

# 一种基于 SURF 和扩展哈希的空间约束图像匹配算法\*

吴铭心

(北京航空航天大学 高等教育研究所, 北京 100191)

**摘要:** 图像匹配是计算机视觉中一个重要的研究方向,是图像拼接、图像检索等相关应用的基础工作。如何实现快速、高效的图像匹配技术是本文的主要研究内容。提出一种基于 SURF 和扩展哈希的空间约束图像匹配算法,为了提高特征检测的速度,首先提取 SURF 特征描述图像局部特征,然后在局部敏感性哈希算法基础上,提出一种改进的高维数据搜索算法,该改进算法变换局部敏感性哈希的投影空间,使变换后的每一维特征数据都比原算法具有更好的局部敏感性。最后采用空间约束 RANSAC 算法剔除误匹配点,进一步增加算法的鲁棒性。实验结果表明,本文提出的算法与传统算法如 BBF、LSH 以及 iDistance 等算法相比具有更优的搜索效率,在一定程度上提高了图像匹配的性能。

**关键词:** 图像匹配; SURF 算法; 局部敏感哈希; 特征搜索; 投影空间

**中图分类号:** TP391

**文献标志码:** A

**文章编号:** 1672-6693(2015)02-0104-07

图像匹配是图像处理和计算机视觉领域中的一个基本问题,同时也是图像配准、图像拼接、目标识别与跟踪等领域的重要基础和核心步骤。当前应用比较广泛的图像匹配算法包括两种:1) 基于区域的匹配算法,该方法不能解决图像的旋转以及尺度缩放问题,并且运算量比较大;2) 基于特征的匹配算法。但是近年来,基于局部不变特征的匹配算法逐渐在图像匹配算法研究中成为一种主流研究方向,其具有运算量比较小、鲁棒性好、在处理图像的旋转、图像光照和视角变化等方面都有很好的适应能力。

基于局部特征的图像匹配算法,主要包括两个匹配过程:1) 特征点的检测遗迹特征向量描述子的建立;2) 特征点的匹配。Lowe<sup>[1]</sup>对现有的各类特征检测方法进行了总结和完善,在2004年提出了 SIFT (Scale invariant feature transform) 算法,利用对稳定的关键点提取,并且生成特征向量描述子,在对于发生了平移、旋转、视角或者仿射变换以及光照变化的图像匹配中,得到了令人满意的效果。但 SIFT 算法也具有自身的缺点,由于其复杂度较高,所以在特征检测和匹配时速度比较慢。2006年5月, Bay 等人<sup>[2]</sup>提出了 SURF (Speeded up robust features) 算法,该算法是基于 SIFT 的改进算法,和 SIFT 相同,在尺度和旋转方面有比较好的鲁棒性,在光照变化和视角变化不变性方面的性能接近 SIFT 算法,但其具有更快的处理速度。本文选择 SURF 算法提取图像局部特征<sup>[3]</sup>。根据 Lowe 的思想, SIFT 匹配算法要求,某一个 SIFT 特征与邻特征之间的距离小于其到次临近特征的距离时(0.6 倍),该 SIFT 特征和其最近邻特征才能被判定为一个匹配对。所以对 SIFT 进行特征匹配需要通过 KNN (K nearest neighbor) 查找进行。但是 SIFT 特征可以达到 128 维,一般情况下一幅图像包括几百至几万个 SIFT 特征点,特征点的个数是根据图像的大小不同而确定的,当利用一般的高维搜索算法例如 KD-Tree<sup>[4]</sup>、R-Tree<sup>[5]</sup> 在处理高维数据时会产生维数灾难的问题(高于 20 维),最直观的穷举搜索虽然不受维度限制,但其代价太高。文献<sup>[6]</sup>以中介真值程度的数值化度量为基础,提出一种灰度图像的匹配算法,算法具有良好的抗噪性和一定的抗失真性。文献<sup>[7]</sup>提出一种颜色仿射变换下的局部特征描述子表示图像,虽然提高特征点对光度变换和仿射变换的不变性,提高了图像局部特征匹配的准确度,但是该算法开销较高,限制了其在视觉数据中的应用。在特定的实际应用中,如大规模宽基线多图匹配应用中,由于需要对所有图像进行两两匹配,因为图像匹配的效率 and 精度便成为了一个急需解决的问题。

