

基于鸟瞰视图的递归特征金字塔语义分割方法

高宏伟, 赵博杨

(沈阳理工大学 自动化与电气工程学院, 沈阳 110159)

摘要: 针对现有自动驾驶场景的鸟瞰视图(BEV)语义分割方法的特征提取效果差、视角转换方法老旧以及交通环境语义分割效果不佳的问题, 提出一种基于鸟瞰视图的递归金字塔的语义分割方法, 简称为IRFPN。传统金字塔特征提取网络包含自底向上、自顶向下以及横向链接三部分, 特征提取效果有待提高。鸟瞰视角转换方面只使用传统的逆透视变换处理车载相机拍摄的图片, 不能对相关语义进行很好的保留。为改善上述不足, 将递归特征金字塔结构和极射线映射相结合。实验结果表明, IRFPN在nuScenes数据集中常见类别语义分割精度提升了0.4%, 对驾驶区域的预测精度提升了2.1%, 相比传统的金字塔特征提取网络效果好, 对常见交通环境语义特征有更好的保留, 对复杂的交通环境具有较好的鲁棒性。

关键词: 递归特征金字塔; 特征提取; 鸟瞰视图; 语义分割; 自动驾驶; 极射线映射

中图分类号: TP391.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1003-1251.2024.03.005

Recursive Pyramid Semantic Segmentation Method Based on Autopilot Aerial View

GAO Hongwei, ZHAO Boyang

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: A recursive pyramid semantic segmentation method based on bird's-eye views (IRFPN) is proposed to address the issues of poor feature extraction, outdated perspective conversion methods, and poor semantic segmentation performance of existing bird's-eye views (BEV) semantic segmentation methods for autonomous driving scenarios. The traditional feature pyramid extraction network includes three parts: bottom-up, top-down, and horizontal linking, and the effectiveness of feature extraction needs to be improved. In terms of bird's-eye perspective conversion, the relevant semantics cannot be preserved well only by using traditional inverse perspective transformation to process images captured by car mounted cameras. To overcome these shortcomings, a recursive feature pyramid structure and polar ray mapping are combined. The experimental results show that IRFPN has improved the accuracy of common categories in the nuScenes dataset by 0.4% and the prediction accuracy of driving areas by 2.1%. It can be concluded that recursive feature pyramids are better than traditional pyramid feature extraction networks, with better retention of semantic features in various common traffic environments, and better robustness to complex traffic environments.

Key words: recursive feature pyramid; feature extraction; aerial view; semantic segmentation; autopilot; polar ray mapping

自动驾驶型汽车需要在极短的时间内获取复杂路段中的各个交通元素的位置、尺寸以及行进方向等道路信息,以确保车辆能够稳定安全地行驶。鸟瞰视图感知技术作为视觉感知领域的重要研究方向,愈来愈广泛地受到科研工作者的关注^[1]。通过多个车载摄像机、毫米波雷达点云、激光点云协助一定的深度学习算法模型,对整个车身四周的环境进行信息收集,矫正之后获得360°的鸟瞰图像,能够快速、直观地展现出自动驾驶场景中的环境信息。

