

Journal of System Simulation

Volume 34 | Issue 4

Article 8

4-19-2022

Feature Matching Algorithm Based on Optimal Geometric Constraints and RANSAC

Xiaojuan Ning

1.*Institute of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China;*
2.*Shaanxi Key Laboratory for Network Computing and Security Technology, Xi'an 710048, China;*
ningxiaojuan@xaut.edu.cn

Jieru Li

1.*Institute of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China;*
1353654876@qq.com

Fan Gao

1.*Institute of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China;*

Yinghui Wang

3.*Institute of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Feature Matching Algorithm Based on Optimal Geometric Constraints and RANSAC

Abstract

Abstract: In order to solve the problem that it's hard to reconcile the quality and computational efficiency of feature point matching. *The initial matching for the extracted feature points is implemented through k-nearest neighbor (KNN) algorithm. According to the characteristics of equal length and same slope of the connecting line between matching points, the optimal geometric constraint is constructed based on the statistical sorting strategy to eliminate the obvious matching errors. Then random sample consensus (RANSAC) algorithm is utilized for further filtering to ensure the accuracy of the feature matching point pairs.* Experimental results show that the method can obtain more matched point pairs under normal light, compared with Lowe's algorithm and GMS algorithm, and can ensure the quality of feature points.

Keywords

statistical ranking, optimal geometric constraint, random sample consensus algorithm, feature point match

Recommended Citation

Xiaojuan Ning, Jieru Li, Fan Gao, Yinghui Wang. Feature Matching Algorithm Based on Optimal Geometric Constraints and RANSAC[J]. Journal of System Simulation, 2022, 34(4): 727-734.

基于最佳几何约束和 RANSAC 的特征匹配算法

宁小娟^{1,2}, 李洁茹^{1*}, 高凡¹, 王映辉³

(1. 西安理工大学 计算机科学与工程学院, 陕西 西安 710048; 2. 陕西省网络计算与安全技术重点实验室, 陕西 西安 710048;
3. 江南大学 人工智能与计算机学院, 江苏 无锡 214122)

摘要: 为解决特征点匹配的质量与计算效率不能兼得的问题, 研究了一种基于最佳几何约束和 RANSAC(random sample consensus)的特征点匹配方法。采用 KNN (*k*-nearest neighbor) 算法对提取到的特征点完成初始匹配, 根据匹配点对连接线长度相等、斜率相同的特点, 基于统计排序策略构建最佳几何约束, 剔除明显错误匹配。利用 RANSAC 算法进行二次过滤, 确保特征匹配点对的正确率, 同时给出实验结果加以验证。结果表明: 在正常光照下, 与 Lowe's 算法和 GMS 算法相比, 该算法匹配到的点对数有了明显增加, 同时很大程度上保证了特征点的质量。

关键词: 统计排序; 最佳几何约束; RANSAC(random sample consensus)算法; 特征点匹配

中图分类号: TP391.41 文献标志码: A 文章编号: 1004-731X(2022)04-0727-08

DOI: 10.16182/j.issn1004731x.joss.21-0857

Feature Matching Algorithm Based on Optimal Geometric Constraints and RANSAC

Ning Xiaojuan^{1,2}, Li Jieru^{1*}, Gao Fan¹, Wang Yinghui³

(1. Institute of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. Shaanxi Key Laboratory for Network Computing and Security Technology, Xi'an 710048, China; 3. Institute of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China)

Abstract: In order to solve the problem that it's hard to reconcile the quality and computational efficiency of feature point matching. The initial matching for the extracted feature points is implemented through *k*-nearest neighbor (KNN) algorithm. According to the characteristics of equal length and same slope of the connecting line between matching points, the optimal geometric constraint is constructed based on the statistical sorting strategy to eliminate the obvious matching errors. Then random sample consensus (RANSAC) algorithm is utilized for further filtering to ensure the accuracy of the feature matching point pairs. Experimental results show that the method can obtain more matched point pairs under normal light, compared with Lowe's algorithm and GMS algorithm, and can ensure the quality of feature points.

