

# 面向弱纹理空间目标的特征点匹配方法

栗博<sup>1,2</sup> 何红艳<sup>1,2</sup> 王钰<sup>1,2</sup> 丁与非<sup>1,2</sup> 孙豆<sup>3</sup> 曹世翔<sup>1,2</sup>

(1 北京空间机电研究所, 北京 100094)

(2 先进光学遥感技术北京市重点实验室, 北京 100094)

(3 中国人民解放军63768部队, 西安 710000)

**摘要** 特征点提取与匹配是遥感图像处理中关键的一环, 目前成熟的算法大多面向对地成像类型的遥感图像, 对于空间目标的遥感图像, 没有考虑成像条件与探测平台的影响因素, 特征点匹配质量较差。针对空间目标的匹配精度不高这一问题, 文章提出了一种基于聚类的特征点匹配算法。首先, 根据空间目标的重复弱纹理进行特征点提取与描述, 再利用特征点的空间位置进行聚类, 并对特征点簇进行匹配; 之后将特征点的主方向减去目标整体方向, 利用特征点主方向对每一个点簇进行再分组, 并完成特征点匹配; 最后利用最近邻次近邻比率方法和随机样本一致算法 (RANSAC) 剔除外点。采用该特征点匹配方法进行的模拟成像数据实验结果表明, 对于空间目标图像, 基于聚类的特征点匹配较直接匹配, 匹配数量的提升最高可达50%, 重投影误差优于1/4个像元。文章提出的这一方法使用目前通用的各种特征描述子, 能够大幅度提高空间目标图像特征点匹配的数量与精度。

**关键词** 特征点匹配 聚类 结构张量 重复纹理 空间目标

中图分类号: TP751.1

文献标志码: A

文章编号: 1009-8518(2024)01-0099-12

DOI: [10.3969/j.issn.1009-8518.2024.00.009](https://doi.org/10.3969/j.issn.1009-8518.2024.00.009)

## Feature Point Matching Method for Weakly Textured Spatial Objects

LI Bo<sup>1,2</sup> HE Hongyan<sup>1,2</sup> WANG Yu<sup>1,2</sup> DING Yufei<sup>1,2</sup> SUN Dou<sup>3</sup> CAO Shixiang<sup>1,2</sup>

(1 Beijing Institute of Space Mechanics & Electricity, Beijing 100094, China)

(2 Key Laboratory for Advanced Optical Remote Sensing Technology of Beijing, Beijing 100094, China)

(3 Unit 63768 of the Chinese People's Liberation Army, Xi'an 710000, Shaanxi, China)

**Abstract** Feature point extraction and matching are crucial aspects of remote sensing image processing. Currently, most mature algorithms are designed for remote sensing images of Earth's surface, with little consideration for the imaging conditions and the influence of the detection platform on spatial target images. As a result, the quality of feature point matching for spatial target images is often poor. To address the issue of low matching accuracy for spatial targets, this paper proposes a clustering-based feature point matching algorithm. First, feature points are extracted and described based on the repetitive weak textures of spatial targets. Then, clustering is performed using the spatial positions of the feature points, and matching is carried out for the clusters of feature points. Subsequently, the main direction of each feature point cluster is adjusted by subtracting the

收稿日期: 2023-08-05

基金项目: 国家自然科学基金(42271448); 中国航天科技集团青年拔尖项目(YF-ZZYF-2022-144)

引用格式: 栗博, 何红艳, 王钰, 等. 面向弱纹理空间目标的特征点匹配方法[J]. 航天返回与遥感, 2024, 45(1): 99-110.

LI Bo, HE Hongyan, WANG Yu, et al. Feature Point Matching Method for Weakly Textured Spatial Objects[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(1): 99-110. (in Chinese)

overall direction of the target. This adjustment is used to further group the points within each cluster, facilitating feature point matching. Finally, outliers are eliminated using the nearest neighbor-to-second-nearest-neighbor ratio method and the Random Sample Consensus algorithm (RANSAC). Simulation experiments with imaging data using this feature point matching method demonstrate that, for spatial target images, clustering-based feature point matching outperforms direct matching. The improvement in the number of matches can reach up to 50%, and the reprojection error is better than 1/4 pixel. The method proposed in this paper utilizes various commonly used feature descriptors, significantly enhancing the quantity and accuracy of feature point matching for spatial target images.

**Keywords** feature point matching; clustering; structural tensors; repeated texture; spatial object

## 0 引言

图像特征点匹配通常是指提取图像中具有某种特殊性质的点作为共轭实体,通过一定的方式对其属性进行定量描述后,计算其相似度,实现共轭实体的配准<sup>[1]</sup>。由于特征点属于局部特征,相较于纹理、颜色等全局特征具有较好的尺度、旋转等不变性,被广泛用于三维重建、图像拼接、空中三角测量、数字高程模型(DEM)生成、目标跟踪等众多摄影测量与计算机视觉领域。目前特征点提取与匹配的相关研究已经比较成熟,可从异常值去除、相似度度量、特征描述、算法加速等多方面对特征点提取与匹配进行优化<sup>[2-9]</sup>。另外,基于深度学习的方法也同样运用于这一领域,如 SuperGlue、AdaSG、GANcoder 等网络模型<sup>[10-14]</sup>,都取得了较好的匹配结果。

目前,针对空间目标遥感图像的特征点匹配的一些成熟算法大多没有考虑成像时的特殊条件。与普通地物目标不同,空间目标图像有两方面的影响因素:1)成像条件的影响。空间环境中航天器受光照变化影响较大,成像整体表现出光照不均,航天器的同一部分在不同图像中呈现不同的光照效果。2)作为目标的航天器自身因素的影响。航天器一般为对称结构,存在较多纹理相似的部分,且其表面细节较少,材料本身纹理单一,这种目标的纹理表现为“重复弱纹理”,重复弱纹理非常容易导致特征点匹配失败。

针对这些问题,香港理工大学吴波等<sup>[15]</sup>分析了行星遥感图像尺度不变特征变换匹配(Scale Invariant Feature Transform, SIFT)算法特征点的主方向分布直方图,提出了高分辨率行星遥感图像照度不变的SIFT匹配方法,解决了阴影造成的局部剧烈变化;东南大学沈佳雁等<sup>[16]</sup>针对遥感图像的大尺度和光照条件不稳定的特点,提出了一种尺度不变的递归扩散算法,提高了复杂遥感图像的特征点匹配结果的准确度;北京邮电大学程鹏飞等<sup>[17]</sup>针对弱纹理图像的特征点提取提出了多邻域结构张量特征(MNSTF)算法,通过特征点不同大小邻域的结构张量特征向量方向差值描述特征点,实现了旋转不变性。这些方法一定程度上提升了遥感图像特征点匹配的质量,但对于重复纹理影响的抑制,目前没有较为有效的方法。

本文为减小对称结构重复纹理对空间目标特征点匹配的不利影响,提出了一种基于聚类的特征点匹配方法,在对图像进行去噪、光照均匀化预处理后,通过两次特征点聚类,使得类内特征点有相近的空间和纹理方向特征,在同类点集之间进行匹配,有效避免重复弱纹理造成的误匹配。实验利用了某项目在不同距离下,依照空间相机在轨成像条件,对空间航天器目标的模拟成像数据,实现了对空间目标图像特征点提取数量的提升,提升程度最高达50%,且重投影误差优于1/4像元。

