

文章编号 1004-924X(2025)21-3331-12

基于边缘增强弱监督 K-means 的大口径望远镜 拼接探测器点云分割

冯晓鹏^{1,2}, 王之一^{1*}, 王建立^{1,2}, 刘昌华^{1,2}, 贾建禄^{1,2}, 马爽¹, 刘塔拉¹

(1. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033;

2. 中国科学院大学, 北京 100049)

摘要:为满足大口径大视场望远镜对探测器平面度检测的高效率与高精度要求,本文针对拼接探测器提出一种融合边缘信息约束的 K-means 聚类分割方法。该方法作为平面度评估前的关键预处理步骤,可有效提取规则结构区域,提升后续平面度指标计算的准确性与稳定性,适用于多阶段、多工况下的探测器检测任务。首先,分析了拼接探测器的结构特征,构建了拼接探测器点云数据的处理方法。然后,提取了边缘缝隙特征以及增强边缘的连续性,基于封闭区域内部点集自适应选取初始聚类中心,避免随机初始化导致的收敛不稳定。最后,在 K-means 目标函数中引入边缘惩罚项与高度值异常检测机制,通过迭代优化实现探测器点云的精细化分割。实验结果表明,基于封闭区域的质心初始化方法降低了平均迭代次数,且避免了人工预设聚类数。相比传统方法,边缘约束项与高度异常判据的引入使边界匹配精度提升 50% 以上。该方法能够有效实现拼接探测器数据集的点云分割,为大口径望远镜拼接探测器的研制与使用提供了一种高效的点云分割方法。

关键词:大口径光电望远镜;拼接探测器;点云分割;边缘检测;聚类

中图分类号:TP181;TH751 **文献标识码:**A

doi:10.3718/OPE.20253321.3331

CSTR:32169.14.OPE.20253321.3331

Edge-enhanced weak-supervised K-means point cloud segmentation for large-aperture telescope tiled detectors

FENG Xiaopeng^{1,2}, WANG Zhiyi^{1*}, WANG Jianli^{1,2}, LIU Changhua^{1,2}, JIA Jianlu^{1,2},

MA Shuang¹, LIU Tala¹

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,

Changchun 130033, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

* Corresponding author, E-mail: wangzhiyi18@mails.ucas.edu.cn

Abstract: To satisfy the requirements for high-efficiency and high-precision flatness assessment of detectors used in large-aperture, wide-field telescopes, a K-means clustering segmentation method integrating edge-information constraints is proposed for mosaic detectors. Employed as a preprocessing step prior to flatness evaluation, the method reliably extracts regular structural regions and thereby enhances the accura-

收稿日期:2025-05-12;修订日期:2025-06-18.

基金项目:国家自然科学基金资助项目(No. 11973041)

cy and stability of subsequent flatness-index computations. It is applicable to detector inspection across multiple stages and operating conditions. First, the structural characteristics of the spliced detector were analyzed to develop a dedicated point-cloud processing procedure. Edge-gap features were extracted and edge continuity was reinforced. An adaptive initialization of cluster centers within closed regions was implemented to avoid instability arising from random initialization. Furthermore, edge-penalty terms and height-anomaly detection mechanisms were incorporated into the K-means objective function. Through iterative optimization, refined segmentation of individual detector point clouds was achieved. Experimental results indicate that centroid initialization within closed regions reduces the average number of iterations and removes the need for manual presetting of cluster counts. Compared with conventional methods, the incorporation of edge constraints and height-anomaly detection improves boundary-matching accuracy by more than 50%. The proposed method effectively segments point clouds of spliced detector datasets, offering an efficient segmentation approach for the development and deployment of spliced detectors in large-aperture telescopes.

Key words: large-aperture optical and infrared telescope; segmented detector; point cloud segmentation; edge detection; clustering

1 引 言

随着天文学的迅速发展,大口径、大视场和宽波段的天文光学望远镜逐渐成为解决前沿科学问题的关键技术手段^[1]。为实现对更遥远、更微弱天体的探测,地基天文望远镜的口径持续增大,同时,为了提升对更广阔天空区域的观测能力,其视场也在不断扩展。这一发展趋势导致焦平面尺寸的显著增加。然而,由于目前单个探测器的制造尺寸水平有限,拼接探测器技术成为当前构建大面积焦平面阵列的主流解决方案^[2]。

拼接探测器的平面度是关键指标。对于给定的光学系统,CCD靶面的倾角误差必须严格控制在焦深范围内,否则会导致部分区域偏离最佳成像面,图像虚实不均,难以满足高精度成像需求^[3]。一般来说,拼接后的焦平面对平面度指标要控制在20~30 μm 内,实际集成过程中通常需多次测量与微调,以达到要求的拼接指标^[4]。

拼接探测器的平面度检测要求:一是单个探测器的平面度检测,二是拼接探测器的整体平面度检测。因此,拼接探测器点云数据中存在3类典型误差来源:其一,FPC信号引出位置附近易出现噪声积聚与边缘缝隙重合,形成局部干扰;其二,为满足装调操作与热胀冷缩的结构稳定性,探测器之间预留约0.5 mm的间隙,也会带来一定的结构性误差;其三,光斑边缘的散射效应

