

复杂环境下毫米波雷达点云聚类算法

张昊宇¹, 薛景怡², 乔 倩²

(1. 浙江海洋大学信息工程学院, 舟山 316022; 2. 浙江海洋大学海洋工程装备学院, 舟山 316022)

摘要: 传统基于密度的带噪声应用空间聚类(Density-based spatial clustering of applications with noise, DBSCAN)算法难以分辨复杂场景, 尤其当两车邻近或人车邻近时, 易引发目标边界模糊、分离困难及噪声归属错误等问题。为有效解决这些问题, 本文提出一种结合自适应网格化和速度信息后处理的DBSCAN算法。首先, 使用对数变换对原始数据进行预处理; 其次, 采用极坐标网格化DBSCAN结合动态椭圆邻域, 有效克服传统算法的空间失真局限; 接着, 利用多普勒速度统计特性, 依据速度一致性准则精准剔除异常噪声点; 然后, 构建空间-速度双重相似性度量机制, 实现噪声点的重归属; 最后, 提出基于速度差异和运动方向差异的聚类分裂策略, 解决混合目标的重叠分离问题。实验结果表明, 相比传统DBSCAN算法, 本文算法在聚类准确率和噪声抑制率方面均有显著提高, 为复杂环境下毫米波雷达点云处理提供了高效可靠的解决方案。

关键词: 点云聚类; 毫米波雷达; DBSCAN; 自适应; 聚类

中图分类号: TN957.52 **文献标志码:** A

引用格式: 张昊宇, 薛景怡, 乔倩. 复杂环境下毫米波雷达点云聚类算法[J]. 数据采集与处理, 2026, 41(5): 1509-1521. ZHANG Haoyu, XUE Jingyi, QIAO Qian. Point cloud clustering algorithm of millimeter-wave radar in complex environments[J]. Journal of Data Acquisition and Processing, 2026, 41(5): 1509-1521.

引 言

随着自动驾驶技术的飞速发展, 毫米波雷达凭借其全天候、全天时工作能力、抗干扰性以及高精度等优势, 已成为环境感知系统中不可或缺的核心传感器之一^[1]。该传感器以点云形式输出原始数据, 包含了距离、速度和角度等信息。为实现机器对原始点云数据的有效理解, 点云聚类是必不可少的预处理步骤, 其核心目标是将属于同一物理目标的点云归为一簇, 为后续的目标检测、跟踪等任务奠定基础。

当前主流的聚类算法包括划分法、层次法、基于网格的算法以及基于密度的算法等^[2-4]。其中, 以K-means为代表的划分法聚类需要预先设定聚类数量, 且无法有效处理非球形的簇^[5]。以AGNES^[6]为代表的层次法聚类虽然不需要预先设定聚类个数, 但是该方法的计算复杂度较高, 导致计算效率较低, 不适用于对实时性要求高的环境。基于网格的聚类算法是通过划分数据空间并根据网格密度来执行聚类操作。这种方法虽然能够处理大量的数据, 但是面对毫米波雷达数据量小、点云稀疏的特性时, 使用该方法得到的聚类精准度往往不足^[7]。以基于密度的带噪声应用空间聚类(Density-based spatial clustering of applications with noise, DBSCAN)算法^[8]为代表的聚类算法由于能够发现任意形状的簇, 同时无需预设簇的数量而备受关注。该算法依赖固定密度阈值实现空间聚类, 而毫米波雷达点云在极坐标系下采集并转换到笛卡尔坐标系后表现出显著的非均匀分布特性, 使其聚类性能存在显著局

限性。

具体而言,传统的DBSCAN算法在处理毫米波雷达点云聚类时面临两大挑战。(1)点云空间分布的非均匀性。雷达在笛卡尔坐标系下呈现出显著的“近密远疏”特性^[9]。这种密度显著变化导致传统的聚类算法难以获得精准结果。(2)动态场景的复杂性。单纯依赖空间信息作为聚类依据在动态环境下易出现一些问题:同一目标的点云因速度差异被错误分割;聚类结果中有效点云被误判为噪声点;不同运动状态的目标在空间上接近,甚至部分点云存在重叠,仅凭空间信息极易产生错误的聚类结果。

目前,体素法常用于将非结构化的离散点云转化为规则有序的数据表达,以便更规范地进行邻域定义和特征提取^[10]。传统的体素划分大多基于笛卡尔直角坐标系的均匀网格。这种标准化的空间划分更适合处理激光雷达数据,当直接应用于呈现“近密远疏”特性的毫米波雷达点云时,会使远处属于同一目标的稀疏点被网格强行割裂,导致几何特征失真。因此,要通过网格化手段优化雷达聚类,必须使用符合毫米波雷达物理特性的空间划分机制。