鸟瞰视图语义分割是一个多阶段的过程,具体可以分为三个部分。

1) 实时图像特征提取:运用车载摄像机对交通环境进行拍摄,通过金字塔特征提取网络处理实时图像,获得多尺度的交通语义特征。

2) 鸟瞰视图特征转换:通过鸟瞰视图转换处理前端产生的多尺度语义特征,获得鸟瞰视角下的特征映射。

3) 鸟瞰视图语义分割:利用上采样处理鸟瞰视图特征,获取与模型匹配的语义分割图^[2]。

车载照相机所拍摄的图片包含不同尺度的交通类别语义特征。特征提取^[3]的质量往往决定最终语义分割的精准程度。通过对图像进行多尺度的特征提取,能够更好地分析自动驾驶场景的道路情况。目前,图像特征提取的方法主要是依据特征金字塔网络(FPN)^[4]进行改进优化的。路径聚合网络(PANet)^[5]提出了自下向上的二次融合,自适应空间特征融合(ASFF)^[6]的提出让网络可以进行自适应学习,可拓展的双向融合(BiFPN)^[7]是在特征金字塔中寻找有效的模块进行重复叠加,以减少对有效信息的丢弃,鲁博等提出一种将BiFPN特征提取结构和Yolov3-tiny相结合的算法^[8],针对目标检测领域使用特征双向融合,使特征提取更加高效。在视角转换方面逆透视变换(IMP)^[9]往往会丢失重要的边缘信息,并且会使一定不规则形状的目标产生畸形,李海华等提出了一种基于逆透视变换的车道线检测方法^[10]。鸟瞰视图(BEV)的感知也多用于驾驶环境的视角转换,但是并没有对交通语义在鸟瞰视图中进行定位。传统的金字塔特征提取网络计算量大,对多尺度特征不能很好保留,而逆透视转换又不能对交通语义进行很好的定位。为了改善上述不足,本文将递归特征金字塔(RFP)^[11]与极射线映射鸟瞰视图转换相结合,提出了一种基于鸟瞰视图的RFP语义分割方法。该方法首先使用RFP

处理车载照相机实时传输的图像,得到多尺度图像特征,再进行极射线鸟瞰视图转换,获得已定位的鸟瞰图像特征,最后利用上采样的方式获取最终的鸟瞰视图分割结果。

本文在FPN的基础上加入了递归特征提取策略^[12],选用空洞池化和自适应空间特征融合相结合的特征提取方法,克服了常规特征金字塔网络对多尺度特征不能较好保留的特点,同时使用极射线映射技术,在极射线扫描映射的转换方式中引入余弦投影策略,使图像特征与BEV特征相关联,解决逆透视转换时图像信息产生扭曲以及交通语义定位不准的缺点。

1 FPN

FPN是自动驾驶语义分割系统中用于提取多尺度物体特征信息的重要组成部分,以Resnet50为主干进行多尺度图像特征提取,获得不同深度的图像特征。由于驾驶场景中,深层特征和浅层特征所包含的信息量不同,运用特征金字塔解决了单一特征层包含特征稀少的问题,通过特征金字塔进行特征提取能够同时保留大目标以及小目标的特征信息。

FPN由自底向上以及包含侧向连接的自顶向下两部分网络组成,其结构如图1所示。其中自底向上的过程与普通的神经网络类似,将图像输入到以Resnet50为骨干的特征提取网络,每个阶段对应一个FPN等级,其作用是使图像特征的长宽减半,并提升维度,图像尺度由3通道600×800的尺度,经多层卷积层的卷积以及归一化和ReLU激活后变为2048通道19×25尺度,之后选用每个阶段的最后一个特征层参与到后续自顶向下的操作。自顶向下的过程通过利用1×1的卷积使各个特征层的维度保持一致,然后使用语义更强的高层特征图进行上采样操作,将小尺寸的特征图进行放大,使其尺寸与上一个阶段的特征层相同。通过侧向连接,利用相加的方式,将两层尺寸一样的特征层进行融合,使高层特征得到增强,确保每一层都包含不同强度的语义特征,最终利用3×3的卷积获得多尺度的图像特征。输出特征 y_i 的计算表达式为