## 1 基于聚类的空间目标特征点匹配方法

利用计算机软件进行特征点自动匹配与人工目视匹配有较大的不同,自动匹配倾向于枚举法,度量

所有特征点的相似性后, 选取相似度最高的一对点为同名特征点。而在人工匹配同名特征点过程中, 总是从全局开始, 一步一步地缩小特征点所在范围, 最后在特征点的一个较小邻域中, 对另一张图像中特征点周围的几个相近的特征点利用局部细节信息, 找到最终正确的同名特征点, 通过多次“聚类”来完成分级多次匹配。

本文提出的方法首先对两张图像进行预处理, 包括去噪和光照均匀化; 然后利用尺度不变特征变换匹配算法 (SIFT) 和加速稳健特征 (SURF) 算法进行特征点的提取与匹配; 对于提取到的特征点集, 通过特征点邻域像素以及特征点间距离约束剔除质量较差的点后, 进行两轮聚类, 其中首轮聚类利用 k-means 方法, 将特征点按空间位置分为若干点簇, 二轮聚类则依据特征点的主方向对点簇进一步划分; 最后在同类间进行特征点匹配, 并剔除外点。算法流程如图 1 所示。

### 1.1 首轮聚类——基于特征点位置的聚类

#### 1.1.1 对特征点坐标的 k-means 聚类

首轮聚类主要是对特征点进行空间位置上的划分, 起到类似“图像分割”的作用。对于空间航天器目标图像, 一个典型的对称结构就是成对的太阳翼, 不同的太阳翼可能有相同的灰度信息, 需利用空间位置信息将它们区分开来。这一步中, 采用 k-means 方法, 利用特征点在图像中的坐标对特征点进行非监督分类。

k-means 聚类是一种常用的聚类算法, 它通过迭代将样本划分为  $k$  簇, 使得同类别中样本距离最小, 类间样本距离最大。以欧氏距离为衡量依据, 将各样本到其所属簇中心点距离的误差平方和定义为损失函数 ( $S_{SE}$ ), 即

$$S_{SE} = \sum_{i=1}^N D_{ist}(x_i, c_j)^2 \quad (1)$$

式中  $N$  为样本总数;  $D_{ist}$  表示欧氏距离;  $x_i$  为第  $i$  个样本;  $c_j$  表示样本  $x_i$  所属簇  $C_j$  的中心点。

在聚类过程中, 首先采用 Arthur 方法选取  $k$  个样本点作为初始簇中心<sup>[18]</sup>, 然后进行迭代运算, 直至满足收敛条件 (达到最大迭代次数或者  $S_{SE}$  变化量 ( $\Delta S_{SE}$ ) 达到精度阈值), 具体迭代包括:

1) 对每个样本  $x_i$ , 计算其到  $k$  个簇中心的欧氏距离, 选距离最小的簇中心代表的点簇作为样本  $x_i$  的归属;

2) 对每个簇  $C_j$ , 重新计算其中心点  $c_j$ ,

$$c_j = \frac{1}{m_{C_j}} \sum_{x_i \in C_j} x_i \quad (2)$$

式中  $m_{C_j}$  为  $C_j$  包含样本的数量。

在首轮聚类中, 直接使用特征点坐标作为样本的特征向量, 即对特征点  $P_i$ , 其图像横纵坐标分别为  $P_i(X)$  和  $P_i(Y)$ , 将其作为前文描述的样本记为  $x_i$ , 其二维特征向量  $F_i$  为

$$F_i = [P_i(X), P_i(Y)] \quad (3)$$

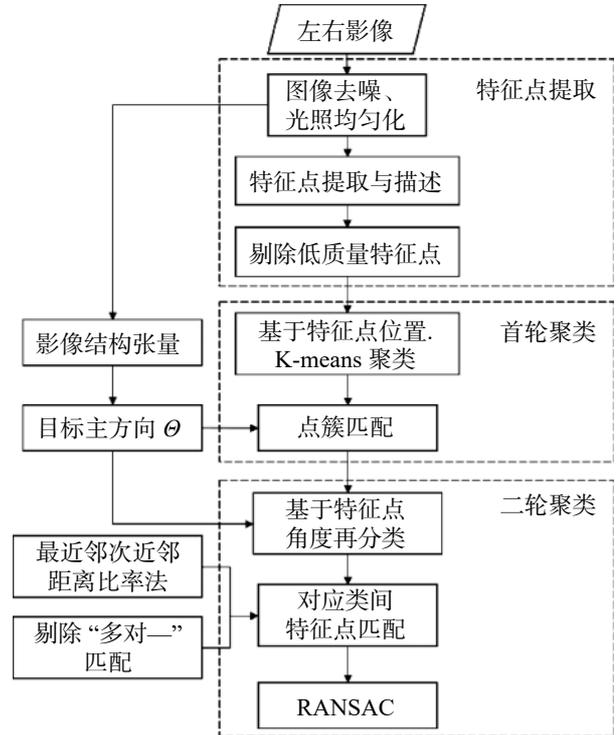


图 1 基于聚类的特征点匹配流程  
Fig. 1 Feature point matching process based on clustering

### 1.1.2 点簇描述与类间匹配策略

聚类完成之后,对  $k$  个类簇进行匹配。用簇中心点位置来描述整个簇:首先计算每张图像上  $k$  个簇中心的中心  $A$ ,以每个簇中心  $c_j$  到  $A$  连线的长度  $d_j$  和角度  $\alpha_j$  作为簇  $C_j$  的描述。在这一过程中,考虑到图像旋转带来的问题, $d_j$  并不会随着图像中目标的旋转而发生较大改变,而  $\alpha_j$  由于目标本体的旋转,一对同名点的  $\alpha_j$  也会有较大差异,不能直接用于簇的描述。因此,实验中首先需消除两张图像上目标旋转造成的影响。

目标的旋转角度通过两张图像中目标的结构张量<sup>[19]</sup>计算得到。结构张量通常用于区分图像的平坦区域、边缘区域和角点区域,其特征值和特征向量则用于确定图像的主要结构方向。由于空间目标图像通常只有目标本身,背景为深空,所以通过直接计算整张图像的结构张量对目标的旋转特性进行表征。

结构张量(二阶矩矩阵, second-moment matrix)描述了一个点的某一邻域内梯度的主要方向以及连贯程度,定义为:

$$\mathbf{T}_\sigma = \begin{bmatrix} g_x^2 * G_\sigma & g_x g_y * G_\sigma \\ g_y g_x * G_\sigma & g_y^2 * G_\sigma \end{bmatrix} = \begin{bmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{bmatrix} \quad (4)$$

式中  $\mathbf{T}_\sigma$  为结构张量,其 4 个元素  $T_{11}$ 、 $T_{12}$ 、 $T_{21}$ 、 $T_{22}$  为图像梯度的函数,其中  $T_{21} = T_{12}$ ;  $g_x$  和  $g_y$  分别代表图像的水平 and 垂直梯度;  $G_\sigma$  为高斯函数; \* 代表卷积运算。为提高计算效率,在求梯度时,将梯度提取模板与高斯函数结合,作为梯度提取的卷积模板,同时完成梯度计算和高斯模糊。 $G_\sigma$  高斯函数的二维完整形式表示为  $G(x,y)$ ,  $x$  和  $y$  为其两个维度,完整表达式为:

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (5)$$

根据窗口大小  $L$ ,自适应计算标准差  $\sigma$ :

$$\sigma = 0.7 \times ((L-1) \times 0.5 - 1) + 0.8 \quad (6)$$

则  $x$ 、 $y$  方向上的梯度提取卷积模板  $\mathbf{G}_x$  和  $\mathbf{G}_y$  的计算公式分别表示为:

$$\mathbf{G}_x(x,y) = \begin{cases} \mathbf{G}(x,y) & x > (L+1)/2 \\ 0 & x = (L+1)/2 \\ -\mathbf{G}(x,y) & x < (L+1)/2 \end{cases} \quad (7)$$

$$\mathbf{G}_y(x,y) = \begin{cases} \mathbf{G}(x,y) & y > (L+1)/2 \\ 0 & y = (L+1)/2 \\ -\mathbf{G}(x,y) & y < (L+1)/2 \end{cases} \quad (8)$$

对于全图结构张量的提取,首先设置一个大小合适的梯度提取卷积模板,滑动模板求得整张图像每一点  $x$  和  $y$  方向上的梯度,并计算局部图像结构张量;再将所有像素的结构张量按对应位置累加,得到全图的结构张量,即:

$$\mathbf{T}_{\sigma,\text{all}} = \sum_{i=0}^{m,n} \mathbf{T}_{\sigma,ij} \quad (9)$$

式中  $\mathbf{T}_{\sigma,\text{all}}$  代表全图结构张量;  $m$  和  $n$  为图像的长和宽;  $\mathbf{T}_{\sigma,ij}$  代表每一像元点  $(i,j)$  的结构张量。

结构张量矩阵形式上为对称半正定矩阵,它存在两个正交的特征向量  $\mathbf{V}_1$ 、 $\mathbf{V}_2$ ,计算公式分别为:

$$\begin{cases} \mathbf{V}_1 = \begin{pmatrix} T_{22} - T_{11} + \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2} \\ -2T_{12} \end{pmatrix} \\ \mathbf{V}_2 = \begin{pmatrix} 2T_{12} \\ T_{22} - T_{11} + \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2} \end{pmatrix} \end{cases} \quad (10)$$

$V_1$ 、 $V_2$  对应特征值分别为:

$$\begin{cases} \lambda_1 = \frac{1}{2} \left( T_{22} + T_{11} - \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2} \right) \\ \lambda_2 = \frac{1}{2} \left( T_{22} + T_{11} + \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2} \right) \end{cases} \quad (11)$$

特征值代表对应特征向量所在方向的权重, 较大的特征值对应着更重要的结构特征。式 (11) 中  $\lambda_2$  较  $\lambda_1$  加了二倍正值  $\sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2}$ , 故而选择较大特征值  $\lambda_2$  对应的特征向量  $V_2$  的方向作为主方向, 得到图像中目标航天器的主方向角度  $\theta$ :

$$\theta = \arctan \left( \frac{T_{22} - T_{11} + \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2}}{2T_{12}} \right) \quad (12)$$

目标航天器主方向角度  $\theta$  的整体计算过程如图 2 所示。得到  $\theta$  后, 用一个二维向量  $[d_j, \alpha_j - \theta]$  来描述每一个簇  $C_j$ , 通过计算两张图像每个点簇二维描述向量的欧氏距离作为衡量, 具有最小距离的点簇为同名点簇 (匹配示意图 3)。

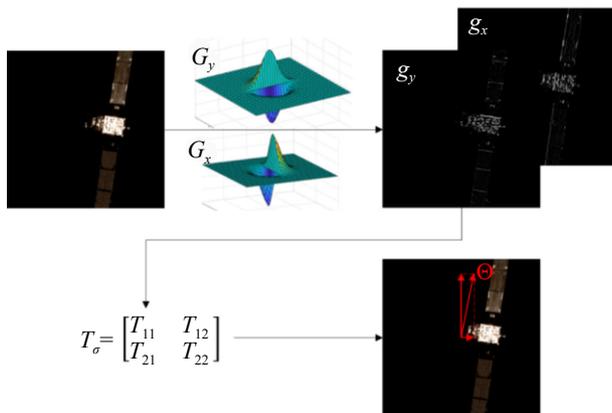


图 2 目标主方向计算示意

Fig.2 Target main direction calculation diagram

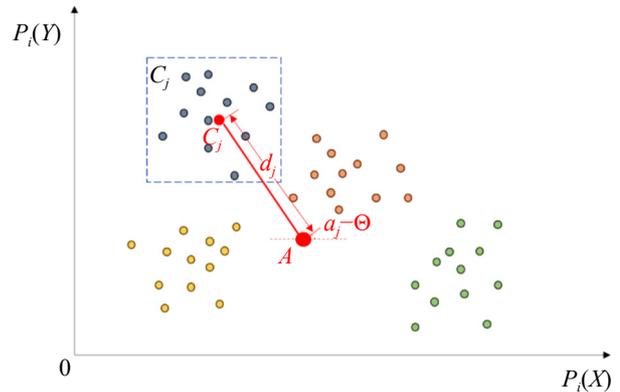


图 3 首轮聚类中点簇的描述示意

Fig.3 Description of point clusters in the first round of clustering

首轮匹配是建立在空间拍摄图像为单目标图像的基础之上, 即图像中只有单一目标, 背景单调, 目标相对背景十分突出。在这个条件下, 对特征点按空间位置聚类的结果代表了目标的各个“部件”。而对于背景纹理复杂、目标不突出的影像, 提取到的特征点没有集中于目标, 特征点聚类结果的分割效果鲁棒性略低。

### 1.2 二轮聚类——基于特征点角度的聚类

二轮聚类是在首轮聚类的结果上更进一步的划分, 主要解决目标细部纹理的重复性造成的误匹配。以航天器太阳翼图像为例 (如图 4 所示), 在同一块太阳翼的图像上, 不同的位置会出现对称的纹理。将图像坐标方向旋转至特征点主方向后, 取特征点邻域计算描述子, 两个特征点邻域相似, 二者的描述子近乎相同, 无法区分。

为解决这一问题, 利用特征点的主方向进行二次分类。首先, 将特征点主方向角度  $\theta_i$  减去目标整体主方向角度  $\theta$ , 消除左右图像角度差异, 并将消除了整体方向角度影响的特征点主方向角度转