为解决上述问题,本文以DBSCAN算法为基础,借鉴体素法思想并克服空间失真缺陷,提出了一种结合自适应网格化与速度信息后处理的DBSCAN聚类算法。该算法主要分为两个阶段:第一阶段采用基于极坐标的自适应网格DBSCAN算法,构建与雷达原始数据特性匹配的非均匀网格,并设计自适应邻域搜索策略,以此解决点云的空间密度变化问题;第二阶段,利用雷达提供的多普勒速度信息对初始聚类结果进行修正,通过目标点云速度一致性剔除簇内的速度异常点,并结合空间信息将误判为噪声点的有效点进行重归属至正确目标簇。最后根据速度方向一致性和运动方向差异有效分离在空间上重叠的目标。这种算法能够显著提高毫米波雷达点云聚类在复杂动态环境下的准确性和鲁棒性。

1 自适应网格DBSCAN算法

DBSCAN算法作为一种基于密度的聚类算法,其核心理念是:如果一个点周围一定距离 ϵ 内存在足够的邻居点,则视该点为核心点。从任意核心点出发,将其距离 ϵ 内的所有邻居点都纳入同一簇内,并将新纳入的核心点的邻居一并纳入簇,直到该密度相连的区域完全被搜索。其他没有被任何簇纳入的点都被称为噪声点。图1展示了该算法的原理。

DBSCAN算法高度依赖两个参数^[11]——邻域半径Eps和最小邻居数Minpts。这两个参数的选择需要通过不断试验才能确定,如果选择不当的参数就会导致错误聚类甚至是无法聚类的情况^[12-13]。

1.1 网格化数据空间

高分辨率雷达原始数据以极坐标结构输出,其在距离方向和方位角方向的采样分辨率是固定的。但当这些数据通过三角函数转换为笛卡尔坐标系时,采样密度因为方位角方向的最小采样间距随距离增大而增大,导致呈现出显著的“近密远疏”特性。传统DBSCAN算法使用固定邻域半径和最小邻居数,无法适应密度分布,易造成近处杂波易被误聚类,而远处真实




图1 DBSCAN算法原理图

Fig.1 Principle diagram of DBSCAN algorithm




图2 传统DBSCAN算法对远距离物体和杂波的影响

Fig.2 Influence of traditional DBSCAN algorithm on distant objects and clutter

目标因点云数量不足无法成簇(如图2所示)。

为解决上述非均匀密度下的聚类失效问题,本文首先采用一种基于对数变换的预处理方法,用于修正雷达点云中存在的非均匀密度分布。具体而言,就是将原始的非均匀点云空间映射到一个分布更为均匀的虚拟极坐标空间中。对于极坐标下的任意点 (r, θ) ,对其径向距离 r 应用非线性变换,生成新的虚拟距离 r' ,同时保持其角度 θ 不变。公式为

$$r' = a \ln(1 + br) \quad (1)$$

式中: a 为尺度系数,用于将变换后的虚拟距离 r' 调整至与原始距离 r 近似的数值范围,从而保持数据原有的尺度特性; b 为压缩系数,用于调节距离压缩的程度。 b 值越大,对近距离点的拉伸和对远距离点的压缩效果越显著。

尽管对数变换在一定程度上改善了点云的均匀性,但仍不能完全实现均匀化。因此,为了进一步高效处理密度不均问题,又采用 r - θ 网格结构将雷达原始测量数据直接映射到二维极坐标网格中(如图3所示)。通过网格化,邻域搜索无需遍历整个数据集,而是被局限在包含查询点的网格单元及相邻的少数几个单元内。该策略极大地减少了邻域搜索的候选点数量,从而降低了平均时间复杂度。

然而,采用极坐标进行网格划分导致了新的问题,不同位置的网格单元所覆盖的物理面积和形状都存在显著差异。这种差异对于后续准确定义邻域提出了挑战,需要使用某种方式去补偿几何上的不均匀性。本文在自适应邻域搜索中提出了详细的解决方案。

1.2 自适应邻域搜索

为解决极坐标网格物理尺寸不均的问题,本文采用自适应邻域搜索策略。其核心是通过动态邻域搜索范围,使其能够根据网格单元的具体位置和物理尺寸自适应变化。在距离 r' 方向上,由于网格分辨率是固定的,搜索范围可以保持不变。但在方位角 θ 方向上,网格单元的弧长会随距离 r' 的增大而增加。如果在该方向上仍然采用固定的邻域搜索范围,那么将导致近处密集区域本应分离的簇被错误合并,而远处稀疏区域同一目标的有效点被分裂或误判为噪声。因此,该策略在进行邻域搜索时,需要计算局部密度系数为

$$C_{i,j} = \frac{r'_{i,j}}{2\Delta r} \left(\sin(\theta_{i,j+1} - \theta_{i,j}) + \sin(\theta_{i,j} - \theta_{i,j-1}) \right) \quad (2)$$