$$y_i = I_i(y_{i+1}, x_i) \quad (1)$$

$$x_i = K_i(x_{i-1}) \quad (2)$$

式中: x_i 是输入特征; K_i 表示自底向上的第 i 个阶段; I_i 表示自顶向下的第 i 个阶段主干输出一组特

征图 $\{y_i | i = 1, \dots, S\}$, S 是阶段的数量, 设 $S = 4$ 。

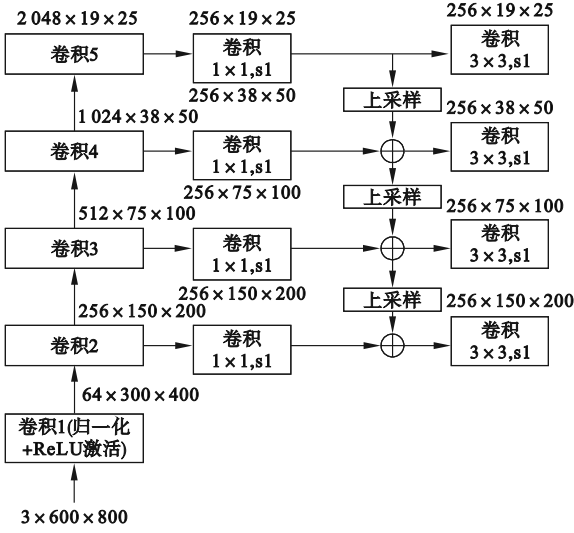


图 1 FPN 结构图

Fig. 1 FPN structure diagram

2 RFP

使用 RFP 进行前端特征提取, 用 R_i 进行功能转换, 转换之后将其和自底向上的主干相连接。对于 $\forall i = 1, \dots, S$, 有

$$x_i = K_i(x_{i-1}, R_i(y_i)) \quad (3)$$

RFP 为递归操作, 将其展开为顺序结构, 结构如图 2 所示。

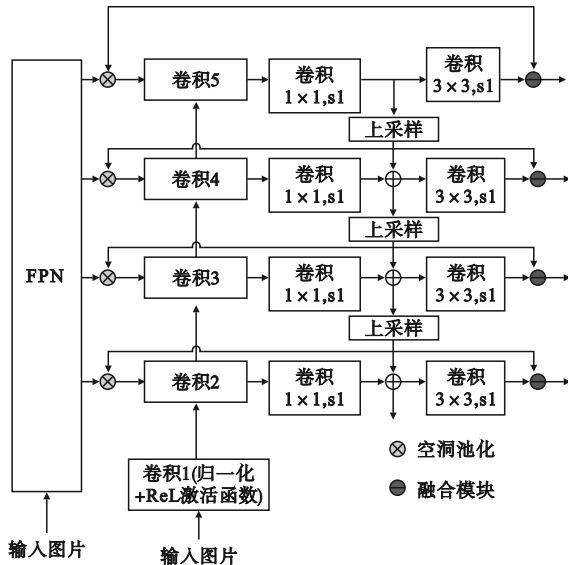


图 2 RFP 结构图

Fig. 2 RFP structure diagram

递归转换公式如下。

$$y'_i = I'_i(y'_{i+1}, x'_i) \quad (4)$$

$$x'_i = K'_i(x'_{i-1}, R'_i(y'_i)) \quad (5)$$

式中 t 为迭代次数。

使用金字塔型空洞池化 (ASPP)^[13] 连接前一部分的 FPN 输出特征, 将 y'_i 作为输入, 将其沿输出通道的维度进行连接, 图中用乘法器符号标记。使用融合模块将步骤 t 产生的 y'_i 与步骤 $t+1$ 的 y'_{i+1} 特征作为输入, 将 y'_{i+1} 通过 1×1 的卷积进行计算, 并进行 Sigmoid 操作, 计算产生结果与 y'_i 做加权和, 以生成最终更新后的 y_i 。其中融合模块结构如图 3 所示。




图 3 融合模块结构图

Fig. 3 Fusion module structure diagram

RFP 能够更直接将信息回传反馈, 调整主干网络的参数, 并利用二次循环的理论使 FPN 再次进行加权融合, 保留更多有用的特征细节, 能够解决前端只使用一次 FPN 保留特征不充分的问题, 用于语义分割的主干网络可以观察图像两次或者更多次, 与丰富特征的卷积神经网络中的级联探测器头有相似之处, 可以做到增强 FPN 以获得愈来愈强大的表示。该种将网络头部接收的梯度特征信息直接与 FPN 自底向上低水平特征相融合的方式, 提升了训练速度和性能。

3 IMP

IMP 是一种常规的视图转换方法, 在自动驾驶场景中, 因为环境中存在透视效应, 使得原本平行的车道线变为相交状态。在相机成像过程中世界坐标系和图像坐标系之间存在着对应关系, 利用逆透视坐标转换原理进行公式化描述如下。

$$X(u, v) = d_z \cdot \cot[\theta_0 - \alpha + u(\frac{2\alpha}{m-1})] \cdot \sin[\gamma_0 - \alpha + v(\frac{2\alpha}{n-1})] + d_x \quad (6)$$

$$Y(u, v) = d_z \cdot \cot[\theta_0 - \alpha + u(\frac{2\alpha}{m-1})] \cdot \cos[\gamma_0 - \alpha + v(\frac{2\alpha}{n-1})] + d_y \quad (7)$$

