

文章编号: 1671-7449(2024)02-0170-09

基于毫米波雷达的运动目标点云聚类 and 扩展算法

苏永利, 陈平*

(中北大学 信息探测与处理山西省重点实验室, 山西 太原 030051)

摘要: 用毫米波雷达对运动目标进行姿态识别时, 雷达点云数据具有噪点多、分布离散的特征, 传统基于密度空间的聚类算法对点云聚类成像的过程中, 会出现邻近目标之间的点云分类错误及同一目标点簇聚类为多个点簇等问题。针对上述情况, 提出一种运动多目标邻近点云优化聚类算法, 利用自适应距离加权的模糊c均值算法对聚类结果进行修正, 提高近邻目标点云聚类准确度。同时提出一种目标点簇扩展聚合算法, 利用卡尔曼滤波对运动目标位置预测, 将多帧迭代三维点云尺寸作为波门对目标点云进行点簇扩展, 提高目标点云完整性。试验结果表明, 所提方法能有效提高聚类准确度。

关键词: 毫米波雷达; 聚类算法; 点簇扩展; 卡尔曼滤波; 模糊c均值

中图分类号: TP391

文献标识码: A

doi: 10.3969/j.issn.1671-7449.2024.02.010

引用格式: 苏永利, 陈平. 基于毫米波雷达的运动目标点云聚类 and 扩展算法[J]. 测试技术学报, 2024, 38(2):170-178.

SU Yongli, CHEN Ping. Cluster and expansion algorithm for moving object point cloud based on millimeter-wave radar[J]. Journal of Test and Measurement Technology, 2024, 38(2):170-178.

Cluster and Expansion Algorithm for Moving Object Point Cloud Based on Millimeter-Wave Radar

SU Yongli, CHEN Ping*

(Shanxi Province Key Laboratory of Information Detection and Processing, North University of China, Taiyuan 030051, China)

Abstract: When using millimeter wave radar for attitude recognition of moving targets, the radar point cloud data has the characteristics of many noisy points and discrete distribution, and the traditional density space-based clustering algorithm for point cloud clustering imaging process, there will be problems such as point cloud classification error between neighboring targets and clustering of the same target point cluster into multiple point clusters. To address the above situation, a motion multi-target neighboring point cloud optimization clustering algorithm is proposed to correct the clustering results using an adaptive distance-weighted fuzzy c-mean algorithm, which improves the accuracy of near-neighbor target point cloud clustering. Meanwhile, a target point cluster expansion aggregation algorithm is proposed, which utilizes Kalman filtering for motion target position prediction, and the multi-frame iterative 3D point cloud dimensions are used as a wavegate to expand the point clusters of the target point cloud to improve the target point cloud integrity. The experimental results show that the proposed method can effectively improve the clustering accuracy.

Key words: millimeter-wave radar; clustering algorithm; point-cluster expansion; Kalman filter; fuzzy c-means

收稿日期: 2023-08-14

基金项目: 国家自然科学基金资助项目(62122070)

作者简介: 苏永利(1995—), 男, 硕士生, 主要从事信息探测与处理研究。E-mail: syl980833924@163.com。

* 通信作者: 陈平(1983—), 男, 教授, 博士生导师, 主要从事信息探测与处理及图像处理与重建研究。E-mail: pc0912@163.com。

0 引言

毫米波雷达传感器具有非视距情况下工作的能力^[1],其三维点云被广泛用于姿态识别^[2,3]。然而,在复杂环境中,运动人体的毫米波雷达点云分布范围离散^[4],特别是近邻目标之间点云混合导致目标点云聚类成像困难。点云成像质量直接影响姿态识别效果,因此,提高点云聚类成像质量对姿态识别具有重要意义。

用于运动目标雷达点云的聚类算法主要包括:基于分区的k-means算法、模糊C均值(Fuzzy c-means, FCM)算法及基于密度的聚类(Density Based Spatial Clustering of Applications with Noise, DBSCAN)算法^[5,6]。K-means算法需提前指定簇数量K,且初始中心的随机确定影响算法的收敛速度和最终聚类效果。FCM算法是一种模糊聚类方法^[7],通过优化目标函数来确定聚类中心和隶属度值,具有较高的准确性,但需提前设定初始参数。DBSCAN算法适用于任意形状的物体,并且不需要先验信息^[8],但存在不同类点云距离较近时聚类效果较差等问题。根据毫米波雷达点云数据的特性,国内外学者提出许多相关的聚类算法。ZHAZNG等^[9]提出了一种稳健的椭圆点云聚类方法,能够实现椭圆搜索区域的形状根据位置而变化。SHEN等^[10]提出利用花授粉优化算法来确定DBSCAN聚类参数,可得到较高的聚类精度,然而未能优化点云密度不均匀问题。PEGORARO等^[11]将DBSCAN算法和扩展卡尔曼滤波(Extended Kalman Filter, EKF)结合,能够有效对目标点云进行扩展并估计出目标的形状,但存在误差时域传递问题。