针对上述问题,本文提出一种基于 SURF 和扩展哈希的空间约束图像匹配算法,算法对尺幅不同的空间进行特征点检测,利用 SURF 描述子描述特征点可以生成 64 维的特征向量,然后采用基于扩展的局部敏感性哈希

\* 收稿日期:2013-07-07 修回日期:2014-11-18 网络出版时间:2015-01-22 11:56

作者简介:吴铭心,男,高级工程师,博士,研究方向为教育信息化,E-mail: wmx@buaa.edu.cn

网络出版地址: <http://www.cnki.net/kcms/detail/50.1165.N.20150122.1156.013.html>

算法搜索近似最近邻特征点,最后采用 RANSAC<sup>[8]</sup>清除错误的匹配点。

## 1 SURF 算法特征的提取和描述

本文选用 SURF 算法对图像匹配的特征进行提取,该算法属于 SIFT 算法的一种扩展,具有更快的执行速度。SURF 算法主要包括对关键点的检测和描述向量的生成两个部分。选用快速 Hessian 算法对关键点进行检测;特征的计算采用经过方向配准的梯度方向直方图,可以保证计算后特征的尺度以及图像旋转不发生改变<sup>[9]</sup>。

### 1.1 特征点的提取

SURF 的算子检测过程属于基于尺度空间的检测,与 SIFT 算法相同,采用 Hessian 矩阵提取特征点。但 SURF 算法相比 SIFT 显著地提高了运算速度,主要原因是使用积分图像完成图像卷积操作。积分图像的定义如下: $F(x, y)$ 表示图像  $I(x, y)$ 中的某一像素,则积分图像  $I_z(x, y)$ 表示以点  $(x, y)$ 以及图像原点为对角确定的矩形区域内的像素之后,即

$$I_z(x, y) = \sum_{i=0}^x \sum_{j=0}^y I(i, j)。 \quad (1)$$

积分图像计算过程中,对原始图像进行一次性遍历,有较快的计算速度,同时计算量小。尺度为  $\sigma$  的图像点  $I(x, y)$ 的 Hessian 矩阵定义为

$$H = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix}, \quad (2)$$

上式中, $L_{xx}(x, \sigma)$ 、 $L_{xy}(x, \sigma)$ 和  $L_{yy}(x, \sigma)$ 是点  $x$  位置的高斯函数二阶偏导数和图像的二维卷积。为了提高高斯卷积的计算准确度以及避免离散化高斯滤波器产生的走样, SURF 算子利用方框滤波器来近似二阶高斯滤波,构造 Hessian 矩阵,滤波器的方框大小为  $9 \times 9$ ,如图 1 所示,卷积计算的过程中,计算量的大小和滤波器无关,最大程度提高了算法的运算速度。

图 1 最上一行中  $x$ 、 $y$  和  $xy$  方向的离散的二阶高斯导数用  $L_{xx}$ 、 $L_{xy}$  和  $L_{yy}$  表示。最下行中  $x$ 、 $y$  和  $xy$  方向的加权方框滤波器近似用  $D_{xx}$ 、 $D_{yy}$  和  $D_{xy}$  表示。原图中,酱扩框滤波器尺寸的大方可以构成尺度不同的图像金字塔。然后利用积分图像加速图像卷积,可以求得快速 Hessian 矩阵的行列式表达式<sup>[6]</sup>:

$$\Delta H = D_{xx}(x)D_{yy}(x) - (0.9D_{xy}(x))^2, \quad (3)$$

其中, $\Delta H$  为点  $I(x, y)$ 周边的方框滤波器响应值,利用  $\Delta$  检测极值点。当行列式为负值时,特征值为异号,该点并非局部的极值;若行列式为正值并且特征值为同号时,则为局部的极值。利用 Hessian 矩阵对尺度图像  $(x, y, \sigma)$ 位置求极值后,首先在极值点周围  $3 \times 3 \times 3$  的立体邻域内采用非极大值抑制(Non-Maximum suppression, NMS)。将极值点与周围的 26 个邻域值对比,若上下尺度和本尺度全部大于或者小于 26 个邻域值,才可以选为候选特征点,然后在尺度空间和图像空间中插值,以得到稳定特征点的位置和其尺度值。

