

一种基于分层学习的关键点匹配算法

高洪波 王洪玉* 刘晓凯

(大连理工大学信息与通信工程学院 大连 116024)

摘要: 关键点匹配技术是计算机视觉中的一项重要技术,其最主要的问题是寻找一种快速鲁棒的关键点匹配算法。该文提出了一种基于分层学习的二值描述符匹配算法。该方法将二值描述符学习过程分为粗细两个层次,结合了固定点抽样模式和随机抽样模式的优点,提高了学习效率;另外,该方法建立了更加合理的点对辨识模型并将其应用到关键点匹配算法中,提高了匹配精度。实验结果表明,在低计算复杂度下,该方法的匹配精度仍优于其它经典的二值描述符匹配算法。

关键词: 计算机视觉; 关键点匹配; 二值描述符

中图分类号: TN911.73

文献标识码: A

文章编号: 1009-5896(2013)11-2751-07

DOI: 10.3724/SP.J.1146.2013.00347

A Keypoint Matching Method Based on Hierarchical Learning

Gao Hong-bo Wang Hong-yu Liu Xiao-kai

(School of Information and Communication Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: Keypoint matching is an important task of computer vision and the major problem is to find a fast and robust keypoints algorithm. This paper presents a binary descriptor matching algorithm based on hierarchical learning method. The descriptor learning process is divided into two levels of coarse and fine, which combines the advantages of the fixed-point sampling mode and random sampling mode, and the process enhances the performance of learning. Meanwhile, a more reasonable point-pair identification model is built and applied into the keypoint matching algorithm which improves the matching precision. Experimental results demonstrate that the proposed algorithm outperforms the classical methods with lower computation time.

Key words: Computer vision; Keypoint matching; Binary descriptor

1 引言

在图像配准、摄像机标定、目标识别和图像检索等计算机视觉应用中,从两幅图像中正确匹配同一物体或者场景的关键点是一项基础而重要的工作。图像关键点的匹配一般分为 3 个部分:(1)关键点的检测,目前主要采用的关键点有角点、斑点和 T-交叉点;(2)关键点的特征描述,该特征描述符应具有强可辨性的特性,即对噪声、几何和光照变化不敏感;(3)描述符向量间的匹配,通过向量间的距离表示图像间的相似度,常用的距离有 Mahalanobis 距离和欧式距离等,描述符的维度与匹配精度和匹配时间成反比。本文的主要贡献在于通过贪婪算法获得更加有效的二值描述符,并提出了一种更加合

理的匹配算法,该匹配算法在具有较快的匹配时间的同时也具有较高的匹配精度。

Lowe^[1]于 1999 年提出的尺度不变特征(SIFT)是目前最著名的描述符。该方法以图像 2 维平面空间和高斯差分(DoG)尺度空间中的局部极值作为关键点,在关键点附近计算局部方向梯度直方图,采用 128 维的矢量描述图像。SIFT 描述符具有较强的尺度和方向不变性以及光照适应力。几年来,许多学者对 SIFT 做出了改进^[2-6]。在相同维数的情况下,GLOH 算法^[2]具有更高的分辨力,但是因采用了数据压缩技术而增加了计算复杂度。DAISY 描述符^[3]由关键点附近的多个采样点所生成的卷积方向图向量组成,该方法对放射变换和光照差异都有较好的鲁棒性,但是该描述符维数较高。上述 SIFT 类方法往往计算量大且描述符维度高,从而影响了关键点的匹配速度。为解决此问题,很多学者针对匹配的 3 个步骤提出了各种改进方法。例如,为了提高关键点的检测速度,Rosten 和 Drummond^[7]提出了 FAST 角点检测算法,该方法通过统计固定

2013-03-18 收到,2013-08-12 改回

国家自然科学基金(61172058),高等学校博士学科点专项科研基金(20120041110011)和中央高校基本科研业务费专项资金(DUT13 JS09)资助课题

