推理2个方面进行评估,实验结果如表6所示.

表6　部署推理性能及效率对比

Tab.6　Comparison of inference performance and efficiency across deployment configurations

推理框架	推理硬件	精确率/%	召回率/%	平均精确率/%	推理时间/ms	FPS/(帧/s)
Pytorch	NVIDIA GeForce RTX 2080Ti	91.56	84.54	82.38	14.24	70.22
Pytorch	NVIDIA Jetson AGX Xavier	91.71	84.36	82.32	80.69	12.39
TensorRT	NVIDIA Jetson AGX Xavier	91.60	84.49	82.17	23.53	42.50

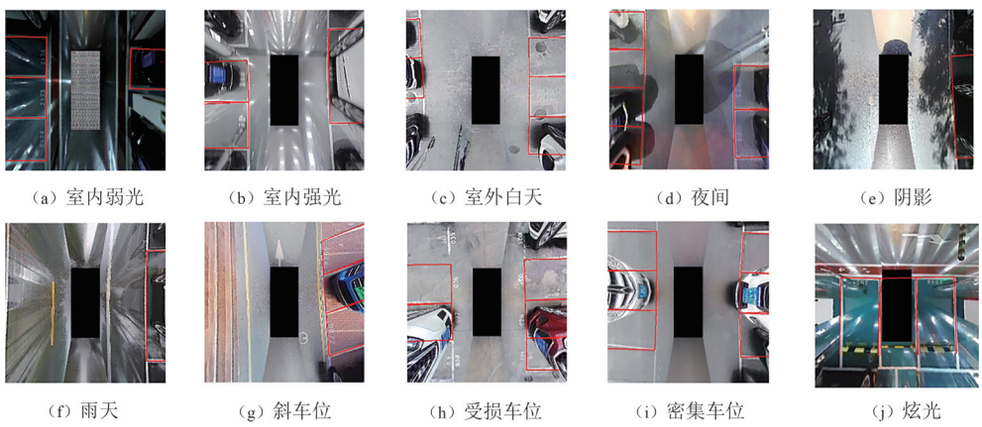
由表6可知:在NVIDIA GeForce RTX 2080Ti服务器级GPU上,本文方法单帧推理耗时为14.24 ms,对应FPS约为70,具备较高的处理效率;在NVIDIA Jetson AGX Xavier边缘设备上,采用原生PyTorch推理时耗时为80.69 ms,FPS为12.39,尚无法满足实时感知需求;使用TensorRT进行FP16精度优化后,推理时间降至23.53 ms,FPS提升至42.50,超过自动泊车系统通常所需的30帧要求;3种配置下的检测精度基本保持一致,表明本文方法在轻量化部署过程中未出现明显的性能衰减,具备良好的端侧部署潜力,通过TensorRT等加速工具可满足实际泊车系统的实时性要求.

2.3.5　复杂场景实验

为进一步验证方法在实际应用中的泛化能力与鲁棒性,从CRPS-D数据集中选取10种具有代表性的复杂场景进行可视化展示,如图5所示.所选场景涵盖多种真实环境下的典型干扰因素,包括光照条件多变(如室内弱光、强光、夜间和强阴影),恶劣天气(如雨天),结构复杂性(如斜置车位和受损车位),以及车位分布密集或地面存在反光等情形.这些场景充分模拟实际停车环境中常见的挑战因素,对模型的感知能力和鲁棒性提出更高要求.

由图5可知:本文方法在各类复杂条件下均能准确检测车位关键点,并有效构建出完整的车位结构;在光照不足、强反光及雨天等视觉干扰较强的场景中,检测结果清晰、边界准确,未出现明显误检或漏检,表现出良好的环境适应性与稳定性;同时,在车位密集和斜置等边界难以区分的复杂场景中,该方法仍具有较高的判别能力,验证了其在多样化泊车环境下的应用潜力.

为全面评估本文方法在复杂场景下的性能,从CRPS-D数据集中选取5类典型挑战场景:室内弱光、室外夜晚、室外阴影、倾斜车位及受损车位,覆盖实际泊车环境中常见的视觉干扰与结构异常情形.



(a) 室内弱光 (b) 室内强光 (c) 室外白天 (d) 夜间 (e) 阴影

(f) 雨天 (g) 斜车位 (h) 受损车位 (i) 密集车位 (j) 炫光

图 5 不同场景下的可视化停车位检测结果

Fig.5 Visualization of parking-slot detection results in diverse challenging scenarios

采用 GCN 作为对比基线，在相同的训练配置与 ResNet18 主干网络下进行复现和对比，以量化本文方法相对于 GCN 的性能增益.