### 1.2 SURF 算法特征描述

根据关键点的邻域信息生成描述子,生成的描述子就是关键点的特征。为了保证描述子旋转不改变的性质,先确定特征点的方向。构造一个特征点为圆心,半径为  $6s$ ( $s$ 表示尺度),邻域为  $x$  轴和  $y$  轴方向上的 Harr 小波响应,然后给响应值赋予不相同的高斯权重系数,以确定靠近特征点的响应的贡献也比较大,距离特征点比较远的响应贡献对应比较小。对  $x$  轴和  $y$  轴方向上  $60^\circ$ 角以内的 Haar 小波响应相加,可以构成一个局部的方向向量,对整个圆形的局域进行遍历,最终确定向量最长的方向为对应特征点的主方向。首先将坐标轴旋转为关键点的方向,再以特征点为中心构造一个长度为 20 的正方形窗口邻域,将该邻域分为  $4 \times 4$  大小的子区域,针对每个子区域计算  $5 \times 5$  个采样点在水平和垂直方向上的 Harr 小波响应,记为  $dx$ 、 $dy$ ,然后使用高斯窗口函数对响应值赋予权重系数。得到四维矢量: $V = (\sum dx, \sum |dx|, \sum dy, \sum |dy|)$ 所以 SURF 描述维数为  $4 \times 4 \times 4 = 64$ 。为保持光照的不变性,对向量归一化处理,得到特征描述符。




图 1 利用盒(box)滤波器来近似高斯滤波器

## 2 基于扩展哈希的空间约束图像匹配算法

### 2.1 局部敏感性哈希(LSH)

根据局部不变特征的匹配问题,根本是对高维特征数据的近邻搜索问题即 KNN 问题。iDistance<sup>[5]</sup>、BBF<sup>[10]</sup>等,能在一定程度上较好地解决数据搜索问题。iDistance 认为,若两个高维向量相似,则它们到任意一个参考点距离也同样相似,根据这一思路,iDistance 对特征集合进行聚类,其中每一类都可以看作一个中心为质心的超球体,对于给定的查询点和查询点的查询半径,利用三角不等式确定每个分类中的查询范围。BBF 在 KD-Tree 的二叉平衡树索引结构保持不变条件下,在回溯查询阶段,加入一个优先查找队列,极大提高 KD-Tree 的查找性能。但以上算法对高维特征数据,在搜索时间和效率方面均表现出一定的瓶颈。LSH<sup>[11-12]</sup>算法是一种新兴的近似搜索算法,能较好地克服维度灾难问题,在一定程度上解决了高维数据搜索问题,并且能够证明其对数据规模  $n$  具有子线性时间复杂度。局部敏感性哈希的关键思想是使用一些哈希函数,确保距离相互比较近的点比距离比较远的点相互冲突的概率大,因此在查询的时候只需要查询与查询点相冲突的点,进而缩小了查询时间。算法过程如下:

- 1) 将查询向量  $p$  映射到海明空间,形成二进制向量,使向量在海明空间中的距离与在原始空间中的距离一致。
- 2) 将哈希函数  $g_i$ ,作用在  $H_p$ ,得到  $H'_p$ ;其中哈希函数  $g_i$  为随机选择  $H_p$  中  $K$  个二进制形成新的  $K$  维二进制向量  $H'_p$ 。
- 3) 哈希函数  $h_i$  作用在  $H'_p$  上,得到  $I_i = h_i(H'_p)$ 。
- 4) 将向量  $p$  存放到  $T_i$  的第  $I_i$  个桶中。

若在两个高维向量  $K$  个海明维上具有相同的哈希值,则这两个高维向量会被哈希到相同的桶中,然后对查询数据点进行相同的哈希计算,穷举搜索与查询点相冲突的桶,会以较大的概率得到  $K$  的近邻向量。而 LSH 算法则理论定义在  $L1$  的范数距离之上,对于建立在  $L2$  范数距离之上的高维特征搜索, $K$  和  $L$  的选择实际要取得搜索时间和精度上的平衡<sup>[4]</sup>。

对于图像匹配、图像检索等操作,提取的图像特征集合大小基本上是从几百至几万(取决于图像的大小及内容),伴随特征集逐渐增大,查找  $K$  近邻所需的索引开销和查询开销也急剧增大<sup>[12]</sup>,同时其海明空间长度也会比较大(例如 SIFT 为  $128 \times 255$ ,SURF 为  $64 \times 255$ ),由于单一海明维带有信息很有限,所以 LSH 算法已经丧失了其局部的敏感性。基于上述问题,并针对它们对 SURT 特征匹配存在的不足,笔者提出一种扩展哈希的空间约束图像匹配算法,新算法无论是在匹配速度和还是匹配精度上,都具有明显的优势。