式中: d_x, d_y, d_z 代表相机在世界坐标系下的位置

信息; γ_0 、 θ_0 代表车载照相机的航向角和俯仰角; m 、 n 代表图像的高和宽; α 为角度偏移系数; u 、 v 分别代表图像坐标系下的横纵坐标; X 、 Y 为转换后世界坐标系下的坐标值。IMP 在水平线方向存在一定程度的弯曲,导致图像向世界坐标系进行转换时会存在一定的误差,对估计道路布局效果较好,但对位于环境中的车辆、行人等动态语义无效。在 BEV 领域已经有人利用深度学习方法将环境信息表示为鸟瞰视图的语义占用网格,每个位置都关联一个状态,可以用 0 或 1 表示其是否被占用,占用概率可表示为 $p(j|g)$,其中 g 表示模型观察到的类别信息,共包含 k 类交通场景语义类别, j 表示给定网格中对象是否存在。传统的研究使用逆传感器模型对占用概率进行估计,新的研究使用卷积神经网络进行训练,模型能够学习单目图像中预测的占用概率,使每个像素位置都能预测一组多类二进制标签。

该类场景和常规的语义分割有相似之处,不同点在于输入输出是建立在完全不同的坐标系统中,即输入为实时车载图像,输出为鸟瞰视图空间图像,使用简单的变压器层可以对输入进行转换,获取鸟瞰视图特征。

变压器层在保持水平维度的同时,沿垂直维度压缩图像的特征,然后沿极坐标对 BEV 特征进行预测,并将其重采样到世界坐标系,变压器层结构如图 4 所示。其中 C 、 W 、 H 、 B 、 Z 分别为输入维度、输入图像宽度、输入图像高度、压缩后特征尺寸和 BEV 特征深度。




图 4 变压器层结构图

Fig. 4 Transformer layer structure diagram

4 改进鸟瞰视图转换

本文改进的鸟瞰视图转换方法与逆透视转换不同,将问题转换为求解极坐标扫描线上交通语义元素的径向距离深度,将映射关系视为图像特

征序列与 BEV 特征序列的转换集。通过在一维扫描线到射线的转换中编码极角大小添加额外的位置信息,极坐标扫描线结构如图 5 所示。




图 5 极坐标扫描线结构图

Fig. 5 Polar scanning line structure diagram

编码器通过沿极射线生成 BEV 特征的独立序列。将图像特征先分为多个大小为 $1 \times H \times C$ 的特征矩阵,再将每一个图像列转换成大小为 $r \times C$ 的 BEV 极射线序列,其中 r 是沿极射线方向的径向距离。给定长度为 r 的输出期望序列,解码器接收距离为 r 的交通语义位置嵌入。通过位置查询的原理,将图像特征与 BEV 特征用固定余弦位置信息的方式相关联。映射可以看作是将语义对象从图像平面分配到其在 BEV 平面上沿一条射线的位置槽。

通过学习一种模型,以单目相机图像和相机内置矩阵 L 为输入,生成鸟瞰场景 Y ,为每个交通语义类别预测一组二进制变量,见公式(8),其中 k 为交通语义种类个数,占用概率 $p(Y^k|I,L)$ 为

$$p(Y^k|I,L) = A(I,L) \quad (8)$$

式中 I 为极射线扫描结构前的特征输入。极射线中每个像素都匹配了图像列中的元素组合,即一个上下文向量,同时本文采用余弦转换投影,使 BEV 特征与原图像特征关联性更强。 Q 和 K 分别代表投影转换后的图像列和位置编码,投影转换公式为

$$Q(b_i) = b_i \cdot W_Q \cdot \cos \theta \quad (9)$$

$$K(h_i) = h_i \cdot W_K \cdot \cos \theta \quad (10)$$

式中 $h_i \in \mathbf{R}^{H \times C}$,表示编码高为 H 的图像列; $b_i \in \mathbf{R}^{r \times C}$,表示沿长度为 r 的极射线对位置查询进行编码; i 代表图像列对应的编码次序; W_Q 和 W_K 分别代表 h_i 和 b_i 的投影矩阵,大小为 $C \times D$; θ 是极射线与坐标轴之间的夹角。通过位置查询 b_i 和输入序列 h_i 可以进行余弦推导,得出 Q 和 K ,分别表示位置查询和对应的键。投影后,使用缩放

点积在每个位置查询和键的组合中使用评分指数 $e_{i,j}$, 计算公式为

$$e_{i,j} = \frac{\langle Q(\mathbf{b}_i), K(\mathbf{h}_j) \rangle}{\sqrt{D}} \quad (11)$$