式中: i, j 为网格在 r'/θ 方向上的索引; $r'_{i,j}$ 为当前单元到传感器的径向距离; Δr 为径向分辨率; $\theta_{i,j}$ 为方位角。该系数用于估计某个具体小区域内大概的有效目标点数量,其值将随着距离的增大而减小。

运行时,根据比值 $C_{i,j}$ 确定的搜索区域在 r' 方向上具有恒定的值,而在 θ 方向上取决于比值 $C_{i,j}$ 。 θ 方向上的搜索距离 w 为

$$w = \frac{g}{fC_{i,j}} \quad (3)$$

式中: g 为网格大小; f 为形状因子。当邻域在 r' 方向和 θ 方向上的尺寸不同时,搜索区域会变为椭圆形。越靠近传感器的位置,椭圆会变得越来越窄;越远离传感器的位置,搜索区域将近似于圆形(如图4所示)。该方法有效补偿了极坐标网格化带来的失真问题,使得算法更好地适应点云的非均匀密度分布。




图3 传感器在网格中的数据输入以及笛卡尔坐标系下的数据转换

Fig.3 Sensor data input in the grid and data transformation in the Cartesian coordinate system

2 基于速度信息的聚类后处理

尽管基于自适应网格的DBSCAN算法在一定程度上提高了DBSCAN的性能,但在复杂动态场景中,仅仅依靠空间密度信息进行聚类仍存在局限性。为进一步提升聚类结果的准确性,引入了基于速度信息的聚类后处理模块。该模块利用雷达点云中的多普勒速度信息,对初步的聚类结果进行细化和修正。

2.1 速度异常点剔除

构成同一物理目标的点云在雷达坐标系下的径向速度表现出高度的一致性,即所有点的速度围绕一个共同的均值小范围波动。若某个点的速度显著偏离簇的整体速度特性,那么认为该点云为噪声或不属于该目标。

针对DBSCAN算法初步聚类得到的聚类 C ,需要收集 C 中所有点 P 的径向速度 V_P 。计算 C 的速度均值 μ 和速度标准差 σ ,有

$$\mu = \frac{1}{N} \sum_{P \in C} V_P \quad (4)$$

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{P \in C} (V_P - \mu)^2} \quad (5)$$

式中: V_P 为点 P 的径向速度; N 为聚类 C 中的点数。

遍历聚类 C 中的每个点 P 。如果速度 V_P 满足条件 $|V_P - \mu| > k * \sigma'$,则判定该点为速度异常点。 k 为预设的阈值系数;同时为了避免因为 σ 过小而过度剔除, $\sigma' = \max(\sigma, \sigma_{\min})$ 。该参数主要参考了雷达的多普勒分辨率,并且考虑车辆震动以及非中心点径向速度偏离等引起的正常速度波动。该速度异常点剔除方法直接利用了目标的运动特性。通过剔除与簇主体速度不一致的点,有效地提升了聚类效果。

2.2 噪声点重归属

在初始聚类及异常点剔除阶段,部分属于真实目标的有效点云,因为传感器噪声、目标遮挡或目标边缘点云稀疏等原因可能被错误标记为噪声点。此类误判会导致目标点云信息缺失,降低检测结果的完整性。为了将这些被误判的有效点重归属,本文提出了一种解决方法。其核心思想是:在完成初步聚类 and 速度异常点剔除后,对每个已识别的聚类,在其空间邻域内搜索被标记为噪声的点,然后结合候选点的空间邻近性和速度信息,判断其是否应被重新分配至该聚类。

首先,计算当前聚类 C 的聚类中心为

$$P_{\text{center}} = \frac{1}{|C|} \sum_{P \in C} P \quad (6)$$

式中: $|C|$ 为聚类 C 中的点云数量; P 为点云的空间坐标。

计算聚类 C 的代表性速度为

$$V_{\text{rep}} = \frac{1}{|C|} \sum_{P \in C} V \quad (7)$$

式中 V 为点云的径向速度。




图4 基于网格的DBSCAN算法对远距离物体和杂波的影响

Fig.4 Influence of grid-based DBSCAN algorithm on distant objects and clutter

为聚类 C 设置搜索半径 r 和速度相似性阈值 ΔV 。其中, r 参考了目标的典型物理尺寸; ΔV 则考虑目标的微多普勒效应, 在包容合理的物理波动的同时排除随机环境噪声。以 C 的中心和代表性速度为基准, 对全局噪声点集中的每一个噪声点 P_{noise} 设置以下两个判断准则。