### 2.2 扩展的局部敏感性哈希

假定对待匹配的图像对  $x$  和  $y$  提取 SURF 特征,形成高维特征集  $A$  和  $B$ ,将特征及  $A$  看作参考的集合,对于  $B$  中所有数据点,查询在  $A$  中的最近以及次近邻点。因此可以建立一种映射准则:将原始高维数据空间  $A$  中的点映射到相对低维空间  $U$ ,保证  $A$  中距离相近的点,其在  $U$  中的映射点,距离相近或者相等时具有较大的概率值。因此在搜索时,对于  $B$  集合中的每一个数据点做映射,在  $U$  中查找与该映射值相近的点。因此,查找到的映射点的原象,即是  $A$  中与  $B$  中查询点相近似的点。因此位置敏感性很大程度上受映射的建立,投影空间的选择以及空间的度量的影响。P. Indyk 对位置敏感性哈希定义如下:映射  $H = \{h: S \rightarrow U\}$ ,对于度量  $D$  关于  $(r_1, r_2, p_1, p_2)$  对  $\forall v, q \in S$  是敏感的,其中  $p_1 > p_2, r_1 < r_2$ ,满足:

- 1) 如果  $v \in B(q, r_1)$ ,那么  $PrH[h(q) = h(v)] \geq p_1$ ;
- 2) 如果  $v \notin B(q, r_2)$ ,那么  $PrH[h(q) = h(v)] \leq p_2$ 。

其中,  $v \in B(v, r)$  定义为度量空间  $M = (S, d)$  中  $\forall v \in S$  为中心,  $r$  为半径的类球体:  $B(v, r) = \{q \in S \mid d(v, q) \leq r\}$ 。这样,只要选择一族这样的映射  $G = \{g: S \rightarrow U^k\}, g(p) = (h_1(p), \dots, h_k(p)), h_i \in H$  中的  $l$  个:  $g_1 \dots g_l$ , 将  $S$  中的点集  $p \in P$  散列到若干个桶  $g_j(p)$ 。实际上,从图像中提出的每个特征向量在各个维上的数据分布都是确定的。为了提高数据点对位置的敏感性,本文统计特征集  $A$  在所有维上的数据分布,然后在每个维上将数据集分为  $N$  等分,并且记录  $N-1$  个分界值。每个维和  $N-1$  个分界值构成基于特征集合均匀分布的新投影空间,对不同的特征集会有不同的分界值。给定第  $i$  维,在该维上随机选择分界值  $h$ ,若某一特征点在第  $i$  维上大于  $h$ ,则该特征点会被赋值 1,否则为 0。

整个算法思路设计如下:

- 1) 计算集合  $A$  在每一维上的数据分布。
- 2) 对于每一维,选择  $N-1$  个值把集合  $A$  划分为  $N$  等分。
- 3) 建立  $K$  个查找结构  $\{I_1, I_2, \dots, I_K\}$ 。对于每个查找结构  $I_m, m=1, \dots, K$ , 随机选择维, 对每个随机维, 从其对应的  $N-1$  个划分值中随机选取一个值为该维的关键值。
- 4) 对集合  $A$  中的所有特征, 若它在其中一个随机维上的值比对应的关键值大, 会被分配一个值 1, 否则分配 0。所以使用投影函数具有相同的二进制串的特征被划分到同一个集合中。对于集合  $B$  中的每一个查询特征向量, 执行如下查找过程:

Function: *Search*

Input: query point  $Q$ ,  $K$  search indexes  $\{I_1, I_2, \dots, I_K\}$

Output:  $KNN$  features for  $Q$

Search *time* = 0

For  $m = 1$  to  $K$

Find the right set  $S_q$  where  $Q$  should be placed according to the  $L$  key values in  $I_m$ .

Execute exhaustive search in the set  $S_q$ , and record the calculated times.

