

一种基于阶阵列的 BRIEF 特征描述子

张妮妮¹, 赵金龙¹, 何佳¹, 陈绥阳^{1,2}, 王杰¹

(1. 西安思源学院 电子信息工程学院, 陕西 西安 710038;

2. 西安交通大学 理学院, 陕西 西安 710071)

摘要:局部特征匹配是机器视觉研究领域中的一个基础问题,也是该领域的研究热点之一,在目标识别、目标跟踪、场景区分等应用中具有重要的作用。而在局部特征匹配研究过程中,如何在满足多种图像变换的前提下,设计一种高效的图像特征描述子是需要解决的一个关键问题。现有的特征描述子,如 SIFT 和 SURF,计算复杂性较高,难以胜任实时视频或移动计算环境;BRIEF 特征描述子计算简单,匹配效率高,能满足实时视频或者移动计算环境的要求,但其仅考虑了单个像素,不具备方向,也就不具有旋转不变性。在 BRIEF 特征描述子的基础上,该文选择多个特征点,并引入阶排列方法,提出一种改进的特征描述子 OPoBRIEF。相对于传统的特征描述子,OPoBRIEF 能够包含更多的局部特征信息,并且计算复杂性较低。通过特征描述子稳定性实验,表明 OPoBRIEF 比 BRRIEF 具有更高的匹配正确率和更好的稳定性。而特征描述子旋转不变性的实验则表明,在旋转角度为 10~12 区间,OPoBRIEF 与 SIFT 效果相当,但明显优于 ORB 算法。

关键词:描述子;二值模式;BRIEF;阶排列;旋转不变性

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2023)05-0081-07

doi:10.3969/j.issn.1673-629X.2023.05.013

BRIEF Feature Descriptor Based on Order Array

ZHANG Wei-wei¹, ZHAO Jin-long¹, HE Jia¹, CHEN Sui-yang^{1,2}, WANG Jie¹

(1. School of Electronics and Information Engineering, Xi'an Siyuan University, Xi'an 710038, China;

2. School of Science, Xi'an Jiaotong University, Xi'an 710071, China)

Abstract: Local feature matching is a basic and hot problem in the area of computer vision, which plays an important role in many application fields such as object recognition, visual tracking, scene classification and so on. The key to this problem is how to design an effective image feature descriptor regarding for different image deformations in the process of local feature matching research. Existing feature descriptors, such as SIFT and SURF, lack the ability for real-time or mobile applications due to their high complexity. BRIEF feature descriptor is simple in calculation and has high matching efficiency, which can meet the requirements of real-time video or mobile computing environment. However, it only considers a single pixel and does not have direction, so it does not have rotation invariance. Based on the BRIEF, we select several feature points and introduce the order arrangement method to propose an improved feature descriptor OPoBRIEF. Compared with traditional feature descriptors, OPoBRIEF can contain more local feature information and has lower computational complexity. The feature descriptor stability experiments show that OPoBRIEF has higher matching accuracy and better stability than BRRIEF. The experiment on the rotation invariance of feature descriptors shows that OPoBRIEF has the same effect as SIFT in the rotation angle range of 10~12, but it is obviously better than ORB algorithm.

Key words: descriptors; binary pattern; BRIEF; order array; rotation invariance

0 引言

在图像处理领域,特征描述子对目标物的不变性研究具有重要意义。一个好的描述子应该能够抵抗目标物的尺度变化、光线变化、旋转变换、仿射变化和噪声干扰。一般而言,一个描述子的构成首先是从图像中提取一些特征点,然后根据特征点周围的区域形成描述子,最后,采用适当的距离度量方法来比对描述子

的相似程度,判定描述子与目标物之间是否同一。对于视觉分类问题而言,常用的方法是通过特征向量来描述一类具有共同点的物体,然后形成可查找的视觉关键字^[1-2]。假定关键点已是已知的,理想的描述子应该是能够包含关键点周围区域的绝大多数重要且惟一的信息内容。

在实时性和稳定性要求严格的应用领域,描述子

收稿日期:2022-06-06

修回日期:2022-10-08

基金项目:陕西省教育厅自然科学基金资助项目(18JK1104);陕西省教育科学规划项目(SGH21Y0322)