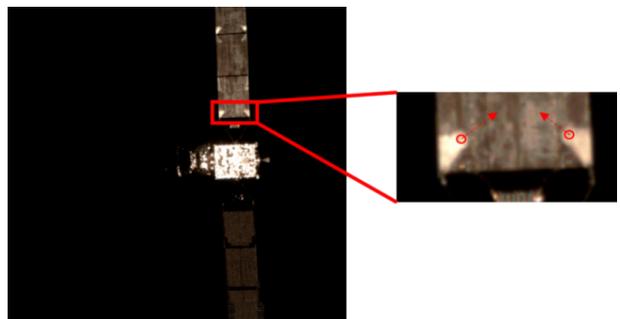


图 4 空间目标图像重复纹理情况

Fig.4 Repeated texture of a space target image

化至  $0^\circ\sim 360^\circ$ ，得到标准化特征点角度  $\theta'_i$ （如图 5 所示）：

$$\theta'_i = \begin{cases} \theta_i - \Theta, & \theta_i \geq \Theta \\ \theta_i - \Theta + 360^\circ, & \theta_i < \Theta \end{cases} \quad (13)$$

对标准化后的特征点角度  $\theta'_i$ ，给定一个角度变化范围值  $\Delta\theta$ ，将首轮聚类后的每一簇点集进一步划分为  $u$  组，即对  $P_i \in P_j$ ，有：

$$P_i \in W_u, \quad (u-1)\Delta\theta < \theta'_i \leq u\Delta\theta \quad (14)$$

式中  $W_u$  代表第二轮聚类中特征点  $P_i$  被归入的点簇。经过上述二轮聚类操作，特征点被分为了  $k \times u$  类。

在首轮聚类和点簇匹配后，得到了左右图像点簇之间的匹配关系，这组关系用 OpenCV 中的 DMatch 数据结构进行保存，每一对点簇存为一个 DMatch 类型的数据，其中保存了左右图像相匹配点簇对应的序号  $I_{dx\_l}$ ， $I_{dx\_r}$ 。而在二轮聚类中，直接对首轮匹配关系进行修改，增加点簇数量，同时更新对应点簇的序号，无需对新点簇再次进行描述和匹配。对于首轮一对匹配的点簇，在第二轮中分别被划分为  $u$  组，则新得到的  $u$  对点簇的匹配关系为：

$$\begin{cases} I_{dx\_l}^{(i)} = I_{dx\_l} \times u + i & (i = 0, 1, \dots, u) \\ I_{dx\_r}^{(i)} = I_{dx\_r} \times u + i & (i = 0, 1, \dots, u) \end{cases} \quad (15)$$

式中  $I_{dx\_l}^{(i)}$ ， $I_{dx\_r}^{(i)}$  代表二轮聚类中相匹配点簇各自的序号。点簇序号更新示意图如图 6，完整的点簇对应关系更新算法如图 7 所示。

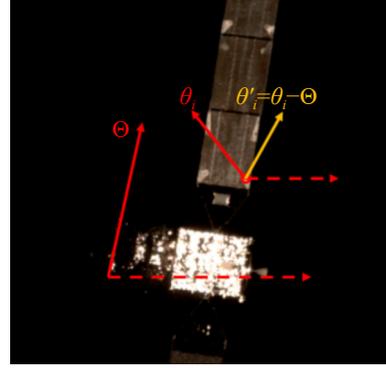


图 5 通过目标主方向消除旋转对特征点方向的影响  
Fig.5 Eliminating the influence of rotation on the direction of the feature point by using the principal

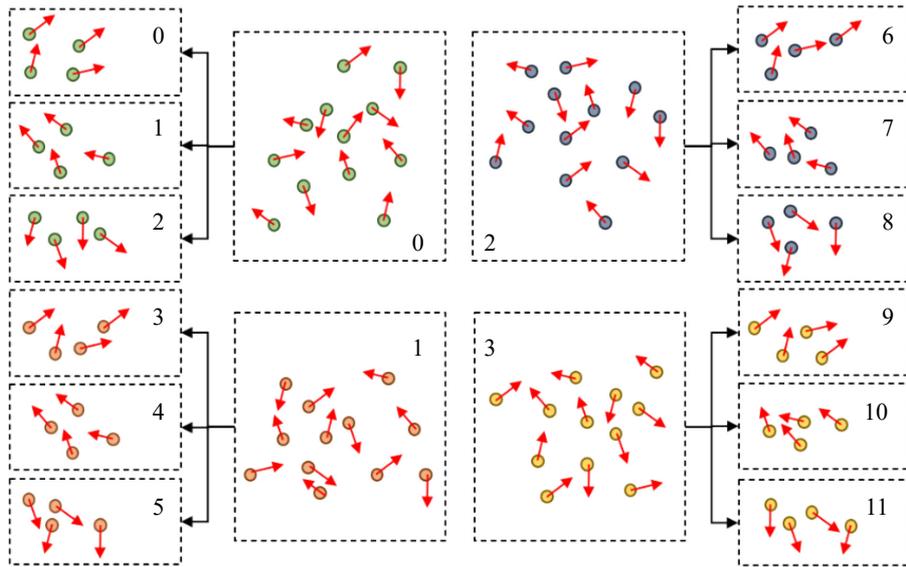


图 6 点簇序号更新  
Fig.6 Cluster number updating

在二轮点簇匹配关系的基础上，对应点簇之间进行特征点匹配（如图 8 所示），此时待匹配的特征点在空间上都属于图像中目标的同一部分，且相对目标本身的特征点主方向相差较小，能够在保证结果准确的前提下，有效提高特征点的匹配数量。

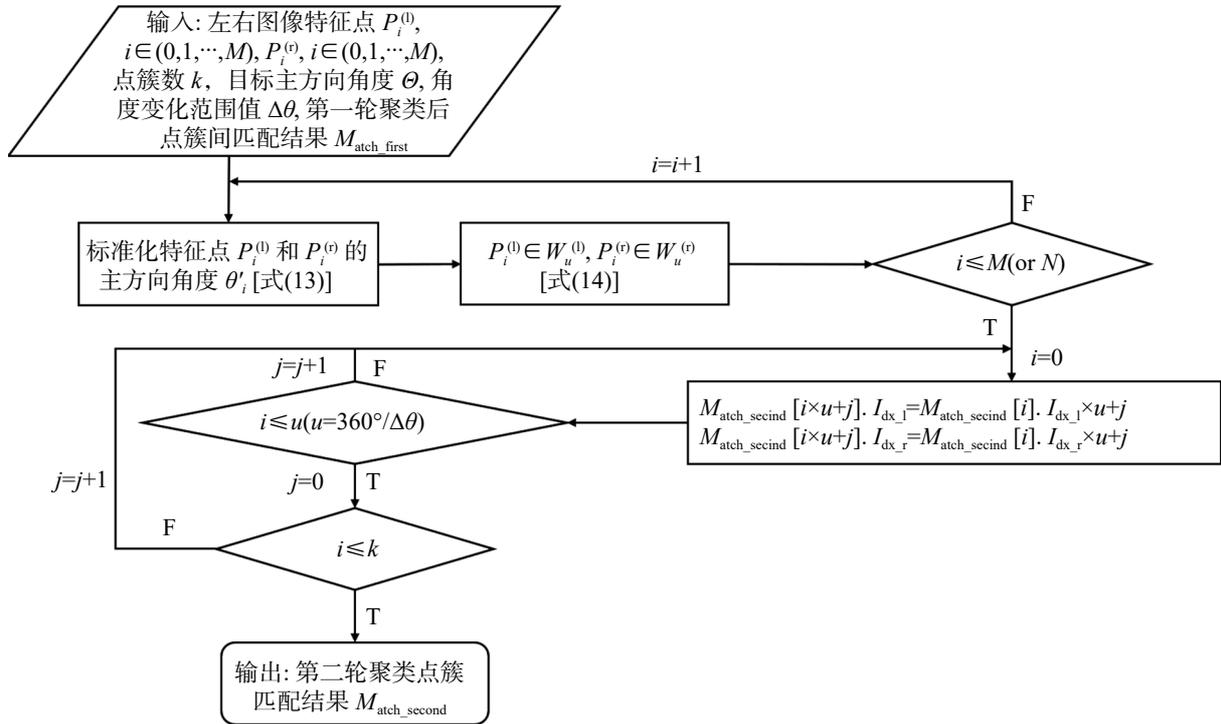


图 7 二轮聚类后新点簇匹配关系更新算法

Fig.7 Calculation of matching relation of new point clusters after two-round clustering