会进一步加剧边界区域的测量不确定性。针对上述实际工况,需要设计符合拼接探测器点云集的处理算法,以满足拼接探测器的数据快速提取与精确平面度测量的需求。高精度点云分割是实现上述需求的核心环节^[5]。

传统的点云分割方法主要依赖几何约束和统计规则来人工设计物体的特征,将原始的点云数据分为不重叠的几组区域,来对应场景中的各个对象,比如基于边缘信息^[6]、模型拟合、区域增长的传统分割方法,但其在复杂点云处理中准确率较低^[7]。随着计算机技术的发展,基于投影、基于体素和基于点的分割等^[8-10]利用深度学习处理点云数据的技术已经十分成熟,并且取得了很好的效果。该技术需要将点云转化为适合卷积神经网络处理的规则结构,通过网络模型进行预测。虽然基于深度学习的方法在通用场景分割中展现出明显的优势,但在大口径望远镜拼接探测器这一特殊应用场景中,需对点云数据进行逐点标注,人工耗时较大,该特性决定了传统方法在拼接探测器领域仍具有不可替代性。

现有传统分割方法在拼接探测器工程适用性方面仍存缺陷。Huang等^[11]提出基于邻域密度的自适应区域生长算法,通过动态调整生长准则降低对初始种子点的依赖,然而,该方法需预先进行地面点云提取,对未预处理的拼接点云适

应性较差。Liu 等^[12]基于 PCL 库提出城市点云分割流程,结合体素滤波与欧几里得聚类提取建筑和地形特征,该方法计算效率较高,但对点云密度分布敏感,易产生过分割。Zhu 等^[13]提出基于八叉树体素化与多阶段区域生长的点云分割算法。该方法通过八叉树结构实现高效空间索引,但是该方法对初始种子点选择敏感,可能影响稳定性。

近年来,研究人员尝试通过引入自适应策略提升点云分割性能。张佩翔^[14]等提出一种基于种子点距离阈值与路面波动权幅联合控制的局部阈值自适应地面点云分割方法,可有效提升地面点提取精度。高云龙^[15]等则在模糊 C 均值聚类算法中引入自适应邻域信息,用于增强聚类稳定性与对噪声点的适应性。这些思路为拼接探测器点云分割的精细化处理提供了启发。

针对上述问题,本文提出一种基于边缘增强弱监督 K-means 的大口径望远镜拼接探测器点云分割方法。将法向量估计提取的边缘点集离散为二值图像,通过形态学闭运算填补缝隙,以构建封闭区域,解决传统边缘检测的断裂问题,增强边缘的连续性。基于封闭区域内部点集自适应选取初始聚类中心,避免随机初始化导致的收敛不稳定。在聚类优化阶段,引入边缘惩罚项及高度值异常检测机制,迭代优化目标函数,实现了边缘精细对齐与高度异常区分。该方法在实际拼接探测器场景中实现高效、精细的边缘分割,具备良好的工程实用价值。

2 改进的弱监督机制 K-means 算法

大口径光电望远镜的焦平面由 16 块探测器拼接而成,每块探测器的分辨率为 4096×4096 像元,单个像元尺寸为 $15 \mu\text{m} \times 15 \mu\text{m}$,如图 1 所示。




图 1 可拼接探测器

Fig. 1 Stitched detector

定制化可拼接探测使用碳化硅作为探测器的基底,侧面使用 FPC 作为信号引出,底面预留定位接口和装调接口。如图 2 所示的方式进行对称式拼接,最大化减小信号引出在靶面所占的比例,提高占空比^[16]。该拼接探测器的扫描点云数据在平面度分析处理中会遇到上述一系列问题。




图 2 拼接探测器模型

Fig. 2 Stitched detector model

针对大口径望远镜拼接探测器点云分割中存在的边缘断裂敏感、初始收敛不稳定及边缘精度不足等问题,本文提出一种基于边缘增强弱监督 K-means 的点云分割方法。该方法通过法向量场估计与形态学闭运算约束初始化中心,在聚类优化阶段引入边缘惩罚项与高度异常判据,实现了复杂拼接结构的精细化分割。

2.1 点云去噪

点云数据采集过程中受到环境干扰、激光回波异常、采样误差等因素的影响,容易出现孤立点、毛刺等噪声。在点云预处理阶段,为了去除由于噪声、遮挡或误采样等因素引入的离群点,常采用基于邻域统计的滤波方法。半径滤波法是一种简单而有效的去噪方法^[17],其基本思想是:若某一点在给定半径 r 范围内的邻居点数量小于预设阈值 $N_{\min}$,则认为该点为离群点并予以剔除^[18]。

设点云中某一点为 p_i ,在三维空间中其坐标为 $p_i = (x_i, y_i, z_i)$,则在给定半径 r 内统计其邻居点数量为 N_i 。该方法的判断准则如下:

$$N_i = \left| \left\{ p_j \in P \mid \|p_i - p_j\| \leq r \right\} \right|. \quad (1)$$