作者简介:张妮妮(1978-),女,教授,硕士,CCF会员(20147M),通讯作者,研究方向为计算机网络、图形图像。

必须能够提供快速的计算和比对结果,这就需要设计一个稳定而高效的描述子,人们为此开展了大量的实验和研究。其中,为了满足描述子的抗尺度不变性,Lowe 提出了基于直方图计算梯度主方向的方法^[3-4],这一方法是在一系列尺度下,对经过高斯滤波的特征点周围区域的灰度值进行采样,计算出图像主方向。该方法被广泛用于描述关键点方向性。类似的计算主方向的方法还有 GLOH^[5]和 HOG^[6]。虽然这些方法并不能很直观地反映图像空间频率关系,但它们拥有很准确的方向判断性。此外,SURF 描述子主要利用特征点周围像素点对 HAAR 滤波的响应来提高运算速度^[7-8],其性能不亚于 SIFT 描述子。即使如此,SIFT 和 SURF 描述子的计算代价依然很高,不能很好地应用于实时图像处理。为此,Ke 和 Skthankar^[9]提出在计算 SIFT 描述子主元时,采用 PCA 方法对特征点周围 41×41 的像斑区域进行计算,从而将原有的 $2 \times 39 \times 39$ 维的向量降低成 20 维向量,形成更为精准的 PCA-SIFT 描述子。PCA-SIFT 描述子保留了 SIFT 描述子的尺度不变性,同时降低了特征向量维数,但在计算描述子过程中会增加一定的计算量和损失少量的差异性。Bin 基于阶序组合池提出了两种抗旋转不变性的描述子^[10]:一种是 MROGH (Multi-support Region Order-based Gradient Histogram),主要是对特征汇聚策略进行了改进;另一种是 MRRID (Multi-support Region Rotation and Intensity Monotonic Invariant Descriptor)。Miksik 和 Mikolajczyk 通过实验验证了基于阶排列的描述子的计算复杂度要低于 SIFT 和 SURF^[5,11]。LIOP (Local Intensity Order Pattern) 方法进一步证实这一观点^[12],LIOP 是一种用来刻画图像局部亮度顺序信息的特征描述方法。该特征描述方法利用图像(块)整体的亮度顺序信息将图像块分割为若干个局部子区域,以此来加快 LIOP 的计算速度。整个图像块的整体和局部亮度顺序信息被提取出来,构成 LIOP 特征。这种特征不仅对光照变换不敏感,对视角变化、图像模糊、图像有损压缩等也同样不敏感。

除了实时应用需求,在大规模数据运算和移动设备上,计算量也是一个至关重要的约束条件。计算量小的描述子主要有 Calonder 提出的二值特征描述子 BRIEF^[13-14],以及基于 BRIEF 的抗尺度变化和旋转变化的改进特征描述子 BRISK^[15]。此外,ORB 也是一种具有抗旋转不变性、计算高效的描述子^[16],它采用了基于 FAST 算子的特征点检测方法。Ziegler 也提出了一种线性时间复杂度的描述子^[17],该描述子通过对两张图片的 RGB 分块值进行排序,结合排序后序列的距离,实现对图片的特征描述^[18]。

该文提出一种基于 BRIEF 的改进的阶排列描述子 OPoBRIEF (Order Permutation of BRIEF)。OPoBRIEF 采样多组对比对进行分析,并对采样点进行排列,从而形成局部特征描述。该方法比 BRIEF 描述子包含更多的局部信息,而且计算简单,易于实现。首先,介绍 BRIEF 相关概念;然后,将 BRIEF 描述子扩展到 N 维,为后续的阶排列提供基础,并分析采样过程中使用 box filter 的滤波效果,以及序列的距离度量计算方式;最后对 OPoBRIEF 的主要性能进行实验分析。

1 相关描述子简介

BRIEF 特征描述子由 Calonder 等在 ECCV'2010 上提出^[1],基本思想是对特征点附近的分块区域随机采样,将采样的像素对灰度化后进行比较,比较结果形成一个二进制串,将这个二进制串作为该特征点的特征描述子。BRIEF 特征描述子的主要优点是计算简单,匹配效率高,能满足实时视频或者移动计算环境的要求。

1.1 BRIEF 描述子

定义一个经过高斯平滑后的图像块 p ,图像块的大小为 $s \times s$,随机在块中采样一对像素点进行比较,比较结果由下式决定。

$$\tau(p;x,y) = \begin{cases} 1 & \text{if } I(p,x) < I(p,y) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