Keywords: statistical ranking; optimal geometric constraint; random sample consensus algorithm; feature point match

引言

自 20 世纪 70 年代以来, 图像特征点匹配作为计算机视觉的核心任务, 是后续高级图像处理的关键, 如目标检测^[1-2]、图像拼接^[3]、三维重建^[4-5]、视觉定位、物体长度测量等。图像匹配方法

以特征点匹配为主流方法之一, 该方法对图像进行特征点的提取、对所提取的特征点生成描述子、利用特征点的描述子进行匹配^[6]。

Harris C G 等^[7]提出的 Harris 算法通过 2 个正交方向上强度的变化率对角点进行定义, 其本身存在尺度固定、像素定位精度低、伪角点较多和计算量

收稿日期: 2021-08-24 修回日期: 2021-12-17

基金项目: 国家自然科学基金(61871320, 61872291); 国家重点研发计划(2018YFB1004905); 教育厅重点实验室项目(17JS099)

第一作者: 宁小娟(1982-), 女, 博士, 副教授, 研究方向为模式识别与图像处理。E-mail: ningxiaojuan@xaut.edu.cn

通讯作者: 李洁茹(1995-), 女, 硕士, 研究方向为图形图像处理。E-mail: 1353654876@qq.com

大等问题。SIFT^[8](scale-invariant feature transform)算法由David G. Lowe提出，打破了角点检测的僵局，该算法对于图像旋转和缩放保持不变性，并且在大范围的仿射失真、噪声增加和照明变化中具备稳健性，但计算量极大，非常耗时。Herbert Bay等^[9]对SIFT算法进行改进并提出SURF(speeded up robust features)算法，在保持SIFT算法优良性的基础上，对光照变化和仿射也具有较强鲁棒性，但匹配时间依然较长，容易造成边界模糊和细节丢失。对此，Calonder M等^[10]提出了一种独立、可靠的二进制基础特征(binary robust independent elementary features, BRIEF)算法，它无需计算类似于SIFT的复杂特征描述子。该算法简单、实时性较好，但无法支持大角度的旋转，因而需要增加其描述子的旋转不变性。为了满足图像匹配对于精度与速度的双重要求，Ethan Rublee等^[11]提出ORB(oriented FAST and rotated brief)算法，该算法计算速度快，同时还保持了旋转不变性，并且抗噪性较强。

一旦有了特征描述子就可以将图像的特征点两两对应起来，这个过程称为特征点匹配。Lin等^[12]提出暴力匹配(brute-force matcher)方法，它将待匹配图片的特征描述子中每一行都与待匹配图片的描述子中每一行进行距离计算。然而暴力匹配最大的问题在于计算的时间复杂度和空间复杂度都比较高，为此引入KNN(k-nearest neighbor)匹

配算法^[13]。这是一种近似匹配，在一定程度上提高了匹配的速度，但无法保证能找到最佳匹配。为了提高匹配正确率，需要对误匹配点(外点)进行剔除。Fischler等^[14]提出RANSAC方法，采用迭代方式从包含离群数据的数据集中估算出数学模型，通常用于匹配后的优化算法，但存在计算量大、效率低等问题。Bian等^[15]提出了一种简单快速的GMS(grid-based motion statistics)优化算法。Bagus等^[16]提出了LMedS (least median of squares)算法，采用调整中值的策略对误匹配进行优化，但是这些算法在效率上表现并不理想。

为解决特征点匹配的质量与计算效率不能兼得的问题，本文提出了一种基于最佳几何约束和RANSAC的特征匹配算法。该算法通过初始匹配、匹配优化2个阶段，实现了最终的特征匹配结果。该方法不仅可以提高匹配点对数，而且确保了特征匹配点对的正确率。

1 基于最佳几何约束和RANSAC的匹配优化

本算法首先对提取到的特征点采用KNN算法完成初始匹配，接着利用匹配点对连接线长度相等、斜率相同的特点，基于统计排序策略构建最佳几何约束，剔除明显错误匹配进行初次优化，最后利用RANSAC算法进行二次过滤，如图1所示。