若满足以下条件,则认为 p_i 是离群点:

$$N_i < N_{\min}, \quad (2)$$

其中: P 表示点云数据集, $\|\cdot\|$ 表示欧式距离, r 为邻域半径, $N_{\min}$ 为邻域数量阈值。

2.2 基于主成分分析的法向估计量边缘提取

基于法向量的边缘检测通过分析点云局部表面法向量变化来识别物体边界。其核心思想为:在连续表面区域,相邻点法向量方向变化平缓^[19];而在物体边缘处,法向量方向会发生剧烈变化。通过检测法向量间的夹角变化,可有效检测点云中的几何边缘^[20]。

对于点云中任意点 p_i , 其 k 个邻近点构成的局部表面协方差矩阵为:

$$C_i = \frac{1}{k} \sum_{j=1}^k (p_j - \bar{p})(p_j - \bar{p})^T, \quad (3)$$

其中: $\bar{p} = \frac{1}{k} \sum_{j=1}^k p_j$ 为邻域点集的质心, k 为邻域点数。

对每个点 p_i , 根据其邻域点集计算协方差矩阵, 并进行特征分解。最小特征值对应的单位特征向量即为该点的法向量方向 n_i , 即:

$$n_i = v_i, \quad (4)$$

其中: v_i 是最小特征值对应的特征向量, 且满足 $\|n_i\| = 1$ 。

通过比较 p_i 与其邻域点 p_j 的法向量差异来识别边界, 边界点集为:

$$E = \begin{cases} p_i & \arccos\left(\frac{|n_i \cdot n_j|}{\|n_i\| \|n_j\|}\right) > \tau, \\ 0 & \text{else} \end{cases}, \quad (5)$$

其中: n_i 表示点 p_i 的法向量, n_j 表示点 p_j 的法向量, τ 表示预设角度阈值。

2.3 形态学闭运算获取初始中心

本文采用将点云投影为二维图像后进行二值化与形态学处理的策略, 这一思路已广泛应用于点云分割任务中。鲁荣荣等^[21]通过图像坐标映射与连通域分析实现平面分割, 郭清达等^[22]结合空间投影与图像形态学处理提高了目标区域的分离度, Chen 等^[23]在激光点云滤波中引入形态学策略以去除非地面噪声。与这些方法不同, 本文进一步结合投影图中边缘结构的法向量特性, 提出了一种基于边缘弱监督机制的 K-means 聚类初始化方法。

不同于传统 K-means 使用随机质心初始化的方式, 本方法在边缘点形成的封闭区域中选取质心作为初始中心点, 有效降低了初始位置选择的随机性, 避免质心落于边缘或空区域, 同时控

制质心的不重复选择, 从而增强了聚类过程的稳定性。同时, 获取每个封闭区域内的高度均值, 作为探测器区域的高度异常判据。

设边缘点集合为 E , 需要从中提取出被边缘包围的封闭区域 R_k 作为初始化质心中心。将边缘投影到二维平面上, 然后用轮廓提取方法识别封闭区域^[24]:

$$\epsilon_{XY} = \{(x_i, y_i) | P_i \in E_i\}. \quad (6)$$

基于边缘投影点集 ϵ_{XY} , 将二维边缘点离散为二值图像 $B(x, y)$, 1 表示边缘点位置:

$$B(x, y) = \begin{cases} 1 & (x, y) \in \epsilon_{XY} \\ 0 & \text{else} \end{cases}. \quad (7)$$

使用形态学闭运算填补边缘缝隙, 使边缘更连续形成封闭结构, 即:

$$B_c = (B \oplus S) \ominus S, \quad (8)$$

其中: $\oplus$ 表示膨胀操作, $\ominus$ 表示腐蚀操作, S 为结构元素。

获取闭合区域 P_k , 区域内点集定义为:

$$R_k = \{p_i \in P | \text{proj}_{xy}(p_i) \in P_k\}, \quad (9)$$

其中: proj_{xy} 表示点在 x, y 平面上的投影。

将每个封闭区域与原始点云匹配, 提取区域内部点集。在每个区域 R_k 内部选取初始聚类中心以及高度均值, 用于初始化 K-means 算法。每个区域内的聚类初始中心以及高度均值如下:

$$c_k(\mu_{x,k}, \mu_{y,k}, \mu_{z,k}) = \frac{1}{|R_k|} \sum_{P_i \in R_k} P_i(x_i, y_i, z_i), \quad (10)$$

其中: $\mu_{x,k}, \mu_{y,k}$ 为封闭区域内所有点的 x, y 均值; $\mu_{z,k}$ 为封闭区域内所有点的高度均值, 用于后续边缘缝隙区域的判断; $|R_k|$ 为第 k 个封闭区域内的点数; c_k 为第 k 个区域的中心; $|R_k|$ 表示区域点的数量。

