

基于激光点云的自动驾驶路面检测

刘良杰, 雷志勇, 胡云卿, 梅文庆

中国中车股份有限公司 湖南株洲

【摘要】为了更有效地获取可通行区域内的道路路面信息,提升三维激光雷达点云特征提取及点云分割的性能,本文提出了一种基于极坐标系的路面检测算法。与笛卡尔坐标系分割相比,利用极坐标对激光雷达产生的三维数据进行处理能够实现更加均匀且精确的分割效果,同时在分割点云时引入二维CNN可以大幅减小耗时。然后将得到的点云输入到PointNet进行栅格点云特征提取并引入RingCNN,最终得到了良好的路面检测准确率,为自动驾驶提供安全可靠的可行驶区域信息。

【关键词】可通行区域;道路路面检测;深度学习;特征提取;点云分割

【收稿日期】2024年8月16日 **【出刊日期】**2024年9月28日 **【DOI】**10.12208/j.jer.20240035

LIDAR Point Cloud-based road pavement detection for autonomous driving

Liangjie Liu, Zhiyong Lei, Yunqing Hu, Wenqing Mei

CRRC Corporation Limited, Zhuzhou, Hunan

【Abstract】In order to more effectively obtain road surface information in the traversable area and improve the performance of three-dimensional laser radar point cloud feature extraction and point cloud segmentation, this paper proposes a road surface detection algorithm based on polar coordinates. Compared with Cartesian coordinate system segmentation, the use of polar coordinates to process the three-dimensional data generated by the laser radar can achieve a more uniform and accurate segmentation effect. At the same time, the introduction of two-dimensional CNN when segmenting the point cloud can greatly reduce the time consumption. Then the obtained point cloud is input into PointNet for grid point cloud feature extraction and RingCNN is introduced, and finally a good road surface detection accuracy is obtained, providing safe and reliable drivable area information for autonomous driving.

【Keywords】Traversable area; Road surface detection; Deep learning; Feature extraction; Point cloud segmentation

引言

近年来,随着人工智能与互联网+技术的迅猛发展,智能网联运载设备成为了时代关注的焦点。自动驾驶作为智能运载装备的核心技术,在人工智能的加持下也得到了飞速的发展。自动驾驶系统主要包含环境感知、决策规划以及运动控制等模块,其中环境感知为规划决策和运动控制提供行驶环境信息,是车辆实现车辆智能驾驶的首要条件。环境感知的主要任务有可通行区域检测、障碍物识别与跟踪等。其中,可通行区域检测的目的是为车辆安全行驶提供精确的可行驶区域,它是规划决策和运动控制的关键参考因素与基础。

根据传感器种类差别,路面可通行区域检测主要分为视觉检测和激光点云检测。视觉检测主要依靠相机传感器来实现装备对周围环境信息的获取,虽然相机能够提供高分辨率的图像信息和丰富的场景语义信息,但因其受天气、环境影响较大。例如在矿区这类具有大量灰尘的工作环境中,相机的性能往往会大打折扣。因此,智能网联车辆开始广泛应用基于激光雷达的环境感知系统。与相机相比,激光雷达能够准确获取几何坐标信息,而且不受光照、阴影等条件的限制。当前,针对三维激光雷达点云的可通行区域路面检测方法,主要包括基于人工特征的方法和基于深度学习的方法这两类。

作者简介:雷志勇(1974-)男,中国矿业大学硕士研究生,高级工程师,主要从事煤矿开采管理工作。

(1) 人工特征方法主要包含以下几种: 基于点云栅格化来提取地面、利用 3D 点提取地面、直接处理点云以获取地面点、依据点云线束提取地面以及借助线束内和线束间特征提取地面。

(2) 基于深度学习的点云检测方法依据点云处理方式, 可分为两类代表性网络结构: 基于投影的点云分割网络和基于点的点云分割网络。基于投影方式的网络, 将点云投影到其他视图或者坐标系下, 从而对点云进行处理, 其中包括: 多视图表示法、球形表示法、体积表示法。基于点的网络直接对点云产生作用, 直接从点云中提取特征信息以获取检测结果, 其包含多层感知机法、点卷积法、基于循环神经网络的方法和基于图的方法。

本文重点对基于激光点云的自动驾驶路面检测方法展开研究, 主要贡献可归纳如下:

(1) 提出一种基于激光点云的路面检测途径, 构建可通行区域检测系统用于道路安全区域检测。该路面检测系统能够为自动驾驶汽车的行驶提供安全区域, 为定位、决策规划和控制提供可靠的参考依据, 进而增强自动驾驶的安全性。

(2) 本研究针对自动驾驶中的可行驶区域路面检测问题, 提出了一种基于深度学习的激光点云检测方法。该方法首先在极坐标系下对激光雷达点云数据进行环形栅格化处理, 然后利用 PointNet 网络提取各栅格单元内的特征信息, 接着通过 RingCNN 对形成的环形特征图进行进一步处理, 最终利用 UNet 模型实现点云分割任务。在训练此网络模型的过程中, 采用 LovaszSoftmax 作为损失函数指导优化, 同时借助 lovasz 扩展这一数学方法实现离散函数的光滑化处理。

