

控制与决策

Control and Decision

基于DST融合多视图模糊推理赋值的三维目标检测

张翠芳, 李成文利, 邹应全, 金楠

引用本文:

张翠芳, 李成文利, 邹应全, 等. 基于DST融合多视图模糊推理赋值的三维目标检测[J]. *控制与决策*, 2021, 36(4): 867–875.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.0434>

您可能感兴趣的其他文章

Articles you may be interested in

基于正态云模型的状态转移算法求解多目标柔性作业车间调度问题

State transition algorithm based on normal cloud model for solving multi-objective flexible job shop scheduling problem

控制与决策. 2021, 36(5): 1181–1190 <https://doi.org/10.13195/j.kzyjc.2019.1233>

混合MIMO相控阵雷达的交错稀疏阵列设计

Interleaved sparse array design of hybrid phased-MIMO radar

控制与决策. 2021, 36(4): 959–966 <https://doi.org/10.13195/j.kzyjc.2019.0965>

尺度自适应的多特征融合相关滤波目标跟踪算法

Scale adaptation and multi-feature fusion correlation filtering object tracking algorithm

控制与决策. 2021, 36(2): 429–435 <https://doi.org/10.13195/j.kzyjc.2019.0445>

基于KPCA和G-G聚类的多元时间序列模糊分段

Fuzzy segmentation of multivariate time series with KPCA and G-G clustering

控制与决策. 2021, 36(1): 115–124 <https://doi.org/10.13195/j.kzyjc.2019.0849>

基于联合知识表示学习的多模态实体对齐

Multi-modal entity alignment based on joint knowledge representation learning

控制与决策. 2020, 35(12): 2855–2864 <https://doi.org/10.13195/j.kzyjc.2019.0331>

基于DST融合多视图模糊推理赋值的三维目标检测

张翠芳[†], 李成文利, 邹应全, 金楠

(西南交通大学 信息科学与技术学院, 成都 611756)

摘要: 针对前置激光雷达的点云数据, 提出一种基于 DST 融合多视图模糊推理赋值的有效障碍物分割判别方法. 将点云数据转换为体素地图并进行路面分割, 得到前、俯视图. 在两视图中根据不同的模糊推理规则对某体素属于目标的程度进行基本概率赋值, 并通过 DST 融合判别目标, 精确分割目标, 从而得到方盒模型参数. 将三维识别问题转换为一系列的二维检测问题, 与直接利用三维点云信息相比, 可以降低数据处理复杂度, 提高系统稳定性. 在自主研发的自动驾驶汽车上采用前置 16 线激光雷达和 TX2 嵌入式开发板进行多次在线试验, 并在 KITTI 上进行对比验证, 结果表明所提方法在实际应用中拥有较好的实时性和准确性.

关键词: 多视图; 模糊推理; DST; 信息融合; 激光雷达; 目标检测

中图分类号: TP181

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.0434

开放科学(资源服务)标识码(OSID):



引用格式: 张翠芳, 李成文利, 邹应全, 等. 基于 DST 融合多视图模糊推理赋值的三维目标检测 [J]. 控制与决策, 2021, 36(4): 867-875.

3D object detection based on DST fusion multi-view fuzzy reasoning assignment

ZHANG Cui-fang[†], LI Cheng-wen-li, ZOU Ying-quan, JIN Nan

(School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: An effective object segmentation and discrimination method based on DST fusion multi-view fuzzy reasoning assignment is proposed for the point cloud data of pre-lidar. The point cloud data is transformed into a voxel map and road surface segmentation is carried out to obtain the front and top views. In the two views, the basic probability of the voxel's degree of belonging to the object is assigned according to different fuzzy inference rules, and the target is distinguished by DST fusing, and the object is accurately segmented to obtain the parameters of the box model. Converting the 3D recognition problem into a series of 2D detection problems, compared with directly utilizing the 3D point cloud information, can reduce the complexity of data processing and improve the stability of the system. Experiments have been carried out on a self-developed autonomous cars using a 16-line lidar and TX2 embedded development board, with the comparison and verification on KITTI. The results show that the method has good real-time and accuracy in practical application.

Keywords: multi-view; fuzzy reasoning; DST; information fusion; lidar; target detection

0 引言

随着人工智能应用的不断扩大, 自动驾驶技术已经成为国内外的研究热点, 正处于高速发展的阶段. 自动驾驶汽车对环境感知技术有很高的依赖性, 在环境感知所用到的传感器中, 激光雷达可以得到高精度的三维点云信息, 因此被应用于障碍物检测、环境地图构建等环节, 为自动驾驶汽车提供可靠的环境信息.

国内外对基于三维激光雷达的目标检测都有较

多研究. Chen 等^[1]将激光雷达点云和 RGB 图像作为输入, 通过多视点三维网络得到障碍物的方盒模型参数; Cai 等^[2]根据不同层次具有不同感受野的特点, 在特征地图上针对不同层次设计不同尺度的检测器, 并使用了特征图的解卷积层来代替输入图像的上采样, 提升了速度和精度. 目前大多前沿方法是采用深度学习^[3-7]融合激光雷达和摄像头信息^[8-10], 由于环境数据信息丰富, 使得运算和工作成本激增, 需要大型工作站并采集实验数据进行标定加以训练, 耗时长

收稿日期: 2019-04-09; 修回日期: 2019-10-30.

基金项目: 国家自然科学基金项目(61503059); 四川省科技计划项目(2018GZ0008).

责任编委: 张文安.

[†]通讯作者. E-mail: cfzhang_scce@home.swjtu.edu.cn.

久. 利用CNN或SVM进行分类^[11-13], 可以提高目标检测的准确率, 但同时也加大了数据处理复杂度. 本文采用TX2嵌入式开发板和VLP-16激光雷达, 属于低成本开发应用平台. 将三维识别问题转换为一系列的二维检测问题^[14-15], 降低了算法复杂度, 稳定了系统性能. 基于三维激光雷达的目标检测方法大多使用俯视图进行目标信息提取, 俯视图信息更完整, 但前视图信息更可靠. 本文对前置激光雷达的点云数据进行目标检测, 由于本实验平台具有车道线检测模块, 自动驾驶汽车不会离开道路车辆行驶区域, 所以检测目标限定为道路上的障碍物, 包括车辆、自行车和行人, 称为有效障碍物, 而道路边上的绿化带、路灯、树等称为无效障碍物.