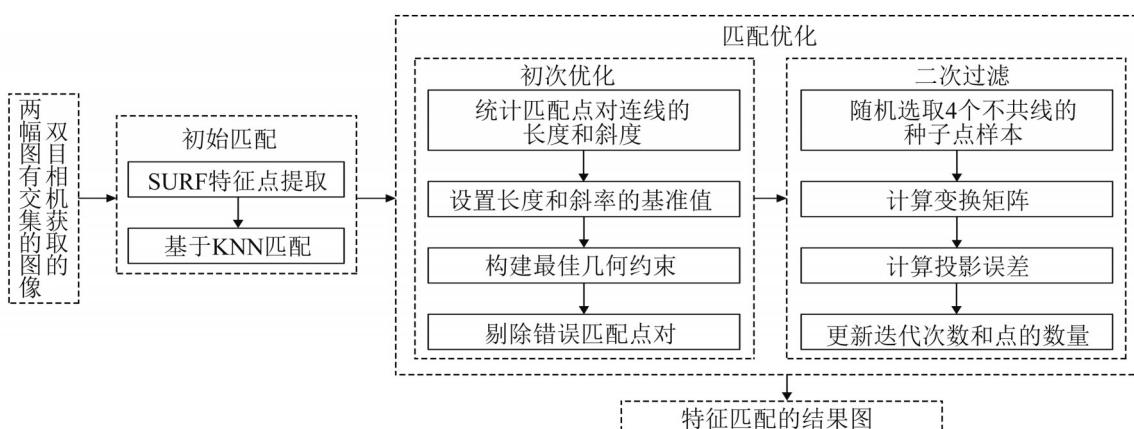


图1 算法结构图
Fig. 1 Overview of our algorithm

1.1 初始匹配

特征点提取是特征点匹配的第一步, 是从输入图像中找出感兴趣的特征点。质量好且数量多的特征点能够为后续获得优秀的特征匹配点对奠定基础。本文采用 SURF 特征点提取算法, 首先利用 Hessian 矩阵确定候选点, 然后再进行非极大值抑制。同时, 为提高算法运行速度, 在精度影响很小的情况下, 用近似的盒状滤波器代替高斯核, 并引用查表积分图, 从而实现提取的特征点数量远多于标准 SIFT 算法。SURF 算法不仅能提取到足量的特征点, 而且特征点的质量也非常高。

在提取特征点的基础上, 本文选取 KNN 算法进行初始匹配。KNN 算法即 K 最邻近法, 在特征匹配时利用 K 近邻查找法找到 k 个与特征点邻近的点。 k 的选择会对匹配的结果造成直接影响, 因此对近邻点个数 k 的选择尤为重要, 本文将 k 的取值设置为 2。若最近邻点和次近邻点的距离比小于阈值 D_{th} (D_{th} 的取值设置为 0.7), 则将最近邻的点作为匹配点。在完成初始匹配后, 后续将对匹配结果进行优化, 降低算法的误匹配率。

1.2 匹配优化

在有些场景下, 会出现 2 幅图像中不同点的相似程度大于同一个点的相似程度, 这样就会出现错误的匹配, 当错误匹配过多时, 会对最终的特征匹配结果造成不可估计的影响。因此在完成了初始匹配的基础上对传统的特征点匹配算法进行优化, 尽可能改善特征匹配的结果。

本文中初始匹配的优化过程由两部分构成, 首先通过特征点匹配连线的几何特征剔除错误匹配, 筛选出满足几何特征约束的匹配点对; 然后通过 RANSAC 算法二次过滤, 从而提高特征匹配的精度。

初始特征匹配的结果中往往存在一些由于误匹配导致的错误匹配连线。基于双目相机拍摄, 而且满足目标离相机的深度一样(匹配点间视差相

近)的前提下, 图像 $I_1(x, y)$ 中的匹配点 $p_{1i}(x_i, y_i)$ 与其在图像 $I_2(u, v)$ 中对应的匹配点 $p_{2j}(u_j, v_j)$ 之间存在 2 个特点: ①正确的匹配点对间距离 d_{ij} 相等; ②正确的匹配点对确定的直线斜率 k_{ij} 相等。如图 2 所示。

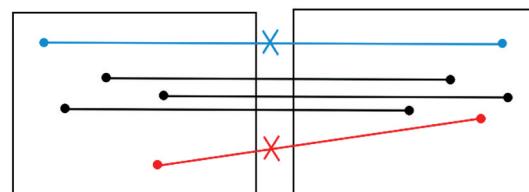


图 2 匹配点对连线几何特征示意图
Fig. 2 Geometric features of connection line between matching point pairs