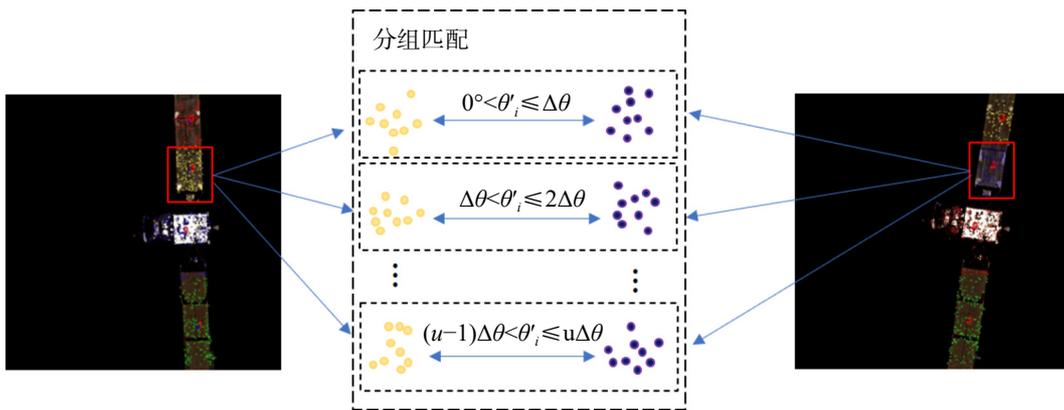


图 8 特征点分组匹配

Fig.8 Group matching of feature points

## 2 实验结果与分析

本文利用空间相机模拟影像对提出的特征点匹配算法进行实验验证, 并与已有算法进行对比。通过多组数据与参数的实验, 证明本文提出的算法对于空间目标影像的特征点匹配数量与质量有较大的提高。

### 2.1 实验环境及数据源

实验开发平台为 VS2019, 主要使用了外部库 OpenCV 4.4.0。实验使用数据为空间航天器目标在不同距离上的模拟图像, 实验中通过模拟卫星轨道数据与相机参数, 并依据在轨成像条件得到了共 4 组图像数据, 其中 1、2 组为远距离 (100 m) 成像, 3、4 组为近距离 (50 m) 成像, 4 组数据图像分辨率均为 1 024 像元×1 024 像元。

实验中, 首先对左右图像进行去噪和光照均匀化, 这一步采用了基于二维伽马函数的光照不均匀图

像自适应校正算法<sup>[20]</sup>, 并对空间目标图像大面积冷空背景的影响进行改进, 依据灰度值提取目标区域, 只对目标本身进行匀光处理。

提取特征点后, 为保证特征点的精度, 便于后续处理, 实验中剔除不满足下述条件要求的特征点: 1) 两个特征点之间的距离不应过近 (小于 2 个像元); 2) 特征点  $5 \times 5$  像元大小邻域内的点与特征点本身像元灰度值相差不应过小 (灰度相差大于 5 的像元少于 5 个)。

在两轮聚类后, 采用 Lowe 提出的比较最近邻距离与次近邻距离的方法对特征点进行匹配<sup>[21]</sup>, 距离比率阈值设为 0.6; 对于可能存在的“多对一”匹配, 仅保留距离最小的点对; 最后利用 RANSAC 方法估计本质矩阵, 要求本质矩阵的可信度达到 99.9%, 点到极线的最大距离在 1 个像元以内, 进而剔除误匹配点。

## 2.2 匹配结果比较实验

基于聚类的空间目标特征点匹配方法通常配合大部分成熟的特征点描述子使用。采用经典的 SIFT 和 SURF 特征, 在使用的特征描述子相同的情况下, 对比直接匹配与基于聚类的匹配方法最终的匹配结果。对于空间目标为航天器的遥感图像而言, 根据其结构设置首轮聚类的类别数  $k=4$ , 特征点的首轮聚类结果如图 9, 左右影像特征点经过首轮聚类后, 被分割后的点簇在目标本体上的分布情况相近。

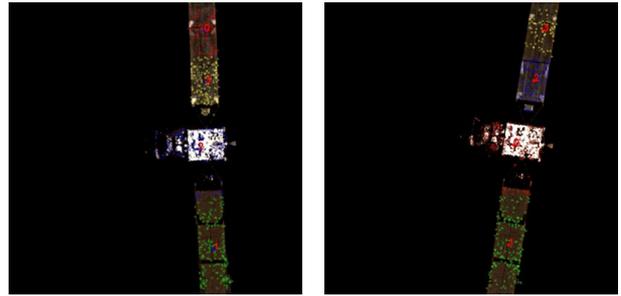


图 9 首轮聚类结果 ( $k=4$ )  
Fig.9 Results of the first round of clustering ( $k=4$ )

二轮聚类中, 为兼顾匹配复杂度与点簇划分程度, 以角度变化步长  $\Delta\theta = 120^\circ$  为例, 将首轮聚类得到的 4 簇点集的每一簇进一步分为 3 类, 再使用 SIFT、SURF 特征描述子利用 RANSAC 算法分别进行外点剔除, 最后计算  $x$  和  $y$  方向上的重投影误差对特征点匹配质量进行量化评价。与不进行分类的匹配结果对比见图 10~13, 其量化比较结果见表 1。