本文提出一种基于DST (dempster-shafer theory) 融合多视图模糊推理赋值的三维目标检测方法. 在体素地图的前视图中, 根据目标的距离和高度信息对所属体素进行模糊推理赋值; 在俯视图中, 根据目标大小特征对所属体素进行模糊推理赋值, 由此得到不同视图下某体素属于有效障碍物的两个基本概率赋

值. 为融合两视图信息, 本文通过DST算法组合基本概率赋值以判别有效障碍物, 从而实现了对有效障碍物的分割, 并得到各目标方盒模型参数.

1 体素地图构建及路面分割

本文采用三维16线velodyne激光雷达, 简称VLP-16, 其16线均匀分布在 $\pm 15^\circ$ 的范围内, 如果激光雷达的安装位置太高, 则浪费了上8线; 若是太低, 则下8线的检测范围有限. 由于自主研发的自动驾驶汽车车身较高, 不适合安装在车顶, 因此将其安装在车前用于检测前方障碍物.

对VLP-16激光雷达扫描的原始数据进行解析, 构建体素地图并进行路面分割, 得到前、俯视图. 在两视图中根据不同的模糊推理规则对某体素属于目标的程度进行基本概率赋值, 并通过DST算法融合判别目标, 精确分割目标从而得到方盒模型参数, 封装成目标传输协议并发送到上位机(工控平台). 基于DST融合多视图模糊推理赋值的三维目标检测框图如图1所示.

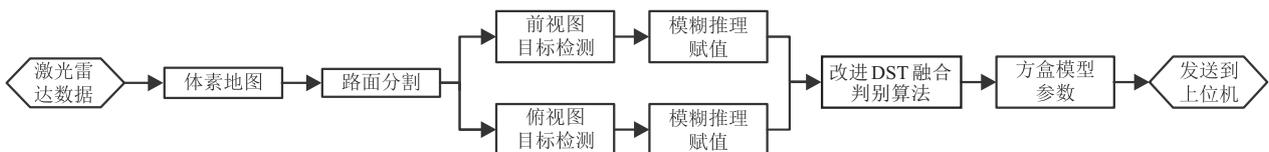


图1 基于DST融合多视图模糊推理赋值的三维目标检测框图

1.1 体素地图的构建

本文将激光雷达数据转换为体素地图, 再根据体素地图进行路面分割和目标检测, 其中体素越小分辨率越高, 也越平滑. 根据激光雷达安装位置及扫描特性, 本文选择自动驾驶汽车前方20m、左右10m、高3m作为感兴趣区域. VLP-16发送到TX2的原始数据是以激光雷达为原点的球坐标系(方位角 α 、俯仰角 ω 和距离 R), 将原始数据转换为三维直角坐标, 但此时的三维直角坐标是激光雷达坐标系下的, 无法直接用于自动驾驶汽车的避障, 需要将激光雷达坐标系转换到车体坐标系, 车体坐标系是以车辆后轴中心为原点的三维直角坐标系. 激光雷达和车体位置关系示意图如图2所示.

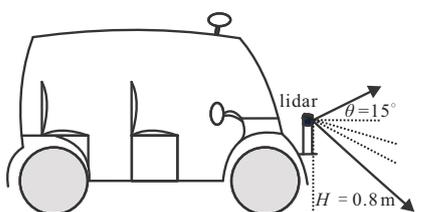


图2 激光雷达和车体位置关系

激光雷达的正前方是 Y_{lidar} , 正右方是 X_{lidar} , 正上方是 Z_{lidar} . 在车体坐标系下, 同样车辆正前方是 Y_{car} , 正右方是 X_{car} , 正上方是 Z_{car} . 由于雷达水平安装在车体的正前方, 只需得到其平移矩阵即可. 激光雷达坐标系转换到车体坐标系见下式:

$$P_{\text{lidar}} = \begin{bmatrix} R \times \cos \omega \times \sin \alpha \\ R \times \cos \omega \times \cos \alpha \\ R \times \sin \alpha \end{bmatrix}, \quad (1)$$

$$P_{\text{car}} = P_{\text{lidar}} + \begin{bmatrix} \text{der } Y \\ \text{der } X \\ \text{der } Z \end{bmatrix}. \quad (2)$$

其中: P_{lidar} 表示点 P 在激光雷达坐标系内的坐标, P_{car} 表示点 P 在车体坐标系内的坐标, $[\text{der } Y, \text{der } X, \text{der } Z]^T$ 为平移矩阵.

建立三维体素地图, 在车体坐标系加上三维平移增量 $[\text{map}_y, \text{map}_x, \text{map}_z]^T$ 使得所有坐标值转正, 并除以体素单位 d 转换为体素坐标, 见下式:

$$P_{\text{map}} = \begin{bmatrix} Y_{\text{map}} \\ X_{\text{map}} \\ Z_{\text{map}} \end{bmatrix} = \left(P_{\text{car}} + \begin{bmatrix} \text{map}_y \\ \text{map}_x \\ \text{map}_z \end{bmatrix} \right) / d. \quad (3)$$

其中: P_{map} 表示体素坐标; $d = 5 \text{ cm}$, 即体素大小为 $5 \text{ cm} \times 5 \text{ cm} \times 5 \text{ cm}$. 三维体素地图尺寸为 $400 \times 400 \times 60$, 自动驾驶车的中心在体素地图中的位置是 $[\text{map}_y, \text{map}_x, \text{map}_z]^T / d$.