图 2 中线段连接的 2 个实心点为一对匹配点, 线段为匹配点间的匹配连线, 由匹配连线的几何特征可知, 各匹配点对的距离相等且斜率相等, 在图中用黑色表示。图 2 中蓝色匹配点对连线的斜率与黑色匹配点对连线的斜率几乎一致, 但距离明显长于黑色匹配点对, 因此可以通过“正确匹配点对中两点距离 d_{ij} 相等”这一特点进行剔除。图 2 中红色匹配点对的距离与黑色匹配点对的距离几乎相等, 但斜率明显不同于黑色匹配点对, 因此可以通过“正确匹配点对确定的直线斜率 k_{ij} 相等”这一特点进行剔除。考虑到实际计算中的误差, 距离和斜率只要近似相等即可。

据此, 计算 $p_{1i}(x_i, y_i)$ 和 $p_{2j}(u_j, v_j)$ 的距离为

$$d_{ij} = \sqrt{(u_j - x_i)^2 + (v_j - y_i)^2} \quad (1)$$

计算斜率为

$$k_{ij} = (v_j - y_i)/(u_j - x_i) \quad (2)$$

式中: $i \in [1, n]$, $j \in [1, n]$, n 为正整数, 是匹配点对总数。

基于最佳几何约束的误匹配剔除方法:

(1) 初始化存储匹配点对连线集合, 设匹配点对连线长度的集合为 map_d , 斜率集合为 map_k ;

(2) 统计每对匹配点对连线的长度 d_{ij} (保留到整数位)、斜率 k_{ij} (保留到小数点后 2 位), 将长度 d_{ij}

作为 map_d 的key, value是满足匹配连线长度 d_{ij} 的条数; map_k 的key为每条匹配线的斜率 k_{ij} , value是满足匹配连线斜率 k_{ij} 的条数;

(3) 求 map_d 中value最大的key, 作为长度的基准, 设为 D ; 求 map_k 中value最大的key, 作为斜率的基准, 设为 K ;

(4) 根据反复实验得出匹配连线长度的误差范围, 将其设置为 m ; 同理, 设置匹配连线斜率的误差范围为 n ;

(5) 当 $D-m \leq d_{ij} \leq D+m$ 时, 保留该匹配点对连线, 否则删除; 同理, 当 $K-n \leq k_{ij} \leq K+n$ 时, 保留该匹配点对连线, 否则删除。

由上述算法思想可知, 本文的几何约束为 $C = (|d_{ij} - D| \leq m) \& (|k_{ij} - K| \leq n)$, 但是经过多次实验后发现该约束下难以获得足量的特征匹配点对, 这是由于该几何约束条件过于苛刻造成的。因此本文将几何约束设置为 $C = (|d_{ij} - D| \leq m) \& (|k_{ij} - K| \leq n)$, 即特征匹配点对连线只要满足长度和斜率2个约束条件任意的一个即可。在此几何约束下不仅能够获得足够数量的特征匹配点对, 而且误匹配率较低。

经过以上步骤实现对错误特征匹配点对的初步去除。接下来将通过RANSAC算法对已经处理过的特征匹配点对进行二次优化, 进一步改善匹配的结果。RANSAC算法将数据归类为内点和外点, 并从数据中迭代估算其数学模型参数。内点和外点通过阈值确定, 内点为与模型距离小于阈值的点。具体步骤为: 首先设置阈值, 其次反复迭代, 如果下一次迭代产生的模型比现有模型的内点多, 则将现有模型更新为新模型。

RANSAC算法优化匹配结果的具体方法:

(1) 初始化投影误差的阈值 λ 、内点集合 I 、最优内点集合 I_{best} 和迭代次数 it ;

(2) 从经过最佳几何约束剔除后的特征匹配点对中随机抽取4个不共线的样本数据;

(3) 根据样本数据计算变换矩阵, 记作 M ;

(4) 计算匹配点集中所有数据与 M 的投影误差 δ_{ij} , 如果 $\delta_{ij} < \lambda$, 则将其加入到 I 中;

(5) 如果 I 中元素数量比 I_{best} 中的元素数量多, 则更新 $I_{best}=I$, 同时更新迭代次数 o ;