由上述实验结果可知, 对于 SIFT、SURF 两种特征点描述子, 基于聚类的匹配方法相较于直接匹配,

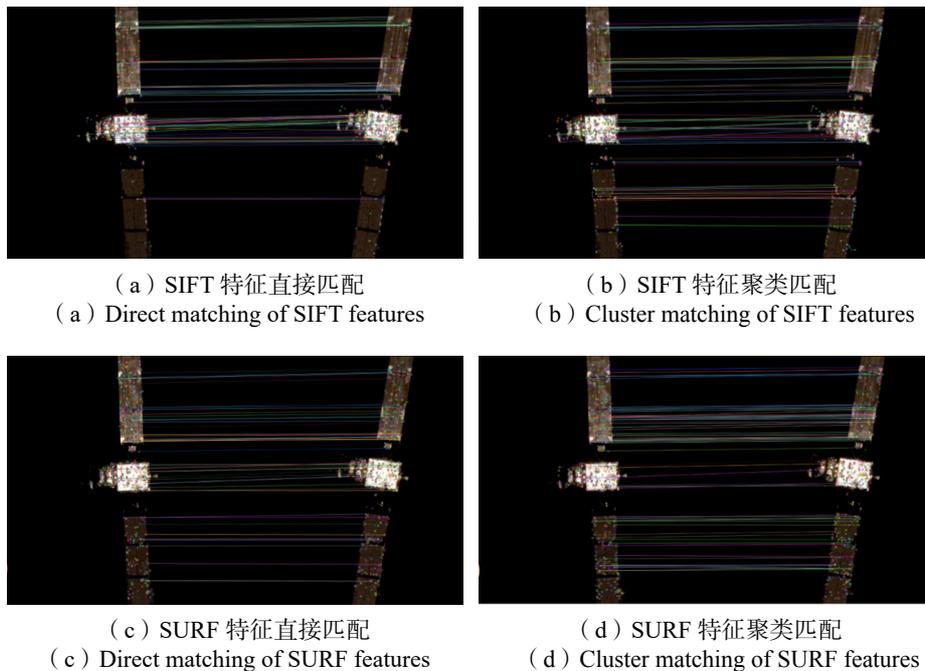


图 10 数据 1: 远距离目标匹配结果

Fig.10 Data set1: long-distance target matching results

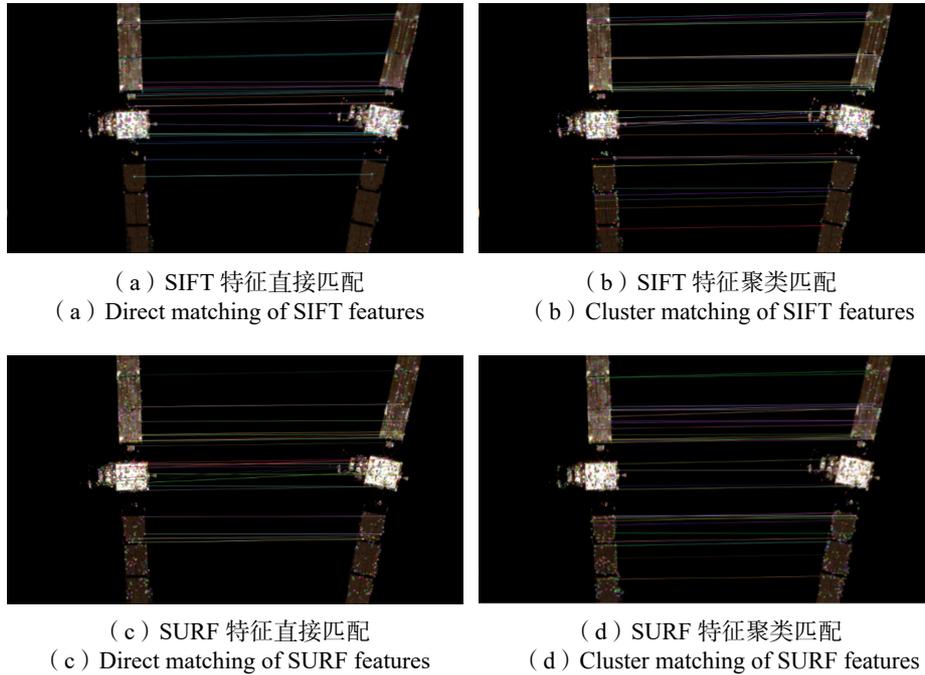


图 11 数据 2: 远距离目标匹配结果  
Fig.11 Data set2: long-distance target matching results

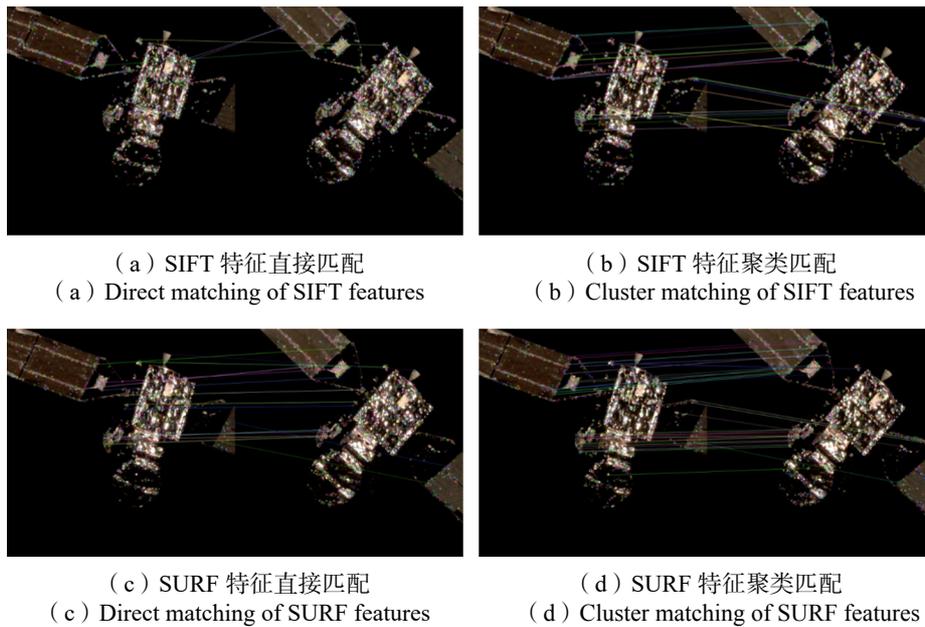
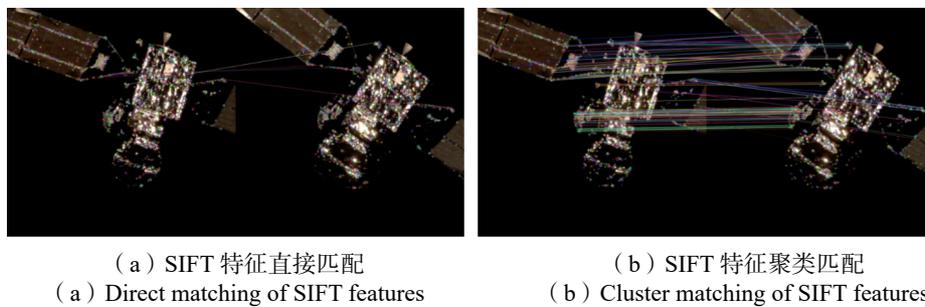
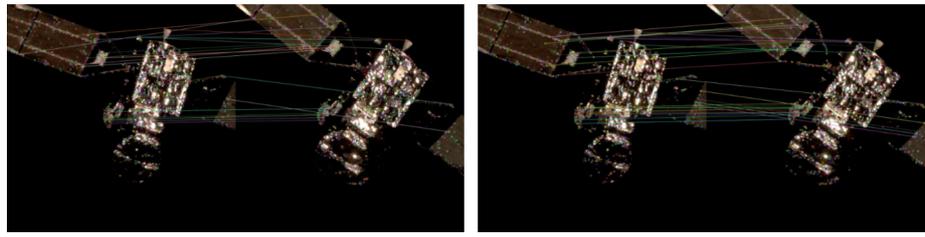