1 可通行区域路面检测架构

1.1 可通行区域模型

如图 1 所示, 该模型能够识别并标定出道路的路面范围。通过检测拟合得到的蓝色曲线描绘了路面区域, 为智能网联车辆提供了精确的安全行驶区域。

1.2 可通行区域检测系统架构

基于三维激光雷达的可通行区域路面检测系统架构主要包括以下模块: 环境数据输入模块、可通行区域路面检测模块、输出模块。

(1) 环境数据输入模块采用安装在车顶的三维

激光雷达采集环境数据。

(2) 可通行区域检测模块具有道路路面检测的任务, 采样基于点云深度学习网络的 PolarNet 算法提取路面点云, 精确地界定出可供行驶的道路路面, 从而为智能网联车辆提供了一个可靠的安全行驶区域范围。

(3) 输出模块用于输出准确的道路路面区域, 为后续智能网联车辆定位以及决策规划提供可靠的道路路面信息。



图 1 可通行区域

1.3 可通行区域检测算法架构

可通行区域检测算法架构以三维激光雷达点云为基础, 主要有两个模块: 道路路面检测模块、整体输出模块。

(1) 道路路面检测模块: 该模块主要功能是使得路面点云带上路面标签, 给智能网联车辆提供可行驶道路范围, 其主要由三个部分构成: 极坐标系下点云环形栅格化、PointNet 提取栅格特征、RingCNN 语义分割。

①为了更高效地表示点云数据, 本文将其转换到极坐标系, 并构建环形栅格化表示。具体步骤如下: 首先, 针对单个激光雷达产生的点云, 我们将点云数据从笛卡尔坐标系 (x, y, z) 转换为极坐标系 (r, θ, z) , 并按照距离 r 和角度 θ 划分空间, 距离 r 被划分为 N_r 个等间隔的环形带, 每个带的宽度为 Δr , 水平角度 θ 被划分为 N_θ 个扇形, 每个扇形的宽度为 $\Delta \theta$, z 方向可作为附加的通道信息。在每个栅格中, 我们对点云数据进行降维处理, 取栅格内点的平均值作为特征。最终得到一个环形栅格化张量, 尺寸为 (C, N_r, N_θ) 。

②利用训练后的 PointNet 网络提取栅格特征, 首先从环形栅格化张量中提取每个栅格内的点集合, 输

入为点的三维坐标和附加特征 $(x, y, intensity)$ 。对每个点云数据 $(x, y, intensity)$ 应用共享的多层感知机 (MLP), 映射到高维特征空间。再使用如最大池化函数对栅格内的点云特征进行聚合, 生成栅格级的全局特征, 随后将局部特征和全局特征进行拼接, 得到增强的栅格特征, 最终输出栅格的高维特征表示 (C', N_r, N_θ) 。

③RingCNN 语义分割是将环形特征栅格输入含有环卷积的卷积神经网络, 从而实现语义分割。针对环形栅格化数据, 本文设计了一种基于环形卷积的语义分割网络。对环形栅格 (N_r, N_θ) , 我们设计了环形卷积核, 以考虑扇形的周期性边界。并使用方向权重使卷积操作具有方向感知能力。在编码器部分, 我们采用多层环形卷积对栅格特征进行逐步下采样, 提取高层语义特征。同时在下采样过程中, 保持距离和角度信息。

在解码器部分, 使用反卷积方法逐步恢复分辨率, 并融合浅层特征, 同时添加跳跃连接以保留空间细节。

(2) 整体输出模块: 该模块的核心任务在于将识别到的道路路面点云以平面区域的行驶输出给到决策规划模块。

2 基于 PolarNet 的路面点云检测

2.1 PolarNet 网络结构

PolarNet 是一种轻量化的点云深度学习网络, 主要用于室外单个三维激光雷达的点云处理。包括卷积层、反卷积层、激活层和池化层。

(1) 卷积层

卷积层通过使用卷积核实现了从局部到全局的信息逐级感知, 并在同一层内共享这些核以有效减少所需参数的数量。如图 2 所示, 输入三个通道数据, 通过卷积产生高层次特征数据。公式如下:

$$F_1 = W_{11} * C_1 + W_{12} * C_2 + W_{13} * C_3 + b_1 \quad (1)$$

$$F_2 = W_{21} * C_1 + W_{22} * C_2 + W_{23} * C_3 + b_2 \quad (2)$$

$$F_3 = W_{31} * C_1 + W_{32} * C_2 + W_{33} * C_3 + b_3 \quad (3)$$

$$F_4 = W_{41} * C_1 + W_{42} * C_2 + W_{43} * C_3 + b_4 \quad (4)$$

其中 C_j 为第 j 通道输入的数据, F_i 为产生的第 i 层特征, W_{ij} 为对应卷积核, $*$ 代表卷积计算。

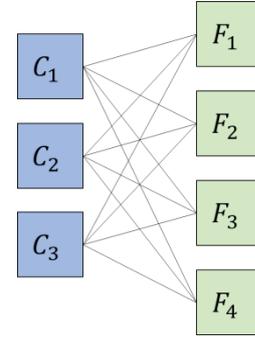


图 2 卷积层

$$X = \frac{\sum x_i}{i} \quad (5)$$

$$Y = \frac{\sum y_i}{i} \quad (6)$$

$$Z = \frac{\sum z_i}{i} \quad (7)$$

将卷积计算过程展开如公式 (8) 所示, 扩展的卷积核 A 矩阵与展开的输入矩阵相乘可得到展开的输出矩阵。

$$\begin{bmatrix} O_{11} \\ O_{12} \\ O_{21} \\ O_{22} \end{bmatrix} = A_E \times \begin{bmatrix} I_{11} \\ I_{12} \\ I_{13} \\ I_{14} \\ \vdots \\ I_{42} \\ I_{43} \\ I_{44} \end{bmatrix} \quad (8)$$

$$A_E = \begin{bmatrix} A_{11} & A_{12} & A_{13} & 0 & A_{21} & A_{22} & A_{23} & 0 & A_{31} & A_{32} & A_{33} & 0 & 0 & 0 & 0 & 0 \\ 0 & A_{11} & A_{12} & A_{13} & 0 & A_{21} & A_{22} & A_{23} & 0 & A_{31} & A_{32} & A_{33} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & A_{11} & A_{12} & A_{13} & 0 & A_{21} & A_{22} & A_{23} & 0 & A_{31} & A_{32} & A_{33} & 0 \\ 0 & 0 & 0 & 0 & 0 & A_{11} & A_{12} & A_{13} & 0 & A_{21} & A_{22} & A_{23} & 0 & A_{31} & A_{32} & A_{33} \end{bmatrix}$$

(2) 反卷积

反卷积被用来将已经分类标记的特征数据恢复到其原始大小, 这一过程也被称为上采样。上采样方法是一个重要的图像处理手段, 其中包括最近邻插值、双线性插值、双三次插值以及反卷积, 和其他上采样方法不同, 反卷积能够在训练过程中学习到一种进行上采样的最优方式。反卷积计算公式如式 (9) 所示, 将小体量数据矩阵 O 转化为大体量数据矩阵 I 。

$$I = A_E^T \times O \quad (9)$$

(3) 激活层

激活层的作用在于对卷积层输出结果进行非线性映射处理。若不运用激活函数, 即便神经网络有

多层, 每一层输出也只是上一层输入的线性变换, 这实际上和最初级的感知机无异。因此, 需激活层把线性组合转变为非线性, 让神经网络拥有拟合任意函数的能力, 常见的激活函数有 Sigmoid、Tanh、ReLU、Leaky ReLU 和 Maxout。

(4) 池化层

池化层, 也被称作欠采样或下采样, 其主要功能是对数据进行特征降维, 能够对数据与参数的数量加以压缩, 并且可以减少过拟合现象, 提高模型的容错率。一般来说, 池化方式有最大池化和平均池化, 具体而言, 是在小邻域内分别用特征的最大值或平均值来代表该邻域内的所有特征值。

2.2 UNet 网络结构

UNet 是一种数据分割网络, 其结构如图 5 所示, 可分为下采样和上采样两部分, 也被称作编码器 - 解码器结构。下采样部分通过卷积层、激活层、最大池化层将数据压缩为固定长度特征。而上采样部分则运用反卷积网络对点云进行分割, 从而产生每个点的类别标签, 见图 5。

2.3 RingCNN 网络结构

RingCNN 是一种卷积神经网络, 它采用了环卷积操作。在环卷积中, 会把特征矩阵处理成首尾相连的形式, 并且让位于相反一侧的梯度借助环卷积核传播至另一侧。如图 6 所示, RingCNN 能够同时学习栅格内部点云特征和特征矩阵环连接特性, 这有利于进一步扩充网络的感知域。基于此, 只需将普通卷积操作替换为环卷积, 再经过训练就能形成 RingCNN, 可用于处理极坐标鸟瞰视图划分的环形栅格, 见图 6。

2.4 PointNet 网络结构

在点云深度学习的发展历程中, PointNet 有着开创性意义。如图 7 所示的 PointNet 架构, 开启了适用于点云数据端到端的深度学习网络模型, 见图 7。