*通信作者:王洪玉 whyu@dlut.edu.cn

半径圆上像素的强度确定角点, 本文也采用该检测方法。Mair 等人^[8]提出的 AGAST 检测器进一步提高了关键点的检测速度。BRISK 算法^[9]采用了多尺度 AGST, 即在尺度空间内利用 FAST 值作为显著度观测搜索最大值, 从而确定关键点。以上方法虽然提升了速度, 但是无法处理图像的旋转和变形等问题。为减少描述符的建立时间, Ke 和 Sukthankar^[10]提出了 PCA-SIFT 算法, 利用主成分分析(PCA)删除大量的冗余信息, 使得描述符的维度从 128 维降到 36 维。Ambai 和 Yoshida^[11]提出了 CARD 算法, 该方法在 SIFT 网格区间或者 GLOH 对数极区间内抽取方向梯度直方图。另一个广泛应用的算法是 SURF^[12], 该方法的匹配性能与 SIFT 相似, 但由于采用了积分直方图和对描述子进行了降维(64 维), 故速度比 SIFT 快。上述方法虽然在一定程度上降低了计算复杂度, 但在图像检索和 3D 重建等大尺度应用中, 仍然因为维度过高而无法满足实时要求。为了解决该问题, 许多学者提出了二值描述符^[13,14]。二值描述符的最大优点是用 Hamming 距离代替欧式距离计算两个局部图像的相似度, 从而大大减少了匹配时间。然而这种方法认为描述符的每一位的分辨力相同, 导致了距离误差的产生。本文在 Hamming 距离的基础上对每一位描述符加入权重因子, 该权重代表了描述符的每一位(bit)的分辨能力。Calonder 等人^[15]提出了 BRIEF 算法, 该描述符是一个不相关的二值向量, 该向量通过比较随机选取的 512 个像素点对的强度大小而获得。Rublee 等人^[16]结合了 FAST 和 BRIEF, 提出了方向 FAST 和旋转 BRIEF(ORB) 算法, 使二值描述符具有了旋转不变性。BRISK 中采用一个有限抽样点数目(60 个)的抽样模式(pattern), 由抽样点组成多个点对(pair)。Alahi 等人^[17]在改进 BRISK 的基础上提出了 FREAK 算法, 该算法是一种基于人眼视网膜细胞分布的抽样模式, 越靠近关键点中心的区域采样点越密集, 高斯核的标准差越小。BRIEF 采用随机选取点对的抽样策略, 为达到理想的匹配精度, 该策略产生的点对数目往往很大, 因而影响了后续的匹配速度; BRISK 和 FREAK 采用固定抽样点位置的方法, 但由此产生的描述符的辨识力受到抽样点个数和位置的影响, 同样难以达到令人满意的匹配结果。本文结合了随机抽样模型和固定抽样模型两者的优点, 提出了先固定抽样后随机抽样的方法, 在局部最优点对附近搜索全局最优点对。

本文提出了一种快速、鲁棒的基于贪婪学习的二值描述符匹配方法。该方法结合了 BRIEF 随机抽

样模型和 FREAK 固定抽样模型两者的优点, 将描述符训练阶段分成粗训练和细训练两个阶段。另外, 本文提出的点对辨识力模型考虑了训练样本的均值距离和方差两个因素, 更合理地描述了点对的辨识能力。实现中, 采用目前速度最快的 FAST-9 关键点检测方法减少了关键点的检测时间。最后, 在匹配过程中采用加权匹配方法明显地提高了匹配精度。

2 算法介绍

2.1 关键点检测

本文采用多尺度的 FAST-9 检测算法^[18]快速检测图像中的关键点。首先利用多尺度高斯核对图像进行平滑, 得到图像的尺度空间 $L(x, y, \sigma) = G(x, y, \sigma) \otimes I(x, y)$ 。其中 \otimes 表示卷积, $G(x, y, \sigma)$ 是高斯函数, σ 是尺度空间因子, 其值越小则表示图像细节特征越明显。本文将尺度空间分为 4 组 16 层, 采用如图 1 所示的 16 像素模板检测角点。在尺度空间下的每一层图像中的任一点 p , 对于圆上的每个位置 $x \in \{1, 2, \dots, 16\}$, 其与 p 的相应位置记为 $p \rightarrow x$, 并属于式(1)表示的 3 种状态中的一种。