再利用 softmax 进行归一化, 以产生相应的概率分布 $\beta_{i,j}$, 计算公式为

$$\beta_{i,j} = \frac{\exp(e_{i,j})}{\sum_{k=1}^H \exp(e_{i,k})} \quad (12)$$

最终通过加权求和的计算完成加权和算法的匹配, 计算表达式为

$$\gamma_i = \sum_{j=1}^H \beta_{i,j} K(h_j) \quad (13)$$

通过上述具体的方法生成上下文信息, 使每个径向槽独立收集图像特征列中的相关信息, 完成从图像信息到 BEV 位置的分配。

对于损失函数, 本文采用二进制交叉损失 l_1 和熵值最大化损失 l_2 相结合, 第一部分是为了鼓励语义占用概率 p^k 与真实占用概率 m_i^k 相匹配, 通过常数因子 α^k 对属于 k 类的占用单元格进行加权, l_1 损失计算公式为

$$l_1 = \alpha^k m_i^k \log p^k + (1 - \alpha^k) (1 - m_i^k) \log(1 - p^k) \quad (14)$$

为了鼓励网络预测模糊区域中的不确定性, 本文引入了第二个损失使预测的熵最大化, l_2 损失计算公式为

$$l_2 = 1 - p^k \log p^k \quad (15)$$

完整损失 l_{all} 公式为

$$l_{\text{all}} = l_1 + l_2 \quad (16)$$

5 实验结果与分析

本文设计了基于鸟瞰视图的递归特征金字塔语义分割方法, 为验证改进方法的优越性, 本文对三种方法进行了比较, 包括变分编码器解码器的逆透视映射 (VED)^[14] 和特征金字塔鸟瞰视图语义分割网络 (PON)^[15], 以及改进递归特征金字塔鸟瞰视图语义分割网络 (improved recursive feature pyramid network, IRFPN) 在自动驾驶环境中的鸟瞰视图语义分割效果。本文使用的数据集为 nuScenes-mini 数据集, 是由 Motional 团队开发的用于自动驾驶的公共数据集, 完整数据集是源于波士顿和新加坡采集的驾驶场景, 包括大约 140 万张图片; 传感器包括六台车载摄像机一个激光雷达以及 GPS 等。各类交通语义信息以 json 文

件形式保存于数据集中, 其中 maps 是以二值图形式采集的地图路线, 像素值为 255, 包含摄像头、激光雷达采集的多种类交通语义数据信息以及空间坐标, 用于在交通场景中构建世界坐标系。本文将所有矢量注释映射到坐标系中, 并转换为地面真实占用图作为标签使用。实验流程如图 6 所示。

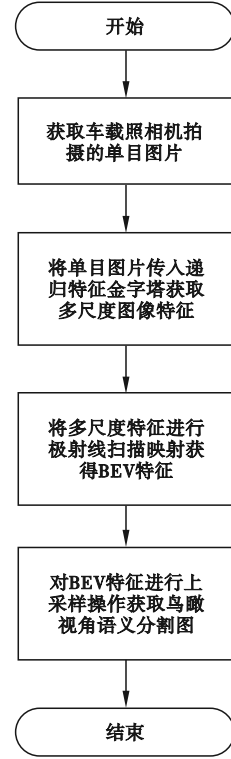


图 6 实验流程图

Fig. 6 Experimental flowchart

本文使用三种方法的实验平台均是搭载了 Nvidia RTX 3080 显卡、Inter i7 10th Gen 处理器、64 G 运行内存、1 T 固态硬盘的计算机, 系统环境配置为 Ubuntu20.04, PyTorch1.10.2, CUDA11.1。在训练阶段使用预训练包含 ResNet-50 的递归特征金字塔网络, 训练 200 轮次, 学习率设置为 0.01, 使用 SGD 优化器对网络进行优化, 批量大小均设置为 8, 输入图像的尺寸为 800×600 。经过多次训练实验, IRFPN 最终在 200 轮前完成收敛工作, 损失值如图 7 所示。

本文的主要评估指标是 IoU 得分, 根据贝叶斯决策边界对预测占用概率大于 0.5 的语义对象进行二重计算得到对应类别的 IoU 得分。在评估时忽略不可见的网格单元。表 1 显示了三种方法在鸟瞰视角自动驾驶场景中对多类常见交通语义预测的 IoU 值, 其中 ours 表示本文算法 IRFPN。