式中, $I(p,x)$ 表示第 p 个图像块中的像素点 x 的灰度值, $I(p,y)$ 表示第 p 个图像块中的像素点 y 的灰度值。在块 p 中随机采样 n 对对比对,形成一个 n 维的二进制描述串,也就是 BRIEF 描述子,如下:

$$f_{n_d}(L) = \sum_{1 \leq i \leq n_d} 2^{i-1} \tau(p;x_i,y_i) \quad (2)$$

在选取采样点时,采样点的空间分布应服从高斯分布,保证采样更为全局化。描述子向量之间的距离可以采用汉明距离,通过异或操作实现快速计算。通常, n_d 代表了形成的二值序列的维度,可以取值为 128、256、512。BRIEF 描述子的一个采样实例如图 1 所示。




图 1 BRIEF 相关的空间采样

1.2 ORB 描述子

BRIEF 描述子本身仅考虑了单个像素,不具备方向,也就不具有旋转不变性。ORB 描述子尝试给 BRIEF 添加一个方向,特征点的主方向是通过矩(moment)和图像矩心计算而来,然后,通过贪心算法寻找二值准则特征集中相关性最低的对比对集合,作为 ORB 描述子。图 2 显示了在大小为 31×31 的图像块上,采用 5×5 大小的子窗口进行处理后获得的 ORB 描述子。




图 2 ORB 相关的空间采样

1.3 BRISK 描述子

BRISK 描述子采用领域采样模式,即在以特征点为中心的每个离散化同心圆上,取均匀分布的 N 个点,如图 3 所示。BRISK 描述子具有旋转不变性和尺度不变性的特点。文献[10]中 BRISK 采用了不同尺度高斯平滑去噪技术,并使用 FAST 算子值作为度量局部的最大性指标,在多尺度空间上寻找最值,使其具有尺度不变性;为了适应旋转不变性,在建立描述子的过程中,利用长距离点对的梯度累加从而估计特征点角点的主方向。




图 3 BRISK 相关的空间采样

2 OPoBRIEF 描述子

Ziegler 通过随机提取图像局部的像素对,比对灰度值形成二值序列,然后计算汉明距离(hamming distance)进行相似匹配^[17]。考虑到灰度对比对的不稳定性,首先增加采样点数量,然后引入阶排列的概念,

加强对二值对比对的条件约束,最后形成更为稳定的阶排列 BRIEF 描述子。

2.1 N 维 BRIEF 描述子

Calonder 提出的 BRIEF 描述子只是利用局部图像邻域内两个随机点的灰度关系来建立局部图像特征描述子,得到的是二值特征描述子。这种方法结构简单,计算速度快。但是,由于只选取了两个采样点,所构成的对比对的关系比较简单,使得描述子不够稳定。通过对局部图像块进行多次采样形成一个采样组,组内采样点数为 $n(n > 2)$,进而引入采样点的阶排列的概念,提出 OPoBRIEF 描述子。

由于有多个采样点需要进行比对,首先对式(1)进行扩展。给定从基准图和测试图中提取特征关键点的集合为 χ , $\chi \subseteq R^s$, 且采样图像的分块区域都经过平滑处理,降低了图像灰度值的一些噪声影响。获得描述子后,可以通过计算不同集合下采样组的相似关系来进行特征匹配。每组采样点中组内采样点的二值测试序列可以描述为:

$$f(x) = \{\tau(L; \{I(x^{(j,i)})\}_{i=1}^{l=n^s}) \in R^d\}_{j=1}^{n_d} \quad (3)$$

其中, $x \in \chi$, $\tau(L; \{I(x^{(j,i)})\}_{i=1}^{l=n^s})$ 代表在经过平滑处理后的图像分块 p 上获得的采样组; n^s 代表采样组内用于进行二值测试的采样点的个数; n_d 代表了形成的二值序列的维度; $\{I(x^{(j,i)})\}_{i=1}^{l=n^s}$ 代表了组内每对采样点的对比对; $I(x)$ 代表了采样点 x 的灰度像素值。

实际上,Calonder 所介绍的二值序列 BRIEF 特征描述子是 $n^s = 2$ 时的情况,即式(1)替换表示为:

$$\tau(L; I(x^{(j,1)}), I(x^{(j,2)})) = \begin{cases} 1: I(x^{(j,1)}) < I(x^{(j,2)}) \\ 0: I(x^{(j,1)}) \geq I(x^{(j,2)}) \end{cases} \quad (4)$$