(1) 距离准则: 计算噪声点 P_{noise} 与聚类中心 P_{center} 之间的欧氏距离 d , 表达式为

$$d(P_{\text{noise}}, P_{\text{center}}) \leq r \quad (8)$$

(2) 速度相似性准则: 计算噪声点速度 V_{noise} 与聚类代表性速度 V_{rep} 的绝对差值, 表达式为

$$|V_{\text{noise}} - V_{\text{rep}}| \leq \Delta V \quad (9)$$

如果噪声点 P_{noise} 同时满足这两个准则, 则将从噪声点集中移除, 并重新分配给聚类 C 。

2.3 重叠分离

当多个运动目标在空间上紧密相邻时, 算法容易将它们错误地合并为单一聚类。尽管这些目标在空间上相邻, 其运动矢量往往呈现出显著差异。本文提出通过分析聚类内部的速度分布特征来实现对错误合并聚类的有效分离。当聚类满足以下 3 个条件时对其进行分离:

(1) 规模充分性准则, 表达式为

$$|C| \geq N_{\min} \quad (10)$$

式中 $N_{\min}$ 为允许分离的最小聚类规模。

(2) 速度离散度, 表达式为

$$\sigma \geq \sigma_{\text{threshold}} \quad (11)$$

式中 $\sigma_{\text{threshold}}$ 为速度标准差阈值。

(3) 双向速度存在性, 表达式为

$$\exists V_p, V_n \in C: V_p > V \text{ 且 } V_n < -V \quad (12)$$

式中: V_p 为聚类中速度值为正的点云径向速度; V_n 为聚类中速度为负的点云径向速度; V 为判断显著正负速度的阈值。该准则用于检测同一簇内是否存在运动方向显著差异的点。若检测到该差异, 则表明聚类中可能包含具有不同运动轨迹或者不同运动状态的多个目标, 此时应该将该聚类分裂以确保聚类结果的准确性。

3 算法流程

3.1 第一阶段: 初始聚类

初始聚类过程中采用极坐标网格划分策略, 同时根据雷达几何特性, 采用椭圆形邻域替代传统 DB-SCAN 的圆形邻域。通过比率矩阵 C 对椭圆进行自适应调整。计算邻域内的点数, 若达到密度阈值则标记为核心点创建并扩展聚类; 若邻域点数不足则标记为噪声点。其中, 密度阈值主要基于雷达的角分辨率与目标最小点云密度进行设定。具体流程如图 5 所示。

3.2 第二阶段: 速度后处理优化

速度后处理优化过程对聚类计算速度统计量, 剔除速度偏差超过阈值的异常点为噪声; 在聚类周围搜索同时满足距离和速度相似性条件的噪声点并重新归属至该聚类中。此外, 还需要检查是否存在速度标准差过大并包含速度方向不一致的混合聚类, 对其进行按速度方向分裂。其中, 速度阈值依据相同目标内点云速度分布集中、不同目标间速度差异相对明显的特点确定, 以此在保留目标内部一致性的同时提高对异常点和混合聚类的区分能力。重复上述过程直至算法收敛, 最终输出聚类结果。具体流程如图 6 所示。




图5 第一阶段:初始聚类流程图

Fig.5 Phase 1: Flowchart of initial clustering




图6 第二阶段:速度后处理流程图

Fig.6 Phase 2: Flowchart of velocity post-processing

4 实验结果与分析

为评估本文算法的性能,本文设计并执行对比实验。实验采用工作频率为 77 GHz 的毫米波雷达,参数配置如表 1 所示。测量过程中,雷达被放置于距离地面 0.5 m 处。通过考虑表 1 中雷达的探测性能以及场景的需求,将极坐标系下的径向距离和方位角均划分为 120 个网格。具体而言,径向网格的大小设定为 0.5 m/格,方位角网格的大小设定为 1°/格。将本文算法与传统 DBSCAN 算法及基于自适应网格 DBSCAN 算法对比,获取实验数据并进行分析。

4.1 实验结果对比

4.1.1 车辆重叠分离

场景1如图7所示。数据包含噪声、6辆汽车和2个行人。其中,行人1和行人2分别以2 m/s的径向速度远离和靠近雷达。车辆1和车辆2则分别以22 m/s的径向速度靠近和远离雷达,车辆3以12 m/s的径向速度远离雷达,车辆4以7 m/s的径向速度缓慢靠近雷达。车辆5以径向速度3 m/s远离雷达,车辆6以8 m/s的径向速度靠近雷达,两辆车在空间上邻近,部分点云出现重叠。

图8展示了传统DBSCAN算法的聚类结果。该算法采用全局固定的邻域半径Eps和最小邻居数Minpts,使其难以适应点云的非均匀密度。具体而言,聚类结果出现明显缺陷:近处密集区域的噪声点被错误识别为独立簇(如行人3),同时,部分噪声点与附近真实目标点云(如车辆2和4、行人1)合并。更重要的是,由于仅依赖空间信息,两辆空间上邻近的车辆(车辆5和6)被错误地合并为一个聚类,导致识别出的车辆数目少于真实目标数量。




图7 真实标签(场景1)
Fig.7 True label (Scene 1)




图8 传统DBSCAN聚类结果(场景1)
Fig.8 Traditional DBSCAN clustering results (Scene 1)