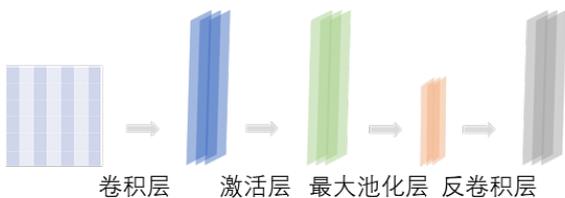


图 5 UNet 网络结构

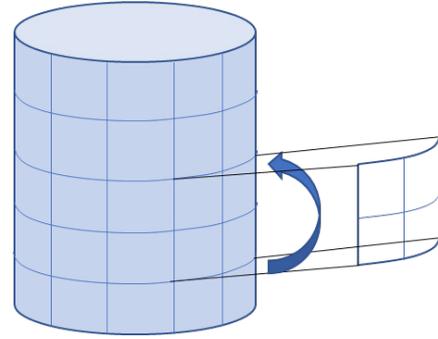


图 6 环卷积

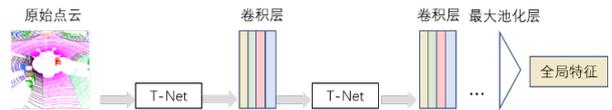


图 7 PointNet 网络架构

上述网络包含如下步骤: 1) 假设输入点云有 n 个点, 每个点有 3 个代表坐标的特征 (x, y, z) , 那么输入点云的序列数据为 $n \times 3$ 。2) $n \times 3$ 的输入数据经 T-Net 矩阵转换, 转变为利于特征提取的数据, 即所谓的对齐序列数据。3) 利用多层感知机 MLP, 将 $n \times 3$ 的序列数据投影至更深层次的特征空间, 从而得到 $n \times 64$ 的序列数据。4) $n \times 64$ 的数据再次通过 T-Net 矩阵转换, 把深层特征空间转换为对进一步提取特征更有利的特征对齐数据。5) 重复步骤 3 和 4, 直至特征达到指定深度, 如 $n \times 1024$ 。6) 深度特征数据 $n \times 1024$ 借助最大池化 Max pooling 简化为 1×1024 的代表性特征数据。通过以上步骤, 实现了点云数据的特征提取。

2.5 基于 PolarNet 道路路面检测

2.5.1 PolarNet 网络结构

如图 8 所示, PolarNet 包括三部分: 基于极坐标划分鸟瞰视图、基于 PointNet 提取栅格点云特征、基于 RingCNN 语义分割。

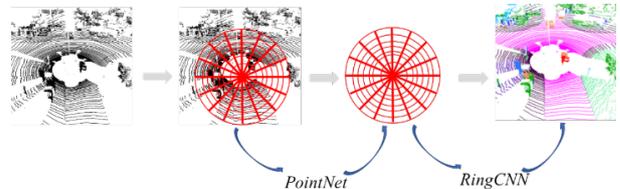


图 8 PolarNet 网络结构

(1) 基于极坐标划分鸟瞰视图, 点云是由激光雷达扫描周围三维环境产生的, 如图 10 所示。若采用三维分割栅格, 时间成本会很高。所以, 将点云表

示为自上而下的正交投影图(即鸟瞰视图), 这种方式能使信息损失最小。然后将鸟瞰视图输入二维分割网络来完成点云分割, 在此过程中, 利用成熟的二维 CNN 可大幅减少检测耗时。

当把鸟瞰视图用于 CNN 时, 为了最大程度地利用 CNN 技术, 要尽量让鸟瞰视图近似于图像数据, 因此, 鸟瞰视图通常采用笛卡尔坐标系栅格划分, 如图 9 所示。然而, 笛卡尔坐标系栅格划分并不适用于激光雷达点云数据。在基于笛卡尔坐标的鸟瞰视图中, 中间栅格和周边栅格可能全是空栅格, 并且其他非空栅格的点云分布极不均匀。这种划分方式不仅会浪费计算资源, 还会导致特征提取不准

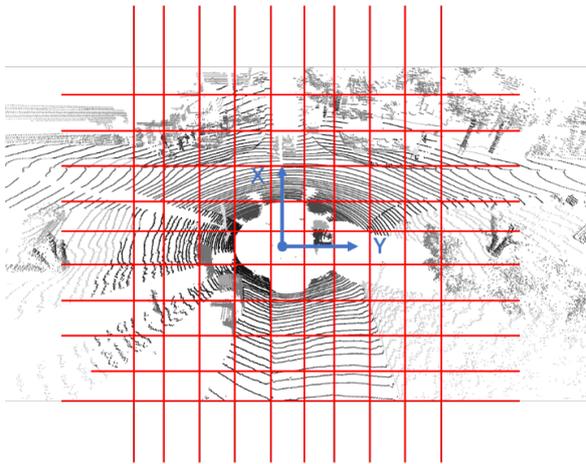


图 9 笛卡尔坐标系栅格化

确。基于激光雷达扫描原理, 极坐标鸟瞰视图以传感器位置为原点, 对 x-y 平面上各个点的方位角和半径进行计算, 并依据量化后的方位角和半径将点划分至网格。

与采用笛卡尔坐标系的鸟瞰视图相比, 极坐标鸟瞰视图有两个优势: 1) 划分更加均匀。若划分栅格数量相同, 笛卡尔鸟瞰视图平均每个栅格内 0.7 ± 3.2 个点, 而极坐标鸟瞰视图仅 0.7 ± 1.4 个点。2) 分割更加准确。采用笛卡尔鸟瞰视图三维重构后栅格内 98.75% 的点标签相同, 而采用极坐标鸟瞰视图, 三维重构后栅格内部点云标签相同率提升到 99.3%。

