

文章编号: 2095-2163(2024)01-0156-07

中图分类号: TP301.6

文献标志码: A

道路场景下毫米波雷达点云聚类处理算法

陈奕龙, 王青春

(北京林业大学 工学院, 北京 100083)

摘要: 毫米波雷达具有体积小、分辨率高,可在风、雨、雾等恶劣条件下工作的优点,但由于场景的复杂性在实际工作中会出现点云过分割、虚警等问题。因此,本文提出一种基于马氏距离与欧氏距离结合的自适应 DBSCAN 聚类算法,依据点云的距离选取相似度度量方法,在密度较大处选择马氏距离,在密度较小处选择欧氏距离,依据“属于同一目标点云,位置、速度、强度接近”这一规律进行筛选。聚类完成后,采用非参数核密度估计算法获取点簇内点云密度,根据点云分布特点估计目标位置,并依据最小二乘法完成多普勒速度分解,估计目标横纵向速度。最后,通过实际道路场景(隧道、公路)测试数据对本文算法的可靠性与稳定性进行验证。

关键词: 毫米波雷达; 聚类算法; 核密度估计

A clustering algorithm for millimeter wave radar point cloud in road scenarios

CHEN Yilong, WANG Qingchun

(School of Technology, Beijing Forestry University, Beijing 100083, China)

Abstract: Millimeter-wave radar has the advantages of small size, high resolution, and can work in bad conditions such as wind, rain, fog, etc. However, due to the complexity of the scene in practice, there will be problems such as over-segmentation of the point cloud and false alarms. Therefore, this paper proposes an adaptive DBSCAN clustering algorithm based on the combination of Mahalanobis distance and Euclidean distance, selecting the similarity measure based on the distance of the point cloud, choosing the Mahalanobis distance at the higher density, choosing the Euclidean distance at the lower density, and selecting the clustering algorithm based on the rule of "belonging to the same target cloud, with the location, speed, and intensity close to each other". The clusters are filtered according to the rule of "belonging to the same target cloud, location, speed, and intensity are close". After the clustering is completed, a nonparametric kernel density estimation algorithm is used to obtain the density of point clouds within the cluster, estimate the target position according to the distribution characteristics of the point clouds, and complete the Doppler velocity decomposition according to the least-squares method to estimate the target transverse and longitudinal velocities. Finally, the reliability and stability of this paper's algorithm is verified by the test data of actual road scenes (tunnel and highway).

Key words: millimeter wave radar; clustering algorithm; kernel density estimation

0 引言

对于自动驾驶车辆行驶过程中依赖于对环境的准确和详细的感知^[1],摄像头、激光雷达和毫米波雷达是最常用的交通传感器^[2]。毫米波雷达与摄像头和激光雷达传感器相比,在探测距离和抗干扰能力上更有优势,在不同亮度和天气条件下,即使在雾、雨、雪等恶劣天气下也能很好地工作^[3-4]。此外,毫米波雷达通过信号处理可以准确提取目标的距离、速度和角度信息^[5]。

目前,77-81 GHz 频段的毫米波雷达可实现 4 cm 的距离分辨率^[6],可用于行人检测和目标分类。这种毫米波雷达可以实时接收大量原始数据,包括来自移动目标(车辆、摩托车、行人等)和静止物体(路面、护栏、树木、建筑物等)的雷达回波。由于毫米波雷达可以很容易地在近距离内采集到不同目标的回波,因此在特征提取之前对多目标识别问题进行雷达数据分割操作是必要的,且具有挑战性和复杂性。

在数据聚类和分割领域, DBSCAN (Density

作者简介: 陈奕龙(1999-),男,硕士研究生,主要研究方向:智能驾驶。

通讯作者: 王青春(1969-),男,博士,教授,主要研究方向:智能设备、电动汽车驱动电机及控制器技术研究。Email: wangqingchun@bjfu.edu.cn