用来形成二值序列串的描述子式也可以扩展到 n_d 维,表示为:

$$f(x) = \{\tau(L; \{I(x^{(j,i)})\}_{i=1}^{l=n^s}) \in R^d\}_{j=1}^{n_d} = \sum_{1 \leq j \leq n_d} 2^{j-1} \tau(L; I(x^{(j,1)}), I(x^{(j,2)})) \quad (5)$$

在 OPoBRIEF 中,阶排列是用在有多个采样点的情况。例如图 4 情况,在平滑过的子块上随机抽取 4 个采样点: $I(x^{(j,1)}) = 60$, $I(x^{(j,2)}) = 160$, $I(x^{(j,3)}) = 15$, $I(x^{(j,4)}) = 200$,该组采样点的阶排列字符串为 4 213。

通过计算得到的阶排列来替换 BRIEF 描述子中的二值测试序列,则 OPoBRIEF 描述子对每个特征点的维度变化为 $n_d \times n^s$ 。显然, n^s 值过大会造成阶排列字符串过于复杂,通常 n^s 取值为 3 和 4 较为合适,两者的阶排列模式只有 6 和 24,计算开销较小。

BRIEF 描述子只选取了两个采样点,构成的对比对关系比较简单,而 OPoBRIEF 选取了多个采样点进行比对,包含更多的局部信息,具有更强的代表性和稳

定性。以图4为例, $\{I(x^{(j,l)})\}_{l=1}^{l=4} = [60, 160, 15, 200]$, 经过了6次比对, 形成阶排列串(4 213), 获得 $\{I(x^{(j,l)})\}_{l=1}^{l=4} = [200, 160, 60, 15]$, 能够包含更多的信息。




图4 构造阶排列的过程

2.2 平滑核的选择

高斯噪声可能损坏阶排列的稳定性, 主要原因是

噪声会引起像素值局部极大值或者极小值突变, 从而改变灰度值在特征向量里的排列顺序。为此, 采用不同大小的高斯核滤波和不同窗口的Boxing滤波, 研究测试OPoBRIEF的稳定性。

通常来说, Boxing滤波的窗口尺寸越大, 阶排列得到的结果就越稳定。但是, 这会导致同样的阶排列生成不同的排列串。为避免这一问题, 该文尝试通过在一些公共图像测试集上进行实验, 寻找一个窗口大小合适的Boxing滤波。图5给出在测试图像集合Benchmark上, 采用不同窗口大小的Boxing滤波算法, 对不同种类的图像集合进行平滑后, 描述子的正确匹配率实验结果。其中, 分块大小 $p = 48$ 、维度 $n_d = 256$, 每一组实验包含了8个不同大小窗口的Boxing滤波测试的结果。由图可见, 当 k 值在13附近时, Boxing滤波能够达到较高正确匹配率。




图5 不同窗口大小Boxing滤波后描述子的正确匹配率

Calonder 建议采用 48×48 的分块、 7×7 的窗口和 $\delta = 2$ 高斯核进行滤波处理, 能够获得稳定的效果^[11]。实验结果表明, 采用boxing滤波比高斯滤波的效果更好, 稳定性高于高斯滤波, 实验结果优于文献[13]。另一方面, 考虑到构造一个boxing滤波只需要四个点和三次加法运算, 算法更为简单有效, 更适用于进行区域分块平滑滤波。

2.3 阶排列距离度量

Ziegler 介绍了三种不同的高效的距离计算方法^[17]: Hamming 距离、Cayley 距离和 Kendall's tau 距离。其中 Kendall's tau 距离已经被证明在计算阶排列

的距离上要比其他两种计算方法好, 虽然它的计算复杂度为 $O(m^2)$, 高于汉明距离和 Cayley 距离的计算复杂度 $O(m)$ 。

为使结果更为精准, 该文选择 Kendall's tau 距离来进行匹配距离的计算。 π 被定义为 $\{I(x^{(j,l)})\}_{l=1}^{l=n}$ 中元素的排列组合。选取两个描述子 π_1 和 π_2 作为匹配描述子, Kendall's tau 距离计算公式如下:

$$K_d(\pi_1, \pi_2) = |\{(i, j) | (\pi_1(i) < \pi_1(j) \wedge \pi_2(i) > \pi_2(j)) \vee (\pi_1(i) > \pi_1(j) \wedge \pi_2(i) < \pi_2(j))\}|, 1 \leq i, j \leq n^s|$$