1.2 路面分割

在体素地图中,有一部分是表征地面的体素. 这些代表地面的体素,并不存在障碍物,且在后续有效障碍物判别中会成为噪点,干扰判别效果,因此本文采用最大最小值高度图的方法对点云数据进行路面分割. 因为单个体素较小,其中包含的点较少,特征不明显,所以在遍历体素时,将相邻4个体素组合成一个大体素,并计算大体素中点的高度的最大值 H_{max} 和最小值 H_{min} ,然后将 H_{max} 与 H_{min} 之差大于阈值 θ 的4个体素均标记为非路面体素,将差值小于 θ 的4个体素均标记为路面体素. 对于任一像素 $(Y_{\text{map}}, X_{\text{map}}, Z_{\text{map}})$,若为非路面体素,则 $T(Y_{\text{map}}, X_{\text{map}}, Z_{\text{map}}) = 1$;若为路面体素,则 $T(Y_{\text{map}}, X_{\text{map}}, Z_{\text{map}}) = 0$. 路面分割前后的对比如图3所示,图3(a)是未进行路面分割的原始图像,图3(b)是用此方法进行路面分割后的俯视图投影.

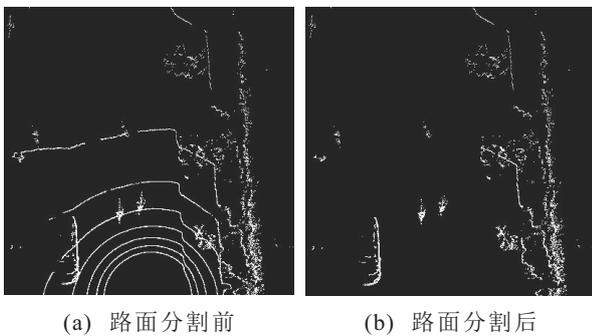


图3 路面分割前后对比

2 DST融合多视图模糊推理赋值

2.1 前视图目标模糊推理赋值

将经过路面分割的体素地图投影为前视图,以体素地图的 $X_{\text{map}} - Z_{\text{map}}$ 为前视图平面直角坐标系的两轴,体素坐标与前视图像素坐标转换公式如下所示:

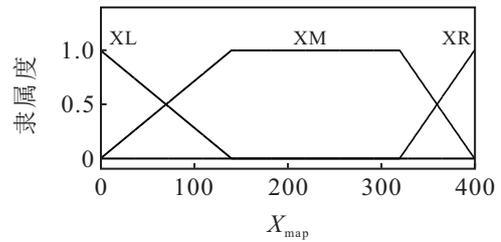
$$P_{\text{front}} = (\text{Col}_{\text{front}}, \text{Row}_{\text{front}}) = (X_{\text{map}}, Z_{\text{map}}), \quad (4)$$

$$\text{PIXEL}_{\text{front}}(\text{Col}_{\text{front}}, \text{Row}_{\text{front}}) = 255 \times (X_{\text{map}}, Z_{\text{map}}). \quad (5)$$

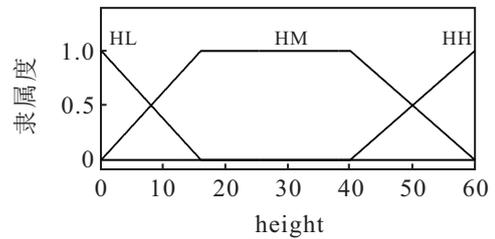
其中: P_{front} 表示前视图像素点, $\text{Col}_{\text{front}}$ 表示前视图图像横坐标, $\text{Row}_{\text{front}}$ 表示前视图图像纵坐标, $\text{PIXEL}_{\text{front}}$ 表示前视图像素值, $T(X_{\text{map}}, Z_{\text{map}})$ 表示是否为路面

点.

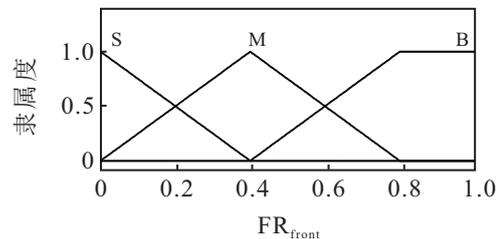
在前视图进行聚类分割后,根据道路目标实测经验对前视图中的矩形轮廓进行模糊推理^[16-17],前视图模糊推理系统有两个输入 $\{X_{\text{map}}, \text{height}\}$,前者表示矩形轮廓几何中心的横坐标,后者表示矩形轮廓的几何高度.有一个输出 $\{\text{FR}_{\text{front}}\}$,表示该矩形轮廓是有效障碍物程度的模糊推理输出. 前视图输入/输出隶属度函数如图4所示,模糊推理规则如表1所示.



(a) X_{map} 对应隶属度函数



(b) height 对应隶属度函数



(c) FR_{front} 对应隶属度函数

图4 前视图输入/输出隶属度函数

表1 前视图模糊推理规则表

height	X_{map}		
	XL	XM	XR
HL	S	B	S
HM	M	B	M
HH	S	B	S

模糊系统的输出为各条规则推理结果的并集,采用最大隶属度法进行反模糊化,得到矩形为有效障碍物的概率,每个矩形包含的体素均有相同的概率,计算公式如下:

$$G_{\text{front}}(j) = \text{FR}(i), \quad j = 1, 2, \dots, n, \quad i = 1, 2, \dots, m. \quad (6)$$

其中: $\text{FR}(i)$ 表示第 i 个矩形是有效障碍物的程度,共有 m 个矩形; $G_{\text{front}}(j)$ 表示第 j 个体素在前视图中属于有效障碍物的程度,共有 n 个体素.

2.2 俯视图目标模糊推理赋值

以体素地图 $X_{map} - Y_{map}$ 为俯视图平面直角坐标系两轴,体素坐标与俯视图像素坐标转换见下式:

$$P_{top} = (Col_{top}, RCol_{top}) = (X_{map}, Y_{map}), \quad (7)$$

$$PIXEL_{top}(Col_{top}, Row_{top}) = 255 \times (X_{map}, Y_{map}). \quad (8)$$

其中: P_{top} 表示俯视图像素点, Col_{top} 表示俯视图图像横坐标, $RCol_{top}$ 表示俯视图图像纵坐标, $PIXEL_{top}$ 表示俯视图像素值, $T(X_{map}, Y_{map})$ 表示是否为路面点.