收稿日期: 2023-07-06

哈尔滨工业大学主办 ◆ 专题设计与应用

Based Spatial Clustering of Applications with Noise)^[7] 被广泛应用。Sun^[8] 在视频分析中提出了一种基于 DBSCAN 的车辆计数方法。Lim^[9] 提出了一种利用 DBSCAN 对汽车雷达系统中检测到的目标进行聚类的方法。Wagner^[10] 提出了对 DBSCAN 算法的修改, 以便于用汽车雷达系统检测行人。虽然 DBSCAN 是汽车雷达系统中最常用的数据分割算法, 但该算法对于输入参数敏感, 若选取不当, 将造成聚类质量下降。由于在 DBSCAN 算法中变量 ε 、MinPts 是全局唯一的, 当空间聚类的密度不均匀时, 聚类质量较差。同时, DBSCAN 算法采用欧式距离度量数据间相似度, 忽略了各个指标属性与量纲不同的问题。

对于车载毫米波雷达, 可用于实现自适应巡航控制 (ACC) 和自动紧急制动 (AEB) 等功能。实现这些功能的前提是获取目标在雷达视场 (FOV) 中的准确位置与速度。聚类后, 雷达获取到不同车辆的点云簇, 如何通过一簇点云的信息确定该车的实际位置与速度也是亟待解决的聚类问题。

基于上述分析, 本文提出了一种基于马氏距离与欧氏距离结合的自适应 DBSCAN 算法, 对检测到的目标点云进行聚类, 并对聚类后目标簇内的点云信息进行后处理, 估计目标的速度与位置信息。该方法将具有相似位置信息的目标分组到几个簇中。由于毫米波雷达的工作特性, 得到的速度为多普勒速度 (径向相对速度), 无法直接获取聚类后目标的横纵向速度, 且簇内点云分布未知, 无法直接确定聚类后目标的实际位置, 本文提出的聚类后处理方法有助于雷达估计聚类后目标准确的位置与速度信息。

1 DBSCAN 算法改进

在传统的毫米波雷达信号处理中, CFAR 算法通常会使用较高的阈值来滤除杂波点云^[11], 该方法虽能有效剔除杂波, 但也会减少有效点云数量。由于多径效应、同源雷达等的影响, 毫米波雷达获得的点云会有较多噪点, 本文将使用 DBSCAN 聚类算法来滤除以上问题引入的噪声。DBSCAN 是一种基于密度的聚类算法, 可以对任意形状的稠密数据集进行聚类, 且能在聚类时发现异常点, 非常适用于毫米波雷达点云数据处理。

对于传统的 DBSCAN 算法, 采用欧氏距离表示点与点的相似性, 相似度大小仅与两点信息相关, 只取决于两个点, 与其他数据的全局统计性质无关, 因此不能完全满足实际要求, 数据距离应该依赖于全

局数据的影响。本文提出的聚类算法, 根据车载毫米波雷达点云分布特点, 将欧氏距离与马氏距离结合作为本文聚类算法的相似性度量方法, 排除近距离较密集点云间不同特征变量量纲与相关性的干扰。

由于毫米波雷达点云“近密远疏”的特点, 雷达的测距与测角性能, 受测角精度与目标与雷达的距离所影响。相对于距离较远的目标, 近距离目标的点云数量与质量明显优于远距离目标。若采取统一的聚类密度门限, 会导致较远的目标点云被当成噪点滤除。因此本文提出基于自适应密度阈值的 DBSCAN 聚类算法来解决以上问题。除了位置信息与速度信息, 毫米波雷达还可提供目标的散射强度, 上述信息均可作为聚类相似度衡量的信息, 提高算法的可靠性, 减少目标过分割或将临近目标聚成一簇的错误。

