

基于 SIFT 和 MSE 的局部聚集特征描述新算法

何林远^{1,2}, 毕笃彦², 马时平², 周 理², 南 栋²

(1. 西安交通大学电子与信息工程学院, 陕西西安 710049; 2. 空军工程大学航空航天工程学院, 陕西西安 710038)

摘 要: 为寻找更具鲁棒性和计算简便的特征描述子, 提出了一种基于 SIFT 和 MSE 的局部聚集特征描述算法. 分析说明了该方法在继承 SIFT 算法良好性质的基础上, 通过对多尺度下信息熵的估计, 能够快速准确找出图像局部结构特征并利用改进的非线性降维方法对特征描述子进行特征重划. 实验结果表明, 在图像尺度缩放、旋转、模糊、亮度变化等多种变换条件下, 该描述子不仅能够取得更多的特征效果, 并且计算速度较原算法大幅提升. 该算法适用于实时性要求较高, 存在旋转、尺度缩放、亮度差异等变换下的结构图像寻找描述子.

关键词: 多尺度熵; 局部聚集特征; 非线性降维

中图分类号: TP391. 4 **文献标识码:** A **文章编号:** 0372-2112 (2014)08-1619-05

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2014.08.025

The New Descriptor Algorithm of Local Aggregation Features Based on SIFT and MSE

HE Lin-yuan^{1,2}, BI Du-yan², MA Shi-ping², ZHOU Li², NAN Dong²

(1. Department of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China;

2. Institute of Aeronautics and Astronautics, Air Force Engineering University, Xi'an, Shaanxi 710038, China)

Abstract: In order search a more robustness and convenient count method which shows a new feature descriptor algorithm is proposed in this paper. It analyzes and explains this way could quickly and accurately to describe local structure features based on inherit a higher quality of SIFT and MSE. In addition, it makes use of a changed locally linear embedding approach to process data so that it could reduce dimension. Experiment has drawn the conclusion that not only it could obtain more and betters the proposed descriptor but also the count speed could faster than SIFT for the image with zoom, rotation, blurring and illumination varying. This algorithm is suitable for searching the images which has structured features, when it exits multiple of varying.

Key words: multiscale entropy; local aggregation features; locally linear embedding

1 引言

图像局部特征描述在表征细节和相关性上扮演着重要作用. 它不仅是图像处理、模式识别研究的基本问题, 也是计算机视觉研究热点话题之一^[1,2]. 关于特征点提取存在相当多的文献. 其中, Harris 提出利用自相关矩阵检测特征点的方法^[3]. Mikolajczyk^[4]提出在不同尺度 Laplace 图像空间中检测多尺度特征点, 通过迭代计算获得特征点局部图像的结构特征. 近年来, 随着 SIFT 算子提出和广泛应用^[5], 该方法逐渐成为了特征描述领域的新宠. 在此基础上, 衍生出多种变异算法. 例如: KE 等^[6]利用主成分分析 (PCA) 提取 SIFT 描述子的主成分构建 PCA-SIFT 描述子, Bay^[7]利用积分图像提出一种尺度和旋转不变 (SURF) 的描述子.

总的来说, SIFT 算子具备一定稳定性, 但对细节丰富的图像寻求特征点时效率不高且误差较大. 分析主要原因如下: (1) 算法在求解主方向时没有考虑邻域内各点对梯度贡献的大小, 导致方向选择存在一定误差; (2) 金字塔组内层数疏密会引起极值点缺失或冗余, 原算法未考虑图像同组内各像素点间相关性及其所含信息量的大小对组内层数的影响, 对复杂几何变化的图像寻找特征点效率低下. 为避免误检、漏检特征点, 本文借鉴多尺度信息熵的概念, 重新规划了高斯金字塔组内层数及求解邻域内的极值. 根据邻域内各像素对特征点的贡献度, 对描述子主方向做进一步细分. 并且采用改进的非线性降维方法, 对数据进行局部有效结构规约, 进一步减少了计算量. 实验表明, 该方法在提高速度的同时, 增强了特征点鲁棒性, 具有一定的实用借鉴价值.

2 SIFT 特征提取

尺度不变特征变换 (Scale-Invariant Feature Transform) 是一种用来侦测与描述影像局部特征, 在空间尺度上寻找极值点, 并提取其位置、尺度、旋转不变量的算法. SIFT 特征提取主要分为以下三个步骤: 尺度空间极值点的检测, 特征点位置的确定, 主方向的提取与特征描述子的生成.