图 12 数据 3: 近距离目标匹配结果  
Fig.12 Data set3: close-distance target matching results





(c) SURF 特征直接匹配 (c) Direct matching of SURF features  
 (d) SURF 特征聚类匹配 (d) Cluster matching of SURF features

图 13 数据 4: 近距离目标匹配结果

Fig.13 Data set4: close-distance target matching results

表 1 基于聚类的匹配与直接匹配结果比较

Tab.1 Comparison of the matching results based on cluster and direct matching

| 评价指标            | 数据 1 (远距离) |        | 数据 2 (远距离) |        | 数据 3 (近距离) |        | 数据 4 (近距离) |        |    |        |        |        |    |        |        |        |
|-----------------|------------|--------|------------|--------|------------|--------|------------|--------|----|--------|--------|--------|----|--------|--------|--------|
|                 | SIFT       |        | SURF       |        | SIFT       |        | SURF       |        |    |        |        |        |    |        |        |        |
|                 | 直接         | 聚类     | 直接         | 聚类     | 直接         | 聚类     | 直接         | 聚类     |    |        |        |        |    |        |        |        |
| 匹配数量            | 55         | 61     | 41         | 58     | 25         | 33     | 27         | 32     | 失败 | 28     | 16     | 33     | 失败 | 98     | 20     | 33     |
| X 向重投影<br>误差/像元 | 0.1992     | 0.1652 | 0.4345     | 0.2358 | 0.3403     | 0.1562 | 0.2828     | 0.2305 | —  | 0.1771 | 0.2282 | 0.2211 | —  | 0.2091 | 0.1930 | 0.1776 |
| Y 向重投影<br>误差/像元 | 0.3983     | 0.0917 | 0.4706     | 0.0895 | 0.1293     | 0.1104 | 0.1634     | 0.1465 | —  | 0.0365 | 0.0510 | 0.0509 | —  | 0.0366 | 0.0353 | 0.0330 |

匹配成功的同名特征点数均有 10% 以上的提升, 其中 SURF 特征在两组数据中的匹配成功点数最大提升量优于 50%。特别地, 当目标本身旋转、畸变较大时, 由于特征点匹配数量少且其中存在较多误匹配, 在利用 RANSAC 计算本质矩阵时, 拟合结果误差太大, 本质矩阵错误, 造成 SIFT 直接匹配不成功。这种情况下, 聚类匹配通过分组使对应点簇间的误匹配较少, 能够很好地完成匹配。

匹配质量方面, 基于聚类的匹配方法在 4 组实验中都有更小的重投影误差, x 和 y 方向上的重投影误差均分别在 0.25、0.10 个像元以内。特征点的分布也更为均匀, 例如图 10、图 11 空间目标图像中航天器下部太阳翼部位, 在利用远距离成像数据与 SIFT 特征进行直接匹配的实验中, 该部位几乎没有匹配成功的同名点对, 而采用基于聚类的匹配方法则有效地改善了这一问题。

### 2.3 聚类数对匹配结果的影响分析

基于聚类的特征点匹配方法的关键参数是类别数的设置。以远距离成像数据和 SURF 特征进行实验, 分析两轮聚类中类别数设置对特征点匹配的影响。

具体实验结果如表 2 及图 14 所示, 其中图 14 的点阵图则更直观地反应了匹配结果随聚类数改变的

表 2 聚类数对匹配结果的影响

Tab.2 Influence of the cluster number on the matching results

| 首轮聚类 k 值 | 二轮聚类 $\Delta\theta$ | 匹配数量    | 重投影误差/像元 |         | 首轮聚类 k 值 | 二轮聚类 $\Delta\theta$ | 匹配数量    | 重投影误差/像元 |         |
|----------|---------------------|---------|----------|---------|----------|---------------------|---------|----------|---------|
|          |                     |         | x 方向     | y 方向    |          |                     |         | x 方向     | y 方向    |
| 3        | 180°                | 47      | 0.288 5  | 0.043 9 | 6        | 60°                 | 57      | 0.225 9  | 0.094 7 |
|          | 120°                | 44      | 0.279 0  | 0.111 9 |          | 30°                 | 24      | 0.697 4  | 0.307 3 |
|          | 60°                 | 43      | 0.273 5  | 0.047 7 | 8        | 180°                | 47      | 0.247 6  | 0.026 7 |
|          | 30°                 | 23      | 0.145 8  | 0.113 4 |          | 120°                | 49      | 0.269 4  | 0.300 6 |
| 4        | 180°                | 55      | 0.161 5  | 0.136 6 | 60°      | 48                  | 0.458 6 | 0.210 7  |         |
|          | 120°                | 58      | 0.235 8  | 0.089 5 | 30°      | 23                  | 0.150 4 | 0.223 4  |         |
|          | 60°                 | 52      | 0.253 8  | 0.075 7 | 10       | 180°                | 41      | 0.420 1  | 0.350 8 |
| 30°      | 24                  | 0.690 4 | 0.303 3  | 120°    |          | 45                  | 0.229 0 | 0.051 3  |         |
| 6        | 180°                | 59      | 0.484 2  | 0.316 6 |          | 60°                 | 41      | 0.253 6  | 0.110 0 |
|          | 120°                | 61      | 0.237 7  | 0.140 2 | 30°      | 22                  | 0.156 3 | 0.122 6  |         |

趋势。可以发现,在首轮聚类 $k=6$ 、二轮聚类 $\Delta\theta=120^\circ$ 时,能够得到最好的匹配结果,正确匹配数量达到了61。当 $\Delta\theta>60^\circ$ 时,不同的聚类匹配结果虽有差异,但都优于直接匹配;当 $\Delta\theta=30^\circ$ 时,匹配结果不理想,匹配成功的同名特征点对数量小于25。

综上分析可知,对特征点匹配结果影响较大的是首轮聚类的簇数 $k$ ,当 $k$ 过小时,局部对称结构没有被完全划分开,仍会出现目标对称结构造成的负面影响;当 $k$ 过大时,聚类结果开始不可控,某一簇特征点在左右两张图像中可能被归入不同的点簇,无法进行匹配。在设置首轮聚类簇数 $k$ 时,应当考虑具体图像中的目标结构,使得 $k$ 对应目标合理的部件数量。

二轮聚类的 $\Delta\theta$ 在大于 $60^\circ$ 时,对匹配结果的影响较小,但当 $\Delta\theta=30^\circ$ 时,则产生了较大的负面影响。二轮聚类中, $\Delta\theta$ 设置太大,会存在过多重复纹理的特征点仍属于同一类的情况,没有起到二轮聚类的作用;但 $\Delta\theta$ 也不可太小,否则会使二轮聚类的类别数过多,在特征点角度接近边界( $\theta'_i \approx u\Delta\theta, u=0,1,2,\dots$ )时,由于特征点角度误差,会将同名特征点划分入不同的点簇,造成漏匹配。从实验结果来看,设置 $\Delta\theta=120^\circ$ 是较好的选择。