图9展示了仅使用自适应网格的DBSCAN算法的聚类结果。相比于传统DBSCAN(图8),该算法在一定程度上改善了噪声处理效果,有效避免噪声点错误聚合成伪簇。但仍然存在少量邻近噪声点被错误归入附近簇的问题(如车辆2和车辆4)。此外,由于单纯依赖空间密度,远处稀疏区域的有效点云(如车辆1)易被误判为噪声点,从而影响了目标的完整性。和传统的DBSCAN算法一样,该算法同样无法有效区分空间上紧密相连的车辆(如车辆5),表明其在重叠目标分离方面的局限性。

图10展示了本文提出的结合自适应网格和速度信息后处理算法的聚类结果。与图8、9对比可见,本文算法取得了显著提升。首先,在噪声抑制方面,通过速度异常点剔除,成功将车辆2和车辆4中与目标主体速度不一致的噪声点剔除。其次,在目标完整性方面,通过噪声点重归属,有效回收了车辆1中因点云稀疏而被初始聚类误判为噪声点的真实目标点云,确保了目标的完整性。最为关键的在于目标分离能力。面对空间上紧邻甚至部分点云重叠的车辆5和车辆6,传统算法仅依靠空间信息难以对其有效区分。本文算法通过充分利用两辆车之间高达11 m/s的显著径向速度差异,结合毫米波雷达的0.039 m/s多普勒分辨率确保的可靠速度测量,在速度后处理阶段成功将图8和图9中被错误合并的车辆聚类精确地分裂为独立的车辆5和车辆6,从而实现了空间邻近重叠目标的有效区分。这些改进共

同提升了算法在复杂雷达点云环境下的鲁棒性和准确性,尤其是在处理重叠目标和非均匀密度点云方面的性能。




图9 基于网格的DBSCAN聚类结果(场景1)

Fig.9 Clustering results of grid-based DBSCAN (Scene 1)




图10 自适应网格+速度优化后聚类结果(场景1)

Fig.10 Adaptive grid and speed optimization clustering results (Scene 1)

4.1.2 人车重叠分离

场景2如图11所示,数据包含噪声、5辆汽车和3个行人。其中,行人1和行人2分别以2 m/s的径向速度远离和靠近雷达。车辆1和车辆2则分别以22 m/s的径向速度靠近和远离雷达,车辆3以12 m/s的径向速度远离雷达,车辆4以7 m/s的径向速度缓慢靠近雷达。车辆5和行人3在空间上紧密邻近,车辆5以径向速度5 m/s远离雷达,而行人3以1.5 m/s的径向速度远离雷达。

图12显示了传统DBSCAN聚类结果,该算法的聚类结果存在两个主要问题。首先,靠近传感器的噪声点未能有效剔除,反而与邻近的目标有效点聚集形成聚类。其次,空间邻近的车辆和行人由于仅依赖空间信息,无法有效分离。




图11 真实标签(场景2)

Fig.11 True label (Scene 2)




图12 传统DBSCAN聚类结果(场景2)

Fig.12 Traditional DBSCAN clustering results (Scene 2)

图13显示了基于网格化DBSCAN聚类结果。该算法在噪声处理方面有着显著改进,近处区域的噪声点并未形成独立簇,但邻近区域噪声点被误判为有效点云,远处的有效点云则被误判为噪声点。此外,与传统DBSCAN算法类似,空间上紧邻的车辆和行人也无法有效分离。

图14显示了本文提出的算法聚类结果。该算法在初始聚类基础上还引入了速度后处理模块进行优化。通过速度异常点剔除,成功将车辆4中的噪声点剔除。同时,有效回收了车辆1和车辆3中因点

云稀疏而被初始聚类误判为噪声点的真实目标点云。最关键的在于,本文算法准确捕捉到车辆5和行人3之间的径向速度差异,该差异远超雷达的多普勒分辨率,在速度后处理阶段能够识别并利用该差异成功将图12和图13中未能分离的邻近车辆和行人精确地分裂为独立的聚类,有效解决了空间重叠目标的区分问题。




图13 基于网格化DBSCAN算法聚类结果(场景2)

Fig. 13 Clustering results of grid-based DBSCAN (Scene 2)




图14 自适应网格+速度优化后聚类结果(场景2)

Fig. 14 Adaptive grid and speed optimization clustering results (Scene 2)

4.2 聚类评价指标与稳定性分析

4.2.1 聚类评价指标

为了评估改进算法及对比算法,引入3个评价指标:轮廓系数(Silhouette coefficient, SC)^[14]、Calinski-Harabaz指数(CH)^[15]及戴维森堡丁指数(Davies-Bouldin, DB)^[16]。

轮廓系数通过簇内相似度与簇间相似度之比来评估聚类质量^[17],取值范围为 $[-1, 1]$ 。当样本点与同一聚类内的其他点的相似度非常高时,该值就会接近1,这也反映出较好的聚类效果。相反,如果轮廓系数接近-1,则说明样本点被分配到错误的簇中。其计算公式为