现有研究主要是对雷达二维数据进行聚类^[12-15],在特殊场景中对三维点云成像具有一定的局限性,而且现有改进的DBSCAN聚类算法未考虑邻近运动目标点云混合的情况^[16,17]。针对上述问题,本文提出一种距离自适应加权FCM算法,对初始DBSCAN聚类结果进行二次聚类修正。并且将DBSCAN和EKF算法结合,利用多帧迭代的点云三维尺寸作为波门对三维点簇数据进行扩展。实验结果表明,优化后的聚类算法和点簇扩展算法有效解决了近邻目标之间点云分类不准确及同一目标点簇分为多个点簇的问题,提高了点云成像准确度。

1 毫米波点云数据生成

调频连续波毫米波雷达通过发射线性调频信号,并在接收端测量反射信号的频移来实现目标的探测与定位。发射的调频信号的频率在T秒内从一个基本值 f_0 增加到一个最大值 f_1 。毫米波雷达发射信号表示为

$$s(t) = \exp\left[j2\pi\left(f_0 + \frac{\xi}{2}t\right)t\right], 0 \leq t \leq T. \quad (1)$$

在每个L调频序列中,每T秒发送一个调频。接收端混合采样后产生中频信号

$$y(m, l) = \alpha \exp[j\phi(m, l)] + w(m, l), \quad (2)$$

式中:m和l分别表示沿快时和慢时的采样指标; α 为考虑目标天线增益、路径损耗和雷达截面的衰减效应的系数; $w(m, l)$ 为高斯噪声项。相位 $\phi(m, l)$ 依赖于快时间和慢时间采样指标。

利用二维傅里叶变换分别对快时间和慢时间两个维度进行傅里叶变换,再经过单元平均恒虚警率算法检测出目标反射点。雷达发射单元沿两个空间维度排列,根据时分复用方案来发射调频信号,就可以估计出反射点的方位角和俯仰角,最后得到包含其笛卡尔坐标、速度和反射功率的点云信息。

2 雷达点云聚类 and 扩展处理

DBSCAN算法将数据点分为3类:核心点、可达点和噪声点,如图1所示。核心点是以半径为r的圆内包含至少4个点的中心点(红点),可达点是那些在核心点的圆内但自身不是核心点的点(蓝点),而噪声点则是既不是核心点也不是可达点的点(黄点)。DBSCAN将核心点和可达点视为具有相似性质的簇,并将它们归为一个集群,而噪声点则不属于任何集群。




图1 DBSCAN算法概念图

Fig. 1 Conceptual diagram of DBSCAN algorithm

本文主要利用改进后的隶属度矩阵进行二次聚类,实现了聚类算法的自适应性。算法首先将点云数据转换成以距离、方位角以及俯仰角的分

辨率为单位的极坐标表示,并通过构建椭球体搜索区域进行初始聚类,得到聚类中心和类别数。然后利用自适应加权计算隶属度矩阵中的距离,将隶属度矩阵和聚类中心经过多次迭代后修正初始聚类数据,得到准确的聚类结果。

2.1 构建聚类搜索区域

雷达点云在笛卡尔坐标系下是非等距采样,水平和垂直距离随着目标距离增大而增大,使用固定聚类领域半径的方法无法适应运动目标距离变化的情况。为了解决这个问题,将点云数据 $P(x, y, z)$ 表示为极坐标形式 $V(R, A, E)$, R, A, E 分别为雷达点云的距离、方位角以及俯仰角信息。

利用雷达的距离、方位角以及俯仰角的分辨率为单位长度,构建聚类算法中的椭球体搜索区域,根据毫米波雷达点云的分布特点,利用雷达分辨率构建的搜索区域更加适用于雷达点云数据,椭球搜索区域具体计算公式为

$$\left(\frac{R-R_0}{r \cdot \Delta r}\right)^2 + \left(\frac{A-A_0}{a \cdot \Delta A}\right)^2 + \left(\frac{E-E_0}{e \cdot \Delta E}\right)^2 \leq 1, \quad (3)$$

式中: r, a, e 为自定义系数; $\Delta r, \Delta A, \Delta E$ 分别为雷达距离、方位和俯仰的分辨率。

2.2 优化聚类算法

经过椭球形搜索区域对雷达点云数据进行初始聚类,聚类结果包括所有样本点的位置坐标信息、样本的中心点信息以及聚类类别的数量。根据初始聚类结果,选择点簇中心距离小于预设值的相邻点簇,利用改进的FCM算法对选择的点簇进行修正,得到最终聚类结果,优化算法流程如图2所示。

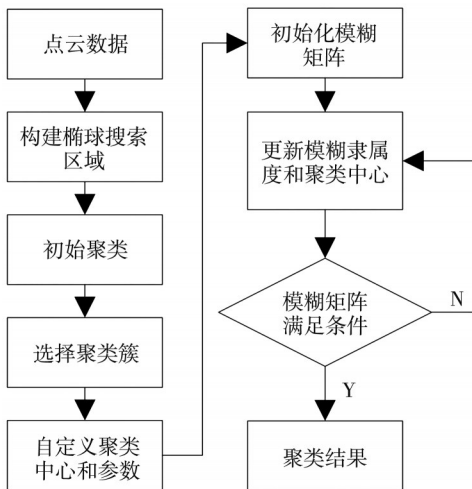


图2 优化聚类算法流程图

Fig. 2 Flowchart of optimized clustering algorithm

在下面优化算法中,模糊矩阵是某个样本点属于某个聚类的概率的矩阵集合,在计算模糊矩阵的时候,利用机器学习中常用作激活函数的Sigmoid函数作为样本点到点簇中心的距离加权系数。 α 是权重值,该权重值表示样本点属于某个聚类类别的程度,优化聚类算法步骤如下:

步骤1 根据雷达测试环境大小对三维点云数据进行初始筛选,对超出测试场景范围的点云过滤,然后在椭球体搜索区域对点云数据 D 进行初始聚类,得到点簇集 $C = \{C_1, C_2, \dots, C_n\}$,其中各点簇中点云空间位置中心为 $C_n = \{p_1, p_2, \dots, p_m\}$;

$$\begin{cases} p_{n,x} = \frac{x_{\max} - x_{\min}}{2}, \\ p_{n,y} = \frac{y_{\max} - y_{\min}}{2}, \\ p_{n,z} = \frac{z_{\max} - z_{\min}}{2}, \end{cases} \quad (4)$$

式中: $x_{\max}, x_{\min}, y_{\max}, y_{\min}, z_{\max}, z_{\min}$ 分别为点簇中 x, y, z 轴的最大和最小值,通过计算三维坐标最大和最小值的平均值,确定各点簇的空间位置中心。

步骤2 计算点簇集中各点簇空间中心之间的距离 $l_{n1, n2}$,选择中心距离小于预设值 λ 的点簇 $C = \{C_j, C_{j+s}, \dots\}$ 进行重新聚类

$$l_{n1, n2} = \begin{vmatrix} 0 & p_{2,1} & \dots & p_{n,1} \\ p_{1,2} & 0 & \dots & p_{n,2} \\ \vdots & \vdots & \ddots & \vdots \\ p_{1,n} & p_{2,n} & \dots & 0 \end{vmatrix} \begin{cases} 1 \leq n1 \leq n, \\ 1 \leq n2 \leq n. \end{cases} \quad (5)$$

预设值 λ 的设置与被测目标的宽度及目标之间的位置有关

$$\lambda = \frac{1}{2}(W_1 + W_2) + \Delta\epsilon, \quad (6)$$

式中: W_1, W_2 分别为近邻目标的宽度; $\Delta\epsilon$ 为目标之间的间隔距离。

步骤3 设置初始值,取模糊权重 α 为2,最大迭代次数 T 为500,误差阈值 ϵ 为0.0001。

步骤4 初始化模糊矩阵为单位矩阵,选择步骤1中计算的点簇中心作为初始自定义聚类中心。

步骤5 根据优化算法的目标函数更新对应的模糊隶属度 U_{ij} 和聚类中心 Z_n 。

$$Z_n = \frac{\sum_{i=1}^m U_{ij}^\alpha D_{ij}}{\sum_{i=1}^m U_{ij}^\alpha}, \quad (7)$$

$$U_{ij} = \frac{1}{\sum_{v=1}^c \left(\frac{\rho_{ij} D_{ij}}{\rho_{iv} D_{iv}} \right)^{\frac{2}{\alpha-1}}}, \quad (8)$$

式中： ρ_{iv} 是激活函数，表示样本点与某个聚类中心的关联程度； D_{ij} 表示样本与类别 C_n 的聚类中心之间的距离。

$$\rho_{iv} = \frac{1}{1 - e^{-D_{iv}}}。 \quad (9)$$

随着样本点与点簇中心距离的增大，点云与该点簇的关联度降低。

$$D_{ij} = \frac{(x_i - x_{nx})^2}{m1} + \frac{(y_i - y_{ny})^2}{m2} + \frac{(z_i - z_{nz})^2}{m3}, \quad (10)$$

式中： $m1, m2, m3$ 为自定义系数，结合毫米波点云分布的特点，点云在俯仰向分布较离散，目标之间交互主要发生在方位向和距离向，因此参数 $m3$ 设置较大降低俯仰数据对隶属度的影响；

步骤 6 如果迭代中的模糊矩阵满足预设条件 $|U_{ij}^{(t)} - U_{ij}^{(t-1)}| \leq \epsilon$ ，则迭代结束，得到新的点簇。否则，增加迭代次数，重复步骤 5。

2.3 EKF 与 DBSCAN 结合实现点簇扩展

点云经过聚类算法处理后，能够滤除大部分噪点。但是，由于毫米波雷达精度较低，在复杂环境中，同一目标的点云从动目标的空间分布上看，距离动目标点云集群有一定的距离且分布比较分散，在经过聚类处理后可能会产生多个点簇。

为把同一目标的多个点簇聚为一类，本文提出利用跟踪滤波和聚类算法结合的方法进行点簇扩展。先将当前帧点云估计出动目标三维尺寸和点云簇的质心点，然后利用跟踪滤波对质心点位置进行预测，为增加点云尺寸的完整性，将估计出的相邻帧点云尺寸结合，作为下一帧点簇扩展的波门，将属于同一目标的点簇归为一类，具体流程如图 3 所示。