If Search *time* > 300

Break;

End if

Ends For

### 2.3 RANSAC 算法

RANSAC 算法<sup>[13-14]</sup>的主要思想是假设样本中含有正确的数据(inliers)即含有可被模型描述的数据,同时包含异常数据(outliers)即不能被模型描述的数据,数据集中噪声,以上数据有可能是因为测量错误、假设或计算错误产生。算法基本思想如下:

- 1) 选取一个抽样集最小的势为  $n$  的模型( $n$  为初始化模型参数所需的最小样本数)和样本集  $P$ , 集合  $P$  的样本数  $\#(P) > n$ , 在  $P$  中随机抽取包含  $n$  个样本的  $P$  的子集  $S$  初始化模型  $M$ ;
- 2) 剩余集合  $SC = P/S$  中与模型  $M$  的误差小于某一设定阈值  $t$  的样本集以及  $S$  构成  $S^*$ 。 $S^*$  认为是内点集, 它们构成  $S$  的一致集(Consensus set);
- 3) 如果  $\#(S^*) > N$ , 则得到的模型参数是正确的, 然后利用集  $S^*$  (内点 inliers) 采用最小二乘等方法再次计算新的模型  $M^*$ ; 重新随机抽取新的  $S$ , 重复以上过程。
- 4) 进行了一定次数的抽样后, 如果还未找到一致集则认为算法失败, 如果找到一致集则选取抽样后得到的最大一致集判断内外点, 算法结束。

本文将 SURF 与 RANSAC 算法结合运用到图像匹配方法中, 根据 SURF 算法从预匹配中随机选取若干匹配点对, 计算出变换矩阵, 然后利用变换矩阵遍历预匹配得到的全部匹配对, 并计算全部预匹配对在某特定阈值下满足该变换矩阵模型的百分比, 重复以上过程  $R$  次。去除变换最佳条件下误差超过某一个特定的阈值的匹配对, 然后用去除后的匹配点重复以上步骤。

## 3 实验结果与分析

本文在图像匹配及  $K$  近邻搜索实验中验证提出的算法, 先将算法进行比较证明该算法的有效性, 再将本文算法在图像检索中具体应用进一步证明算法的实用性。

### 3.1 参数选择

参数  $L$  和  $N$  的选择在一定程度上影响搜索的性能。为了使投影空间中数据集的每一维具有很强的局部敏感性, 进而保证相似数据能以很大的概率哈希到同一个桶中, 本文经实验表明当  $N=3, L=16$  时能取得较好的搜索精度。与 BBF 算法相似, 为保证搜索算法的效率, 笔者限定算法的搜索次数为 300; 选择哈希函数的个数  $K=200$ , 使其对不同大小的特征向量集合都具有实用性。使用 RANSAC 去除误匹配点时, 选择  $R=1000$ 。由于改进算法具有很好的局部敏感性, 本文提出的算法对于不同的图像集都取得不错的结果。以上参数的选择只不过是在搜索精度和搜索效率上的取舍, 为保证算法比较的公平性, 本文在保证各个算法一定可用精度的前提

下,同时比较算法的搜索精度和搜索时间。实验中选用的硬件分别: Intel(R) Core(TM)2 Duo CPU E6550@2.33 GHz,2.0 GB 内存。实验平台为: Matlab 2010b。

### 3.2 KNN( $K=2$ ) 搜索

根据基于 SIFT 特征的图像匹配算法要查询最近邻以及次近邻的特征,所以实验中选用各个算法的 2 近邻查找性能进行验证。采用的标准数据库根据文献[14]中的 11 组数据(供包括 102 幅图,含有约 4 000 000 SURT 特征)在大小不同和变换不同的条件下(旋转、平移、缩放、光照等)的图像作为实验数据,实验中图像类别、数目集特征点数量等信息如表 1 所示,其中 *Image\_num* 表示图像库中图像的数目,图像库中索引图像特征集大小、平均特征集大小、最大特征集及最小特征集大小分别用 *Index\_Size*、*Aver\_Size*、*Max\_Size*、*Min\_Size* 表示。2NN 搜索的实验结果参见表 2,相比其他算法,本文提出的算法对不同大小的图像特征集均有很高的搜索精度(%)和效率(ms)。