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (13)$$

式中: $a(i)$ 为样本点 i 到同一聚类内其他样本点的平均距离; $b(i)$ 为样本点 i 到最近聚类的平均距离。

CH指数通过计算簇间离散度和簇内离散度之比来评估聚类质量,取值范围为 $[0, \infty)$ 。CH指标的值越大表示该聚类的效果越好^[18]。其计算公式为

$$W = \sum_{k=1}^K \sum_{x \in C_k} (x - c_k)^2 \quad (14)$$

$$B = \sum_{k=1}^K n_k (c_k - c)^2 \quad (15)$$

$$CH = \frac{B}{W} \frac{n - K}{K - 1} \quad (16)$$

式中: W 为簇内离散度(紧致性),每个簇内的所有点到该簇中心的欧氏距离的平方和,并将所有簇的该值进行累加; B 为簇间离散度(分离性),每个簇的中心到全局所有点云的总中心的距离的平方,并乘以该簇所包含的点数进行加权,最后将所有簇累加; K 为聚类的数量; k 为当前聚类; C_k 表示第 k 个聚类内的所有点; c_k 为第 k 个聚类的中心; n_k 为第 k 个聚类内点云数量; n 为所有点云的数量; c 为所有聚类中心的平均中心。

DB 指数通过计算簇内紧致度与簇间分离度之间的平均最坏情况来评估聚类质量,取值范围是 $[0, \infty)$ 。DB 指数的值越小表示聚类效果越好。其公式为

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{s_i + s_j}{d(c_i, c_j)} \right) \quad (17)$$

式中: s_i 为聚类 i 中每个点到其聚类中心 c_i 的平均距离; $d(c_i, c_j)$ 为聚类中心 c_i 和聚类中心 c_j 的距离; $\max_{j \neq i}$ 为固定第 i 个簇,遍历所有 $j \neq i$,取括号内比值最大的那个。

通过上面的3个评价指标对传统DBSCAN算法、基于网格化的DBSCAN算法以及自适应网格与速度后处理结合的算法进行性能指标计算,结果如表2所示。可以看出,本文算法在各项聚类评价指标上均显著优于传统DBSCAN算法以及网格化DBSCAN算法。表2中的黑体表示在评价维度上结果最优。以人车重叠场景为例,本文算法的轮廓系数比传统DBSCAN算法提升了14.4%,CH指标提升了381.3%,DB指标降低了41.5%。这些指标的优化,充分验证了引入速度后处理的有效性。轮廓系数的提升与DB指标的降低都表明聚类结果的“内紧外疏”得到了强化,目标的边界更加清晰。而CH指标的大幅增长,直接反映出算法的鲁棒性得到提升。综上,本文算法能够有效克服因目标重叠造成的聚类模糊性,显著降低了复杂场景下的目标误分割与误合并的可能性。

表2 算法性能评估指标对比

Table 2 Comparison of algorithm performance evaluation metrics

场景	算法	轮廓系数	CH 指标	DB 指标
车辆重叠	传统DBSCAN算法	0.755 9	975.24	0.348 7
	网格化DBSCAN算法	0.772 8	992.48	0.324 0
	网格化+速度后处理	0.826 8	3 554.29	0.215 6
人车重叠	传统DBSCAN算法	0.741 5	705.41	0.328 9
	网格化DBSCAN算法	0.775 2	736.55	0.278 6
	网格化+速度后处理	0.848 3	3 395.42	0.192 3

4.2.2 稳定性分析

传统DBSCAN算法在毫米波雷达点云聚类中,面对空间位置邻近甚至重叠的物理目标时,常将不同的目标错误合并为同一聚类,或将部分真实目标点误判为噪声。这些现象导致了聚类结果的不稳定性和准确性不足,严重影响了算法在复杂环境下的稳定性。本文算法通过融合多普勒速度信息,对初步聚类结果进行优化修正,显著提升了在重叠场景下目标的识别精度和聚类稳定性。

为了直接量化本文算法在复杂环境下点云归属的精确性与聚类结果的稳定性,本文引入了点云准确率(Accuracy, ACC)作为评价指标。该指标从点云层面衡量聚类结果的精确性,即被正确分类的点云数量占所有点云总数的比例,公式为

$$ACC = \frac{\text{被正确分类的点云数量}}{\text{总点云数量}} \times 100\% \quad (18)$$

式中总点云数量为场景中所有雷达点云的总和。ACC值越高,表明算法在处理重叠目标时点云的归属精确性与聚类稳定性越强,能够更好地形成清晰的目标边界并有效避免目标欠分割。