图1 $n=9, r=3$ 的角点检测模板

$$S_{p \rightarrow x} = \begin{cases} d, & I_{p \rightarrow x} \leq I_p - t & \text{(darker)} \\ s, & I_p - t < I_{p \rightarrow x} < I_p + t & \text{(similar)} \\ b, & I_p + t \leq I_{p \rightarrow x} & \text{(brighter)} \end{cases} \quad (1)$$

其中 t 为阈值, I_p 是位置 p 的颜色值。然后利用 ID3 算法^[19]判断候选像素是否为角点, 最后对检测出的角点进行非最大值抑制。

2.2 二值描述符的训练

关键点的二值描述符由对比关键点附近的一组点对的强度构成, 即通过比较两点像素的强度形成一位二值测试(test), 最终由多个二值测试组成二值

描述符 F : $F = \sum_{0 \leq a < N} 2^a T(P_a)$ 。其中, N 是描述符的长度, P_a 表示一个点对, $T(P_a)$ 是一位二值测试, 其表达形式如式(2)。

$$T(P_a) = \begin{cases} 1, & (I(p_a^1) - I(p_a^2)) > 0 \\ 0, & \text{其它} \end{cases} \quad (2)$$

$I(p_a^1)$ 表示点对 p_a 中第 1 个点的平滑后强度。

为使描述符具有尺度、旋转、光照不变性。

BRIEF^[15] 采用在平滑图像中随机抽样的策略构成点对集合, 但是为了达到理想的分辨力, 该方法需要长时间的训练过程。为提高训练的效率, FREAK^[17] 提出固定抽样策略, 经过高斯平滑处理的少量固定点组成的所有可能点对进行训练。该策略虽然降低了训练复杂度, 但固定抽样点不一定包含最优的点对集合。为此, 本文提出一种粗细结合的抽样模式。首先, 采用 FREAK 的固定点抽样模式进行粗训练找到初始较好的点对集合, 如图 2(a)所示。中心点对应关键点的位置, 半径为 1.0, 图中的每一个圆表示相应抽样点上的高斯核标准差, 为突出关键点周围的细节部分, 圆的大小与该点距离中心的距离成线性关系, 即离中心点越远的抽样点对应的圆半径越大。为了简化粗训练过程, 将 FREAK 的 7 层抽样模式减少为 3 层: 中心层, 中间层和外层(如图 2(b)所示)。相比 FREAK 的 43 个点(903 个可能点对), 本文模型仅有 19 点(171 个可能点对), 从而减少了计算量。为满足高斯标准差与中心位置的线性关系, 同时为了保证所有抽样点的高斯标准差尽量包含图像信息, 将 3 层抽样点与中心点的距离分别设置为 0, 0.3, 0.7, 高斯标准差分别为 0.15, 0.25, 0.30。比较图 2(a)和图 2(b)可知, 两种抽样模型在边缘部分都有未覆盖的信息, 但本文抽样模型中的未覆盖信息明显少于 FREAK 模型。

由文献[11]可知, 一个理想的点对应具有两个特征: 一是该点对的所有训练样本的测试序列均值接

近 0.5; 二是该点对的测试序列和其它点对的测试序列相关度尽可能低, 即每个 1 点对都有助于提高描述符的分辨力。根据以上两个特征, 本文提出了如式(3)所示的新的点对辨识模型。

$$D_a = \frac{\exp(-M^2(a))}{\underset{R}{\operatorname{argmax}} R(a,b)}, \quad \text{s.t. } 0 \leq a < N; \quad (3)$$

$$0 \leq b < N; a \neq b$$

其中 $M(a) = \frac{\sum_{0 \leq a < N} T(P_a)}{N} - 0.5$, $R(a,b)$ 表示测试序列 a 和 b 的相关度。由式(3)所示, 一个点对的分辨力与测试序列均值和 0.5 的距离成反比, 与其它测试序列的最大相关度也成反比。该模型不同于 FREAK, 其只用第 1 个特征表征点对的分辨力, 然后简单地去除超过相关度阈值的点对。本文模型考虑了这两个特征, 同时加强了第 2 个特征在训练中的作用, 故该模型更加合理, 实验部分也验证了该模型的有效性。