2.1 尺度空间极值点的检测

为获得尺度不变性, SIFT 算法利用高斯差分算子代替拉普拉斯算子进行极值检测.

$$\frac{\partial G}{\partial \sigma} = \sigma^2 \nabla^2 G \approx \frac{G(x, y, k\sigma) - G(x, y, \sigma)}{k\sigma - \sigma} \quad (1)$$

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) \\ = L(x, y, k\sigma) - L(x, y, \sigma) \quad (2)$$

2.2 特征点位置确定

为了提高关键点的稳定性, 需要对各尺度空间 DOG 函数进行准确估计. 利用 DOG 函数在尺度空间的 Taylor 展开式进行二次曲线拟合, 通过误差迭代算法精确计算极值点的位置.

$$D(X) = D + \frac{\partial D^T}{\partial X} X + \frac{1}{2} X^T \frac{\partial^2 D}{\partial X^2} X + o \quad (3)$$

2.3 特征主方向的提取与描述子的生成

为使描述符具有旋转不变性, 根据局部特征为每个关键点分配一个基准方向. SIFT 中使用梯度直方图的方法求取局部结构的稳定方向. 在特征描述上, Lowe 建议描述子为在关键点尺度空间内 4×4 窗口中计算的 8 个方向的梯度信息, 共 $4 \times 4 \times 8 = 128$ 维向量表征. 如图 1 所示.




图1 SIFT描述子示意图

3 基于 MSE 的局部聚集特征的选取

文中通过参阅大量文献^[8,9], 在传统 SIFT 算法基础上, 通过尺度空间划分、寻找主方向和建立关键点描述符关系等方面进行了深入的研究, 提出了一种更高效稳定的图像特征描述算法.

3.1 MSE 细化尺度空间

SIFT 算法中, 对每个尺度空间均采用相同层数进行分解. 然而通过大量实验发现, 金字塔各尺度下层数的唯一会引发后续极值检测的准确性, 致使对局部极

值检测的漏检和误检. 基于以上原因, 本算法在借鉴多尺度熵 (MSE)^[10] 的基础上, 考虑不同尺度变换下包含图像信息熵大小的不同, 对组内层数进行细化.

$$H = - \sum_{k=0}^N p_k \log p_k \quad (4)$$

其中 N 为图像灰度级的级数, p_k 为像素点灰度值落在 k 的概率. 一维熵表示图像灰度分布的聚集特征, 但不能反映图像灰度分布的空间特征, 为此, 本文加入能够反映灰度分布空间特征的特征量构成图像二维熵. 选择图像邻域灰度均值作为灰度分布的空间特征量, 与图像的像素灰度组成特征二元组, 记为 (i, j) , 其中 i 表示像素的灰度值, j 表示邻域灰度均值, 如公式 5 所示. 但是, 该二维灰度直方图仅依赖于图像概率信息, 没有考虑图像中局部邻域内灰度的均匀性和在不同尺度下对信息熵的影响. 据此, 重新定义离散的图像二维熵如公式 6 所示. 其中, C 为在一定邻域内, 周围像素点的总的概率和, h_i 表示图像中灰度级 i 出现的频数, $h(\sigma)$ 为在尺度 σ 图像的二维熵, p_{ij} 为像素点灰度值落在第 k 个区间的概率. 则该二维熵突出反映在一定尺度下, 图像中像素位置的灰度信息和像素邻域内灰度分布的综合特征.

$$p_{ij} = f(i, j), H = - \sum_{i=0}^N p_{ij} \log p_{ij} \quad (5)$$

$$p_{ij} = \frac{f(i, j)}{\sum_c f(i, j)},$$

$$H(\sigma) = \sum_{i=0}^N p_{ij} \log p_{ij} = \sum_{i=0}^N h_i p_{ci} \log p_{ci} \\ p_{ci} = \frac{i}{\sum_{i=0}^N h_i} \quad (6)$$

由此可见, 在小尺度下, 二维熵最大保存了图像大量的细节; 在大尺度下, 图像的尺度熵则较粗地显示了图像信息量的大小. 根据信息量的大小, 按照比例关系可对同尺度下进行有效的分层, 对含有信息量大的尺度进行更精细的分层, 找出在该尺度下邻域范围内的极值. 对含有信息量较小的尺度进行粗略分层, 以达到节省计算时间的目的. 最终, 产生结果如图 2 所示.