实验结果表明,在车辆重叠场景下,本文算法的聚类准确率达到88.1%,明显优于传统DBSCAN算法的79.59%。这表明本文算法在处理空间上紧邻甚至部分点云重叠的车辆目标时,能够更加精确地划分目标边界,减少点云的错误归属。在人车重叠场景下,由于人与车在尺寸、点云密度以及径向速度上存在显著差异,这对点云的精确归属提出了更高要求。在此场景下,本文算法的准确率也由传统DB-

SCAN算法的86.55%提升至97.24%,进一步验证了本文算法在复杂环境下处理重叠目标时的鲁棒性和准确性,有效解决了传统DBSCAN算法在复杂环境下的不稳定性问题。

5 结束语

本文提出了一种结合自适应网格化与速度信息后处理的DBSCAN聚类算法。该算法首先使用对数变换将数据进行均匀化,然后通过极坐标系下的自适应网格DBSCAN处理点云分布的“近密远疏”特性,再利用目标径向速度的一致性进行聚类后处理,包括速度异常点剔除、基于空间-速度双重判据的噪声点重归属以及聚类分裂。实验结果表明,该方法在减少误分类、提升聚类准确性方面效果显著。然而,单站毫米波雷达的径向速度信息仍存在不完整性,限制了对目标二维或三维运动状态的全面感知,特别地,当空间上紧邻的多个目标处于相对静止状态时,由于缺乏可观测的多普勒速度差异,本文所提的速度后处理分裂策略会因不满足判定准则而失效。未来的研究将探索引入雷达反射截面积与回波功率强度。即便是并排紧邻的静止目标,其点云的能量分布也会呈现双峰特性。在计算空间距离的基础上引入反射功率权重,精准切断目标间的错误连接。此外,结合多传感器融合技术或者利用多帧数据进行轨迹追踪,以弥补速度信息的缺失,实现对目标运动状态更全面、鲁棒的感知与分离。

参考文献:

- [1] MILIND S P, MURAT T, DAN W, et al. Automotive radars: A review of signal processing techniques[J]. IEEE Signal Processing Magazine, 2017, 34(2): 22-35.
- [2] 贾瑗玮. 基于划分的聚类算法研究综述[J]. 电子设计工程, 2014, 22(23): 38-41.
JIA Aiwei. Survey on partitioned clustering algorithms[J]. Electronic Design Engineering, 2014, 22(23): 38-41.
- [3] 张鹏. 毫米波交通雷达中的聚类算法研究[D]. 西安: 西安电子科技大学, 2023.
ZHANG Peng. Research on clustering algorithm in millimeter wave traffic radar[D]. Xi'an: Xidian University, 2023.
- [4] 陈新泉, 周灵晶, 刘耀中. 聚类算法研究综述[J]. 集成技术, 2017, 6(3): 41-49.
CHEN Xinquan, ZHOU Lingjing, LIU Yaozhong. Review on clustering algorithms[J]. Journal of Integration Technology, 2017, 6(3): 41-49.
- [5] 杨晓明. DBSCAN聚类算法的改进研究与应用[D]. 大连: 大连交通大学, 2023.
YANG Xiaoming. Improvement research and application of DBSCAN clustering algorithm[D]. Dalian: Dalian Jiaotong University, 2023.
- [6] 崔世斌, 牛智勇, 李若楠, 等. 基于AGNES聚类算法的城市交通运行状态分析研究[J]. 西昌学院学报(自然科学版), 2020, 34(4): 62-67.
CUI Shibin, NIU Zhiyong, LI Ruonan, et al. Research on urban traffic operation state analysis based on AGNES clustering algorithm[J]. Journal of Xichang University (Natural Science Edition), 2020, 34(4): 62-67.
- [7] 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.
- [8] 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 Pinpin, 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.
- [9] 陈奕龙, 王青春. 道路场景下毫米波雷达点云聚类处理算法[J]. 智能计算机与应用, 2024, 14(1): 156-161, 167.
CHEN Yilong, WANG Qingcun. A clustering algorithm for millimeter wave radar point cloud in road scenarios[J]. Intelligent Computer and Applications, 2024, 14(1): 156-161, 167.
- [10] 张心宇. LiDAR点云目标检测及基于FPGA的实现研究[D]. 大连: 大连理工大学, 2023.
ZHANG Xinyu. Research on LiDAR point cloud target detection and FPGA-based implementation[D]. Dalian: Dalian University of Technology, 2023.