俯视图更能完整地呈现前方道路的情况,也更加直观.在俯视图中判断有效障碍物,可以有更精细的模糊规则.俯视图模糊推理系统有两个输入 $\{length, width\}$,表示矩形轮廓的长度和宽度,有一个输出 $\{TP_{top}\}$,表示该矩形轮廓是有效障碍物程度的模糊推理输出.俯视图输入/输出隶属度函数如图5所示,模糊推理规则如表2所示.

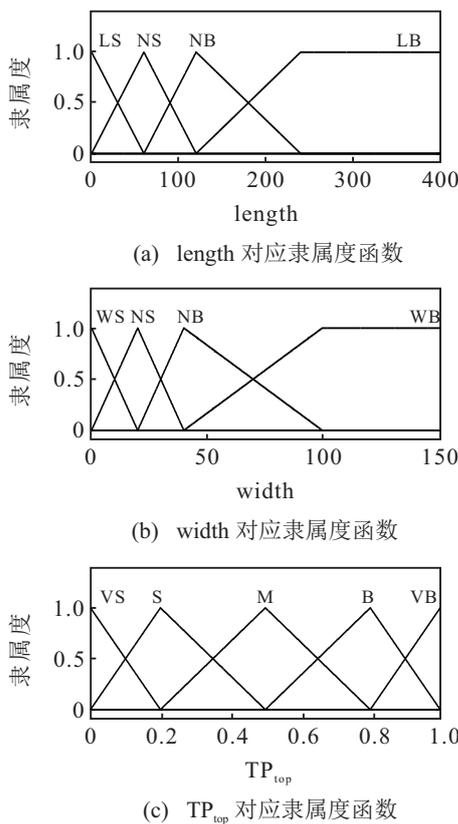


图5 俯视图输入/输出隶属度函数

表2 俯视图模糊规则表

width	length			
	LS	NS	NB	LB
WS	VB	M	S	S
NS	B	B	M	S
NB	M	M	B	VS
WB	S	S	VS	VS

同2.1节,得到每个体素属于有效障碍物的概率,计算公式如下:

$$G_{top}(j) = TP(i), \quad j = 1, 2, \dots, n, i = 1, 2, \dots, m. \quad (9)$$

其中: $TP(i)$ 表示第 i 个矩形是有效障碍物的程度, $G_{top}(j)$ 表示第 j 个体素在俯视图中属于有效障碍物的程度.

2.3 基于DST的多视图信息融合

证据理论由Dempster提出,并由Shafer扩充和发展,也称为D-S证据理论,缩写为DST.这是一种信息融合算法,可以解决信息融合过程中,由于模糊状态所产生的不确定性、传感器数据和环境数据之间的部分误差^[18-20].由于DST算法的基本概率赋值难以确定,不同的赋值情况使得融合结果不同,因此本文将上述模糊推理所得的 G_{front} 和 G_{top} 作为基本概率赋值,融合后判别该体素是否属于有效障碍物.

用 Y (yes) 表示某体素属于有效障碍物, N (no) 表示某体素不属于有效障碍物, U (unkown) 表示不确定.可设 $m(N)$ 表示某体素不属于有效障碍物的基本概率赋值, $m(Y)$ 表示某体素存在障碍物的基本概率赋值, $m(U)$ 表示某体素不确定状态的基本概率赋值.存在目标识别框架 $U = \{Y, N\}$, 幂集为 $2^U = \{\emptyset, T, N, U = \{Y, N\}\}$, 其中空集的基本概率赋值为零,所有可能的基本概率赋值之和为1,如下式:

$$\begin{cases} m(\emptyset) = 0; \\ m(\emptyset) + m(Y) + m(N) + m(U) = 1. \end{cases} \quad (10)$$

在前视图和俯视图的模糊推理中所得的基本概率赋值均可能为1,产生组合冲突,所以对所有基本概率赋值均减去一无穷小正数的方法来进行近似处理,避免组合冲突,如下式:

$$\begin{cases} m_1(\emptyset) = 0, \\ m_1(Y) = G_{front} - 2 \times \varepsilon_1, \\ m_1(N) = 1 - G_{front} + \varepsilon_1, \\ m_1(U) = \varepsilon_1; \end{cases} \quad (11)$$

$$\begin{cases} m_2(\emptyset) = 0, \\ m_2(Y) = G_{top} - 2 \times \varepsilon_1, \\ m_2(N) = 1 - G_{top} + \varepsilon_1, \\ m_2(U) = \varepsilon_1. \end{cases} \quad (12)$$

其中 $\varepsilon_1 = 0.005$.

经此处理后,结合具体数据情况计算融合后的基本概率赋值见下式:

$$\begin{cases} m_2(\emptyset) = 0, \\ K = m_1(N)m_2(Y) + m_1(Y)m_2(N), \\ m(Y) = \frac{m_1(Y)m_2(Y) + m_1(Y)m_2(U) + m_1(U)m_2(Y)}{1 - K}, \\ m(N) = \frac{m_1(N)m_2(N) + m_1(N)m_2(U) + m_1(U)m_2(N)}{1 - K}, \\ m(U) = 1 - m(Y) - m(N). \end{cases} \quad (13)$$

对于组合后的基本概率赋值进行判决. 设定判决门限 $\varepsilon_2 = \varepsilon_3 = 0.1$, 若满足

$$\begin{cases} m(Y) - m(N) > \varepsilon_2, \\ m(U) < \varepsilon_3, \\ m(Y) > m(U), \end{cases} \quad (14)$$

则判定该体素属于有效障碍物, 其判定结果为Y. 若满足

$$\begin{cases} m(N) - m(Y) > \varepsilon_2, \\ m(U) < \varepsilon_3, \\ m(N) > m(U), \end{cases} \quad (15)$$

则判定该体素不属于有效障碍物, 其判定结果为N. 其余状态则无法判定该体素是否属于有效障碍物, 判定结果均为U. 保留判定结果为Y或U的体素.