图7 损失值
Fig.7 Loss data

表1 多类常见交通语义 IoU

Table 1 IoU in the union of multiple common traffic semantics

方法	可驾 驶区	人行 横道	步道	停车位	小汽车	卡车	公交车	施工 车辆	行人	摩托车	自行车	平均值
VED	58.3	18.1	24.8	17.8	13.1	8.5	10.9	5.8	0.8	0.4	1.2	14.5
PON	58.0	33.8	31.3	13.7	24.1	17.6	22.6	5.4	5.7	7.9	9.1	20.8
ours	60.1	33.7	28.0	16.1	24.3	17.6	28.6	6.3	6.3	6.0	6.1	21.2

下降,但是对于小汽车、公交车、工程用车的预测准确率均有提升,其中对于公交车的预测提升了6%,而对于驾驶场景中最重要的行人预测准确率提升了0.6%。

为了验证 RFP 以及极射线扫描映射在鸟瞰

视图中的语义分割效果,完成两组消融实验,对比结果如表2所示,其中 a 表示 RFP, b 表示极射线扫描映射结构,ours-a-b 表示未使用 RFP 和极射线扫描结构,ours-b 表示未使用极射线扫描结构。

表2 消融实验结果对比

Table 2 Comparison of ablation experiment results

方法	可驾 驶区	人行 横道	步道	停车位	小汽车	卡车	公交车	施工 车辆	行人	摩托车	自行车	平均值
ours-a-b	58.3	22.4	17.4	0	18.4	18.4	27.1	0.1	4.8	4.1	2.2	15.7
ours-b	59.6	30.6	27.6	15.7	22.9	18.7	25.7	6.3	5.7	6.3	4.9	20.4
ours	60.1	33.7	28.0	16.1	24.3	17.6	28.6	6.3	6.3	6.0	6.1	21.2

由表2可见,相比不使用 RFP,使用该项技术平均 IoU 提升了 4.7%,各个类别均有较大提升,其中人行道提升了 8.2%,小汽车、行人、自行车分别提升了 4.5%、0.9%、2.7%,而使用极坐标扫描映射可以在平均 IoU 上获得 0.8% 的提升,虽然摩托车类别下降了 0.3%,但是小汽车、公交车、行人、自行车分别获得了 1.4%、2.9%、0.6% 和 1.2% 的提升。经过以上实验可以得出,RFP 和极射线扫描映射能够有效提高鸟瞰视角下对于交通

语义的分割精度。

使用 IRFPN(ours)在 nuScenes 数据集的测试集部分分割结果可视化展示如图8所示,其中 GT 代表标签。

由图8可以看出,IRFPN 和 PON 分割预测效果明显优于 VED,VED 对于动态交通语义基本无效。而 IRFPN 相比 PON 在行人的分割方面更加细致,对于小汽车、公交车的预测则优于 PON。