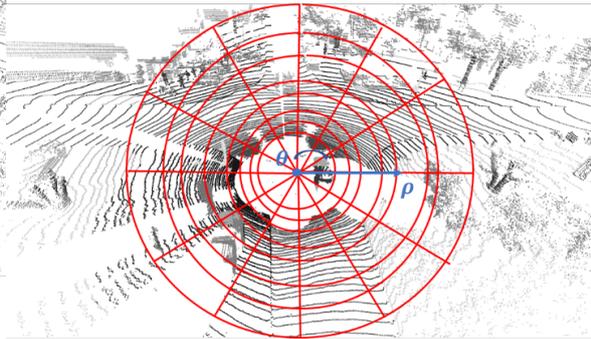


图 10 极坐标系栅格化

(2) 基于 PointNet 提取栅格点云特征。网络由全连接层、BN 优化层、ReLU 激活层构成, 每个栅格点云的固定长度特征 h 是 1×512 , 对栅格特征 h 最大池化, 最终所有栅格特征组成栅格特征图。其中第 i 行第 j 列栅格特征值如下:

$$fea_{i, j} = MAX(\{h(p) | w_i < p_x < w_{i+1}, l_i < p_y < l_{i+1}\}) \quad (10)$$

其中 w 和 l 是栅格边线位置, p_x 和 p_y 是点 p 坐标位置。

(3) 基于 RingCNN 语义分割, 把获取到的整个栅格特征矩阵输入 RingCNN, 以此开展语义分割。采用 UNet 架构作为语义分割网络, 先对整个栅格特征图进一步特征提取, 然后通过上采样解码的方式为每个点标记标签。

2.5.2 损失函数及优化策略

本文使用 LovaszSoftmax, 一种基于对交并比

IOU 衡量来进行优化的损失函数, 该函数借用数学工具 lovasz 扩展, 使离散的 IOU 损失函数变得光滑, 与 Dice 损失函数相比, LovaszSoftmax 更适用于数据分割。如图 11 所示为 IOU 交并比。

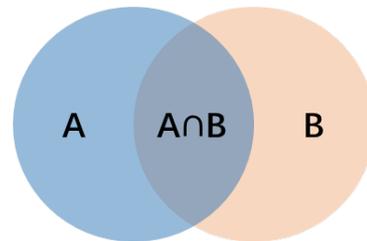


图 11 IOU 示意图

IOU 定义:

$$IOU = \frac{|\{y^* = c\} \cap \{\tilde{y} = c\}|}{|\{y^* = c\} \cup \{\tilde{y} = c\}|} \quad (11)$$

其中 c 代表某一种检测类别例如路面或者非路

面, y^* 代表训练数据集类别标签, \tilde{y} 代表网络检测类别。

若直接使用 IOU 来构建损失函数, 以此表示网络预测效果和训练集之间的差距, 则:

$$LossIOU = 1 - IOU \quad (12)$$

若定义检测结果与训练集标签不匹配部分为:

$$M_c(y^*, \tilde{y}) = \{y^* = c, \tilde{y} \neq c\} \cup \{y^* \neq c, \tilde{y} = c\} \quad (13)$$

则优化目标函数为:

$$\Delta_{LossIOU}: M_c \in \{0, 1\}^p \rightarrow \frac{M_c}{\{y^* = c\} \cup M_c} \quad (14)$$

IOU 为点云离散形式无法求导, 导致优化困难, 为此, 利用成熟的数学工具 lovasz 扩展对其进行光滑延拓, 且延拓后的函数为凸函数, 为后续优化带来了极大的便利。

假设存在一组离散函数:

$$\Delta: \{0, 1\}^p \rightarrow R \quad (15)$$

经过 lovasz 扩展实现光滑延拓后变为:

$$\bar{\Delta}: m \in R^p \rightarrow \sum_{i=1}^p m_i g_i(m) \quad (16)$$

即变量 m 从离散空间 $\{0, 1\}^p$ 转变到连续空间 R^p , 相应地, 函数从离散空间 R 转换到连续空间 $\sum_{i=1}^p m_i g_i(m)$ 。

则经 lovasz 扩展进行光滑延拓后, 得到目标函数为:

$$\bar{\Delta}: m \in R^p \rightarrow \sum_{i=1}^p m_i (\Delta(\{\pi_1, \dots, \pi_i\}) - \Delta(\{\pi_1, \dots, \pi_i\})) \quad (17)$$

其中 π 是 m 的取值按照由大到小排列顺序, 即 $x_{\pi_1} \geq x_{\pi_2} \dots \geq x_{\pi_p}$, m 在路面检测模型中代表网络点云分割与点云路面标签的差距。