则聚类初始化中心表示为:

$$C = \{c_1, c_2, \dots, c_k\}. \quad (11)$$

作为 K-means 后续优化聚类的初始中心。

2.4 改进的 K-means 聚类优化函数

传统 K-means 仅基于空间坐标进行聚类分割, 难以区分边缘区域与异常高度点。本文在传统 K-means 基础上引入一个新的边缘类(第 $K+1$ 类)。具体做法如下: 在每一次聚类分配时, 如果某一点与所有封闭区域的类中心空间-高度综合距离均偏离较大, 则将其直接归入第 $K+1$ 类, 作

为异常或边缘点处理。这一机制能够有效防止主类被边缘或异常点“污染”,提升了探测器区域与边缘区剥离的准确性。

本文在经典 K-means 目标函数基础上,进一步引入两类先验信息:(1) 边缘点集的几何约束;(2) 各封闭区域的高度统计均值。形成新的优化目标如下:

$$J = \sum_{i=1}^n \sum_{j=1}^{k+1} w_{ij} (\| (x_i - y_i) - (c_{jx}, c_{jy}) \|^2 + \lambda_z (z_i - c_{jz})^2 + \lambda_E D_E(p_i)), \quad (12)$$

其中: (x_i, y_i, z_i) 表示第 i 个点的空间坐标; $c_j = (c_{jx}, c_{jy}, c_{jz})$ 表示第 j 类的聚类中心; w_{ij} 为指示函数,若点 i 归属第 j 类则为 1,否则为 0; λ_z 为高度惩罚系数; λ_E 为边缘距离惩罚系数; $D_E(p_i) = \min_{q \in E} \|p_i - q\|$ 表示 p_i 到边缘点集 E 的距离。

根据聚类分配规则,对每个点 (x_i, y_i, z_i) 定义归属为:

$$\text{assign}(i) = \arg \min_{j=1, \dots, K} \{ \| (x_i, y_i) - (c_{jx}, c_{jy}) \|^2 + \lambda_z (z_i - c_{jz})^2 \}, \quad (13)$$

其中 μ_j 表示第 j 类当前所有点的高度均值。

引入高度均值异常判据:

$$|z_i - c_{jz}| > z_{\text{thresh}} \cdot \sigma_j, \quad (14)$$

其中: c_{jz} 为第 j 类高度均值; σ_j 为第 j 类高度标准差; z_{thresh} 为异常倍数。

若满足式(14),则将该点归入第 $K+1$ 类,即边缘类:

$$\text{assign}(i) = \begin{cases} j^*, & \text{if } |z_i - c_{jz}| \leq z_{\text{thresh}} \cdot \sigma_j \\ K+1, & \text{otherwise} \end{cases}. \quad (15)$$

更新包括边缘类在内的聚类中心如下:

$$c_j = \text{mean} \{ p_i; \text{assign}(i) = j \}, j = 1, 2, \dots, K+1. \quad (16)$$

最后,若中心点偏移量小于阈值 ϵ ,则终止迭代:

$$\max_j \|c_j^{(t+1)} - c_j^{(t)}\| < \epsilon. \quad (17)$$

算法流程如图 3 所示,能够有效结合边缘信息和空间结构,实现对点云区域的自动分割,并为每个探测器区域确定唯一且稳定的初始聚类中心,进一步提升了聚类分割的准确性和稳定性。同时,基于高度值异常判据引入边缘类,有效分离边缘点,并提高与真实结构的一致性。

2.5 评估指标

边缘匹配度用于衡量聚类边界与真实几何边缘的吻合程度,定义如下:

$$M_e = \frac{1}{N} \sum_{j=1}^N \exp\left(-\frac{d_j^2}{2\sigma^2}\right), \quad (18)$$

其中: d_j 表示第 j 个聚类边界点到最近真实边缘的欧氏距离; σ 表示容忍度参数; N 表示边界点总数。 $M_e \in [0, 1]$, 值越大表示边缘匹配度越高。




图 3 改进的 K-means 算法流程

Fig. 3 Flowchart of improved K-means algorithm

3 实验装置

实验采用自主搭建的高精度二维扫描平台,实物如图 4 所示。该系统由气浮隔振平台、二维运动平台与双探头光学测量单元构成,综合性能达亚微米级精度。基座平台系统选用主动式气浮隔振光学平台,为测量提供稳定性支撑。




图4 高精度二维扫描平台

Fig. 4 High-precision 2D scanning stage

运动系统采用米思米(MISUMI)E-RSZ12-8S-X360-Y600-DE30-XC5-YC5 高精度二维平台,在600 mm×360 mm行程内实现 $\pm 5 \mu\text{m}$ 的重复定位精度与 $\pm 10 \mu\text{m}$ 的直线度。测量系统采用Keyence CL-3000控制器,带动两台探 CLP015 N/CLP015 进行测量。

基于QT框架开发了上位机控制软件,如图5所示,实现运动平台实时位置与双探头高度数据的同步精准采集。1号工作探头执行拼接探测器大范围扫描;2号基准探头以 $\pm 0.41 \mu\text{m}$ 高精度线性度实时测量定制化的面形优于 $\lambda/20$ 的平面反射镜。