### 3 结束语

针对空间目标的重复弱纹理与其他因素对现有特征点提取匹配算法的限制,本文提出了一种基于聚类的特征点匹配方法。该方法使用目前通用的特征点描述子修改算法匹配部分,首先利用特征点的空间位置进行 $k$ -means聚类,减小图像中目标对称结构的影响;再利用特征点的角度进行二次聚类,将重复纹理的特征点区分开来。经过两轮聚类,算法在匹配阶段即剔除了相近特征点可能造成的误匹配。实验结果表明,基于聚类的特征点匹配算法较直接匹配能显著提高空间重复弱纹理目标的特征点匹配结果的质量,使匹配数量最高增加50%,重投影误差优于 $1/4$ 像元,特征点分布更为均匀,有利于目标三维重建、图像拼接等后续处理,适用于空间目标如航天器等结构划分清晰、目标相对背景突出的遥感图像。

#### 参考文献 (References)

- [1] 耿则勋,张保明,范大昭.数字摄影测量学[M].北京:测绘出版社,2010.  
GENG Zexun, ZHANG Baoming, FAN Dazhao. Digital Photogrammetry[M]. Beijing: Surveying and Mapping Press, 2010. (in Chinese)
- [2] SHAO F, AN J, LIU Z X. Feature Point Matching Algorithm Based on Local Relative Velocity Consensus[C]//2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP). Piscataway: IEEE, 2021, 1817: 12-14.
- [3] WU R, WANG K, MA J Q. Feature Points Matching Algorithm Based on Homography Constraint and Gray Scale Truncation Number[J]. *Journal of Physics: Conference Series*, 2019, 1229: 012049.
- [4] 唐管政,唐大全,谷旭平.一种改进的ORB特征点匹配算法[J]. *舰船电子工程*, 2021, 41(6): 50-53.  
TANG Guanzheng, TANG Daquan, GU Xuping. An Improved ORB Feature Point Matching Algorithm[J]. *Ship Electronic Engineering*, 2021, 41(6): 50-53. (in Chinese)
- [5] XIA Y F, JIANG J, LU Y F, et al. Robust Feature Matching via Progressive Smoothness Consensus[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 196: 502-513
- [6] GONG D C, HUANG X, ZHANG J D, et al. Efficient and Robust Feature Matching for High-Resolution Satellite Stereos[J]. *Remote Sensing*, 2022, 14(21): 5617.

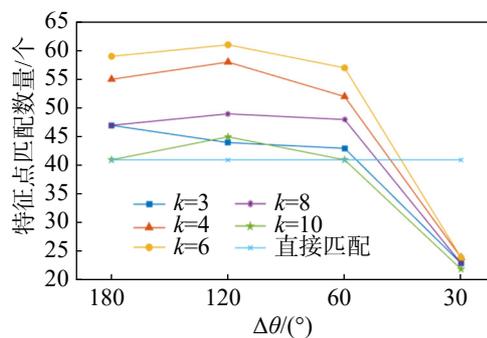


图14 聚类数与匹配结果关系  
Fig.14 Relationship between the number of clusters and the matching results

- [7] 曹南, 蔡扬扬, 李旭洋, 等. 高分辨率遥感影像特征点自动化匹配方法研究[J]. *地理空间信息*, 2022, 20(11): 9-13.  
CAO N, CAI Y Y, LI X Y, et al. Research on Automatic Feature Point Matching of High-resolution Remote Sensing Images[J]. *Geospatial Information*, 2022, 20(11): 9-13. (in Chinese)
- [8] 潘峰, 沈建新, 秦顺, 等. 融合GMS的ORB特征点提取与匹配算法[J]. *计算机工程与设计*, 2022, 43(8): 2244-2251.  
PAN F, SHEN J X, QIN S, et al. ORB Feature Point Extraction and Matching Algorithm Based on GMS[J]. *Computer Engineering and Design*, 2022, 43(8): 2244-2251. (in Chinese)
- [9] LI W X, CHEN Q, GU G H, et al. Feature Point Matching of Infrared and Visible Image[J]. *Applications of Digital Image Processing XLIII*, 2020: 1151029.
- [10] 赵威驰, 赵其杰, 江俊晔, 等. 基于沙漏网络的人脸面部特征点检测[J]. *光学学报*, 2019, 39(11): 251-260.  
ZHAO W C, ZHAO Q J, JIANG J Y, et al. Facial Feature Point Detection Based on Hourglass Network[J]. *Acta Optica Sinica*, 2019, 39(11): 251-260. (in Chinese)
- [11] SARLIN P E, DETONE D, MALISIEWICZ T, et al. SuperGlue: Learning Feature Matching with Graph Neural Networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE, 2020, 4937-4946.
- [12] LIU Y, HUANG K, LI J Y, et al. AdaSG: A Lightweight Feature Point Matching Method Using Adaptive Descriptor with GNN for VSLAM[J]. *Sensors*, 2022, 22(16): 5992.
- [13] 刘欣, 吴俊娴, 张占月. 一种基于卫星图像匹配的无人机自主定位算法[J]. *航天返回与遥感*, 2021, 42(2): 130-138.  
LIU Xin, WU Juxian, ZHANG Zhanyue. An Autonomous Positioning Algorithm for UAV Based on Satellite Image Matching[J]. *Spacecraft Recovery and Remote Sensing*, 2021, 42(2): 130-138. (in Chinese)
- [14] KNIAZ V V. GANcoder: Robust Feature Point Matching Using Conditional Adversarial Auto-encoder[C]//Optics, Photonics and Digital Technologies for Imaging Applications VI. Bellingham: Society of Photo-Optical Instrumentation Engineers, 2020.
- [15] WU B, ZENG H, HU H. Illumination Invariant Feature Point Matching for High-resolution Planetary Remote Sensing Images[J]. *Planetary and Space Science*, 2018, 152: 45-54.
- [16] SHEN J Y, GUO X C, ZHOU W Z, et al. Feature Point Matching Method for Aerial Image Based on Recursive Diffusion Algorithm[J]. *Symmetry*, 2021, 13(3): 407.
- [17] 程鹏飞, 周修庄, 唐玲, 等. 一种面向弱纹理图像的特征点描述子[J]. *北京邮电大学学报*, 2021, 44(6): 13-19.  
CHENG P F, ZHOU X Z, TANG L, et al. A Feature Point Descriptor for Weak Texture Images[J]. *Journal of Beijing University of Posts and Telecommunications*, 2021, 44(6): 13-19. (in Chinese)
- [18] ARTHUR D, VASSILVITSKII S. k-means++: The Advantages of Careful Seeding[C]//Proceedings of The Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. Philadelphia: SIAM, 2007: 1027-1035.
- [19] BAGHAIE A, YU Z. Structure Tensor Based Image Interpolation Method[J]. *AEUE - International Journal of Electronics and Communications*, 2015, 69(2): 515-522.
- [20] 刘志成, 王殿伟, 刘颖, 等. 基于二维伽马函数的光照不均匀图像自适应校正算法[J]. *北京理工大学学报*, 2016, 36(2): 191-196, 214.  
LIU Zhicheng, WANG Dianwei, LIU Ying, et al. An Adaptive Correction Algorithm for Non-uniform Illumination Images Based on Two-dimensional Gamma Function[J]. *Transactions of Beijing Institute of Technology*, 2016, 36(2): 191-196, 214. (in Chinese)
- [21] LOWE D G. Distinctive Image Features from Scale-Invariant Keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.

(编辑: 夏淑密)