表 1 图像及特征数量信息

	船	砖块	汽车	东方公园	格勒诺布尔	涂鸦	信息与自动化研究所	笔记本	残油	玩具	树
<i>Image_num</i>	10	8	7	10	10	9	10	10	10	10	7
<i>Index_Size</i>	9 210	9 846	3 554	4 642	4 432	2 731	4 699	1 345	3 563	1 123	12 386
<i>Aver_Size</i>	6 005	12 459	2 389	3 645	3 642	3 329	2 388	1 511	28 521	1 343	93 335
<i>Max_Size</i>	7 451	14 741	3 456	5 760	5 854	4 567	3 535	2 346	3 452	1 453	15 334
<i>Min_Size</i>	3 278	10 501	1 404	2 125	3 124	3 431	1 565	911	1 634	1 343	3 975

表 2 相关算法的 2NN 搜索精度和搜索效率比较

		船	砖块	汽车	东方公园	格勒诺布尔	涂鸦	信息与自动化研究所	笔记本	残油	玩具	树
LSH	<i>Acc1</i>	50.52	45.14	66.28	58.53	47.00	56.78	75.53	69.76	72.39	46.20	37.17
	<i>Acc2</i>	26.92	16.33	34.67	38.50	28.34	38.25	60.14	36.62	56.66	10.26	18.76
	<i>Time</i>	1 031	2 181	274	753	677	492	786	93	522	41	2 084
BBF	<i>Acc1</i>	48.15	45.66	62.56	54.06	49.52	56.67	63.07	81.66	68.04	78.57	43.89
	<i>Acc2</i>	21.99	17.47	31.72	27.97	24.44	32.24	38.40	54.99	44.64	52.58	18.78
	<i>Time</i>	795	2 631	318	487	531	464	321	149	276	123	2 367
iDistance	<i>Acc1</i>	59.17	58.62	68.25	55.54	55.12	56.26	61.10	75.26	59.92	73.58	52.90
	<i>Acc2</i>	33.90	31.57	40.71	30.52	32.59	33.24	38.55	46.65	36.78	46.05	28.88
	<i>Time</i>	1 432	4 012	390	562	1 664	466	309	128	224	99	3 687
Our algorithm	<i>Acc1</i>	62.53	60.14	79.58	64.89	66.78	67.11	71.65	88.97	72.31	70.11	50.0
	<i>Acc2</i>	33.09	27.02	56.21	41.34	38.24	43.16	46.64	77.31	47.55	32.32	25.51
	<i>Time</i>	712	1 725	315	553	578	447	340	173	300	66	1 494

### 3.3 图像匹配性能实验

本文从标准数据库<sup>[14]</sup>中选取 8 幅图进行图像匹配性能验证,其中每两幅属于同一主题,为了验证算法的鲁棒性,实验中的图像具有不同的尺度缩放、光照、噪声等,并采用 Recall VS(1-precision) 曲线<sup>[15]</sup>作为评价准则,匹配性能越好,曲线就越接近 y 轴。实验结果如图 3 所示,本文提出的算法性能曲线远远高于其他算法并且逼近穷举算法,表明该算法具有非常理想的图像匹配性能。

### 3.4 图像匹配性能实验

本文从标准数据库<sup>[10]</sup>中选取 8 幅图进行



图 2 图像匹配试验数据

图像匹配性能验证,其中每两幅属于同一主题,为了验证算法的鲁棒性,实验中的图像具有不同的尺度缩放、光照、噪声等,并采用 Recall VS(1-precision)曲线为评价标准,若匹配的性能越好,曲线就越接近 y 轴。实验结果如图 3 所示,本文提出的算法性能曲线远远高于其他算法并且逼近穷举算法,表明该算法具有非常理想的图像匹配性能。