在不考虑一般性的情况下，本文只考虑了匀速运动状态。将 EKF 预测的位置作为质心，以质心的相对位置建立波门，将满足波门半径范围内的点云都归为一类，若点簇与波门相交没有完全满足目标波门，则将点簇归入目标点簇中。

利用 EKF 进行点簇扩展的步骤如下：

步骤 1 对第 T 帧点云数据集 R 进行聚类，得到点云簇 $C_T = \{C_1, C_2, \dots, C_n\}$ 和点簇质心 $P_T =$

$\{P_1, P_2, \dots, P_n\}$ ；

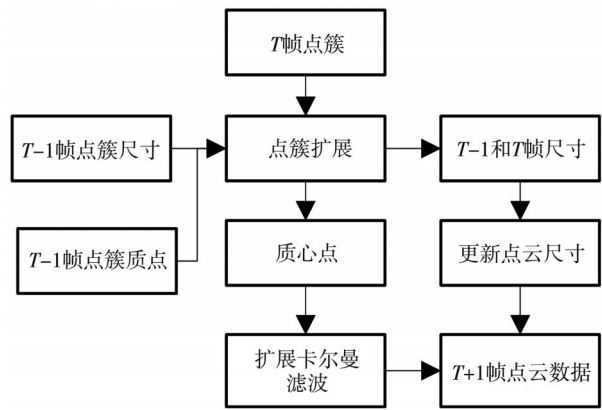


图 3 点簇扩展算法流程图

Fig. 3 Flowchart of point-cluster expansion algorithm

步骤 2 估计点簇 C_n 尺寸大小，得到点簇的最小外接矩形 $S_T = \{S_1, S_2, \dots, S_n\}$ ；

步骤 3 选择 $T-1$ 帧中对 T 帧进行点簇扩展的波门，更新 T 帧关联波门俯仰向尺寸，产生新的外接波门矩阵 S_T ；

步骤 4 使用 EKF 对 P_T 中每个质点进行最优估计下一帧位置，产生预测质点集 $p_T = \{p_1, p_2, \dots, p_n\}$ ；

步骤 5 当产生新增数据 R_{T+1} 时，得到聚类结果 $C_{T+1} = \{C_1, C_2, \dots, C_n\}$ ，将预测质点集 p_T 放入 C_{T+1} 中；

步骤 6 将在距离和方位向把质点集 p_T 包含于点簇 C_{T+1} 范围内的点簇与所属质点关联；

步骤 7 以质点 p_T 为相对位置构建外接矩形 S_T 为点簇扩展波门，对关联点簇 C_{T+1} 进行点簇扩展，将属于同一波门的点簇聚为一类，生成最终的聚类结果。

3 实验结果与分析

本文利用 AWR2243 四芯片级联开发板对室内封闭场所的运动人体目标进行测试，雷达系统放置于门后，测量时雷达距离地面高度约为 1 m，测试设备布置如图 4 所示。

为评估改进算法的聚类效果，引入聚类正确率评价指标，聚类正确率用于比较正确聚类点云数和雷达探测对象个数，计算公式为

$$C_A = \frac{T}{N + M}, \quad (11)$$

式中： T 为目标正确聚类数； N 为雷达探测对象个数； M 为目标错误聚类数。当出现同一目标点云

聚类为多个点簇的情况,选择点数最多的点簇作为目标点簇进行聚类准确度计算。



图4 雷达测试布置图

Fig. 4 Radar test layout

表1 雷达传感器参数设置

Tab. 1 Radar sensor parameter settings

参考名称	数值
起始频率/GHz	77
调频斜率/(MHz $\cdot\mu\text{s}^{-1}$)	78.9
ADC采样时间/ μs	40
ADC采样点数	256
调频个数	64