- [11] 王子洋,李琼琼,张子蕴,等. 应用于无人驾驶车辆的点云聚类算法研究进展[J]. 世界科技研究与发展, 2021, 43(3): 274-285.
WANG Ziyang, LI Qiongqiong, ZHANG Ziyun, et al. Research progress of unmanned vehicle point cloud clustering algorithm [J]. World Sci-Tech R&D, 2021, 43(3): 274-285.
- [12] 王光,林国宇. 改进的自适应参数DBSCAN聚类算法[J]. 计算机工程与应用, 2020, 56(14): 45-51.
WANG Guang, LIN Guoyu. Improved adaptive parameter DBSCAN clustering algorithm[J]. Computer Engineering and Applications, 2020, 56(14): 45-51.
- [13] 卢建云,邵俊明,张蔚. 基于RAPIDS的无参DBSCAN算法[J]. 数据采集与处理, 2023, 38(2): 426-438.
LU Jianyun, SHAO Junming, ZHANG Wei. Parameter-free DBSCAN algorithm based on RAPIDS[J]. Journal of Data Acquisition and Processing, 2023, 38(2): 426-438.
- [14] 朱连江,马炳先,赵学泉. 基于轮廓系数的聚类有效性分析[J]. 计算机应用, 2010, 30(S2): 139-141, 198.
ZHU Lianjiang, MA Bingxian, ZHAO Xuequan. Clustering validity analysis based on silhouette coefficient[J]. Journal of Computer Applications, 2010, 30(S2): 139-141, 198.
- [15] CALINSKI T, HARABASZ J. A dendrite method for cluster analysis[J]. Communications in Statistics, 1974, 3(1): 1-27.
- [16] DAVIES D L, BOULDIN D W. A cluster separation measure[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1979, 1(2): 224-227.
- [17] 焦继斌. 基于改进DBSCAN算法的船舶异常行为检测[D]. 大连:大连海事大学, 2024.
JIAO Jibin. Ship abnormal behavior detection based on improved DBSCAN algorithm[D]. Dalian: Dalian Maritime University, 2024.
- [18] 蔡忱. 一种基于噪声抑制的聚类有效性指标及其应用研究[D]. 西安:西安理工大学, 2020.
CAI Chen. A clustering validity index based on noise suppression and its application[D]. Xi'an: Xi'an University of Technology, 2020.

作者简介:



张昊宇(1987-),通信作者,男,博士研究生,讲师,研究方向:雷达系统设计、毫米波雷达算法等, E-mail: haoyu19871202@163.com。



薛景怡(1999-),女,硕士研究生,研究方向:毫米波雷达算法, E-mail: 3294962647@qq.com。



乔倩(1985-),女,博士研究生,讲师,研究方向:宽禁带半导体深紫外光电传感器, E-mail: qiaoqian@zjou.edu.cn。

(编辑:刘彦东)

Point Cloud Clustering Algorithm of Millimeter-Wave Radar in Complex Environments

ZHANG Haoyu^{1*}, XUE Jingyi², QIAO Qian²

(1. School of Information Engineering, Zhejiang Ocean University, Zhoushan 316022, China; 2. School of Marine Engineering Equipment, Zhejiang Ocean University, Zhoushan 316022, China)

Abstract: Conventional density-based spatial clustering of applications with noise (DBSCAN) algorithms struggle in complex dynamic traffic due to non-uniform density of millimeter-wave radar point clouds, causing ambiguous boundaries, poor separability, and noise misclassification. This paper proposes a two-stage enhanced DBSCAN framework integrating adaptive polar grid partitioning with velocity-based post-processing. In stage one, a dynamic elliptical neighborhood search adapts its range according to radial distance, ensuring accurate initial spatial clustering under density variations. Stage two exploits Doppler radial velocity statistics: Outliers are removed via a velocity-consistency criterion, misclassified valid points are reassigned through a spatial-velocity dual-similarity framework, and overlapping clusters are split based on velocity dispersion and motion direction. Experimental results demonstrate significant improvements over traditional DBSCAN. In vehicle-overlapping scenarios, accuracy rises from 79.59% to 88.1%; in pedestrian-vehicle overlaps, from 86.55% to 97.24%. Evaluation metrics show the silhouette coefficient improves by 14.4%, the Calinski-Harabasz index by 381.3%, and the Davies-Bouldin index decreases by 41.5%, indicating clearer boundaries and better cluster stability. The proposed method effectively resolves overlaps and suppresses noise, offering a reliable preprocessing solution for millimeter-wave radar in dynamic environments.

Highlights:

1. Adaptive polar-grid DBSCAN with dynamic elliptical neighborhoods compensates for radial-distance-dependent density distortion, ensuring robust initial clustering under non-uniform point-cloud distribution.
2. Velocity-consistency filtering and spatial-velocity dual-similarity reassignment accurately remove outliers and recover misclassified valid points, preserving target integrity.
3. Overcome the inherent limitation of spatial-only DBSCAN by leveraging velocity dispersion and directional differences to split overlapping clusters, enabling accurate separation of adjacent targets with distinct motions.

Key words: point cloud clustering; millimeter-wave radar; DBSCAN; adaptive; clustering

Foundation items: National Natural Science Foundation of China (No.62571053); Discipline Construction Program of Zhejiang Province (No.1106406022102).

Received: 2025-06-12; **Revised:** 2025-08-15

***Corresponding author, E-mail:** haoyu19871202@163.com.