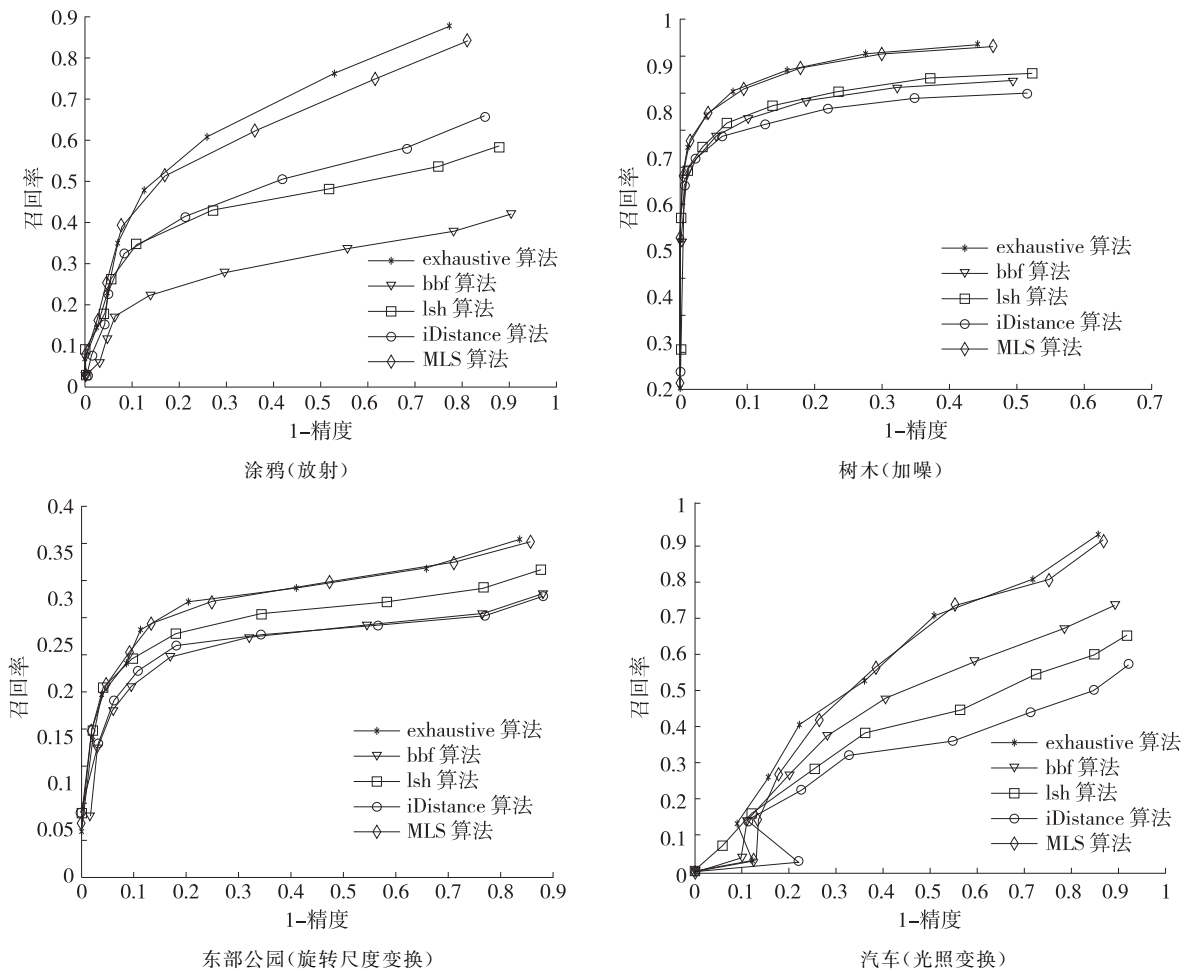


图 3 不同变换下图像匹配性能比较

### 3.5 图像检索性能实验

为证明算法的可用性,再将本文算法在图像检索中应用。根据文献[16]的图像相似度衡量标准,对准则数据库<sup>[14]</sup>的前 1 000 幅进行两两匹配,然后统计本文算法和 LSH 算法的检索率,结果见图 4 所示。

## 4 结论

本文提出一种基于 SURF 特征和扩展哈希的图像匹配算法,并且结合 RANSAC 模型进一步去除了误匹配点,提高了图像匹配的效率。功过实验结果可以验证,使用本文算法比原始 LSH 算法的复杂性低同时具有比较高的局部敏感性,特别有利于高维特征数据的搜索。大量实验表明,相比于原始的局部敏感性哈希算法、BBF 和 iDistance 等常用的高维数据搜索算法,本文算法的 K 近邻搜索速度可以更快并且搜索精度更高,所以本算法可以得到更好的图像匹配性能。

### 参考文献:

[1] Lowe D G. Distinctive image features from scale-int key points[J]. International Journal of Computer Vision,2004,