2.4 获取方盒模型参数

在经过信息融合后的点云体素地图中进行聚类分割后, 得到能将目标障碍物包围起来的最小长方体大小和其左上角体素坐标, 建立长方体列表 CuboidLists, 其中的每一个长方体均包含6个属性: 长宽高和几何左上角三维坐标, 即 [CuboidLists_{length}, CuboidLists_{width}, CuboidLists_{height}], [CuboidLists_y, CuboidLists_x, CuboidLists_z], 需要与俯视图和前视图中的矩形进行匹配与校正, 建立俯视图矩形轮廓列表 TopRectLists 和前视图矩形轮廓列表 FrontRectLists. 设在车体坐标系下方盒模型的大小为 [Box_{length}, Box_{width}, Box_{height}], 单位 cm, 通过下式转化得到方盒模型的长、宽和高:

$$\begin{bmatrix} \text{Box}_{\text{length}} \\ \text{Box}_{\text{width}} \\ \text{Box}_{\text{height}} \end{bmatrix} = d \times \begin{bmatrix} \text{CuboidLists}_{\text{length}} \\ \text{CuboidLists}_{\text{width}} \\ \text{CuboidLists}_{\text{height}} \end{bmatrix}. \quad (16)$$

设方盒模型的几何中心坐标为 [Box_{CenterY}, Box_{CenterX}, Box_{CenterZ}], 在体素地图中 CuboidLists_z 即是 CuboidLists_{height}, 计算转化关系见下式:

$$\begin{bmatrix} \text{Box}_{\text{CenterY}} \\ \text{Box}_{\text{CenterX}} \\ \text{Box}_{\text{CenterZ}} \end{bmatrix} = d \times \left(\begin{bmatrix} \text{CuboidLists}_y \\ \text{CuboidLists}_x \\ 0 \end{bmatrix} + \begin{bmatrix} \text{CuboidLists}_{\text{length}} \\ \text{CuboidLists}_{\text{width}} \\ \text{CuboidLists}_{\text{height}} \end{bmatrix} \div 2 \right). \quad (17)$$

警示位在警示范围内有危险目标时会置为0F, 方便上位机在未进行路径规划时得到警示. 伪代码见算法1.

算法1 获取方盒模型参数.

输入: CuboidLists, TopRectLists, FrontRectLists;

输出: 方盒模型参数.

匹配各列表图形;

for $i = 0; i \leq \text{CuboidLists.end}(); i++$ do

 if CuboidLists(i) 与 TopRectLists(i) 的 x, y 值重合率小于 0.9 then

 CuboidLists(i).length = (CuboidLists(i).length + TopRectLists(i).length) / 2;
 CuboidLists(i).width = (CuboidLists(i).width + TopRectLists(i).width) / 2;

 end

 if CuboidLists(i) 与 FrontRectLists(i) 的 x, z 值重合率小于 0.9 then

 CuboidLists(i).width = (CuboidLists(i).width + FrontRectLists(i).width) / 2;
 CuboidLists(i).height = (CuboidLists(i).height + FrontRectLists(i).height) / 2;

 end

end

CuboidLists 的长宽高转化为车体坐标系量纲, 并计算其几何中心坐标;

if (CenterY < 8.5) || ((-2.5 ≤ CenterX) && (CenterX ≤ 2.5)) then

 警示位置为 0F;

else

 警示为置为 00;

end

将得到的方盒模型参数通过目标传输协议发送给上位机, TX2 和工控平台之间的目标传输协议如图 6 所示, 协议中包括帧头、扫描此帧的时间戳、警示位、

方盒模型的几何中心坐标、方盒模型大小以及帧尾。

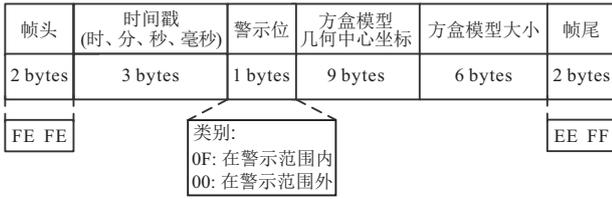
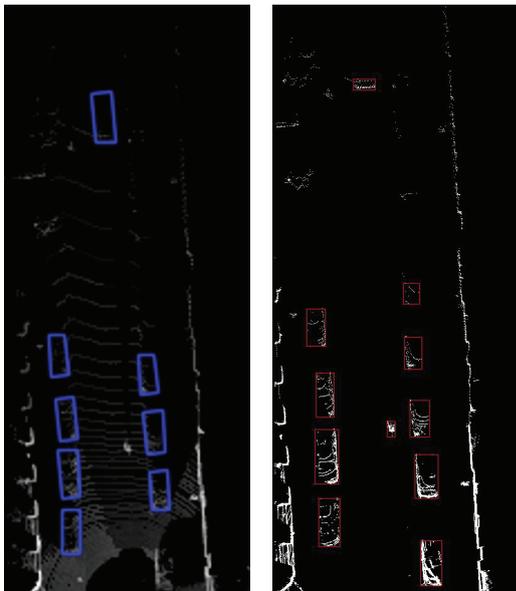


图6 TX2和工控平台之间的目标传输协议

3 实验结果与分析

3.1 在KITTI数据集上测试

在Jetson TX2平台上,基于KITTI数据集(简单难度)就本文所提方法与文献[1]的MV3D(BV+FV)方法进行对比,该方法仅用LIDAR数据作为输入,与本文方法输入数据一致.另外,为了便于本文方法与MV3D(BV+FV)方法在同样条件下对比,本文选择前方100米为有效检测范围.其中一帧检测结果如图7所示.



(a) MV3D(BV+FV) (b) 本文方法

图7 本文方法与MV3D(BV+FV)方法的结果对比

对比图7(a)和图7(b)可以看出,MV3D(BV+FV)方法相比本文方法对车辆轮廓检测更加完整,特别是当检测目标较远时,优势更为明显.对比发现,在目标检测数量上,本文方法明显优于MV3D(BV+FV)方法,在自动驾驶应用上更具优势.在TX2平台最优性能条件下,对比本文方法与MV3D(BV+FV)方法的车辆检测准确率和单帧运算时间如表3所示.本文方法检测目标的数量略高于MV3D(BV+FV)方法,因此本文方法的车辆检测率略好;本文方法的运算时间明显优于MV3D(BV+FV)方法,更符合自动驾驶系统中的实时性要求.