1.1 相似性度量改进

如图 1 所示, 若采取欧氏距离度量 A 、 B 与该簇数据质心原点处的相似性, 则 A 、 B 两点与该簇数据相似性一致。但根据该组数据分布特点, OB 方向为高方差方向、 OA 为低方差方向, B 点与该簇数据相似度更高。根据马氏距离除以方差的特性, B 点距离原点距离更近, 与该组数据相似度更高。




图 1 马氏距离应用实例

Fig. 1 Application example of markov distance

本文提出在点云密度较大的近距离检测时, DBSCAN 算法领域扩展采用马氏距离描述点云间相似度, 排除变量之间相关性干扰与测量量纲的影响, 在中远距离的检测采用多参数欧氏距离描述点云间关系。

马氏距离 (Mahalanobis Distance) 是一种距离的度量, 表示点与一个分布之间的距离。其是一种有效计算两个未知样本集相似度的方法, 可以看作是欧氏距离的一种修正, 修正了欧式距离中各个维度尺度不一致且相关的问题。马氏距离表达如式 (1) 所示:

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (1)$$

其中, Σ 是多维随机变量的协方差矩阵, μ 为样本均值, 该均值指聚类算法核心点领域内样本均值。

除位置信息与速度信息外, 毫米波雷达还可提供目标点云的强度信息。当距离较远时, 雷达能接收到的点云信号均为目标较强点反射得到的, 强度相似性较强, 故可将强度信息、位置信息、速度信息作为描述中远距离 DBSCAN 算法聚类各个点云之间的距离。但是, 当直接使用 x 、 y 、 $Strength$ 、 $Velocity$ 时, 这4个参数之间存在绝对值差异。因此, 为了使每个参数的值对于聚类效果影响接近, 本文使用其平均值和标准差, 对每个参数进行零均值归一化, 如式(2)所示:

$$z = \frac{x - \mu}{\sigma} \quad (2)$$

对于归一化后的各个特征采用欧氏距离来度量 DBSCAN 聚类算法各个点云之间的距离。表达式如式(3)所示:

$$d = [(x_1 - x_2)^2 + (y_1 - y_2)^2 + (Strength_1 - Strength_2)^2 + (v_1 - v_2)^2]^{1/2} \quad (3)$$

其中, x_i 、 y_i 、 $Strength_i$ 、 v_i 分别表示目标的横坐标、纵坐标、反射强度、相对径向速度。

1.2 聚类参数自适应

DBSCAN 算法相对容易设置的参数为 \minPts 。因此, Sander 等^[12] 给出公式: $\minPts = 2dim - 1$, 其中 dim 为输入数据的维度。

参数 eps 通常是很难设置的, 受较多因素影响。目标相对雷达的距离、角度对得到的采样点数影响很大。如图2所示, 本文对本车静止, 前车前进的场景下, 同一车辆目标 5~200 m 点云数量进行统计, 点云数量与距离呈负相关。




图2 同一目标点云数量变化

Fig. 2 Change in the number of point clouds for the same target

传统 DBSCAN 算法未考虑毫米波雷达的采样密度不均匀特点, 采用固定的领域半径和点数, 而远近目标的聚类效果受目标点云分布影响差异很大。

本文采用基于目标点云距离与车辆目标特征而自适应变化的门限, 如式(4)所示。

$$e = \Delta\theta \times R \times \delta \quad (4)$$

其中, $\Delta\theta$ 为雷达的角度分辨率; R 为点云目标到雷达的距离; δ 为自定义阈值系数。

根据毫米波雷达点云数据分析, 点云密度在一定距离范围内十分接近, 且考虑到实际应用中的计算资源合理分配, 可认为领域半径在一定距离范围内保持一致, 通过点云距离对领域半径自适应调整。

2 目标信息计算

本文针对完成毫米波雷达点云聚类的目标点簇进行运动状态解算的研究。聚类后, 可得到一簇点云内每一个点云的距离、角度、多普勒、强度等信息, 依靠簇内每个点云信息来进行点簇的运动状态解算。