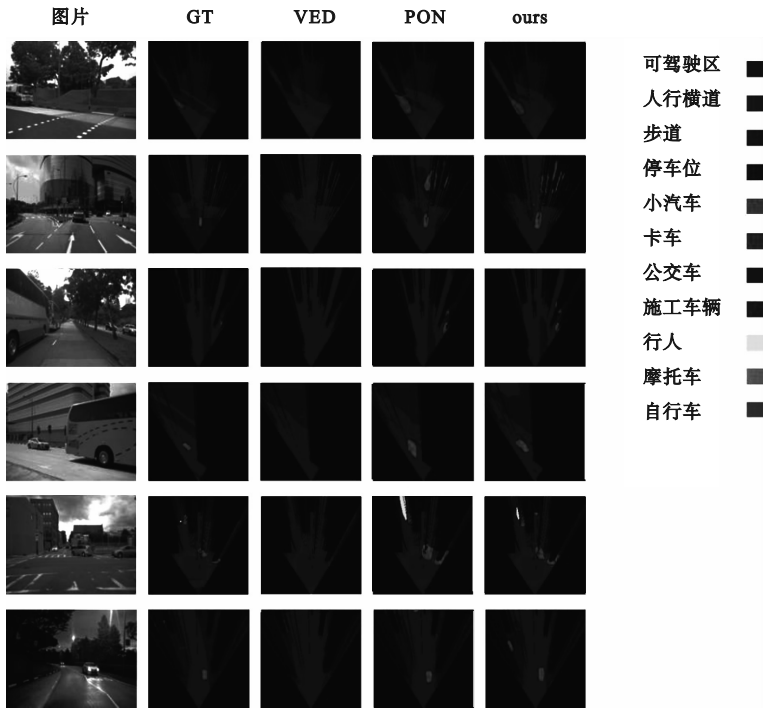


图8 三种方法语义分割结果可视化图

Fig.8 Visualization of semantic segmentation results using three methods

6 结论

RFP 具有结构简单、特征细节保留更充分、能提取多尺度特征信息的特点,适合应用于解决鸟瞰视图下的自动驾驶语义分割问题。本文针对真实驾驶场景中,自动驾驶系统对实时图像特征提取不充分,普通逆透视转换对交通语义预测不佳的问题,提出了一种基于鸟瞰视图的递归特征金字塔语义分割方法 IRFPN,有效提升了对于常见交通语义的分割效果,对鸟瞰视图转换部分进行了优化,使用极射线扫描映射的形式使 BEV 视角特征与原车载图像特征关联性更强,针对常见交通语义有更好的预测效果。为验证算法的有效性,通过消融实验验证 RFP 和极射线扫描映射相结合能够有效提升鸟瞰视图下的自动驾驶语义分割精度,IRFPN 对驾驶场景的鸟瞰视图语义分割具有一定的参考价值。

参考文献 (References):

- [1] 常嘉义,秦瑞,李庆,等. 基于全景鸟瞰视图的障碍物检测方法研究[J]. 计算机科学,2014,41(S2):78-82.
CHANG J Y, QIN R, LI Q, et al. Research of obstacle detection based on aerial panorama image[J]. Computer Science, 2014,41(S2):78-82. (in Chinese)
- [2] 王恩德,齐凯,李学鹏,等. 基于神经网络的遥感图像语义分割方法[J]. 光学学报,2019,39(12):93-104.

WANG E D, QI K, LI X P, et al. Semantic segmentation of remote sensing image based on neural network[J]. Acta Optica Sinica, 2019, 39(12):93-104. (in Chinese)

- [3] 潘云杰,李颖,王欣威,等. 基于 SPA 和 SQPE 的往复压缩机滑动轴承故障特征提取方法[J]. 沈阳理工大学学报, 2022,41(4):20-25.
PAN Y J, LI Y, WANG X W, et al. Fault feature extraction method for reciprocating compressor sliding bearing based on SPA and SQPE[J]. Journal of Shenyang Ligong University, 2022,41(4):20-25. (in Chinese)
- [4] 沈万里,张玉金,胡万. 面向图像修复取证的 U 型特征金字塔网络[J]. 计算机应用,2023,43(2):545-551.
SHEN W L, ZHANG Y J, HU W. U-shaped feature pyramid network for image inpainting forensics[J]. Journal of Computer Applications, 2023,43(2):545-551. (in Chinese)
- [5] 林成创,赵鑫森,尹爱华,等. AS-PANet:改进路径增强网络的重叠染色体实例分割[J]. 中国图象图形学报,2020,25(10):2271-2280.
LIN C C, ZHAO G S, YIN A H, et al. AS-PANet: a chromosome instance segmentation method based on improved path aggregation network architecture[J]. Journal of Image and Graphics, 2020,25(10):2271-2280. (in Chinese)
- [6] 郑楚伟,林辉,吴晓明,等. 基于自适应空间特征融合的 YOLOv5 安全帽检测系统设计[J]. 机电工程技术,2022,51(9):37-42.
ZHENG C W, LIN H, WU X M, et al. Design of YOLOv5 helmet detection system based on adaptive spatial feature fusion[J]. Mechanical & Electrical Engineering Technology, 2022,51(9):37-42. (in Chinese)
- [7] 李兰,陈明举,石浩德,等. 基于 BIFPN-GAN 特征融合的图像修复算法研究[J]. 无线工程,2022,52(12):2141-2148.
LI L, CHEN M J, SHI H D, et al. Research on image inpainting algorithm based on BIFPN-GAN feature fusion[J]. Radio Engineering, 2022,52(12):2141-2148. (in Chinese)

(下转第47页)