图 4 相关算法的图像检索率

60(2):91-110.  
[2] Bay H, Tuytelaars T, van Gool L. SURF: speeded up

- robust features[C]//Proceedings of the European conference on computer vision (ECCV 2006). New York: Elsevier Science Inc, 2006: 404-417.
- [3] 赵璐璐, 耿国华, 李康, 等. 基于 SURF 和快速近似最近邻搜索的图像匹配算法[J]. 计算机应用研究, 2013, 30(3): 921-923.  
Zhao L L, Gen G H, Li K, et al. Images matching algorithm based on SURF and fast approximate nearest neighbor search[J]. Application Research of Computers, 2013, 30(3): 921-923.
- [4] Omercevic D S, Drbohlav O, Leonardis A. High-dimensional feature matching: employing the concept of meaningful nearest neighbors[C]//In proc ICCV. Rio de Janeiro: IEEE 2007: 930-938.
- [5] Beis J S, Lowe D G. Shape indexing using approximate nearest-neighbor search in high-dimensional spaces[C]//Proc conf computer vision and pattern recognition. Ashington: IEEE Computer Society, 1997: 1000-1006.
- [6] 周宁宁, 吕文杰. 中介相似性量度的图像匹配[J]. 中国图象图形学报, 2012, 17(9): 1135-1142.  
Zhou N N, Lü W J. Image matching based on the medium similarity measure[J]. Journal of Image and Graphics, 2012, 17(9): 1135-1142.
- [7] 葛娟, 曹伟国, 周炜, 等. 一种颜色仿射变换下的局部特征描述子[J]. 计算机辅助设计与图形学学报, 2013, 25(1): 26-33.  
Ge J, Chao W G, Zhou W, et al. A local feature descriptor under color affine transformation[J]. Journal of Computer-aided Design & Computer Graphic, 2013, 25(1): 26-33.
- [8] 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, 1981, 24(6): 381-395.
- [9] Herbert B, Andreas E, Tinne T, et al. SURF: speeded up robust features[J]. Computer Vision and Image Understanding, 2008, 110(3): 346-359.
- [10] Indyk P, Motwani R. Approximate nearest neighbors towards removing the curse of dimensionality[C]//In proc of the 30th ACM symp on theory of computing. New York: ACM, 1998: 604-612.
- [11] Gionis A, Indyky P, Motwaniz R. Similarity search in high dimensions via hashing[C]//In the VLDB journal. San Francisco: Morgan Kaufmann Publishers Inc, 1999: 518-529.
- [12] Lu Y S, Rao Q. A self-tuning method of LSH index[J]. Journal of Huazhong University of Science and Technology: Nature Science, 2006, 34(11): 34-37.
- [13] 刘毅. 基于一致性随机采样的图像特征匹配鲁棒确认[J]. 重庆邮电大学学报: 自然科学版, 2010, 22(3): 45-48.  
Liu Y. Robust verification for image feature matching based on RANSAR[J]. Journal of Chongqing University of Posts and Telecommunication: Natural Science Edition, 2010, 22(3): 45-48.
- [14] The University of Kentucky Center for Visualization & Virtual Environments. Object recognition benchmark [EB/OL]. (2013-07-01). <http://vis.uky.edu/~stewe/ukbench/>.
- [15] Ke Y, Sukthankar R. PCA-SIFT: a more distinctive representation for local image descriptors[C]//Proc conf computer vision and pattern recognition. USA: IEEE, 2014: 511-517.
- [16] Shapiro S D. Feature space transforms for curve detection[J]. Pattern Recognition, 1978, 10(3): 129-143.

## A Spatial Constraint Image Matching Algorithm Based on SURF and Extended Hash

WU Mingxin

(Higher Education Research Institute, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

**Abstract:** Image matching is an important research in computer vision, which also is a fundamental task for image stitching, image retrieval and other computer vision application areas. The main work of this paper is to find image matching technology with speediness and high efficiency. The paper presents a spatial constraint image matching algorithm based on SURF and extended hash. The local invariant feature SURF descriptors are extracted from images, which greatly improves speed of feature detection. Then a high dimensional search algorithm is improved inspired by local sensitive hash algorithm (LSH), which enhances the local sensitivities of local sensitive hash by changing the projection space. At last, the mismatching points are wiped out by the RANSAC algorithm in order to enhance the robustness of the algorithm. The experiment results express that the algorithm obtains higher search accuracy and efficiency comparing to those classical high dimensional search methods such as BBF, LSH, iDistance and so on, and obviously improves the performance of image matching.

**Key words:** image matching; SURF algorithm; LSH; feature search; projection space

(责任编辑 游中胜)