将全部点对根据分辨力进行排序, 选取前 N 个较好的点对作为粗训练的结果。此时的训练结果的分辨力往往较差, 需要进一步训练, 即进入细训练阶段。在固定点对的附近存在最佳的点对, 故在点对的空间邻域内随机抽取点对应该可以找到更好的点对以代替原有的固定点对, 这样就打破了固定点抽样模式的局限性, 得到更理想的二值描述符。具体方法为: 对于粗训练结果的一个点对(如图 2(c)所示), 在以这两个点为中心的半径为 r 的两个圆内, 分别均匀地抽取两个点形成新的点对, 抽样点到中心的距离不大于 0.7。为满足高斯标准差与中心点的线性关系, 本文采用了如式(4)的分段函数表示随机抽样点相应的高斯核半径:

$$\sigma = \begin{cases} d/3 + 0.15, & 0 < d < 0.3 \\ 0.125d + 0.2125, & 0.3 < d < 0.7 \end{cases} \quad (4)$$

d 为抽样点到中心点的距离。根据式(3)比较新产生




图 2 抽样模式

的点对的辨识力是否优于原有的点对, 若好于后者, 则保留, 否则进入下一步抽样过程, 迭代该过程多次, 直到找到最优的点对。

本文二值描述符训练的过程如表 1 所示。

表 1 二值描述符训练过程

输入: S 个训练样本(关键点)。
输出: N 个点对(包括点对位置和辨识力)。
粗训练阶段:
(1) 根据采样模型(图 2(b)), 建立样本集合的二值描述矩阵 $D_{S \times N}$, N 为描述符的长度。
(2) 计算每一列的均值和与其它列的最大相关度。由式(3)计算出该列(即测试对)的辨识力。
(3) 根据得到的各个点对的分辨力, 对点对进行排列, 至此保留前 N 个较好的点对。
细训练阶段:
for $0 \leq a < N$
for $0 \leq m < M = 200$
(4) 以两个固定点为中心, 随机抽取一点组成新的点对, 由公式(3)计算该点对的辨识力。
(5) 如果新点对的辨识力优于旧点对, 则将新点对替换旧点对; 否则, 删除该点对。
(6) $m = m + 1$ 。返回步骤(4)。
(7) end
(8) $a = a + 1$
(9) end

2.3 确定关键点方向

为了估计关键点的旋转角度, 本文采用对选出的多个点对的局部梯度求和的方法。点对的选择遵循两个准则: 一是选取长的点对, 二是所选的点对集合具有对称性。如图 3 所示, 本文选取了 36 个点对(少于 FREAK 中的 45 个点对)。用 G 表示计算关键点方向的点对集合, 则关键点方向可由式(5)计算获得。

$$o = \frac{1}{M} \frac{1}{2} \sum_{P_o \in G} (I(P_o^{n_1}) - I(P_o^{n_2})) \frac{P_o^{n_1} - P_o^{n_2}}{\|P_o^{n_1} - P_o^{n_2}\|} \quad (5)$$




图 3 计算关键点方向的点对集合

其中, M 为 G 中点对的个数, P_o^n 是所选点空间坐标的 2 维向量。相比于 SIFT 统计所有像素梯度的方法, 选取固定点对计算关键点方向的方法大大地减少了计算量。

2.4 二值描述符的匹配

本文采用最近邻算法(NN)估计描述符的性能。给定一对图像, 若原图像中的一个关键点在目标图像中的映射位置未超出目标图像的范围, 则该关键点在目标图像中是可见的。设原图像中有 P 个关键点, 目标图像中有 Q 个关键点, 原图像中的关键点在目标图中可见的数目为 P' , 目标图像中的关键点在原图像中可见的数目为 Q' 。对原图像中的每一个关键点, 采用 NN 算法在目标图像中找到与该关键点最近距离的关键点, 称这两点为一对匹配点。根据两幅图像间的几何关系统计正确匹配的个数 n , 则称 $R_e = \frac{n}{\min(P', Q')}$ 为召回率, 其中的 $\min(P', Q')$

为最佳匹配数。对于二值描述符, Hamming 距离是一个理想的相似度测量工具, 将式(3)计算得到的辨识力作为该点对的可信度, 并对其归一化后作为该点对的权重。如此两个二值描述符的距离可以表示为 $\text{Dist}(F_1^i, F_2^j) = \sum_{0 \leq a < N} W_a H(a)$, 其中 W_a 为第 a 个