2.6 网络训练与数据集

本课题运用组内大数据服务集群来训练 PolarNet 网络。通过数据集中的测试数据对训练网

络的有效性进行验证, 依据 IOU 标准, 经测试, 训练所得的 PolarNet 检测道路路面的准确率在 92%以上。

语义分割所使用的数据集包括:

SemanticKITTI、A2D2、Paris - Lille - 3D, 在本研究中, 采用 SemanticKITTI 数据集对 PolarNet 进行训练。KITTI 数据集的数据采集平台配备了 2 个灰度摄像机、2 个彩色摄像机、1 个 Velodyne 64 线三维激光雷达、4 个光学镜头以及 1 个 GPS 导航系统, KITTI 数据平台的外观与传感器布置情况可参照图 12。网络训练所使用的数据是 Velodyne 64 线三维激光雷达点云数据, 具体而言, 是场景分割数据集 SemanticKITTI 数据集。64 线激光雷达安装于平台车顶部, 可环形扫描 360°, 从而获取车辆周围完整的三维环境数据。



图 12 KITTI 数据平台

3 实车实验验证

为验证道路路面提取的有效性, 采用基于林肯 MKZ 系列车辆改装智能车平台与 32 线激光雷达采集数据, 通过服务器集群搭建运行软件系统, 对实验结果展开分析。展示了林肯 MKZ 自动驾驶平台, 表 1 列举了 32 线激光雷达参数指标, 表 2 列举了服务器集群配置, 表 3 列举了单个服务器配置参数。

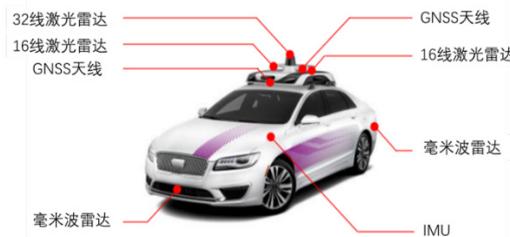


图 13 林肯 MKZ 自动驾驶平台

表 1 32 线激光雷达参数

参数类型	性能指标
通道数量	32 线
测量范围	高达 200m
测量精度	±5cm @ <50m; ±10cm @50m to 200m
水平视场 360°	360°
水平精度	0.1° ~ 0.4°
垂直视场	40° (+15.0° to -25.0°)
垂直精度	0.33° (非线性分布)
旋转频率	5Hz ~ 20Hz
工作温度	-20°C ~ +60°C
储存温度	-40°C ~ +80°C
工作电压	10.5V ~ 18V
点云数量	600000/s (单模) 1200000/s (双模)

表 2 服务器集群配置

设备类型	设备型号	数量
塔式服务器	PowerEdgeT640	7 台
硬件防火墙	SG-6000-C2100	1 套
核心交换机	S3956B	1 台
汇聚层交换机	S2928C	3 台

表 3 单个服务器配置

配件	配件型号	数量
CPU	E5-2683 英特尔至强	2 个
	16 核/32 线程	
	40M 缓存	
GPU	2.1GHz 主频	
	英伟达 TITAN X Pascal	4 个
内存	12G 显存	
	16G 内存	16 个
硬盘	240GB 固态硬盘	1 个
	2TB 机械硬盘	2 个

3.1 试验结果分析

将车载三维激光雷达所采集数据标定至车体坐标系，并截取空间范围处于 $\{0m < x < +30m, -10m < y < +10m\}$ 的点云数据，去除上仰视场角的线束点云，并经过点云下采样，输入可通行区域检测系统，从而获取路面信息。

3.1.1 路面检测结果分析

使用KITTI64线激光雷达数据集对完成训练的

网络进行测试，采用PolarNet进行路面检测，测试结果如表4所示，PolarNet在路面检测任务上达到了93.1%的准确率，召回率为92.5%，F1分数为92.8%，可视化结果如图14、图15所示。在图中，紫色代表路面点，由此可知，经过训练的PolarNet能够绕开行驶中的车辆，检测出可安全行驶的路面区域。这一结果证明了PolarNet在路面检测方面具有稳定性和较高的准确率。