复杂场景性能对比如表 7 所示.由表 7 可知：在室内弱光场景下，本文方法的平均精确率为 92.02%，提升 11.65%，精确率从 73.93% 升至 94.02%，表明低光照条件下模型对误检的抑制能力显著增强；在室外夜晚场景中，2 类方法的性能差异最为明显，本文方法的平均精确率为 45.82%，GCN 仅为 23.71%，绝对提升达 22.11%，GCN 的精确率仅为 14.27%，出现大量误检，而本文方法通过结构感知机制可有效降低误检率；在室外阴影场景下，本文方法的平均精确率为 78.45%，较 GCN 提升 14.45%，召回率由 84.01% 升至 85.94%，两者漏检控制能力相近，但本文方法在定位精度上优势更突出；针对倾斜车位场景，本文方法的平均精确率达到 83.56%，提升 15.35%，精确率从 58.20% 跃升至 81.97%，反映出本文方法对斜置车位的几何结构建模更为准确；在受损车位场景中，2 类方法的性能差距最小，本文方法的平均精确率为 73.65%，较 GCN 提升 1.49%，精确率与召回率接近，说明在车位线破损时两者均面临一定挑战，但本文方法仍保持微弱优势.

表 7 复杂场景性能对比

Tab.7 Performance comparison in complex scenarios %

场景类型	方法	精确率	召回率	平均精确率
室内弱光	GCN*	73.93	88.05	80.37
	本文方法	94.02	90.10	92.02
室外夜晚	GCN*	14.27	70.14	23.71
	本文方法	33.13	74.31	45.82
室外阴影	GCN*	51.68	84.01	64.00
	本文方法	72.16	85.94	78.45
倾斜车位	GCN*	58.20	82.39	68.21
	本文方法	81.97	85.22	83.56
受损车位	GCN*	62.72	84.96	72.16
	本文方法	62.11	90.45	73.65

注：*表示基于公开代码进行复现的结果.

根据复杂场景性能对比实验结果，本文方法在弱光、夜间、阴影及斜置车位等极具挑战的场景中均取得显著的性能提升，验证了结构建模与训练优化策略对复杂环境适应性的关键作用.

3 结论

1) 所提的端到端停车位检测方法在无需额外后处理的前提下，能够基于关键点关系自动构建车位结构，并融合车位拓扑先验.在 CRPS-D 数据集上，相比基线方法平均精确率显著提升，验证了该方法在高密度与不规则车位场景中的适应性.

2) 采用稀疏配对聚焦损失，将关键点匹配建模为困难样本感知任务，通过聚焦于结构模糊区域中的易混淆对，增强模型在遮挡、模糊及密集场景下的判别能力，损失函数改进带来 0.51% 的平均精确率提升，显著缓解误匹配问题.

3) 使用注意力引导的特征插值模块，以角点引导方式建模车位的连接结构，显式强化车位拓扑关系学习，模块设计带来 1.18% 的平均精确率增量，提升检测网络在斜置、破损等非典型结构下的检测稳定性.

4) 应用 SA-CutMix 策略，在保持结构语义完整的前提下进行区域混合，增强模型对结构缺失、遮挡等样本的适应能力，数据增强策略引入带来最高 2.93% 的平均精确率提升，有效提高模型的泛化能力与训练鲁棒性.

本文方法在多种复杂停车场景中均表现出良好的检测准确性和稳定性，尤其在低光照、雨天、阴影与密集车位等典型挑战场景中依然保持较高鲁棒

性.未来研究将进一步探索跨视角一致性建模与图像补全机制,以提升极端条件下的检测效果,并扩展方法在实际任务中的适用性.

参考文献(References):

[1] Jung H G, Lee Y H, Kim J. Uniform user interface for semiautomatic parking slot marking recognition[J]. IEEE Transactions on Vehicular Technology, 2010, 59(2): 616－626.

[2] Suhr J K, Jung H G. Sensor fusion-based vacant parking slot detection and tracking[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(1): 21－36.

[3] Lee M, Kim S, Lim W, et al. Probabilistic occupancy filter for parking slot marker detection in an autonomous parking system using AVM[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(6): 2389－2394.