图5 上位机软件平台

Fig. 5 Upper computer software platform


测量过程中,为了获得高精度的点云数据,本研究进一步设计并实现了一种实时差分算法,用于在数据采集过程中同步消除平台引起的误

差干扰。通过对1号探头与2号探头在同一时间点下的高度信息进行逐点差分运算,有效消除共模干扰成分,仅保留目标表面的真实形貌特征。记录电机的运动坐标 X, Y 以及双探头差分值 Z ,最终输出的结果即为拼接后的目标点云数据 $P(x, y, z)$ 。

4 实验结果与分析

4.1 数据集介绍

实验过程中,在16片探测器拼接安装固定后,使用软件设定电机的步长为0.5 mm,设置 X, Y 轴的中心点为坐标零点,双轴的扫描范围均限制为 $[-125, 125]$,驻停时间为0.5 s,等待两个扫描探头稳定后读取测量数据,结果保存至上位机。采集得到的原始点云数据每组为250 000个。为确保实验数据的可重复性与算法的稳定性,进行了3次重复测量。同时,更换测量探头CLV050N(线性度 $\pm 1.4 \mu\text{m}$)再次进行3次重复测量,得到3组数据。选取CLP015N探头的3次独立测量数据, $Y=25 \text{ mm}$ 截线处,提取同一截线的高度数据,结果如图6所示。可以看到,在不同测量设备下,3次测量的高度曲线在整个 X 方向上高度一致,未见明显漂移或系统性误差。

图6 $Y=25$ 处横截线上的3次测量高度(CLP015N)Fig. 6 Third measurement height on horizontal section at point $Y=25$ (CLP015N)

进一步计算探头CLP015N的3次测量在每个 X 位置的标准差,如图7所示,其最大值为 $1.140 \mu\text{m}$,平均值为 $0.355 \mu\text{m}$,小于平台与探头的系统误差上限。由此说明,本系统在大范围扫描测量中具有较高的重复性。




图7 同一截线3次测量的点对点标准差分布(CLP015N)
Fig.7 Standard deviation distribution of three measurements on same cross-section (CLP015N)

4.2 实验结果

通过双探头差分降噪技术消除平台噪声后,选取一组点云原始数据,采用基于邻域的半径滤波算法,对原始点云进行预处理剔除离群点,最终获得去噪化处理的三维点云数据集,如图8所示。




图8 拼接探测器点云集
Fig.8 Point cloud dataset of splicing detector

本实验完成了点云数据的结构化分割,重要结果如图9~图11所示。图9展示了基于法向量差异的边缘检测结果,可见向量估计法能准确捕获点云中具有显著曲率变化的几何边缘(红色点集,彩图见期刊电子版),但原始边缘点存在局部断裂现象。

图10为经过二值化处理的投影图像,能够明显可见细碎边缘。

图11显示经形态学闭运算处理后的二值图像,通过 3×3 圆形结构元素的膨胀-腐蚀操作,成功填补边缘缝隙,形成完整封闭结构。




图9 边缘点云集
Fig.9 Point cloud dataset of edge




图10 二值化投影
Fig.10 Binarization projection

图12和图13分别展示了基于 $K+1$ 聚类方法对探测器点云数据的三维分割结果和二维投影分布,右侧高度图表示不同的聚类结果。其中,三维点云分割图(图12)能够直观反映各探测器区域空间分布及其边界,边缘类以显著不同的颜色进行区分。二维投影图(图13)进一步突出了不同聚类结果在平面上的分布关系,有助于分析各区域的空间分布规律与边界过渡。通过为边缘类指定高对比度颜色,各类点云在空间和投影平面上均能实现清晰分隔,提高了分割结果的可视化效果和分析直观性。整体结果表明, $K+1$




图 11 形态学运算结果

Fig. 11 Morphological operation result




图 12 拼接探测器分割结果(三维)

Fig. 12 Segmentation result of splicing detector(3D)




图 13 拼接探测器分割结果(二维)

Fig. 13 Segmentation result of splicing detector(2D)

聚类能够有效地区分探测器区域与边缘点,满足复杂结构点云的区域分割需求。图中圆点代表初始聚类中心。

最后,在三维高度图中(图 14),颜色梯度映射的高度信息代表点云高度,再现了拼接探测器不同模块之间的平面形变特征与倾斜角度的差异性,为拼接探测器的平面度检测提供了一种高效的点云分割方法。




图 14 拼接探测器高度云图

Fig. 14 Height cloud map of spliced detector

鉴于原始点云数据量巨大,为分析拼接探测器特定区域的边缘特性,本文针对探测器的关键边缘进行了研究。选取 CLP015N 探头的测量数据, Y 方向在 25~30 mm 内的点云数据,如图 15 所示,即 X 方向主截线区域。灰色区域代表探测器主体区域,边缘 1~3 为 3 次独立测量下提取的边缘点。图中 Y 方向距离适当拉宽以便于观察。