表 4 检测性能

检测准确率	召回率	F1 分数
93.1%	92.5%	92.8%

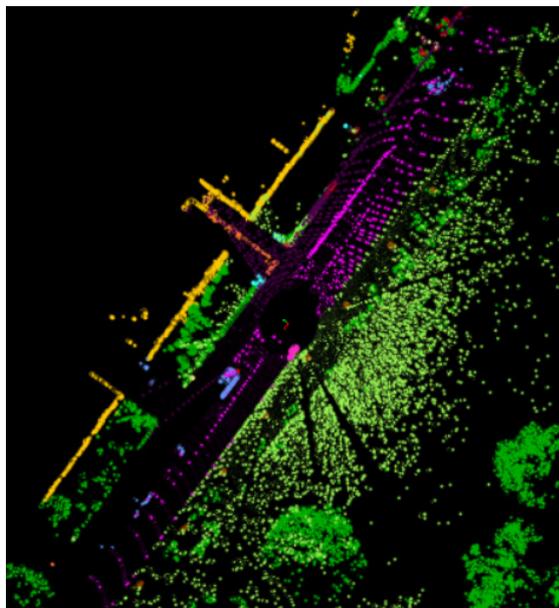


图 14 PolarNet 测试结果

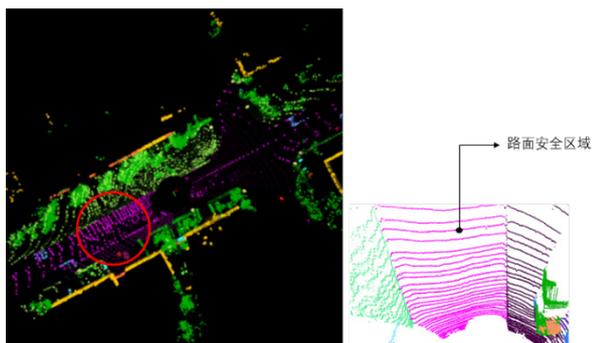


图 15 PolarNet 测试结果

对于平台车车顶 32 线激光雷达所采集的数据, 采用 PolarNet 检测其中的路面区域。仅考虑下俯视角的线束点云, 在经过点云下采样后, 利用 PolarNet 对点云进行分割以获取路面点集, 效果如图 16 所示, 其中蓝色点表示路面点集。从图中可以看出, 路面点的检测结果比较完整, 效果良好。基于 IOU 标准, 网络返回的道路路面检测准确率为 92.2%, 在车辆前方点云检测到的路面点集包含 500 - 550 个点。

车载激光雷达采用单模形式, 仅考虑下俯视角的线束点云, 经过下采样来减少点云数量。通过对每帧检测到的路面点和真实路面点进行统计, 并统计每帧检测点与真实点的交并点集数量, 就能得

到基于 IOU 标准的检测方法准确率, 具体情况如表 4 所示。

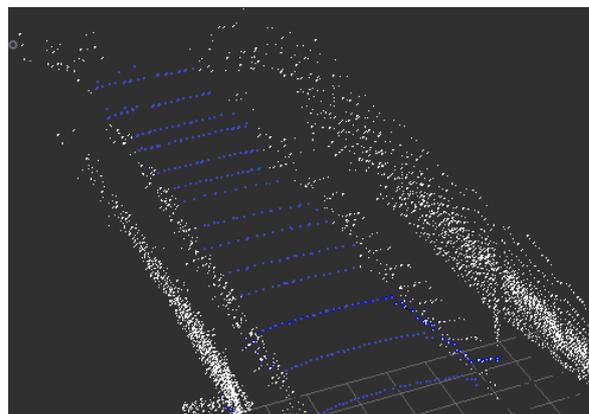


图 16 PolarNet 路面检测

$$IOU = \frac{\{\text{真实点}\} \cap \{\text{检测点}\}}{\{\text{真实点}\} \cup \{\text{检测点}\}}$$

表 5 路面检测率

{真实点} ∩ {检测点}	{真实点} ∪ {检测点}	路面 IOU
574	623	92.1%
565	612	92.3%
568	616	92.2%

采由表 5 可知, 采用点云分割网络 PolarNet 检测路面的准确率稳定在 92.2%附近, 波动不大。此检测结果可为智能网联车辆提供有效, 准确的道路安全区域。

4 结论

本文提出了基于三维激光点云的自动驾驶路面检测方法, 主要研究内容及结论如下:

(1) 采用深度学习的方法, 通过利用对极坐标系栅格化, 使用 PointNet 提取栅格内部点云特征, 并采用基于 RingCNN 的 UNet 网络架构进行点云分割。

(2) 采用 KITTI 数据集中的分割数据集, 采用 LovaszSoftmax 损失函数及 Adam 优化器进行网络优化, 使得网络逐步收敛至准确稳定检测路面点集。基于 IOU 标准路面点检测准确率在 92.2%附近。

参考文献

[1] Van, Brummelen, Jessica, et al. Autonomous vehicle perception: The technology of today and tomorrow[J].