点对的权重, $H(a) = \begin{cases} 1, & F_1^{ia} \neq F_2^{ja} \\ 0, & F_1^{ia} = F_2^{ja} \end{cases}$, F_1^{ia} 是第 1

幅图像中的第 i 个关键点的描述符中的第 a 个点对的测试值。由于该方法加强了高可信度点对在关键点相似度中的作用, 因而比原始的 Hamming 距离更准确(见第 3 节实验结果)。

3 实验结果

为验证本文算法的有效性, 本节以 INRIA 数据库中的图片作为训练数据, 从中检测出大约 17000 个关键点作为训练样本, 将 Mikolajczyk 和 Schmid 提供的数据库作为测试数据, 如图 4 所示, 包括 6 组图像, 这些图像包含了如视点变化、旋转、亮度变化、模糊和尺度变化等多种图像变化情况。所有算法都在 Window XP Professional 2002+VC2010+Opencv2.3.4 环境下运行, 计算机配置为 Intel(R) Core(TM)2 Duo 2.93 GHz, 2 G RAM。SURF, BRIEF 和 FREAK 算法采用 Opencv2.3.4 库提供的代码实现。

首先, 为验证本文算法的匹配精度, 将本文算法与经典的二值描述符算法 BRIEF 和 FREAK 算法进行比较。具体参数如下: FAST 检测器阈值为 45, 描述符长度 $N = 64$, 设定正确匹配的阈值为 5



图 4 本文选用的数据库

个像素距离。如图 5 所示，其中横坐标中的数字表示最佳匹配数，图中的数字表示该方法的正确匹配数目。在多数变化情况下，本文算法的正确匹配个数都多于其它算法，仅仅在 Car 和 Tree 两组图像中的正确匹配数略低于 BRIEF 算法。这是因为 Car 中光线太暗，Tree 中模糊度过高，这两组中的图像对比度很差，而本文算法为了减少计算描述符的时间，减少了确定关键点方向的点对数目，从而导致图像对比度差时，关键点方向计算误差较大的问题。

为了证明本文算法在计算速度上的优越性，我们统计了不同算法的计算时间，对尺寸为 1000×700 的 Bike 图的统计结果，如表 2 所示。为获得数目大致相同的可见关键点，调整检测算法的阈值，SURF 算法中的阈值取 500，其它 3 种算法采用 FAST 算法检测关键点，两幅图像中的 FAST 算法阈值分别取 50 和 12。从表 2 看出，在总匹配时间上，SURF 明显比其它 3 种基于二值描述符的匹配算法慢，本文算法虽然稍慢于 BRIEF 算法(约慢 1.5 倍)，但明显比 FREAK 算法快(约提高 3.1 倍)。实验结果表明，本文算法在较快的匹配速度下，仍能达到较高的匹配精度。

为验证本文方法在抽样方法和距离计算这两个方面的改进，仍以 Bike 为实验数据，利用 FAST 角点计算两幅图像的关键点，阈值分别取 50 和 12。

测试结果如图 6 所示：总体上来说，描述符长度越大匹配效果也越好，细抽样优于粗抽样，加权 Hamming 距离比 Hamming 距离好。经过细抽样训练的描述符性能提高 6%，而加权 Hamming 的匹配结果最大提升约 10%。

图 7 给出了本文算法在多个图像对的匹配结果，正确匹配的关键点用线段连接，未正确匹配的关键点仅用空心圆标示。

4 结论

本文提出了一种基于分层学习策略的二值描述符匹配算法，该算法具有快速、鲁棒的特点。本文

表 2 不同算法的计算时间(ms)

	SURF	BRIEF	FREAK	本文算法
第 1 幅图像 关键点数	1853	762	762	762
第 2 幅图像 关键点数	848	710	710	710
关键点检测 时间	87.52	36.52	36.52	36.52
描述符生成 时间	4547.01	87.01	625.24	107.22
关键点匹配 时间	2884.03	36.29	86.37	96.83
总时间	7518.56	159.82	748.13	240.57