表3 车辆检测准确率和单帧运算时间对比

方法	车辆检测准确率/%	单帧运算时间/ms
MV3D(BV+FV)	87.00	399.00
本文方法	88.54	174.60

3.2 道路实际测试

本实验所用的自主研发自动驾驶汽车如图8所示,整体实验平台的系统框图如图9所示,主要包括车辆控制系统、路径规划系统和环境感知系统.本方法属于环境感知系统的目标检测部分,图9中白色部分表明信息交流情况:激光雷达VLP-16通过以太网发送数据包给Jetson TX2, TX2解析并检测目标,将目标信息通过以太网发送给工控平台.



图8 自主研发的自动驾驶车

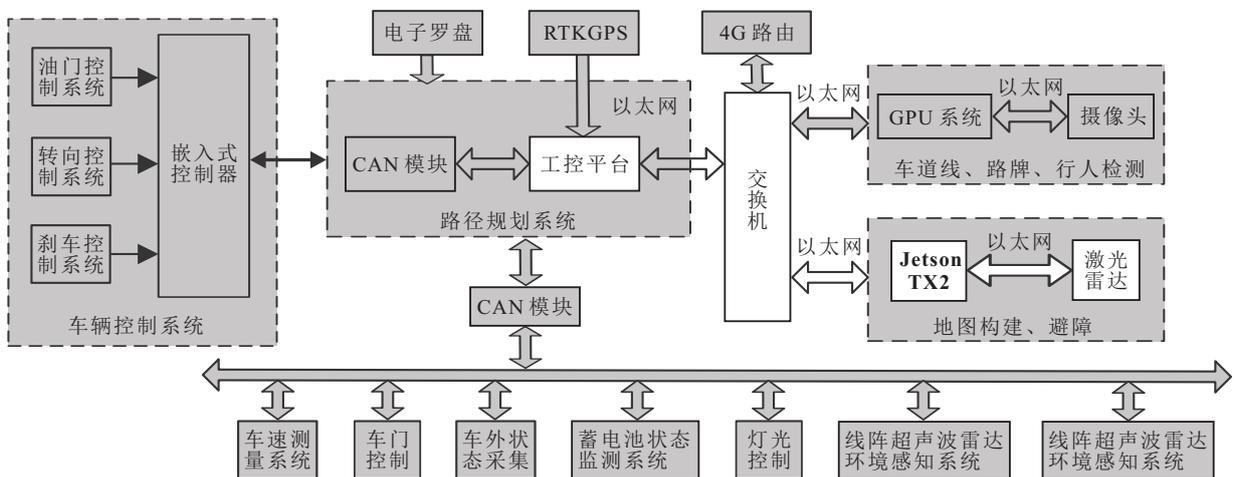


图9 整体实验平台的系统框图

在校内路段进行实车测试,校内测试路段为双向四车道且两边有人行道,具有完整性和普适性.在道路实测中,本文选择自动驾驶汽车前方20m、左右10m和高3m作为有效区域.在道路上的有效障碍物不仅只是车辆,还有自行车和行人等.前视图模糊推理前后检测结果对比如图10所示,图10(a)为模糊推理前,用检测框标记出了所有物体;图10(b)为模糊推理后的前视图检测结果.其中图右边人行道上的树和灌木因为高度不符合推理结果,属于无效障碍物,没有用检测框标记出来.

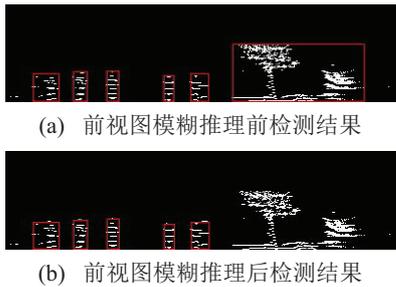
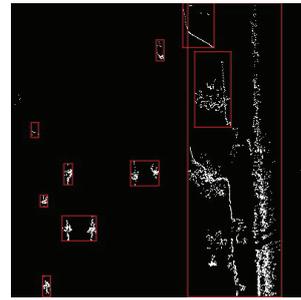


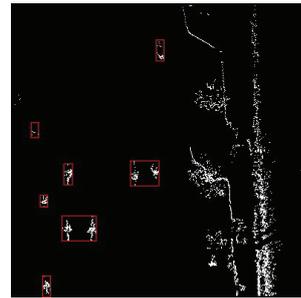
图10 前视图模糊推理前后检测结果对比

俯视图模糊推理前后检测结果对比如图11所示,图11(a)是模糊推理前,图11(b)是模糊推理后俯视

图检测结果.其中图右边人行道上的树和灌木因为长度和宽度均不符合推理结果,属于无效障碍物,但是图中还存在欠分割的情况.