[4] 王晋疆, 王鹏飞. 一种基于环视系统的车位检测方法[J]. 分析仪器, 2019(1): 71－77.
Wang Jinjiang, Wang Pengfei. Parking slot detection based on around view monitor systems[J]. Analytical Instrumentation, 2019(1): 71－77. (in Chinese)

[5] 吴晓雯.空停车位数量及定位检测算法研究[D]. 兰州: 兰州交通大学, 2022:5－6.
Wu Xiaowen. Research on the algorithm of detecting the number and location of empty parking spaces. Lanzhou: Lanzhou Jiaotong University, 2022:5－6. (in Chinese)

[6] Zhang L, Huang J H, Li X Y, et al. Vision-based parking-slot detection: a DCNN-based approach and a large-scale benchmark dataset[J]. IEEE Transactions on Image Processing, 2018, 27(11): 5350－5364.

[7] Li W, Cao L B, Yan L B, et al. Vacant parking slot detection in the around view image based on deep learning[J]. Sensors, 2020, 20(7): 2138.

[8] Lee J, Sung K, Park D, et al. KEPS-NET: Robust Parking slot Detection based Keypoint estimation for High Localization Accuracy[C]// ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, 2023: 1－5.

[9] Yu Z P, Gao Z, Chen H S, et al. SPFCN: select and prune the fully convolutional networks for real-time parking slot detection[C]//2020 IEEE Intelligent Vehicles Symposium (IV). Las Vegas, 2020: 445－450.

[10] Zhou S, Yin D, Lu Y D. PASSIM: parking slot recognition using attentional semantic segmentation and instance matching[C]//2022 IEEE 5th International Conference on Big Data and Artificial Intelligence (BDAI). Fuzhou, 2022: 169－175.

[11] Lai C, Yang Q Y, Guo Y X, et al. Semantic segmentation of panoramic images for real-time parking slot detection[J]. Remote Sensing, 2022, 14(16): 3874.

[12] Huang J H, Zhang L, Shen Y, et al. DMPR-PS: a novel approach for parking-slot detection using directional marking-point regression[C]//2019 IEEE International Conference on Multimedia and Expo (ICME). Shanghai, 2019: 212－217.

[13] Min C, Xu J L, Xiao L, et al. Attentional graph neural network for parking-slot detection[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3445－3450.

[14] Bui Q H, Suhr J K. Transformer-based parking slot detection using fixed anchor points[J]. IEEE Access, 2023, 11: 104417－104427.

[15] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, 2017: 6517－6525.

[16] Redmon J, Farhadi A. Yolov3: An incremental improvement[EB/OL].(2018-04-18)[2026-03-01].https://arxiv.org/abs/1804.02767.

[17] 陈正华.基于全景环视图的自动泊车空闲停车位检测算法研究[D]. 南昌:华东交通大学,2024:23－25.
Chen Zhenghua. Research on vacant parking slot detection algorithm based on surround view images. Nanchang: East China Jiaotong University, 2024:23－25. (in Chinese)

[18] Sohan M, Sai Ram T, Rami Reddy C V. A review on YOLOv8 and its advancements[C]//Data Intelligence and Cognitive Informatics. Singapore, 2024: 529－545.

[19] 王琬琪.基于改进YOLOv7的车位检测方法研究[D]. 吉林:北华大学,2024:5－6.
Wang Wanqi. Research on improved YOLOv7-based method for parking space detection. Jilin: Beihua University, 2024:5－6. (in Chinese)

[20] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver , 2023: 7464－7475.

[21] 任文博.基于深度学习和全景图像的停车位实时检测技术研究[D]. 十堰:湖北汽车工业学院,2024:4－6.
Ren Wenbo. Research on real-time parking lot detection technology Based on deep learning and panoramic images. Shiyan: Hubei University of Automotive Technology, 2024:4－6. (in Chinese)

[22] Xu Shangliang, Wang Xinxin, Lv Wenyu, et al. PP-YOLOE: an evolved version of YOLO[EB/OL].(2022-12-12)[2026-04-28]. https://arxiv.org/abs/2203.16250.

[23] 王明全.基于深度学习的车位检测研究与应用[D]. 镇

江:江苏大学,2023:8－10.
Wang Mingquan. Research and application of parking space detection based on deep learning[D]. Zhenjiang: Jiangsu University, 2023:8－10.(in Chinese)

[24] Zhang Y, Guo Z, Wu J, et al. Real-time vehicle detection based on improved yolo v5 [J]. Sustainability, 2022, 14(19): 12274.