毫米波雷达点簇运动状态解算包括位置解算与速度解算。位置解算是通过簇内点云的径向距离与方位角计算每一个点云的联合概率密度, 并根据点云分布特点与功能需求, 对密度极大值点与极小值点进行加权处理。速度解算是通过簇内点云的多普勒速度与方位角的正弦值、余弦值进行最小二乘法计算, 得到横向与纵向相对速度。

2.1 位置解算

聚类点簇中包含多个点云, 后续进行跟踪时, 点簇解算的位置信息会作为跟踪滤波的量测值输入, 若位置解算不准会导致跟踪结果出现漂移, 带来虚假航迹问题。因此, 在跟踪滤波前, 需要先基于聚类点簇的 N 个点云确定簇内点云质心, 以质心为单位进行后续的跟踪滤波。

对毫米波雷达道路场景下目标进行分析, 由于安装位置与角度的差异及雷达对于不同物体反射能力不同, 导致目标点云并非呈均匀分布, 若采取均值法确定质心对位置进行解算, 会导致解算结果偏差较大。

非参数核密度估计算法可对未知分布的数据进行概率密度的估计, 该方法利用核函数和带宽为每个观测点计算概率密度, 然后将每个点的概率密度归一化, 并使用核估计函数在感兴趣的区域上求和, 以确定沿表面网格的每个点的密度。

本文选择点云径向距离与方位角两个参数, 利用核密度估计算法求取径向距离与方位角的联合概率密度函数, 完成二元核密度估计。

若一组数据 x_1, x_2, x_3, \dots 是独立同分布的 N 个样

本,同时给定核函数 K 和带宽 h ,此时任意点 x 处的核密度如式(5)所示。

$$f_h(x) = \frac{1}{M} \sum_{i=1}^M K_h(x - x_i) \quad (5)$$

式中: $K(\cdot)$ 为核函数, h 为带宽。

本文选择广泛应用的高斯核,其本质是在衡量样本和样本之间的“相似度”,在一个刻画“相似度”的空间中,让同类样本更好地聚在一起,进而线性可分。该核函数不仅计算效率高,而且只有一个 sigma 参数,可以非常容易地调节高斯函数对高低频信息的保留程度。带宽的选择采用 rule of thumb 方法,由该方法可知带宽与待估计的概率密度函数的二阶导数有关。而待估计的概率密度函数是未知的,假设该函数为一个方差为 σ^2 的已知函数,可求解出 h ,如式(6)所示。

$$h = \left(\frac{4}{3}\right)^{1/5} \sigma n^{-1/5} \quad (6)$$

由于聚类点簇中点云分布服从分布未知,可将点云中每个点云的距离表示为目标质心径向距离、测量噪声、与径向距离偏差三者之和。如式(7)所示:

$$\dot{r}_i = r + dr_i + n_r = r + v_{r_i} \quad (7)$$

式中: \dot{r}_i 为第 i 个点云的径向距离, r 为质心径向距离, dr_i 为径向距离偏差,用于描述第 i 个测量点的径向距离与质心径向距离之间的差值, n_r 为径向距离的测量噪声。

通过计算可得到聚类点簇中点云径向距离的概率密度函数表达式,如式(8)所示:

$$f(\dot{r}_i) = \frac{1}{\sqrt{2\pi(\sigma_r^2 + h_r^2)} M} \sum_{j=1}^M \exp\left(-\frac{(\dot{r}_i - r - dr_j)^2}{2(\sigma_r^2 + h_r^2)}\right) \quad (8)$$

同理可得到聚类点簇中点云方位角的概率密度函数表达式,如式(9)所示:

$$f(\dot{\theta}) = \frac{1}{\sqrt{2\pi(\sigma_\theta^2 + h_\theta^2)} M} \sum_{j=1}^M \exp\left(-\frac{(\dot{\theta}_i - \theta - d\theta_j)^2}{2(\sigma_\theta^2 + h_\theta^2)}\right) \quad (9)$$