(a) 俯视图模糊推理前检测结果



(b) 俯视图模糊推理后检测结果

图11 俯视图模糊推理前后检测结果对比

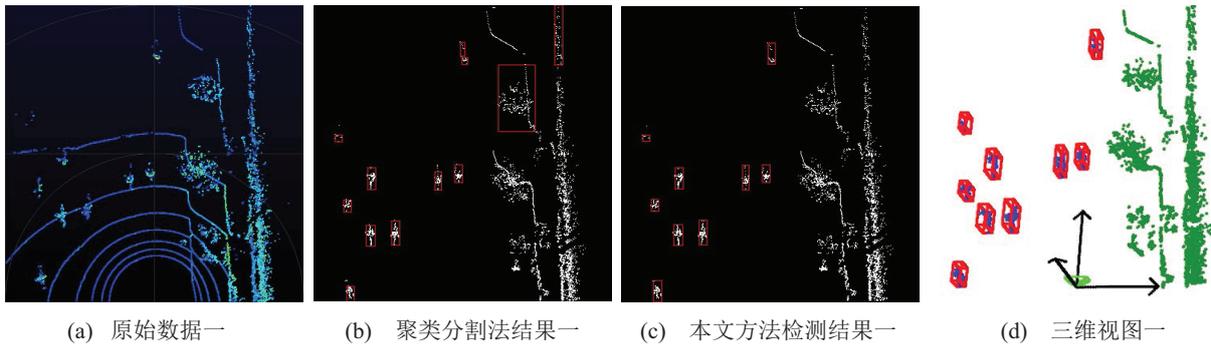


图12 多视图融合检测结果对比一

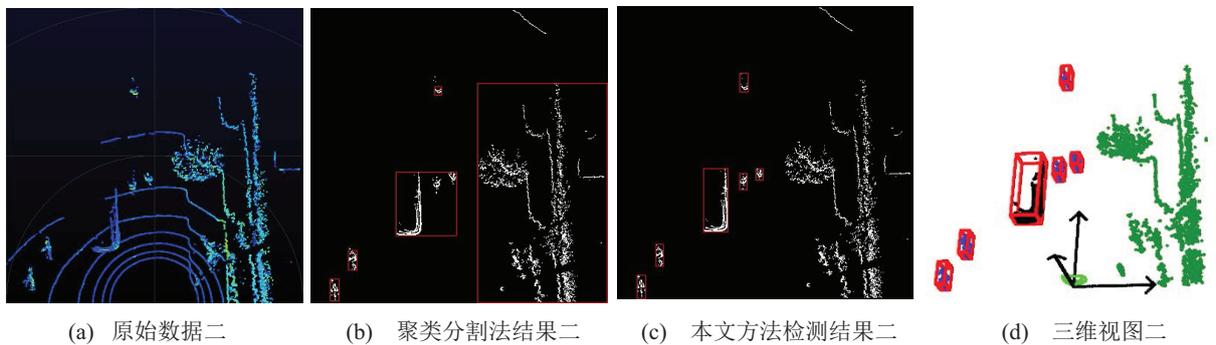


图13 多视图融合检测结果对比二

多视图融合检测结果与聚类分割法对比如图12和图13所示,聚类分割法仅利用俯视图进行检测.图12(a)和图13(a)是激光雷达扫描的原始数据.图12(b)和图13(b)是进行聚类分割法的检测结果,图12(b)中存在过分割问题,图13(b)中存在严重的欠分割问

题,且均存在检测到无效障碍物的情况.图12(c)和图13(c)是多视图信息融合后的检测结果,分割准确无欠分割问题,检测结果均为道路上的有效障碍物.本文方法与直接聚类分割相比检测更加准确,减少了过、欠分割问题,并在一定程度上对有效障碍物进行

判别,为决策系统甄别障碍物进行了预筛选.图12(d)和图13(d)是使用本文方法检测结果的三维视图,与原始数据相比,在滤除地面点后准确检测到目标,证明本文方法拥有较好的准确性.本文方法与聚类分割法的检测准确率和在TX2上单帧运算时间如表4所示.准确率是指一帧检测结果中有效障碍物个数与障碍物总数之比.本文方法的准确率明显高于聚类分割法,单帧运算时间稍多于聚类分割法.本文方法单帧运算时间满足自动驾驶车的避障需求.

表4 本文方法与聚类分割法的准确率和单帧运算时间对比

方法	准确率/%	单帧运算时间/ms
聚类分割法	72.82	106.57
本文方法	93.33	119.85

本文对3段不同道路情况进行实时统计分析,每段道路取连续300帧的准确率如图14所示.其中:图14(a)路段一的道路情况良好,车速较慢(10~15 km/h),图14(b)路段二的道路情况较为拥挤,车速较慢(10~15 km/h),图14(c)路段三道路情况良好,车速较快(20~25 km/h).本文方法在实际检测过程中的平均准确率为0.949%.

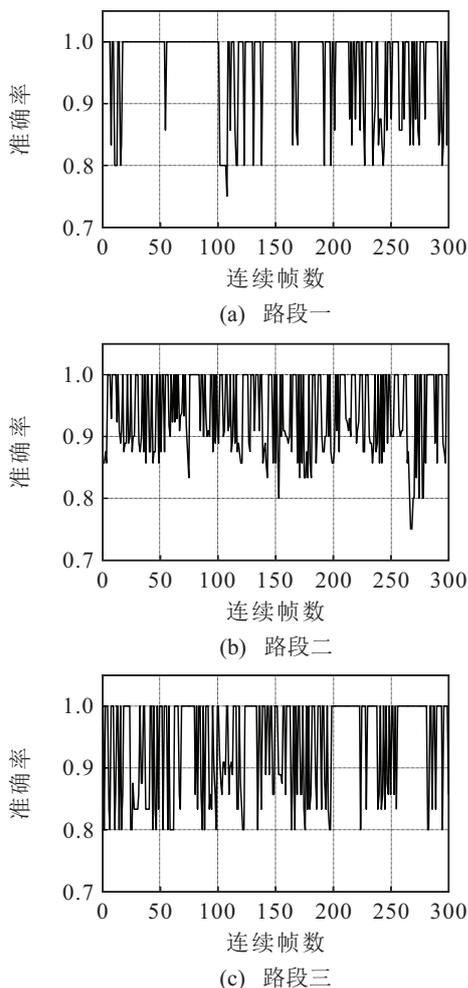


图14 3种道路情况连续帧数目标检测准确率对比

激光雷达数据扫描频率为5 Hz,每段道路连续300帧数据串行接收处理时间如表5所示.按照最大平均330.9 ms,速度最大25 km/h计算,平均每个周期行进3.3 m左右,考虑到自动驾驶车辆制动的的时间和距离以及危险目标的速度等情况,警示范围为自动驾驶车辆前方8.5 m或其中轴线的左右2.5 m. TX2嵌入式开发板开始从VLP-16激光雷达接收一帧数据到将方盒模型参数发送给上位机平均用时124.13 ms.其中,算法运行用时/帧等于平均时间减去扫描时间(200 ms),算法平均运行用时124.13 ms.