3.1 聚类算法实验

为验证优化后的聚类算法在复杂场景中的性

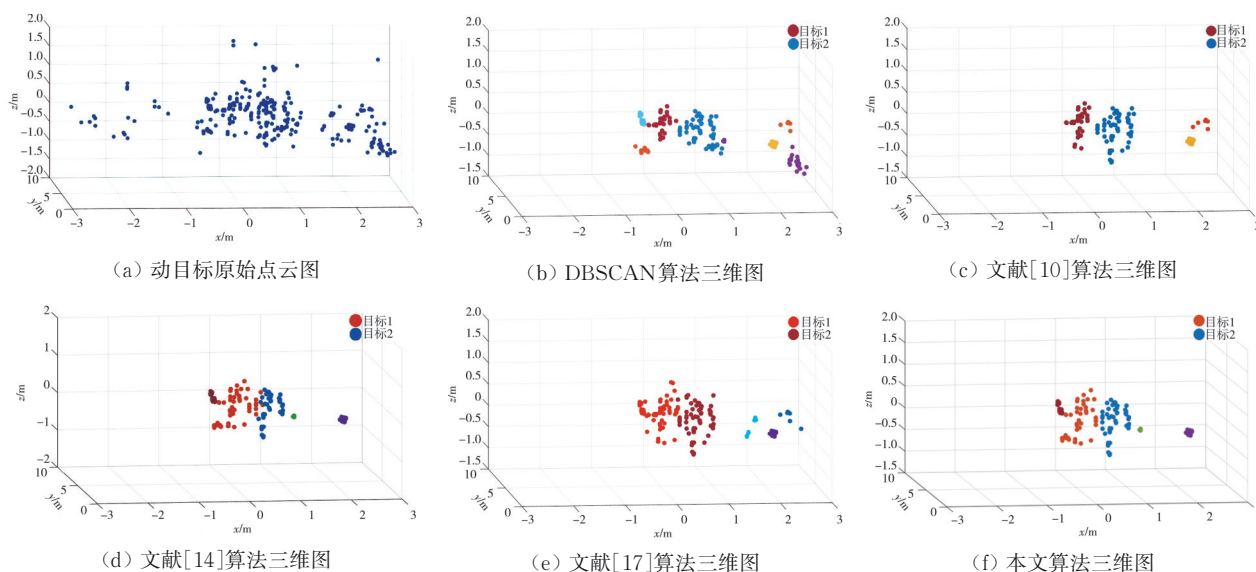


图6 场景一算法对比图

Fig. 6 Comparison of algorithms in scene 1

从图6中可以看出,用传统算法处理后目标点云聚类不完整,目标之间近邻点分类误差较大。采用文献[10, 14, 17]聚类算法后,能有效增加聚类目标完整性,但在目标之间距离过近时,对目标近邻点云的识别有一定误差,而改进后的算法能够有效增加近邻点云识别准确率。

针对该场景所采集的100帧数据进行量化统

能,在室内设置两个实验场景,如图5所示。对身体宽度约为0.6 m的近邻运动目标采集100帧运动数据,分别用改进的聚类算法、传统DBSCAN算法及文献[10, 14, 17]所提算法进行数据处理,对处理后的点云聚类准确度取平均值作为最终的评价指标。



图5 聚类算法实测图

Fig. 5 Clustering algorithm measured diagram

场景一中两目标中心保持约60 cm的距离以0.7 m/s的速度在距离雷达3~6 m的位置来回移动,两目标身体最近之间的部位间隔约为15 cm。选择场景一中的一帧典型数据进行分析,如图6所示。利用DBSCAN聚类算法需提前输入聚类参数,本文通过多次实验选择聚类效果最好的结果来设置聚类参数。

计,对比5种算法聚类准确度的平均值,聚类效果统计结果如表2所示。通过对比100帧数据处理后的结果可知,本文优化后算法的聚类精度为91%,较其他几种算法提高8%~17%。

在场景二中,目标之间的中心保持约60 cm的距离,以0.7 m/s的速度在距离雷达3~6 m的位置沿着来回移动,图7为场景二中其中一帧的

点云经过聚类后的结果。

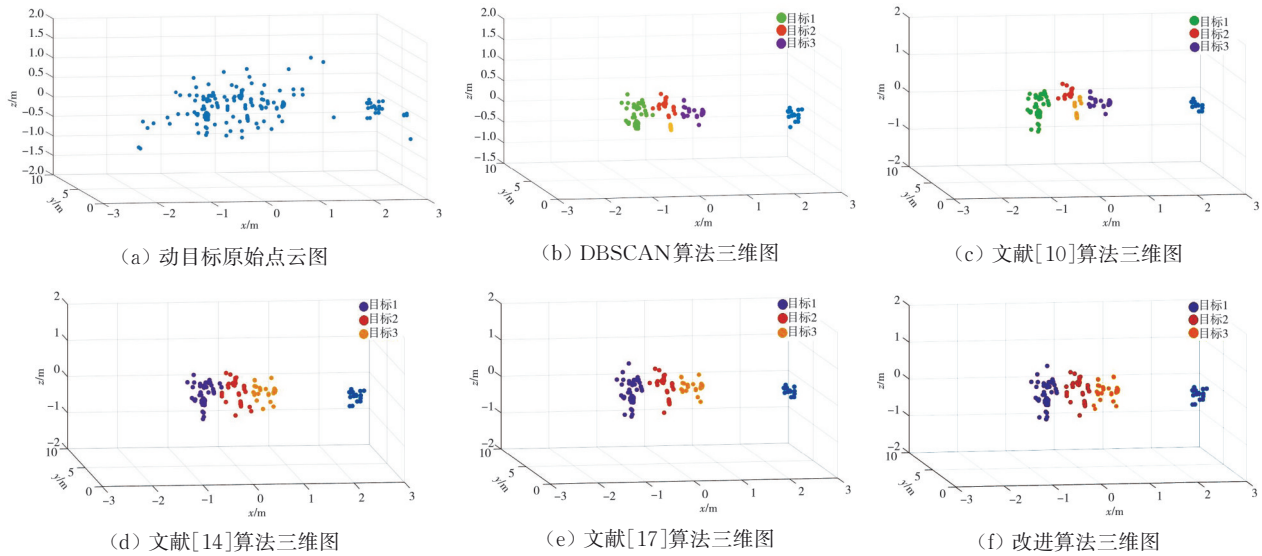


图 7 场景二算法对比图

Fig. 7 Comparison of algorithms in scene 2

表 2 场景一检测结果统计

Tab. 2 Statistics of detection results in scene 1

算法	聚类准确度/%		
	目标 1	目标 2	平均值
DBSCAN	73	75	74
文献[10]	79	78	78
文献[14]	84	82	83
文献[17]	81	83	82
本文	89	92	91