本文利用非参数核方法估计径向距离及方位角的概率密度,并计算点云径向距离偏差与方位角偏差的联合概率密度函数,结果如式(10)所示:

$$f(\dot{r}_i, \dot{\theta}_i) = \frac{1}{2\pi\sqrt{(\sigma_r^2 + h_r^2)(\sigma_\theta^2 + h_\theta^2)} M^2} \times \sum_{j=1}^M \sum_{k=1}^M \exp\left(-\frac{(\dot{r}_i - r - dr_j)^2}{2(\sigma_r^2 + h_r^2)} - \frac{(\dot{\theta}_i - \theta - d\theta_k)^2}{2(\sigma_\theta^2 + h_\theta^2)}\right) \quad (10)$$

$$\frac{(\dot{\theta}_i - \theta - d\theta_k)^2}{2(\sigma_\theta^2 + h_\theta^2)} \quad (10)$$

根据上式可获取该簇所有点云的概率密度,根据车载毫米波雷达点云分布特点与实测数据分析,将概率密度极大值点 x 轴坐标与极小值点 x 轴坐标加权,得到质心的 x 坐标。同时,考虑车载毫米波雷达需实现 ACC、AEB 等预警安全功能,故质心的 y 坐标选取距离最小值点的 y 坐标,确保安全预警功能的实现。

2.2 速度解算

聚类点簇中包含多个点云,后续进行跟踪时,点簇解算的位置信息会作为跟踪滤波的量测值输入,若位置解算不准会导致跟踪结果出现漂移,带来虚假航迹问题。因此,在跟踪滤波前,需先基于聚类点簇的 N 个点云确定簇内点云质心,以质心为单位进行后续的跟踪滤波。

毫米波雷达可以提供非常准确的速度信息,但只能测量相对径向速度,因此不能直接获取目标的速度矢量,而需要通过速度解算来得到目标的横纵向速度。

如果车辆向前移动,从其角度来看,本车与目标发生相对运动,同时本车运动状态通过车载传感器获取,可通过二者相对速度解算出目标车辆的运动状态。

如图 3 所示,假设前方目标点簇中有 n 个点云。




图 3 速度解算示意图

Fig. 3 Schematic diagram of speed calculation

由式(11)可知,需要通过目标点簇中至少 2 个点云信息进行最小二乘法解算目标的实际横纵向速度和纵向速度。

$$\begin{bmatrix} v_{r,1} \\ \vdots \\ v_{r,N} \end{bmatrix} = \begin{bmatrix} \cos(\theta_1) & \sin(\theta_1) \\ \vdots & \vdots \\ \cos(\theta_N) & \sin(\theta_N) \end{bmatrix} \begin{bmatrix} v_x \\ v_y \end{bmatrix} \quad (11)$$

3 实验验证

实验采用实际道路测试数据集对本文聚类算法的可靠性与稳定性进行验证。数据集为2023年1月12日采集于江苏南通市区的实测数据集。采集数据的汽车雷达为77 GHz前向毫米波雷达,数据包含点云纵坐标、横坐标、多普勒速度、强度等信息。

3.1 聚类识别实验

聚类点簇中包含多个点云,后续进行跟踪时,点簇解算的位置信息会作为跟踪滤波的量测值输入,若位置解算不准会导致跟踪结果出现漂移,带来虚假航迹问题。因此,在跟踪滤波前,需要先基于聚类点簇的 N 个点云确定簇内点云质心,以质心为单位进行后续的跟踪滤波。

为了评估与对比该文提出的聚类算法,本文采用Davies-Bouldin指数作为聚类算法的评价指标,该指标通过测量聚类之间的相似性和聚类内部差异,来表示聚类效果。 DBI 越小,表示聚类之间越相似,聚类内部差异越小,聚类效果越好。本文进行3组对比试验,对比结果见表1。