(6) 如果计算的迭代次数 $o > it$, 则退出; 否则迭代次数加1, 重复上述步骤。

通过以上算法对特征匹配点对进行2次处理后, 将很大程度上提高特征匹配的正确率。

2 实验结果与分析

本文工作的实验环境为: Ubuntu 操作系统, CPU 为 Inter(R)Core(TM)i5-8500 CPU @ 3.00 GHz, 内存为 16 GB。开发语言为 Python2.7, OpenCV 版本为 2.7。

在实验中使用了2组不同的数据, 其中图3(a)的一组数据是来源于公开的 MiddleBurry 数据集里的一组 Cones 数据; 图3(b)的一组数据是来源于本实验室专用双目相机拍摄, 且目标离相机的深度一样(匹配点间视差相近)的一组 Book 数据。



(a) Cones数据



(b) Books数据

图3 实验数据

Fig. 3 Experimental data

运用本文方法对 Cones 数据和 Book 数据进行了相关的实验, 如图4所示。由图4可以看到, 通过基于 KNN 的初始匹配以及匹配优化算法可以有效实现特征匹配。

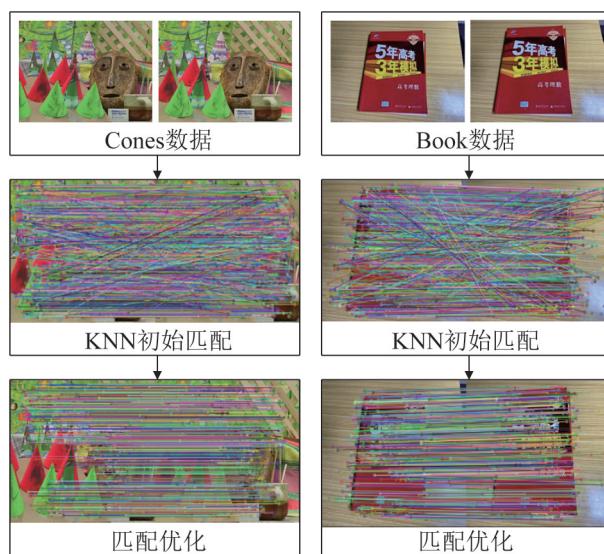


图4 匹配优化结果
Fig. 4 Matching optimization results

2.1 初始匹配分析

本节分别从特征点提取结果、特征点个数以及算法运行时间等方面对比了SIFT算子、ORB算子以及本文采用的SURF算子，以此验证本文选取方法的有效性，结果如表1所示。

表1 不同算法特征点提取结果

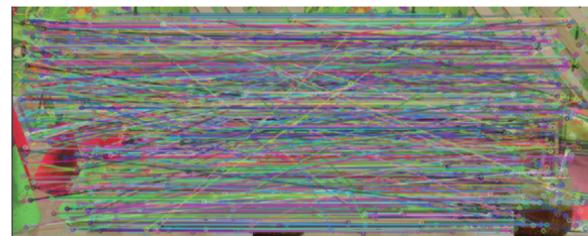
Table 1 Feature point extraction results of different algorithms

算法	特征点提取结果	特征点个数(个)	运行时间/s
SIFT		478	0.167
SURF		1 344	0.200
ORB		500	0.018

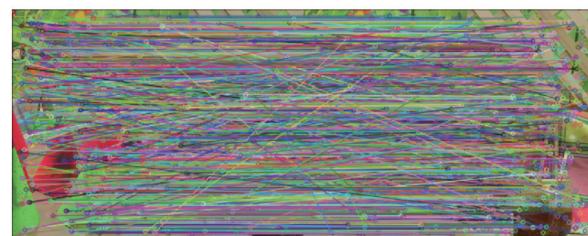
由表1的对比结果可知，在同一计算机环境中，SIFT方法提取到的特征点数量是最少的，ORB算法的运行时间成本最低，且提取到的特征点数量较少。即使SURF特征点提取方法运行时