从图 7 中可以看出,目标 2 的点云分布较稀疏,用传统算法和文献[10]的算法处理后目标 2 的点云聚类为两个点簇。经过文献[14, 17]和本文的聚类算法后,有效增加了聚类目标完整性,但是文献[14]的部分近邻点云会出现分类误差,文献[17]中目标 2 和目标 3 的部分稀疏点云没有被聚类,本文算法能有效提高目标点云聚类的准确率。

统计该场景采集的 100 帧数据经过聚类处理后的结果,对比结果如表 3 所示。通过对比可知优化后算法的聚类准确率为 89%,较其他算法提高 5%~13%。

表 3 场景二检测结果统计

Tab. 3 Statistics of detection results in scene 2

算法	聚类准确度/%			平均值
	目标 1	目标 2	目标 3	
DBSCAN	76	75	79	76
文献[10]	82	72	77	77
文献[14]	84	83	86	84
文献[17]	85	74	83	81
本文	89	92	88	89

综合场景一和场景二的聚类结果,各算法的准确率比较如图 8 所示。从图中可以看出,在本文的两个实验场景中,本文提出的算法效果最好,平均准确率可达到 90%,因此本文能有效提高近邻目标聚类准确率。




图 8 聚类准确率柱状图

Fig. 8 Histogram of clustering accuracy

3.2 点簇扩展实验

为验证点簇扩展算法的有效性,在室内设置两个实验场景,分别对单个运动目标和两个移动目标进行测试,如图 9 所示。在运动过程中采集 100 帧运动数据,然后用本文扩展算法和文献[15]算法进行扩展处理,将每帧处理后的点云聚类准确度进行平均作为最终的评价指标。

场景一中单人目标以 0.7 m/s 的速度沿雷达方位 0° 方向,从距离雷达 2 m 处正常行走走到 8 m 的位置。选择所采集数据的其中一帧典型数据进行分析,如图 10 所示。



图9 扩展算法实测图

Fig. 9 Extended algorithm measured diagram

从图 10 中可以看出, 经过聚类后, 目标聚类为 3 个点簇。利用文献[15]中算法进行点簇扩展后, 多个点簇能够聚为一类, 然而由于算法中只

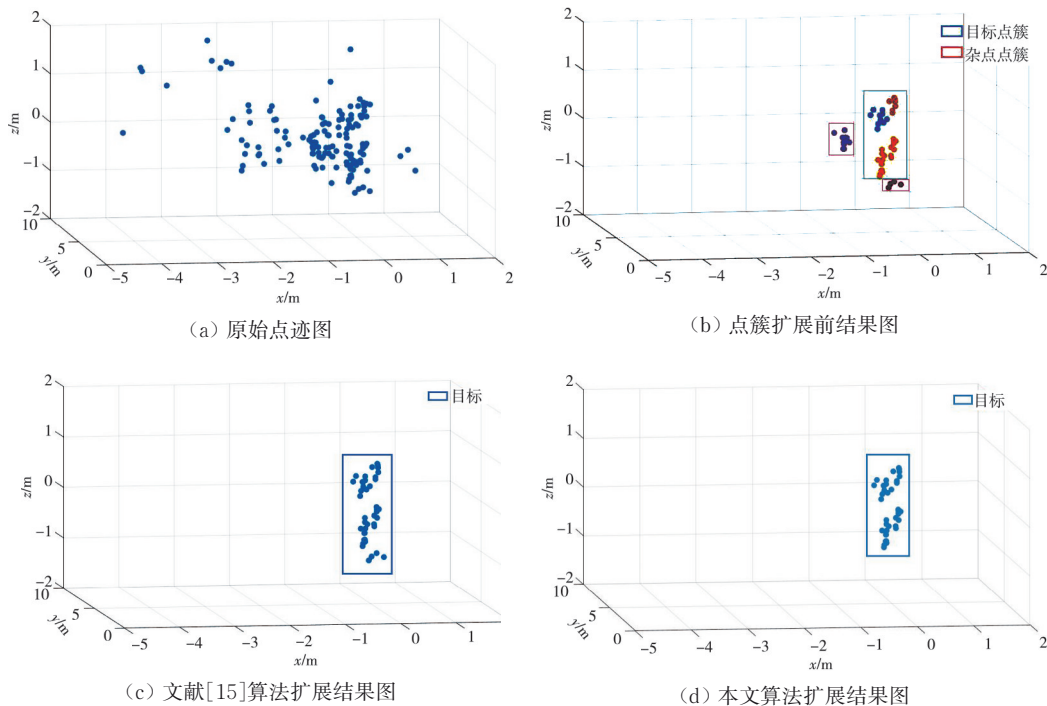


图 10 场景一算法对比图

Fig. 10 Comparison of algorithms in scene 1

场景二两人目标之间水平距离 0.6 m, 纵向距离 0.6 m, 目标以 0.7 m/s 的速度沿雷达方位 0° 方向, 从距离雷达 2 m 处正常行走走到 8 m 的位置。选择所采集数据中一帧典型数据进行分析, 如图 11 所示。