(6)

3 实验与结果

在公共图像数据集上进行了不同采样大小的测试。首先计算了 $n^s = 3$ 和 $n^s = 4$ 情况下提取的 OPoBRIEF 描述子,并与 BRIEF 进行对比;而后又对 OPoBRIEF 的旋转不变性进行了实验和分析。实验硬件环境: Intel(R) 双核 CPU-E7500, 主频 2.9 GHz, 6.0 GB 内存, 软件环境: Linux 系统, 基于 OpenCV 类库采用 C 语言编程。

3.1 描述子稳定性实验

实验选取五个不同的图片数据集 wall、ubc、leuve、trees 和 bikes 进行测试, 每组图片 6 个, 如图 6 所示。这五个不同的数据集可用来测试在不同情况下图像变换对描述子稳定性的影响。其中, wall 主要针对的是相机的镜头视点的改变; ubc 主要针对的是图像压缩率的变化; leuve 主要针对的是图像的光照变化; trees 和 bikes 主要针对的是图像的模糊变化。

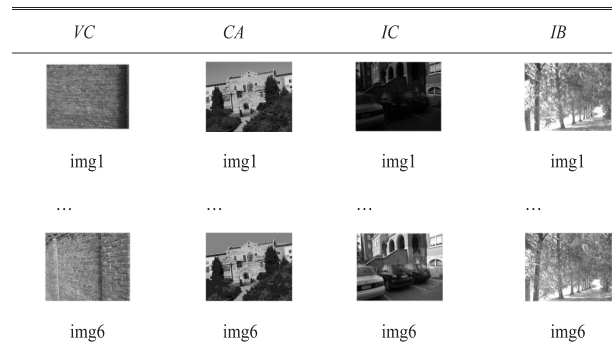


图6 图像测试集示例

Surf 算法是 OpenCV 中一个快速和高效的特征点检测算法, 因此, 该文主要采用 Surf 进行关键点提取。表 1 是每组图片比对结果, 在最高匹配率前面加上了星号做标记。表 1 记录了在 $n_d = 256$ 的情况下, 3 采样点 OPoB-3, 4 采样点 OPoB-4 和 BRIEF (B-256) 三种方法的实验结果。

表1 不同数据集的正确匹配率

图像	GT	B-256/%	OPoB-3/%	OPoB-4/%
wall	112	2 385	* 2 343 (98.24)	2 289 (95.97)
	113	2 218	* 2 060 (92.88)	1 961 (88.41)
	114	1 557	* 1 174 (75.40)	601 (38.60)
	115	1 179	* 686 (58.18)	82 (6.96)
	116	728	* 178 (24.45)	31 (4.26)
bikes	112	1 300	* 1 295 (99.62)	1 295 (99.62)
	113	1 114	1 109 (99.55)	* 1 110 (99.64)
	114	825	816 (98.91)	* 819 (99.27)
	115	636	631 (99.21)	* 633 (99.53)
	116	424	414 (97.64)	* 418 (98.50)
trees	112	3 415	* 3 159 (92.50)	3 066 (89.78)
	113	2 869	2 560 (89.23)	* 2 555 (89.06)
	114	1 978	1 655 (83.67)	* 1 612 (81.50)
	115	1 797	1 516 (84.36)	* 1 536 (85.48)
	116	1 265	1 049 (82.92)	* 1 070 (84.58)
leuve	112	1 155	* 1 146 (99.22)	1 136 (98.35)
	113	830	* 825 (99.40)	* 825 (99.40)
	114	669	657 (98.21)	* 660 (98.65)
	115	488	* 480 (98.36)	* 480 (98.36)
	116	410	402 (98.05)	* 408 (99.51)
ubc	112	2 673	* 2 663 (99.63)	2 647 (99.03)
	113	2 511	* 2 489 (99.12)	2 472 (98.45)
	114	2 282	* 2 249 (98.55)	2 241 (98.20)
	115	1 962	* 1 923 (98.01)	1 901 (96.89)
	116	1 513	1 440 (95.18)	* 1 437 (94.98)

通过分析表 1 的实验结果可以发现, 除了第一组实验, OPoBRIEF 比 BRIEF 的整体匹配效果好, 其中, OPoB-4 比 OPoB-3 的整体匹配效果更好, OPoB-4 的