图 15 Y 方向的点云数据

Fig. 15 Point cloud data in Y-direction

统计结果表明, $X = \pm 123$ mm, ± 61 mm 及 0 mm 为典型边缘聚集位置。针对这 5 个位置,本文分别采用包括 K-means, K-medoids 等算法在内的 4 种方法进行聚类对比,并对各算法的边缘匹配度进行评估。其中,本文改进的 K-means 算法需要边缘封闭区域,因此在整体聚类后参与计算。

图 16 和图 17 分别展示了在无 FPC 引脚干扰、边缘较窄的 X 方向区域下,两种不同探头 (CLP015N, 线性度为 ± 0.41 μm ; CLV050N, 线性度为 ± 1.4 μm) 获得的数据在各典型边缘点的

匹配度对比情况。从结果可以看出,改进的 K-means 算法在两组数据中均表现出明显的优势,在所有典型边缘点的匹配度均高于传统的 K-means, K-medoids, Spectral 和 Mean Shift 算法,表现出更高的准确性和稳定性。相比之下,Mean Shift 方法在拼接探测器的分割表现较差,匹配度最低,且稳定性较差。传统 K-means 和 K-medoids 方法在部分点上略有波动,但整体优于 Mean Shift 方法。




图 16 X 方向典型边缘点匹配度对比 (CLP015N)

Fig. 16 Comparison of typical edge point matching degrees in X-direction (CLP015N)




图 17 X 方向典型边缘点匹配度对比 (CLV050N)

Fig. 17 Comparison of typical edge point matching degrees in X-direction (CLV050N)

采用相同方法,对 X 方向在 25~30 mm 内的点云数据(如图 18 所示)进行 Y 方向边缘特征分析。边缘同样主要集中在 $Y=\pm 123, \pm 61$ 及 0 mm 的位置。




图 18 X 方向的点云数据

Fig. 18 Point cloud data in X-direction

在有 FPC 引脚干扰、缝隙较宽的 Y 方向区域,对不同两种探头的数据进行匹配度对比,结果如图 19 和图 20 所示。在 ± 61 mm 等宽缝隙位置, Spectral 算法均能够实现较好的边缘匹配,但改进的 K-means 算法在检测精度和匹配一致性方面依然能够更为准确、稳定地识别探测器边界结构。整体而言,改进算法在所有边缘聚集点的匹配度始终保持在较高水平,进一步验证了其在拼接探测器的复杂结构环境下的适用性和优越性。




图 19 Y 方向典型边缘点匹配度对比 (CLP015N)

Fig. 19 Comparison of typical edge point matching degrees in Y-direction (CLP015N)

实验结果显示,除 Mean Shift 算法外,其余各算法在 CLP015N 和 CLV050N 两种探头下的边缘匹配度的表现基本一致。鉴于上述两种探头在上述分割指标表现上的相似性,为评估算法的整体性能,实验采用两种探头测量的 6 组拼接探测器点云数据集作为对象,对表 1 的算法在相同硬件环境下独立运行 10 次,统计其均值。采用轮廓系数和边缘匹配度作为核心评价指标,同时统计平均迭代次数(详见表 1)。轮廓系数作为评估聚类分割质量的通用指标,其值域为 $[-1, 1]$,数值越大表明聚类结构越合理(类内紧密、类间分




图 20 Y 方向典型边缘点匹配度对比 (CLV050N)
Fig. 20 Comparison of typical edge point matching degrees in Y-direction (CLV050N)

离)。边缘匹配度则是为拼接探测器场景设计的指标,用于量化聚类结果对图像几何边界特征的保持能力,其值越接近 1,表示算法识别的聚类边界与真实物理边缘的吻合度越高。

表 1 不同算法的评估指标对比
Tab. 1 Comparison of evaluation indicators of different algorithms

算 法	初始 质心	迭代 次数	轮廓 系数	边缘匹 配度
K-means	是	14.7	0.34	0.64
K-Medoids	是	12.5	0.35	0.67
Mean Shift	否	—	0.22	0.33
Spectral	是	—	0.30	0.51
改进 K-means	否	2.3	0.375	0.98

结合表 1 中的实验数据,针对拼接探测器点云分割这一高精度应用场景,改进 K-means 算法的各项核心指标均表现良好。其轮廓系数^[25-26]达到 0.375,较传统 K-means 和 K-Medoids 分别提升约 10.3% 和 7.1%,说明聚类结构更加合理、边界更清晰。在边缘匹配度方面,改进 K-means 达 0.98,增强了对拼接边缘、缝隙等关键物理特征的还原能力。

在效率方面,改进 K-means 算法展现出明显优势。实验数据显示,其平均仅需 2.3 次迭代即可收敛,较传统 K-means 的 14.7 次和 K-Medoids

的 12.5 次,分别减少了 84.4% 和 81.6% 的迭代次数,大幅提升了处理效率。与此相比,Mean Shift, Spectral Clustering 等算法不涉及明确的迭代步骤,难以保证收敛效率及稳定性,且在实际应用中存在参数调优复杂、运行速度慢等问题。