表5 激光雷达数据接收及处理时间

路段	帧数	总用时/s	平均用时/(帧/ms)	算法用时/(帧/ms)
路段一	300	95.584	318.6	118.6
路段二	300	99.287	330.9	130.9
路段三	300	96.897	322.9	122.9
平均	300	97.256	324.1	124.1

4 结论

本文基于TX2嵌入式开发板和VLP-16激光雷达的低成本应用平台,提出一种自动驾驶汽车前方三维目标检测方法.在道路上靠近自动驾驶汽车的车辆、自行车以及行人都是有效障碍物.根据两种视图的特点,结合模糊推理和DST进行道路有效障碍物判别,在一定程度上为上位机甄别障碍物进行了预筛选.将三维识别问题转换为一系列的二维检测问题,降低了数据处理复杂度,稳定了系统性能.本文方法基于TX2在KITTI数据集上进行测试,对比验证了本文方法的实时性.将本文方法应用在自主研发的自动驾驶汽车上,在校园路段进行了大量试验,验证了方法的有效性和可靠性.但是随着自动驾驶汽车行驶速度的提高,某些检测目标可能仅有一部分出现在体素地图中,此时其矩形轮廓并不完全符合模糊推理规则,使得目标检测准确率降低,因此需进一步研究完善模糊推理规则,提高目标检测的准确率.

参考文献(References)

- [1] Chen X Z, Ma H, Wan J. Multi-view 3D object detection network for autonomous driving[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6526-6534.
- [2] Cai Z, Fan Q, Feris R S. A unified multi-scale deep convolutional neural network for fast object detection[C]. Lecture Notes in Computer Science. Amsterdam: ECCV, 2016: 354-370.
- [3] Chen J, Cho Y K, Kira Z. Multi-view incremental segmentation of 3D point clouds for mobile robots[J]. IEEE Robotics and Automation Letters, 2019, 4(2):

- 1240-1246.
- [4] Ku J, Mozifian M, Lee J, et al. Joint 3D proposal generation and object detection from view aggregation[J]. IEEE International Conference on Intelligent Robots and Systems. Madrid: IEEE, 2017: 5750-5757.
- [5] Qi C R, Liu W, Wu C. Frustum pointNets for 3D object detection from RGB-D data[C]. IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2017: 918-927.
- [6] Song W, Zou S, Tian Y. Classifying 3D objects in LiDAR point clouds with a back-propagation neural network[J]. Human-centric Computing and Information Sciences, 2018, 8(1): 29.
- [7] Du X, Ang M H, Karaman S. A general pipeline for 3D detection of vehicles[C]. IEEE International Conference on Robotics and Automation(ICRA). Montreal: IEEE, 2018: 3194-3200.
- [8] Takabe A, Takehara H, Kawai N. Moving object detection from a point cloud using photometric and depth consistencies[C]. The 23rd International Conference on Pattern Recognition. Cancun: IEEE, 2016: 561-566.
- [9] Fehr D, Beksi W J, Zermas D. Covariance based point cloud descriptors for object detection and recognition[J]. Computer Vision & Image Understanding, 2016, 142: 80-93.
- [10] Hu F C. A combined clustering and image mapping based point cloud segmentation for 3D object detection[C]. Proceedings of the 30th Chinese Control and Decision Conference. Shenyang: IEEE, 2018: 1664-1669.
- [11] Huang J, You S. Pole-like object detection and classification from urban point clouds[C]. 2015 IEEE International Conference on Robotics and Automation (ICRA). Seattle: IEEE, 2015: 3032-3038.
- [12] Borcs A, Nagy B, Benedek C. Instant object detection in lidar point clouds[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7): 992-996.
- [13] Pang G, Neumann U. 3D point cloud object detection with multi-view convolutional neural network[C]. International Conference on Pattern Recognition. Cancun: IEEE, 2016: 585-590.
- [14] Lertniphonphan K, Komorita S, Tasaka K. 2D to 3D label propagation for object detection in point cloud[C]. IEEE International Conference on Multimedia and Expo Workshops. San Diego: IEEE, 2018: 1-6.
- [15] Pang G, Neumann U. Fast and robust multi-view 3D object recognition in point clouds[C]. 2015 International Conference on 3D Vision. Lyon: IEEE, 2015: 171-179.
- [16] Chien J C, Lee J D, Chen C M. An integrated driver warning system for driver and pedestrian safety[J]. Applied Soft Computing, 2013, 13(11): 4413-4427.
- [17] Kapitanova K, Son S H, Kang K D. Using fuzzy logic for robust event detection in wireless sensor networks[J]. Ad Hoc Networks, 2012, 10(4): 709-722.
- [18] Cao H, Sun H, Jia Q, et al. Laser-scanner grid map building based on Dempster-Shafer evidence theory[C]. 2009 International Conference on Mechatronics and Automation. Changchun: IEEE Computer Society, 2009: 4930-4935.
- [19] Cao H, Sun H, Jia Q, et al. Multi-ultrasonic-sensor grid map building based on D-S evidence theory[C]. International Conference on Information and Automation. Changchun: IEEE, 2009: 910-915.
- [20] Mustafa M, Biswajeet P, Hossein R. Improving landslide detection from airborne laser scanning data using optimized Dempster - Shafer[J]. Remote Sensing, 2018, 10(7): 1029.

作者简介

张翠芳(1961—), 女, 教授, 博士, 从事信号与信息处理、非线性系统的神经网络辨识与控制等研究, E-mail: cfzhang_scce@home.swjtu.edu.cn;

李成文利(1995—), 女, 硕士生, 从事激光雷达目标检测与识别的研究, E-mail: swjtu_lcw1@qq.com;

邹应全(1976—), 男, 副教授, 博士, 从事工程类技术研究与开发、传感器技术等研究, E-mail: zouyingq@home.swjtu.edu.cn;

金楠(1993—), 男, 硕士, 从事智能控制理论及其应用的研究, E-mail: 2214061996@qq.com.

(责任编辑: 齐 霖)