图2 高斯差点金字塔示意图

3.2 局部聚集构造主方向

本文根据圆具有良好旋转不变性这一特点,通过同心圆来构造特征点的主方向.由于原算法中按照 3σ 取邻域窗口半径,本文采用构造 3 个半径不同的同心圆环,根据贡献度的大小来进行权值累加.为快速计算方便,采用均分原则进行半径划分,具体按照公式 7 和公式 8 实施.

$$\begin{cases} r_1 = 1.5\sigma_{oct} \\ r_2 = 2\sigma_{oct} \\ r_3 = 3\sigma_{oct} \end{cases} \quad (7)$$

$$w = |\nabla(x, y)| e^{-\frac{(x')^2 + (y')^2}{2\sigma^2}} r, \quad \sigma = 1.5\sigma_{oct} \quad (8)$$




图3 极值点主方向确定示意图

3.3 聚类的 LLE 表征描述子

通过研究发现,不同描述符、描述符内部之间存在几何相关信息.而 SIFT 忽略了这种相关信息,使得算法效率不高.虽然 PCA-SIFT 作为其改进算法,利用图像特征主要成分来实现降低维数的目的,但该方法过于强调优化目标而忽略子空间几何结构.此外由于采用线性降维方法,未认真考虑目标各局部特征的非线性关系,致使对部分局部关键信息表述不够完整.基于以上原因,本文采用改进的 LLE^[11,12] 算法对描述子进行降维.为最大保持原有样本点的成分,使变换后尽可能含有原样本点的信息,采用聚类的思想对算法进行改进^[13,14].该方法主要包括以下几个步骤:

(a) 对 128 维向量按照方向的划分进行聚类,聚类后的值作为新样本点模值.

(b) 对高维空间中的每个样本点 $A_i (f = 1, 2, \dots, n)$, 计算它和其他样本点间的距离,根据距离的大小,选择前 K 个点与 $A_i (f = 1, 2, \dots, n)$ 最近的点作为其近邻点.

(c) 对每个 A_i , 找到它 K 个近邻点之后,计算该点和每个近邻点间的权重值间的误差,权值 w_j^i 表示第 j 个数据点对第 i 点重构所具有的贡献.

$$\epsilon(W) = \sum_{i=1}^n \left\| x_i - \sum_{j=1}^k w_j^i x_j \right\|^2 \quad (9)$$

d . 根据高维空间中的样点 $A_i (i = 1, 2, \dots, n)$ 和它的近邻 $A_i (i = 1, 2, \dots, K)$ 之间的权重 W_j^i 来计算映射成流型

的低维嵌入空间中的值 y_i 和 y_j , 如公式 10 所示.

$$\varphi(y) = \sum_{i=1}^n \left\| y_i - \sum_{j=1}^k w_j^i y_j \right\|^2 \quad (10)$$

其中, $\sum_{i=1}^n y_i = 0$ 且 $\frac{1}{n} \sum_{i=1}^n y_i y_i^T = I$ 为使 $\varphi(y)$ 对平移、旋转和伸缩变化都具有不变性.

4 实验及结果分析

本实验是在 Inter Core i5-3210、Windows7, 仿真平台为 OpenCV2.4 的 PC 机上完成的.实验中分别采用 Lena、Airplane、Fruits 为测试图像,包含了尺度、旋转、模糊、光照、色彩等场景变换.本文从算法的鲁棒性和实时性两个方面考察算法的性能,并将其与 SIFT、PCA-SIFT 算法进行了对比实验.结果如下.

4.1 鲁棒性

通过图 4 可看出,较 SIFT 算法,本算法在尺度、旋转、模糊、光照情况下,均可产生更多的特征点,其主要原因为组内增加了更多的层数,使得在局部空间中可获得更多的极值点,从而为下一步特征分类和比对做好准备.同时,通过表 1 和表 2 可得到如下规律:SIFT 算法产生的特征点数和方向数的比值较本算法偏大,主要原因为本算法在主方向的选取上,采用邻域的相关贡献权值累加得到,从而使能量更加集中于主方向,产生了较少的辅方向.但该算法在处理模糊图像时,与原方法相差不大.综合来看,本文提出的算法在求取特征点上优于 SIFT 算法.

表 1 两种算法寻找特征点数表

算法	Lena	模糊 Lena	旋转 Lena	光照 lena	Fruits	Airplane
SIFT	272	333	246	301	324	525
本算法	577	343	481	678	679	941

表 2 两种算法特征点方向数表

算法	Lena	模糊 Lena	旋转 Lena	光照 lena	Fruits	Airplane
SIFT	318	253	283	344	386	634
本算法	583	271	481	677	737	1042

4.2 实时性

经过多次测试,将本文算法、SIFT 算法、PCA-SIFT 算法计算时间如表 3 所示.本算法由于采用了非线性降低维数的方法,较 SIFT 算法相比,效率提升较多.但相比 PCA-SIFT 而言,处理结果相对较慢,究其原因,主要是在进行尺度划分时,产生了更多的层数和更多的极值所致.