更为重要的是,改进 K-means 算法无需人工设定初始质心,简化了工程流程,避免了传统 K-means, K-Medoids 以及 Spectral Clustering 因初始条件选择带来的聚类不稳定和一致性问题。这一特点对于大规模、高维度的拼接探测器点云数据处理尤为重要,不仅提升了自动化水平,也保证了测量结果的重复性。

5 结 论

本文针对拼接探测器点云数据的结构特征和实际需求,提出了一种基于边缘增强的弱监督 K-means 点云分割方法。该方法通过融合边缘特征的形态学闭运算与改进的聚类策略,实现了对复杂点云数据的自适应、高质量分割。实验结果表明,形态学闭运算显著提升了边缘的连续性和完整性,基于封闭区域质心的初始化方式将平均迭代次数降低至 2.3 次,较传统 K-means 减少超过 80%,同时无需人工预设初始质心,彻底实现了零人工干预的自动分割流程。在分割精度方面,改进算法的边缘匹配度达到 0.98,较传统 K-means 提升超过 50%,在真实拼接边界识别和几何结构还原方面表现出极高的准确性和稳定性。总体来看,该方法不仅大幅提升了分割效率和稳定性,更能满足拼接探测器大规模、高精度点云分割的工程应用需求。本文未涉及拼接后整体平面度的误差建模与精度评估,相关分析将在后续工作中进一步展开。

作者贡献声明:

冯晓鹏:测量方法的提出,论文构思和撰写;
王之一:论文审核与编辑写作;
王建立:实验指导和论文审核;
刘昌华:实验设计及数据整理和分析;
贾建禄、马爽和刘塔拉:实验数据分析。

参考文献:

- [1] 张景旭. 地基大口径望远镜系统结构技术综述[J]. 中国光学, 2012, 5(4): 327-336.
ZHANG J X. Overview of structure technologies of large aperture ground-based telescopes[J]. *Chinese Optics*, 2012, 5(4): 327-336. (in Chinese)
- [2] LUPPINO G A, METZGER M R, MIYAZAKI S. *CCD Mosaic Development for Large Optical Telescopes*[M]. New Developments in Array Technology and Applications. Dordrecht: Springer Netherlands, 1995: 297-308.
- [3] HAO J G, ESTRADA J, CEASE H, *et al.* Measuring the flatness of focal plane for very large mosaic CCD camera[C]. *Ground-based and Airborne Instrumentation for Astronomy III. San Diego, California, USA*. SPIE, 2010: 77353U.
- [4] 王志. CCD靶面与安装定位面夹角误差的光学检测方法[J]. 红外技术, 2012, 34(4): 213-216.
WANG ZH. Optical measurement method of angle error between CCD target surfaces and locating faces[J]. *Infrared Technology*, 2012, 34(4): 213-216. (in Chinese)
- [5] 郭宁馨, 张景旭, 刘昌华, 等. 大口径大视场望远镜探测器平面度检测方法综述[J]. 激光与红外, 2020, 50(4): 387-395.
GUO N X, ZHANG J X, LIU CH H, *et al.* Overview of CCDs flatness test method for large aperture and wide-field telescope[J]. *Laser & Infrared*, 2020, 50(4): 387-395. (in Chinese)
- [6] LAWIN F J, DANELLJAN M, TOSTEBERG P, *et al.* Deep projective 3D semantic segmentation[C]. *Computer Analysis of Images and Patterns*. Cham: Springer, 2017: 95-107.
- [7] CHEN X Z, MA H M, WAN J, *et al.* Multi-view 3D object detection network for autonomous driving[C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 6526-6534.
- [8] WU B C, WAN A, YUE X Y, *et al.* SqueezeSeg: convolutional neural nets with recurrent CRF for real-time road-object segmentation from 3D LiDAR point cloud[C]. *2018 IEEE International Conference on Robotics and Automation (ICRA)*. May 21-25, 2018, Brisbane, QLD, Australia. IEEE, 2018: 1887-1893.
- [9] ENGELMANN F, KONTOGIANNI T, HERMANS A, *et al.* Exploring spatial context for 3D semantic segmentation of point clouds[C]. *2017 IEEE International Conference on Computer Vision Workshops (ICCVW)*. October 22-29, 2017, Venice, Italy. IEEE, 2017: 716-724.
- [10] LANDRIEU L, SIMONOVSKY M. Large-scale point cloud semantic segmentation with superpoint graphs[C]. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 4558-4567.
- [11] HUANG J B, ZHENG Z, ZHANG Y F, *et al.* Segmentation clustering algorithm for point cloud processing of targets on the ground[J]. *Journal of Physics: Conference Series*, 2023, 2478 (6): 062023.
- [12] LIU Y, ZHONG R F. Buildings and terrain of urban area point cloud segmentation based on PCL[J]. *IOP Conference Series: Earth and Environmental Science*, 2014, 17(1): 012238.
- [13] ZHU Q Z, YU M. A corn point cloud stem-leaf segmentation method based on octree voxelization and region growing[J]. *Agronomy*, 2025, 15(3): 740.
- [14] 张佩翔, 王奇, 高仁璟, 等. 局部阈值自适应的地面点云分割[J]. 光学精密工程, 2023, 31(17): 2564-2572.
ZHANG P X, WANG Q, GAO R J, *et al.* Ground point cloud segmentation based on local threshold adaptive method[J]. *Opt. Precision Eng.*, 2023, 31(17): 2564-2572. (in Chinese)
- [15] 高云龙, 李建鹏, 郑兴莘, 等. 基于自适应近邻信息的模糊C均值聚类算法[J]. 光学精密工程, 2024, 32(7): 1045-1058.
GAO Y L, LI J P, ZHENG X SH, *et al.* Fuzzy C-means clustering algorithm based on adaptive neighbors information[J]. *Opt. Precision Eng.*, 2024, 32(7): 1045-1058. (in Chinese)
- [16] 刘昌华. 主焦点式大口径大视场光学校正镜及拼接探测器关键技术[D]. 长春: 中国科学院长春光学精密机械与物理研究所, 2023.
LIU CH H. *Key Technologies of Corrector Lens and Mosaic Sensors for Large Aperture and Wide-field Telescope*[D]. Changchun: Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, 2023. (in Chinese)