从图 11 中可以看出, 经过聚类后, 目标 1 聚类为 2 个点簇, 目标 2 聚类为 2 个点簇。经过文献[15]算法扩展后, 目标 1 将 2 个点簇聚为一类, 但由于目标 2 俯仰向存在杂点, 导致目标 2 将杂点点簇聚为一类。采用本文算法进行三维扩展后, 可有效减少俯仰向杂点的影响。

考虑二维数据, 将俯仰向的杂点点簇也扩展到目标点簇。本文算法进行三维扩展后有效解决俯仰向杂点的影响。

表 4 为场景一中 100 帧数据聚类结果准确度对比, 本文算法的聚类准确率为 93%, 较扩展前提高 15%, 较文献[15]算法提高 7%。

表 4 场景一检测结果统计

Tab. 4 Statistics of scene 1 detection results

算法	目标聚类准确度/%
扩展前	78
文献[15]	86
本文	93

表 5 为场景二中 100 帧数据点簇扩展结果准确度对比, 本文算法的聚类准确率为 92%, 较扩展前提高 19%, 较文献[15]算法提高 9%。

表 5 场景二检测结果统计

Tab. 5 Statistics of detection results in scene 2

算法	聚类准确度/%		
	目标 1	目标 2	平均值
扩展前	75	71	73
文献[15]	82	84	83
本文	91	93	92

综合场景一和场景二的点簇扩展结果, 各算法扩展后点云聚类的准确率比较如图 12 所示。

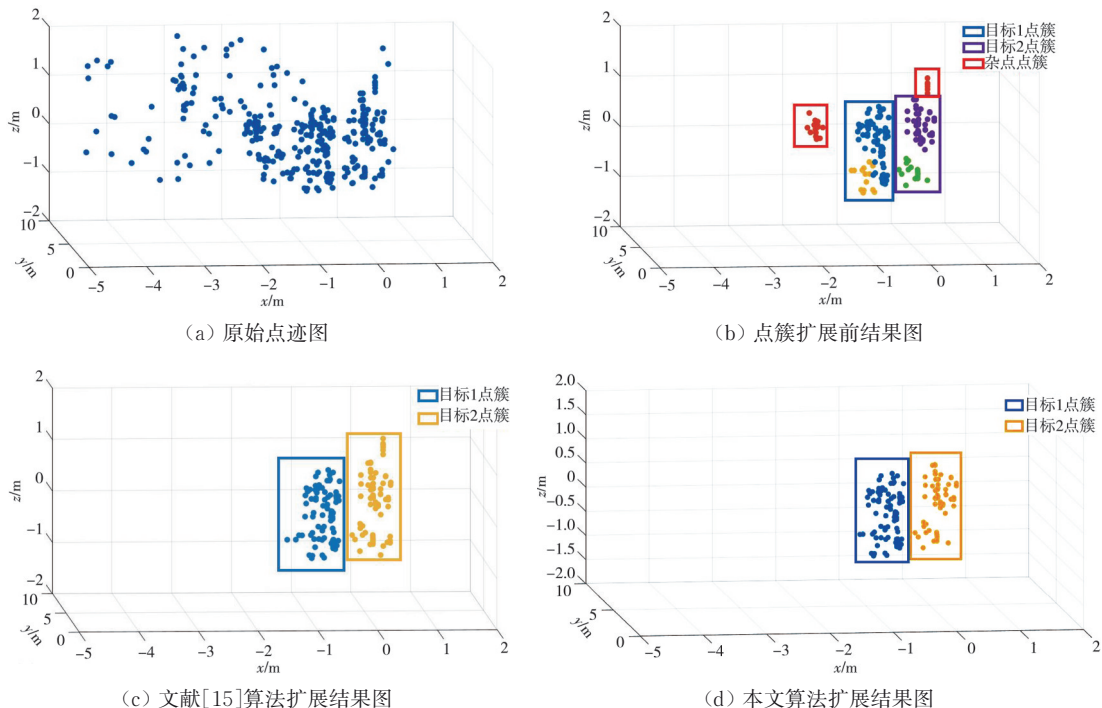


图 11 场景二算法对比图

Fig. 11 Comparison of algorithms in scene 2

从图 12 中可以看出,在两个实验场景中,本文提出的算法效果最好,所提扩展算法可以提高成像准确率,平均准确率可达到 92%。然而在点簇扩展过程中,需要进行多帧迭代才能逐渐提高目标点云的准确度,而且本文只考虑了目标匀速状态,在目标的运动状态变换或者距离过近的时候可能会导致目标点簇聚类准确度降低。




图 12 聚类准确率柱状图

Fig. 12 Histogram of clustering accuracy

4 结语

本文提出一种近邻运动目标自适应距离加权的聚类算法,利用改进的模糊矩阵隶属度二次聚类对 DBSCAN 聚类结果进行修正,提高运动目标近邻点分类的准确性。同时,本文提出一种目标点簇扩展聚合算法,利用扩展卡尔曼滤波对运动目标位置预

测,将多帧点云尺寸联合迭代作为波门,对下一帧点云进行点簇扩展。通过实验前后的对比证明,改进聚类算法的聚类准确度可达到 90%,点云扩展算法的聚类准确度可达到 92%,这两种算法能够有效提高运动目标点云成像的准确度,为后续的姿态识别等应用奠定了良好的基础。

参考文献:

[1] 逄暄,肖泽龙. 基于圆锥扫描的 W 波段毫米波辐射成像系统[J]. 测试技术学报, 2018, 32(5):450-454.
 LU Xuan, XIAO Zelong. A MMW radiometric imaging system based on conical scanning at W band[J]. Journal of Test and Measurement Technology, 2018, 32(5): 450-454. (in Chinese)

[2] LATTANZI E, DROMEDARI M, FRESCHI V. A scalable multitasking wireless sensor network testbed for monitoring indoor human comfort [J]. IEEE Access, 2018, 6: 17952-17967.