- Transportation Research Part C Emerging Technologies, 2018.
- [2] Che E, Jung J, Olsen M. Object Recognition, Segmentation, and Classification of Mobile Laser Scanning Point Clouds: A State of the Art Review[J]. *Sensors*, 2019, 19(4).
- [3] Husain A, Vaishya R. A time efficient algorithm for ground point filtering from mobile lidar data. In *Proceedings of the 2016 International Conference on Control, Computing, Communication and Materials (ICCCCM)*, Allahabad, India, 21–22 October 2016; pp. 1–5.
- [4] Yadav M, Singh A. K, Lohani, B. Extraction of road surface from mobile lidar data of complex road environment. *Int. J. Remote Sens.* 2017, 38, 4655–4682.
- [5] Wang G, Wu J, He R, et al. A point cloud-based robust road curb detection and tracking method[J]. *IEEE Access*, 2019, 7: 24611-24625.
- [6] Kang Y. A lidar-Based Decision-Making Method for Road Boundary Detection Using Multiple Kalman Filters[J]. *Industrial Electronics, IEEE Transactions on*, 2012, 59(11):p.4360-4368.
- [7] Cosgun A, Ma L, Chiu J, et al. Towards Full Automated Drive in Urban Environments: A Demonstration in GoMentum Station, California[C] 2017 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2017.
- [8] Yadav M, Singh A K, Lohani B. Extraction of road surface from mobile lidar data of complex road environment[J]. *International Journal of Remote Sensing*, 2017, 38(16): 4655-4682.
- [9] Guo Y, Wang H, Hu Q, et al. Deep learning for 3d point clouds: A survey[J]. *arXiv preprint arXiv:1912.12033*, 2019.
- [10] Qi C R, Su H, Mo K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017: 652-660.
- [11] Qi C R, Yi L, Su H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[C]. *Advances in neural information processing systems*. 2017: 5099-5108.
- [12] Li Y, Bu R, Sun M, et al. Pointcnn: Convolution on x-transformed points[C]. *Advances in neural information processing systems*. 2018: 820-830.
- [13] Maturana D, Scherer S. Voxnet: A 3d convolutional neural network for real-time object recognition[C]. 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2015: 922-928.
- [14] Liu Y, Fan B, Xiang S, et al. Relation-shape convolutional neural network for point cloud analysis[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2019: 8895-8904.
- [15] Ronneberger O, Fischer P, Brox T, U-Net: Convolutional Networks for Biomedical Image Segmentation[C] *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer International Publishing, 2015.
- [16] Long J, Shelhamer E, Darrell T, Fully Convolutional Networks for Semantic Segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4):640-651.
- [17] Hu K, Wang T, Li Z, et al. Real-time extraction method of road boundary based on three-dimensional lidar[J]. *J. Phys.* 2018, 1074: 012080.
- [18] Zhang Y, Wang J, Wang X, et al. 3d lidar-based intersection recognition and road boundary detection method for unmanned ground vehicle[C]. 2015 IEEE 18th International Conference on Intelligent Transportation Systems. IEEE, 2015: 499-504.
- [19] Yadav M, Singh A K, Lohani B. Extraction of road surface from mobile lidar data of complex road environment[J]. *International Journal of Remote Sensing*, 2017, 38(16): 4655-4682.
- [20] Chen Z, Zhang J, Tao D. Progressive lidar adaptation for road detection[J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 6(3): 693-702.
- [21] Han X, Lu J, Zhao C, et al. Semisupervised and weakly supervised road detection based on generative adversarial networks[J]. *IEEE Signal Processing Letters*, 2018, 25(4): 551-555.
- [22] Roynard X, JE Deschaud, Goulette F. Paris-Lille-3D: A Point Cloud Dataset for Urban Scene Segmentation and Classification[C] 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops

- (CVPRW). IEEE, 2018.
- [23] Wang Y, Sun Y, Liu Z, et al. Dynamic Graph CNN for Learning on Point Clouds[J]. ACM Transactions on Graphics, 2018, 38(5).
- [24] Zhang C, Luo W, Urtasun R, Efficient Convolutions for Real-Time Semantic Segmentation of 3D Point Clouds[C] 2018:399-408.
- [25] Lang A H, Vora S, Caesar H, et al. PointPillars: Fast Encoders for Object Detection from Point Clouds[J]. 2018.
- [26] Berman M, Triki A R, Blaschko M B, The Lovasz-Softmax Loss: A Tractable Surrogate for the Optimization of the Intersection-Over-Union Measure in Neural Networks[C] 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.
- [27] Lawin F J, Danelljan M, Tosteberg P, et al. Deep Projective 3D Semantic Segmentation[C] International Conference on Computer Analysis of Images and Patterns. Springer, Cham, 2017.
- [28] Rethage D, Wald J, Sturm J, et al. Fully-Convolutional Point Networks for Large-Scale Point Clouds[J]. Springer, Cham, 2018.
- [29] Thomas H, Qi C R, Deschaud J E, et al. KPConv: Flexible and Deformable Convolution for Point Clouds[C] 2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2020.
- [30] Liang Z, Yang M, Deng L, et al. Hierarchical Depthwise Graph Convolutional Neural Network for 3D Semantic Segmentation of Point Clouds[C] 2019 International Conference on Robotics and Automation (ICRA). IEEE, 2019.
- [31] 张旻昊, 无人机激光雷达智能识别输电线路缺陷探究[J]. 工程学研究, 2022; 1: (5) : 77-80.
- [32] 朱凯, 电动汽车技术革新与交通工程变革的深度融合[J]. 工程学研究, 2024; 3: (2) : 29-38.

版权声明: ©2024 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>