[25] 单凯强, 桑海峰. 基于全景视频下标记点特征的停车位检测技术研究[J]. 电子测量与仪器学报, 2022, 36(2): 203－210.
Shan Kaiqiang, Sang Haifeng. Research on parking slot detection technology based on the mark point of panorama video[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 203－210.(in Chinese)

[26] 常新新. 基于LSD和目标检测的划线停车位识别与监控分析[D]. 湘潭:湘潭大学,2023:14－15.
Chang xinxin. Identification and monitoring analysis of scribed parking spaces based on line segment detector and object[D]. Xiangtan: Xiangtan University, 2023:14－15.(in Chinese)

[27] Jian D H, Lin C H. Vision-based parking slot detection based on end-to-end semantic segmentation training[C]//2020 IEEE International Conference on Consumer Electronics (ICCE). Las Vegas, 2020: 1－4.

[28] 李伟东, 钟健聪, 孙浩, 等. 一种基于环视图像的空停车位检测方法[J]. 大连理工大学学报, 2022, 62(5): 535－542.
Li Weidong, Zhong Jiancong, Sun Hao, et al. A vacant parking slot detection method based on around view images[J]. Journal of Dalian University of Technology, 2022, 62(5): 535－542.(in Chinese)

[29] 闫旭东, 钱莉. 基于全景环视图像的停车位检测算法[J]. 华中师范大学学报(自然科学版), 2024, 58(5): 526－532.
YAN Xudong, QIAN Li.Parking slot detection based on surround-view image[J]. Journal of Central China Normal University (Natural Sciences), 2024, 58(5): 526－532.(in Chinese)

[30] 黄丹阳, 田传印, 姚艳南. 基于深度学习的停车位检测研究[J]. 中国汽车, 2023, 33(4): 43－47.
Huang Danyang, Tian Chuanyin, Yao Yannan. Vehicle parking slot detection research based on deep learning[J]. China Auto, 2023, 33(4): 43－47.(in Chinese)

[31] 李成, 赵宇明. 基于360°环视的高效停车位检测网络[J]. 自动化仪表, 2020, 41(11): 76－81.
Li Cheng, Zhao Yuming. Efficient parking space detection network based on 360°Panorama[J]. Process Automation Instrumentation, 2020, 41(11): 76－81.(in Chinese)

[32] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C]//European conference on computer vision 2020. Cham, 2020: 213－229.

[33] Lungoci T, Negru M. Embedded parking slot detection and classification for smart city scenarios [C]//2024 IEEE 20th International Conference on Intelligent Computer Communication and Processing (ICCP). Cluj-Napoca, 2024: 1－6.

[34] Fu L, Ma D L, Qu X, et al. ParkScape: a large-scale fisheye dataset for parking slot detection and a benchmark method[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5025013.

[35] Musabini A, Novikov I, Soula S N, et al. Enhanced parking perception by multi-task fisheye cross-view transformers[J]. IET Conference Proceedings, 2024(10): 31－38.

[36] Zhai H, Mei J L, Chen L, et al. SAM-PS: Zero-shot parking-slot detection based on large visual model[C]//2024 IEEE Intelligent Vehicles Symposium (IV). Jeju Island, 2024: 1594－1600.

[37] Yun S, Han D, Chun S, et al. CutMix: Regularization strategy to train strong classifiers with localizable features[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, 2020: 6022－6031.

[38] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, 2017: 2999－3007.

[39] Do H, Choi J Y. Context-based parking slot detection with a realistic dataset[J]. IEEE access, 2020, 8: 171551－171559.

[40] Zheng R T, Lian S K, Liang W H, et al. Center keypoint for parking slot detection with self-calibrated convolutions network[C]//2022 17th International Conference on Control, Automation, Robotics and Vision (ICARCV). Singapore, 2023: 305－310.

[41] Bui Q H, Suhr J K. One-stage parking slot detection using component linkage and progressive assembly [J]. IEEE Intelligent Transportation Systems Magazine, 2023, 15(6): 33－48.

[42] Tian Y, Ye Q, Doermann D. Yolov12: Attention-centric real-time object detectors[J]. Advances in neural information processing systems, 2026, 38: 78433－78457.

[43] Ding Z, Zhou Y, Zhao J, et al. Real-time oriented object detection transformer in remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2026, 64: 1－14.

[44] Duan Z J, Zhuang Y M, Chao Y F, et al. BEV-PolyNet: BEV-based polygonal end to end parking slot detection framework[J]. IEEE Robotics and Automation Letters, 2025, 10(10): 10322－10329.