间较长于SIFT算法，但SURF算法提取到的特征点数量远多于其他2种算法，且书本边缘信息中的特征点均可获取。

对图3中的2组数据通过SURF算法提取到特征点后，分别采用BF算法和KNN算法进行初始匹配来验证本文选取方法的有效性，如图5~6所示。



(a) BF算法



(b) KNN算法

图5 Cones 数据的初始匹配结果对比
Fig. 5 Comparison of initial matching results of Cones data



(a) BF算法



(b) KNN算法

图6 Book 数据的初始匹配结果对比
Fig. 6 Comparison of initial matching results of Book data

由图5和图6的实验结果可知，虽然BF算法和KNN算法都存在着大量的错误匹配，但KNN算法

在这两组数据集中的匹配效果略优于BF算法。

2.2 确定最佳几何约束

在不同几何约束条件下，当几何约束剔除后，匹配点对数和算法运行时间会有所不同，具体结果如表2所示。

表2 几何约束实验结果
Table 2 Experimental results of geometric constraints

长度m和斜率n	初始匹配点数(个)	几何约束剔除后的匹配点对数(个)	运行时间/s
$m=13 \& n=0.03$	1 258	21	0.814 524
$m=13 \parallel n=0.03$	1 258	884	0.790 735
$m=14 \& n=0.03$	1 258	21	0.790 647
$m=14 \parallel n=0.03$	1 258	889	0.791 691
$m=15 \& n=0.03$	1 258	21	0.794 338
$m=15 \parallel n=0.03$	1 258	893	0.789 879

由表2的对比结果可知，当特征匹配点对连接线长度和斜率2个约束条件都必须满足时，几何约束剔除匹配后的匹配点对数明显减少，当特征匹配点对连接线长度和斜率2个约束条件满足之一时，不仅可以剔除错误匹配，而且几何约束剔除匹配后的匹配点对数是足够的。

在确定最佳几何约束C之后，根据反复实验结果得出匹配线长度的误差范围m；匹配线斜率的误差范围n，结果如表3所示。本文在进行多次测试实验后发现：当 $m=15, n=0.03$ 时，不仅可以很大程度上剔除错误匹配，还能留下足够多的匹配点对，算法的运行速度快。

表3 不同误差范围的结果
Table 3 Results of different error ranges

长度m和斜率n	初始匹配点数(个)	几何约束剔除后的匹配点对数(个)	运行时间/s
$m=13, n=0.02$	1 258	881	0.828 312
$m=13, n=0.03$	1 258	884	0.790 466
$m=14, n=0.02$	1 258	886	0.827 559
$m=14, n=0.03$	1 258	889	0.820 967
$m=15, n=0.02$	1 258	890	0.797 841
$m=15, n=0.03$	1 258	893	0.788 993
$m=16, n=0.02$	1 258	892	0.790 702
$m=16, n=0.03$	1 258	895	0.797 179

2.3 匹配结果分析

为了验证本文的特征匹配算法是可靠的，将本文算法同Lowe's算法^[17]和GMS算法进行对比。Lowe's算法是一种获取优秀匹配点的经典算法，GMS算法是一种基于网格运动统计的快速鲁棒的特征匹配方法。在同一实验环境下，使用Lowe's算法、GMS算法和本文算法分别对图3中的2组数据进行处理，对比的实验结果如表4~5所示，匹配结果如图7所示。

表4 Cones 数据结果对比

Table 4 Comparison results for Cones data

算法	匹配到的点对数(个)	运行时间/s
Lowe's	795	0.825 712
GMS	757	1.393 039
本文	850	0.881 369

表5 Book 数据结果对比

Table 5 Comparison results for Book data

算法	匹配到的点对数(个)	运行时间/s
Lowe's	608	0.694 027
GMS	592	1.244 794
本文	713	0.693 211

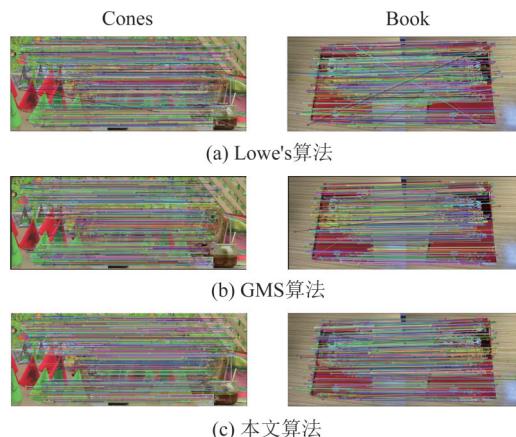


图7 Cones 数据、Book 数据的匹配结果对比
Fig. 7 Comparison of matching results for Cones data and Book data