正确匹配率高于 BRIEF。实验结果同时说明选择的采样点数量越多, 描述子包含的信息量越多, 匹配的正确性也就越高。在测试描述子对旋转不变性的实验中,

描述子 OPoBRIEF 的匹配效果并不比 BRIEF 描述子好很多。在 trees 和 bikes 测试集上的实验结果表明, OPoB-4 的匹配效果明显优于 OPOB-3 和 BRIEF。尤其是在 trees 的数据集上,描述子 OPOB-4 要比描述子 BRIEF 平均多出 21 对以上的正确匹配对,这说明描述子 OPoBRIEF 对图像的模糊有较强的抵抗性。而在用来测试光照变化对描述子影响的数据集 leuue 上, OPOB-4 的效果也明显优于 OPOB-3 和 BRIEF。最后在不同压缩率比图像的测试中, BRIEF 的性能大多数情况会好过 OPoBRIEF,但两者的差距并不是十分巨大。

3.2 OPoBRIEF 的旋转不变性实验

为了检验 OPoBRIEF 的旋转不变性,设计了一组实验。实验所用的数据集是 new york 图片序列,该图片序列包含了 35 张图片,覆盖了从 0 到 170 和 170 到 350 度旋转的图片。特征点的提取算法使用的是最新版 OpenCV 中的 SIFT 和 ORB 算法,其中使用 SIFT 特征点提取法获得 26 235 对匹配对,使用 ORB 算法获得 26 430 对匹配对。如果考虑每 10 度作为一个错误区间,则有 26 200 对匹配对被衡量。实验结果如表 2 所示,提供了错误区间为 10 到 50 的实验结果。从实验结果可以发现, SIFT 算法的主方向的准确率为 69.03%,要远高于 ORB 算法的主方向的准确率 57.95%,但在其他旋转度 SIFT 算法不及 ORB。通常算法中都会选用 10 度到 12 度作为偏移区间,因此, SIFT 主方向计算方法更能满足该文的主方向计算需求。SIFT 与 OPoBRIEF 的对比结果如图 7 所示,表明 OPoBRIEF 的旋转不变性不亚于 SIFT 特征描述子的效果。

表 2 不同旋转度的匹配率

MoE	SIFT/%	ORB/%
10	69.03	57.95
20	73.95	73.59
30	75.15	80.69
40	75.66	85.02
50	76.29	87.32




图 7 OPoBRIEF 与 SIFT 特征描述子旋转不变性比较

3.3 实验结果

在上述稳定性实验中,选择采样点数量越多,描述子包含的信息量越多,匹配的正确性也相应越高,说明 OPoBRIEF 比 BRIEF 的整体匹配效果好。在测试描述子对旋转不变性的实验中,描述子 OPoBRIEF 的匹配效果也好于 BRIEF 描述子,对于 SIFT 特征描述子来说, OPoBRIEF 的旋转不变性更加稳定。

4 结束语

对二值描述子 BRIEF 进行了改进,引入了更多的对比对来加强特征描述子的信息含量,并引入了灰度值的序排序,提出了一种改进的描述子 OPoBRIEF。与 BRIEF 描述子相比, OPoBRIEF 需要增加的计算开销很少,适合移动与实时计算环境;选择三采样点 (OPoB-3) 和四采样点 (OPoB-4) 进行了实验,结果表明提出的描述子稳定性更好;进一步的实验还证明,采用 Kendall's tau 距离进行描述子匹配时,该方法的匹配效果更好。

参考文献:

- [1] CSURKA G, DANCE C R, FAN L, et al. Visual categorization with bags of keypoints[C]//Proceedings of the 8th European conference on computer vision. Prague: Springer, 2004:1-22.
- [2] 莫海军,陈杰,王顺栋. 结合点云纹理信息的快速点特征直方图描述子算法[J]. 华南理工大学学报:自然科学版, 2021, 49(6):56-65.
- [3] 汪永生,李岩,刘明. 一种改进 ORB 特征描述子图像匹配算法[J]. 巢湖学院学报, 2020, 22(6):77-85.
- [4] LOWE D. Distinctive image features from scale-invariant key points[J]. International Journal of Computer Vision, 2004, 60:91-110.
- [5] MIKOLAJCZYK K, SCHMID C. A performance evaluation of local descriptors[J]. IEEE Trans. on PAMI, 2005, 27(10):1615-1630.
- [6] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]//Proceedings of the 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR). San Diego:IEEE, 2005:886-893.
- [7] BAY H, ESS A, TUYTELAARS T, et al. SURF: speeded up robust features[J]. Computer Vision and Image Understanding, 2008, 110(3):346-359.
- [8] KE Y, SUKTHANKAR R. PCA-SIFT: a more distinctive representation for local image descriptors[C]//Proceedings of the 2004 IEEE computer society conference on computer vision and pattern recognition (CVPR). Washington: IEEE, 2004:506-513.
- [9] FAN B, WU F C, HU Z Y. Rotationally invariant descriptors using intensity order pooling[J]. IEEE Trans. on PAMI,