[3] KIM Y, ALNUJAIM I, OH D. Human activity classification based on point clouds measured by millimeter wave MIMO radar with deep recurrent neural networks [J]. IEEE Sensors Journal, 2021, 21(12): 13522-13529.

[4] 李洋,李悠,林赞,等. 面向封闭环境行人监测的毫米波雷达噪声特征研究[C]//第十六届全国信号和智能信息处理与应用学术会议论文集,计算机工程与应

- 用, 2022: 406-410.
- [5] 鞠夕强, 孟文, 孟祥印, 等. 一种改进的毫米波雷达聚类算法[J]. 科学技术与工程, 2021, 21(20): 8537-8543.
- JU Xiqiang, MENG Wen, MENG Xiangyin, et al. An Improved clustering algorithm for millimeter wave radar[J]. Science Technology and Engineering, 2021, 21(20): 8537-8543. (in Chinese)
- [6] 刘昀晓. 交通场景毫米波监视雷达多目标跟踪算法研究[D]. 北京: 北京信息科技大学, 2021.
- [7] 王宇, 陈婧, 王高. 基于改进的模糊C均值聚类算法的颗粒种子图像分割方法[J]. 中北大学学报(自然科学版), 2018, 39(2): 177-182.
- WANG Yu, CHEN Jing, WANG Gao. Particle seed images segmentation method based on the improved fuzzy C-means clustering Algorithm [J]. Journal of North University of China (Natural Science Edition), 2018, 39(2): 177-182. (in Chinese)
- [8] YANG Juhua, LI Xutong, XING Dongfeng, et al. Turnout fault diagnosis based on DBSCAN/PSO-SOM[J]. Journal of Measurement Science and Instrumentation, 2022, 13(3): 371-378.
- [9] ZHANG R Y, CAO S Y. Robust and adaptive radar elliptical density-based spatial clustering and labeling for mm wave radar point cloud data [C]//2019 53rd Asilomar Conference on Signals, Systems, and Computers. IEEE, 2019: 919-924.
- [10] SHEN L, LI K, ZHU L, et al. Radar Point cloud clustering method based on optimization [C]//2021 IEEE 4th International Conference on Computer and Communication Engineering Technology (CCET). IEEE, 2021: 158-162.
- [11] PEGORARO J, ROSSI M. Real-time people tracking and identification from sparse mm-wave radar point clouds[J]. IEEE Access, 2021, 9: 78504-78520.
- [12] KUMAR M N, SAMHITHA G, SRAVYA K. Vehicle speed detection using Kalman filter and DBSCAN [C]//2022 International Conference on Computer Communication and Informatics (I-CCCI). IEEE, 2022: 1-5.
- [13] 林凤泰, 严蘋蘋, 张慧, 等. 基于最近迭代点的毫米波雷达点云数据处理方法[J]. 信号处理, 2023, 39(2): 288-297.
- LIN Fengtai, YAN Pingping, ZHANG Hui, et al. Iterative closest point method for point cloud data processing of millimeter wave radar [J]. Journal of Signal Processing, 2023, 39(2): 288-297. (in Chinese)
- [14] ZHANG X, CAO L, WANG T. A density-based adaptive distance fuzzy clustering algorithm based on the multi-target traffic radar [C]//2020 13th International Congress on Image and Signal Processing, Bio-Medical Engineering and Informatics (CISP-BMEI). IEEE, 2020: 511-515.
- [15] 沈磊, 刘康. 毫米波雷达的扩展目标点云聚合算法[J]. 现代电子技术, 2023, 46(3): 1-5.
- SHEN Lei, LIU Kang. Extended-target point cloud aggregation algorithm for millimeter wave radar [J]. Modern Electronic Technology, 2023, 46(3): 1-5. (in Chinese)
- [16] LI M, STOLZ M, FENG Z, et al. An adaptive 3D grid-based clustering algorithm for automotive high resolution radar sensor [C]//2018 I-EEE International Conference on Vehicular Electronics and Safety (ICVES). IEEE, 2018: 1-7.
- [17] 钟晋孝, 晋良念. 毫米波雷达目标点云稳健自适应聚类方法[J]. 科学技术与工程, 2022, 22(5): 1936-1943.
- ZHONG Jinxiao, JIN Liangnian. Robust and adaptive clustering for point cloud with millimeter wave radar [J]. Science, Technology and Engineering, 2022, 22(5): 1936-1943. (in Chinese)