由表4~5可知，本文获取到的匹配点对数相较于Lowe's算法和GMS算法也有了明显的提升。Lowe's算法的优点是在去除了大量错误匹配的同时提高了匹配计算的速度。而本文算法与Lowe's算法的时间成本基本持平；GMS算法的优点是可以迅速剔除

错误匹配，从而提高匹配的稳定性。而本文算法的时间成本和匹配的点对数都优于GMS算法。由图7可知，对于2种不同的数据集，Lowe's算法仍旧存在着明显的错误匹配，GMS算法存在的明显错误匹配比Lowe's算法少，而本文算法基本不存在肉眼可直接观察到的错误匹配。因此本文算法在误匹配的剔除和获取到的匹配点对数量上都优于Lowe's算法和GMS算法，从而验证了本文算法在特征匹配优化上的有效性。

同时，针对处于不同光照环境下算法的鲁棒性不同^[18]，分析了在同一实验环境中不同光照环境对本文方法的影响，如表6和图8所示。分光线1(光线暗时)、光线2(正常光线时)、光线3(较强光线下)和光线4(一张图片处于光线暗、一张图片处于正常光线)等4种情况下本文算法的实验结果。

表6 不同光照下的实验结果
Table 6 Experiment results under different illumination

光线强度	匹配的点对数(个)	运行时间/s
光线1	510	0.589 114
光线2	713	0.693 211
光线3	786	0.948 643
光线4	561	0.731 228

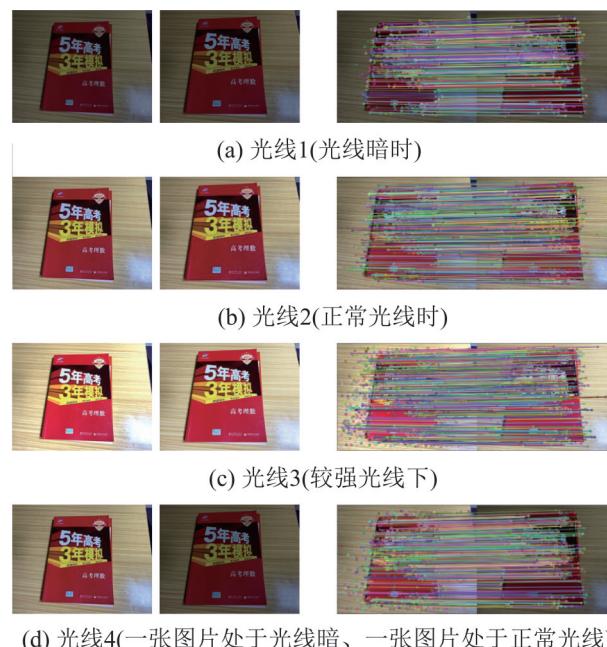


图8 不同光照下的匹配结果

Fig. 8 Matching results under different illumination

由表6和图8可知，当光照处于光线1和光线4时，匹配的点对数会减少，但基本不存在明显的肉眼可直接观察到的错误匹配；当光照过强时，如光线3时，匹配的点对数会增加，但是会存在极少数明显的肉眼可直接观察到的错误匹配；当处于光线2(正常光线)时，不仅有足够多的高质量的匹配点对数，而且不存在肉眼可直接观察到的错误匹配。所以本文在正常光照情况下，解决了以往的特征点匹配算法误匹配多、匹配点对数量少、时间成本高等问题。但在光线过暗和过亮时，会影响本文算法的准确性与高质量匹配点对的数量。

3 结论

本文实现了一种高效的特征点匹配方法，该方法采用SURF算子提取出数量多且质量好的特征点，同时利用KNN算法完成初始匹配。考虑到初始匹配后会存在错误匹配的情况，通过匹配连线存在斜率和长度相等的几何特征，基于统计排序的思想构建最佳几何约束，剔除不符合条件的错误匹配。接着在此基础上通过经典的RANSAC算法优化匹配结果。该方法解决了以往的特征点匹配算法误匹配多、匹配点对数量少等问题，在很大程度上保证了特征点匹配的质量，为后续三维特征的匹配奠定了一定的基础。然而本文在确定最佳几何约束和误差范围需要经过大量的实验，算法的鲁棒性还有待提高。当光线过暗和过亮时，会影响本文算法的准确性与匹配点对的数量。因此，在后续工作中，需要探索如何避免光照强度的影响，来进一步提高算法的准确率和高效性。

参考文献：

- [1] Lowe D G. Object Recognition from Local Scale-Invariant Features[C]// 7th International Conference on Computer Vision. Greece: Corfu, 1999: 1150-1157.
- [2] Scitovski R, Majstorović S, Sabo K. A Combination of RANSAC and DBSCAN Methods for Solving the Multiple Geometrical Object Detection Problem[J]. Journal of Global Optimization (S0925-5001), 2021, 79(3): 669-686.