表1 聚类效果对比

Table 1 Comparison of clustering effects

	本文算法	DBSCAN 算法
实验1	0.342 2	0.397 6
实验2	0.268 8	0.356 6
实验3	0.342 2	0.454 6

3.1.1 实验1

行驶场景为隧道,本车在右侧车道以15.26 m/s行驶,前方有4辆目标车向前行驶,同时隧道两侧墙壁反射大量回波噪点。对该场景的点云分别进行传统DBSCAN算法与改进DBSCAN算法处理后,对比聚类效果。

本文算法将隧道墙壁反射的点簇视为噪点,将前方4辆车反射回的点云聚类成目标,最终得到图4中的结果(图中黑色框为实际车辆位置)。从图中可以看出,常规的DBSCAN方法会将远处目标都当做噪点处理,只保留近处目标信息,而采用改进DBSCAN算法,则能保留远处目标的信息,同时通过位置信息、强度信息、速度信息门限的设置将隧道墙壁的反射点视为噪点。对于改进的DBSCAN算法,Davies-Bouldin指数为0.342 2,优于原始DBSCAN算法的0.397 6。

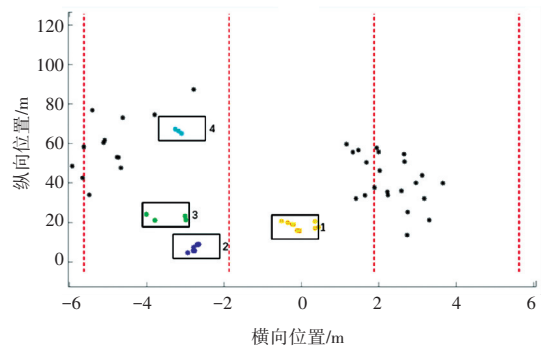


图4 聚类结果

Fig. 4 Cluster result

3.1.2 实验2

行驶场景为隧道,本车在右侧车道以15.82 m/s行驶,前方有3辆目标车向前行驶,其中左侧车辆为扩展目标。对该场景的点云分别进行传统DBSCAN算法与改进DBSCAN算法处理,对比聚类后效果。

本文算法将扩展目标成功聚类成一簇,最终得到图5中结果。常规的DBSCAN算法在处理近距离扩展目标时,易将同一目标过分割,聚类成多个簇,而改进DBSCAN算法采用马氏距离,考虑扩展目标多参数的分布情况,成功聚类成一簇,同时大型车辆扩展目标与相邻车道的小车也成功聚成两簇。对于改进的DBSCAN算法,Davies-Bouldin指数为0.268 8,优于原始DBSCAN算法的0.365。




图5 聚类结果

Fig. 5 Cluster result

3.1.3 实验3

行驶场景为快速路,前方有一个高架桥,两侧有护栏,本车在右侧车道以16.65 m/s行驶,前方有6辆目标车。对该场景的点云分别进行传统DBSCAN算法与改进DBSCAN算法处理,对比聚类后效果。

本文算法将目标与道路边缘护栏、树木成功分割,最终得到图6结果。采用常规的DBSCAN算法时,由于右边车辆靠近围栏,存在围栏的反射,聚类后的点云图像包含了部分围栏的反射点,相邻车的界限变得模糊,容易将相邻车辆归为同一类,从而导致错误的目标识别。采用改进DBSCAN算法应用

多参数欧氏距离衡量点云间的相似度,成功将护栏与运动目标分隔开, Davies-Bouldin 指数为 0.342 2, 优于原始 DBSCAN 算法的 0.454 6。

3.2 聚类后处理实验

行驶场景为封闭道路,本车以 4.6 m/s 速度跟随目标车辆前行,目标车辆配有 RTK 获取速度与位置信息真值。选取连续 10 帧点云信息进行聚类后处理信息解算,解算结果如图 7 所示。图 8 表示估计的位置速度信息与真实值的偏差,估计精度,见表 2,均小于 0.5 满足算法设计要求。