表 3 三种算法计算时间表

算法	Lena	模糊 Lena	旋转 Lena	光照 lena	Fruits	Airplane
SIFT	8.52	7.48	10.22	8.47	9.33	17.42
PCA-SIFT	3.54	2.86	4.26	4.12	3.74	7.44
本算法	4.94	4.77	6.54	4.66	5.62	9.78




图4 寻找特征点实例

5 结论

为更好地兼顾特征描述子的鲁棒性和提高计算效率,本文提出了一种基于局部特征描述的算法.实验表明,该方法在提高效率的同时,利用局部信息的聚集特征,寻找出更多稳健的特征点,为更进一步对特征比对、分析提供了依据.下一步的工作是:在提取更多特征点的同时,加快处理速率,使之能更快更好的应用于实践中.

参考文献

- [1] 唐永鹤,等.基于Laplacian的局部特征描述算法[J].光学精密工程,2011,19(12):3009-3006.
Tang Yong-he, et al. Local feature description algorithm based on Laplacian[J]. Optics and Precision Engineering, 2011, 19(12):3009-3006. (in Chinese)
- [2] 曹健,等.角点特征在目标识别中的应用[J].北京理工大

学学报,2011,31(3):308-312.

Cao jian, et al. Object recognition with corner-based feature [J]. Transactions of Beijing Institute of Technology, 2011, 31(3):308-312. (in Chinese)

- [3] Harris C, Stephens M A. Combined corner and edge detector [A]. Proceeding of the 4th Alvey Vision Conference [C]. Manchester, UK:AVC,1988.147-152.
- [4] K Mikolajczyk, C Schmid. Scale & affine invariant interest point detectors[J]. International Journal on Computer Vision, 2004,60(1):63-86.
- [5] D G Lowe. Object recognition from local scale invariant features[A]. Proceeding of International Conference on Computer Vision[C]. Corfu, Greece:ICCV,1999.1150-1157.
- [6] KE Y, SUKTHANKER R. PCA-SIFT: A more distinctive representation for local image descriptors[A]. Proceedings of International Conference on Pattern Recognition [C]. Washington, USA:ICPR,2004,511-517.

- [7] BAY H, ESS A, THYTELAARS T, et al. Speed-up robust features(SURF)[J]. Computer Vision and Image Understanding, 2008, 110(15): 346 – 359.
- [8] 夏胜平, 等. 面向非合作目标识别的大规模类属超图建模[J]. 电子学报, 2011, 39(6): 1399 – 1404.
XIA Sheng-ping, et al. Learning large scale class specific hyper graphs for non-cooperative object recognition[J]. Acta Electronica Sinica, 2011, 39(6): 1399 – 1404. (in Chinese)
- [9] 傅卫平, 秦川. 基于 SIFT 算法的图像目标匹配与定位[J]. 仪器仪表学报, 2011, 32(1): 163 – 169.
Fu W P, Qin CH. Matching and location of image object based on SIFT algorithm[J]. Chinese Journal of Scientific Instrument, 2011, 32(1): 163 – 169. (in Chinese)
- [10] Costam, Goldberger A L, Peng C K. Multiscale entropy analysis of complex physiologic time series[J]. Physical Review Letters, 2002, 89(4): 1 – 4.
- [11] S Y Roweis. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290 (5500): 2323 – 2326.
- [12] Varini C, Degenhard A, Nattkemper T W. ISOLLE: LLE with geodesic distance[J]. Neurocomputing, 2006, 35(17): 1768 – 1771.
- [13] S z Selim, M A Ismail. K-Means——Type algorithms: a generalized convergence theorem and characterization of local optimality[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1984, PAMI – 6: 81 – 87.
- [14] M P Perrone. K-means clustering for hidden markov models [A]. In Proc 7th Int Workshop on Frontiers in Handwriting Recognition[C]. Amsterdam, the Netherlands: ICDAR, 2000. 229 – 238.

作者简介



何林远 男, 1983 年生, 博士生, 讲师, 研究方向为图像处理与计算机视觉。
E-mail: hal1983@163.com



毕笃彦 男, 1962 年生, 教授, 博士生导师, 研究方向为图像处理与模式识别。
E-mail: biduyan@163.com