- [3] Sung-Hyok Ro, Se-Hun Kim. An Image Stitching Algorithm for the Mineralogical Analysis[J]. Minerals Engineering (S0892-6875), 2021, 169(6): 106968.
- [4] Steven M S, Charles R D. Photorealistic Scene Reconstruction by Voxel Coloring[J]. International Journal of Computer Vision (S0920-5691), 1999, 35(2): 151-173.
- [5] Zhu Qing, Wang Zhendong, Hu Han, et al. Leveraging Photogrammetric Mesh Models for Aerial-Ground Feature Point Matching Toward Integrated 3D Reconstruction[J]. ISPRS Journal of Photogrammetry and Remote Sensing (S0924-2716), 2020, 166(8): 26-40.
- [6] Jiang Xingyu, Ma Jiayi, Xiao Guobao, et al. A review of Multimodal Image Matching: Methods and Applications [J]. Information Fusion (S1566-2535), 2021, 73(9): 22-71.
- [7] Harris C G, Stephens M. A Combined Corner and Edge Detector[C]// 4th Alvey Vision Conference. Manchester: AVC, 1988: 147-151.
- [8] David G Lowe. Distinctive Image Features from Scale-Invariant Keypoints[J]. International Journal of Computer Vision (S0920-5691), 2004, 60(2): 91-110.
- [9] Bay H, Tuytelaars T, van Gool L. SURF: Speeded Up robust Features[C]// European Conference on Computer Vision. Graz: Springer, 2006: 404-417.
- [10] Calonder M, Lepetit V, Strecha C, et al. Binary Robust Independent Elementary Features[C]// European Conference on Computer Vision. Crete: Springer, 2010: 778-792.
- [11] Rublee E, Rabaud V, Konolige K, et al. ORB: An Efficient Alternative to SIFT or SURF[C]// IEEE International Conference on Computer Vision. New York: IEEE, 2011: 2564-2571.
- [12] Lin W Y D, Cheng M M, Lu J, et al. Bilateral Functions for Global Motion Modeling[C]// 13th European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014: 341-356.
- [13] 王心醉, 董宁宁, 李欢利. 基于SIFT算法的图像特征点提取和匹配研究[J]. 南京医科大学学报(自然科学版), 2013, 33(2): 286-290.
- Wang Xinzui, Dong Ningning, Li Huanli. Research of Features Extraction and Matching in the Image Based on the SIFT Algorithm[J]. Journal of Nanjing Medical University (Natural Science Edition), 2013, 33(2): 286-290.
- [14] Fischler M A, Bolles R C. Random Sample Consensus: a Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography[J]. Communications of the ACM (S0001-0782), 1981, 24(6): 381-395.
- [15] Bian J W, Lin W Y, Matsushita Y, et al. GMS: Grid-Based Motion Statistics for Fast, Ultra-Robust Feature Correspondence[C]// IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE, 2017: 4181-4190.
- [16] Bagus Mulyawan, Nicholas Jovianto, Janson Hendryli, et al. Land Mapping with Least Median of Squares Regression Using Landsat Imagery: a Case Study Jakarta and Surrounding Area[J]. IOP Conference Series: Materials Science and Engineering (S1757-8981), 2020, 852(1): 012024.
- [17] Muja M, Lowe D G. Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration[C]// IEEE Conference on Computer Vision Theory and Applications. Lisbon, Portugal: IEEE Computer Society, 2009: 331-340.
- [18] Huang Jiawei, Liu Shiguang. Robust Simultaneous Localization and Mapping in Low-Light Environment[J]. Computer Animation and Virtual Worlds(S1546-4261), 2019, 30(3/4): e1895.