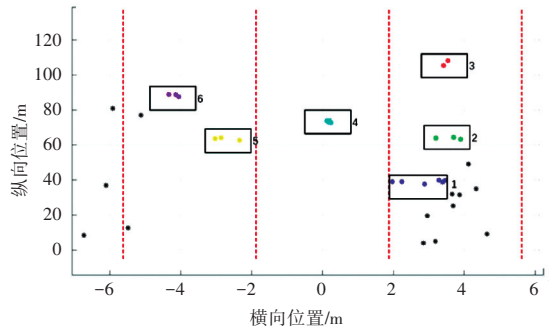


图 6 聚类结果

Fig. 6 Cluster result

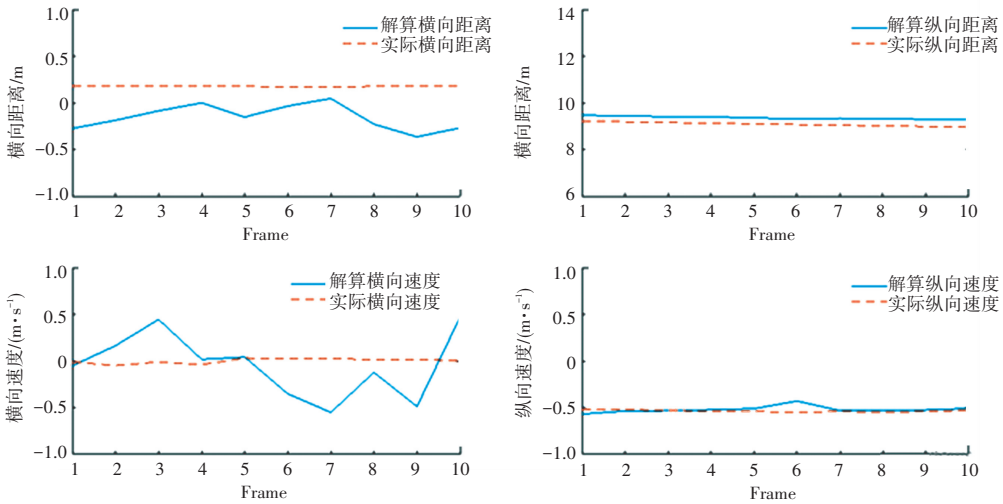


图 7 解算结果与真值对比

Fig. 7 Comparison between solution results and true values




图 8 解算结果误差

Fig. 8 Calculation result error

表 2 位置解算误差均值

Table 2 Mean value of position calculation error

	横向往位置/ m	纵向往位置/ m	横向往速度/ (m · s ⁻¹)	纵向往速度/ (m · s ⁻¹)
估计值与真值偏差	0.33	0.27	0.28	0.02

下,出现点云过分割、虚警、噪点多等问题,提出一种改进的聚类算法。该算法考虑毫米波点云分布“近密远疏”的特点,通过马氏距离与欧氏距离结合的方法,消除参数之间相关性干扰与测量量纲的影响,解决近距离密集场景扩展目标的聚类问题,对远距离点云采用多指标欧氏距离衡量相似度。其次,针对 DBSCAN 算法参数全局唯一的局限性,提出根据点云距离自适应变化的门限策略,利用自适应邻域半径的 DBSCAN 算法进行聚类处理得到目标点簇。最后,利用非参数核密度估计方法与最小二乘法对聚类后的目标进行速度、位置估计。实验结果表明,该算法可在复杂行车环境下,将目标车准确识别,相比 DBSCAN 算法具有更好的聚类效果,聚类后位置、速度估计满足误差小于 0.5 的设计要求。

参考文献

[1] MEYER M, KUSCHK G. Automotive radar dataset for deep learning based 3d object detection [C]//2019 16th European radar conference (EuRAD). IEEE, 2019: 129-132.

4 结束语

针对车载毫米波雷达在实际道路复杂工作路况

(下转第 167 页)