- [17] LANDRIEU L, BOUSSAHA M. Point cloud oversegmentation with graph-structured deep metric learning [C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2019: 7432-7441.
- [18] 王羽尘, 于斌, 陈晓阳, 等. 基于激光雷达点云的道路几何信息提取与数字化建模研究[J]. *中国公路学报*, 2023, 36(3): 45-60.
WANG Y CH, YU B, CHEN X Y, *et al.* Extraction and digital modeling of road geometric information using LiDAR data point clouds [J]. *China Journal of Highway and Transport*, 2023, 36(3): 45-60. (in Chinese)
- [19] 张宏伟. 基于遥感影像与点云数据的建筑物三维重建技术研究[D]. 郑州: 解放军信息工程大学, 2017.
ZHANG H W. *Research on Building 3D Reconstruction Based on Remote Sensing Images and Point Cloud Data*[D]. Zhengzhou: PLA Information Engineering University, 2017. (in Chinese)
- [20] 仲宇, 白钊, 刘勇, 等. 基于改进 3D-Harris 角点检测算法的电厂地下管廊点云拼接方法研究[J]. *热力发电*, 2023, 52(1): 89-97.
ZHONG Y, BAI F, LIU Y, *et al.* Study on point cloud splicing method of underground pipe gallery in power plants based on improved 3D-Harris operator [J]. *Thermal Power Generation*, 2023, 52(1): 89-97. (in Chinese)
- [21] 鲁荣荣, 朱枫, 吴清潇, 等. 一种板型物体混叠场景的快速分割算法[J]. *光学学报*, 2019, 39(4): 0412003.
LU R R, ZHU F, WU Q X, *et al.* A fast segmenting method for scenes with stacked plate-shaped objects [J]. *Acta Optica Sinica*, 2019, 39(4): 0412003. (in Chinese)
- [22] 郭清达, 全燕鸣. 采用空间投影的深度图像点云分割[J]. *光学学报*, 2020, 40(18): 1815001.
GUO Q D, QUAN Y M. Depth image point cloud segmentation using spatial projection [J]. *Acta Optica Sinica*, 2020, 40(18): 1815001. (in Chinese)
- [23] CHEN Q, GONG P, BALDOCCHI D, *et al.* Filtering airborne laser scanning data with morphological methods [J]. *Photogrammetric Engineering & Remote Sensing*, 2007, 73(2): 175-185.
- [24] 宋大虎, 李忠科, 王忠, 等. 特征保持的点云光顺算法[J]. *中国机械工程*, 2014, 25(11): 1498-1501.
SONG D H, LI ZH K, WANG ZH, *et al.* A feature-preserving algorithm of point cloud smoothing [J]. *China Mechanical Engineering*, 2014, 25(11): 1498-1501. (in Chinese)
- [25] WANG Z, HU J C, SHI Y S, *et al.* Target fitting method for spherical point clouds based on projection filtering and K-means clustered voxelization [J]. *Sensors*, 2024, 24(17): 5762.
- [26] CHEN H, WU H Y, YANG N, *et al.* Irregular object measurement method based on improved adaptive slicing method [J]. *Multimedia Tools and Applications*, 2024, 83(17): 50557-50580.

作者简介:



冯晓鹏(1996—),男,山东威海人,博士研究生,2018年于南京航空航天大学获得学士学位,主要从事大口径光学自由曲面检测等方面的研究。E-mail: fengxiaopeng20@mails.ucas.edu.cn

通讯作者:



王之一(1996—),男,吉林长春人,博士,助理研究员,2018年于山东大学获得学士学位,2024年于中国科学院长春光学精密机械与物理研究所获得博士学位,主要从事大口径光学自由曲面精密检测、非接触式光学探针测量等方面的研究。E-mail: wangzhiyi18@mails.ucas.edu.cn