- 2012,34(10):2031–2045.
- [10] MIKSIK O, MIKOLAJCZYK K. Evaluation of local detectors and descriptors for fast feature matching[C]//2012 21st international conference on pattern recognition (ICPR). Tsukuba:IEEE,2012:2681–2684.
- [11] WANG Z H, FAN B, WU F C. Local intensity order pattern for feature description[C]//Proceedings of the 2011 international conference on computer vision. Barcelona: IEEE, 2011:603–610.
- [12] CALONDER M, LEPETIT V, STRECHA C, et al. BRIEF: binary robust independent elementary features[C]//11th European conference on computer vision (ECCV). Heraklion: Springer,2010:778–792.
- [13] CALONDER M, LEPETIT V, ÖZUYSAL M, et al. BRIEF: computing a local binary descriptor very fast [J]. IEEE Trans. on PAMI,2012,34(7):1281–1298.
- [14] LEUTENEGGER S, CHLI M, SIEGWAT R. BRISK: binary robust invariant scalable keypoints[C]//Proceedings of the IEEE international conference on computer vision (ICCV). Barcelona:IEEE,2011:2548–2555.
- [15] ETHAN R, VINCENT R, KURT G K, et al. ORB: an efficient alternative to SIFT or SURF[C]//Proceedings of the IEEE international conference on computer vision (ICCV), Barcelona:IEEE,2011:2564–2571.
- [16] ZIEGLER A M, CHRISTIANSEN E, KRIEGMAN D, et al. Locally uniform comparison image descriptor[C]//International conference on neural information processing systems (NIPS). Lake: [s. n.],2012:1–9.
- [17] ÖZUYSAL M, CALONDER M, LEPETIT V, et al. Fast key-point recognition using random ferns [J]. IEEE Trans. on PAMI,2010,32(3):448–461.
- [18] 卢来,王军民,范锐. 基于自适应增强的图像二值描述子[J]. 计算机工程,2016,42(6):230–240.
- backpropagation and approximate inference in deep generative models[C]//International conference on machine learning. Beijing:PMLR,2014:1278–1286.
- [20] XIONG L, CHEN X, HUANG T K, et al. Temporal collaborative filtering with Bayesian probabilistic tensor factorization [C]//Proceedings of the 2010 SIAM international conference on data mining. Philadelphia:Society for Industrial and Applied Mathematics,2010:211–222.
- [21] JARRETT D, CEBERE B C, LIU T, et al. Hyperimpute: generalized iterative imputation with automatic model selection [C]//International conference on machine learning. New York:PMLR,2022:9916–9937.
- [22] YOON J, JORDON J, SCHAAR M. Gain: missing data imputation using generative adversarial nets [C]//International conference on machine learning. New York: PMLR, 2018: 5689–5698.

(上接第41页)

(9):847–855.

- [15] JAFRASTEH B, HERNÁNDEZ-LOBATO D, LUBIÁN-LÓPEZ S P, et al. Gaussian processes for missing value imputation[J]. arXiv:2204.04648,2022.
- [16] HAWTHORNE G, HAWTHORNE G, ELLIOTT P. Imputing cross-sectional missing data: comparison of common techniques[J]. Australian & New Zealand Journal of Psychiatry, 2005,39(7):583–590.
- [17] SILVA-RAMÍREZ E L, PINO-MEJÍAS R, LÓPEZ-COELLO M, et al. Missing value imputation on missing completely at random data using multilayer perceptrons[J]. Neural Networks,2011,24(1):121–129.
- [18] STEKHOVEN D J, BÜHLMANN P. MissForest—non-parametric missing value imputation for mixed-type data [J]. Bioinformatics,2012,28(1):112–118.
- [19] REZENDE D J, MOHAMED S, WIERSTRA D. Stochastic