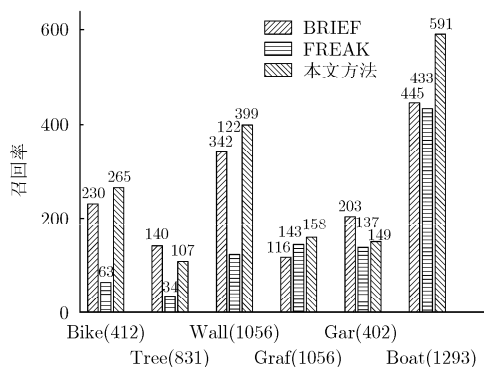


图 5 在不同场景下 3 种不同方法的匹配精度图

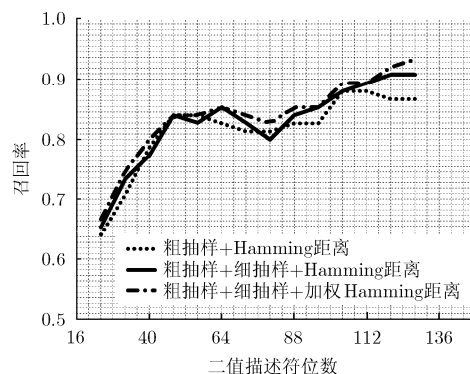


图 6 匹配精度图




图 7 本文算法的匹配结果

方法在建立更合理的点对辨识模型的基础上, 将学习过程分为粗细两个层次, 该策略结合了不同抽样模式的优点, 从而提高了学习效率; 将训练出的点对辨识力作为该点对的权重应用到后续的匹配过程中, 从而增强了匹配算法的精度。实验结果表明, 相比于经典的匹配算法, 本文方法不仅在多种变化情况下具有更高的匹配精度, 而且计算量较少。

参考文献

- [1] Lowe D. Object recognition from local scale-invariant features[C]. Proceedings of the 7th IEEE International Conference on Computer Vision, Greece, 1999: 1150-1157.
- [2] Mikolajczyk K and Schmid C. A performance evaluation of local descriptors[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(10): 1615-1630.
- [3] Tola E, Lepetit V, and Fua P. DAISY: an efficient dense descriptor applied to wide-baseline stereo[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(5): 815-830.
- [4] 张良, 王海丽, 吴仁彪. 基于改进局部不变特征的感兴趣点匹配[J]. 电子与信息学报, 2009, 31(11): 2620-2625.
Zhang Liang, Wang Hai-li, and Wu Ren-biao. Matching of interesting points based on improved SIFT algorithm[J]. *Journal of Electronics & Information Technology*, 2009, 31(11): 2620-2625.
- [5] 胡珂立, 谷宇章, 王营冠. 基于分水岭分割和尺度不变特征点的多目标全自主跟踪算法[J]. 电子与信息学报, 2012, 34(8): 1827-1832.
Hu Ke-li, Gu Yu-zhang, and Wang Ying-guan. Full-automatic tracking algorithm for multi-object based on watershed segmentation and scale-invariant feature points[J]. *Journal of Electronics & Information Technology*, 2012, 34(8): 1827-1832.

- 1827–1832.
- [6] 王山虎, 尤红建, 付琨. 基于大尺度双边 SIFT 的 SAR 图像同名点自动提取方法[J]. 电子与信息学报, 2012, 34(2): 287–293. Wang Shan-hu, You Hong-jian, and Fu Kun. An automatic method for finding matches in SAR images based on coarser scale bilateral filtering SIFT[J]. *Journal of Electronics & Information Technology*, 2012, 34(2): 287–293.
- [7] Rosten E and Drummond T. Machine learning for highspeed corner detection[C]. Proceedings of the 9th European Conference on Computer Vision, Austria, 2006: 430–443.
- [8] Mair E, Hager G, Burschka D, *et al.* Adaptive and generic corner detection based on the accelerated segment test[C]. Proceedings of the 11th European Conference on Computer Vision, Greece, 2010: 183–196.
- [9] Leutenegger S, Chli M, and Siegwart R. BRISK: Binary Robust Invariant Scalable Keypoints[C]. Proceedings of the 13th European Conference on Computer Vision, Spain, 2011: 2548–2555.
- [10] Ke Y and Sukthankar R. PCA-SIFT: a more distinctive representation for local image descriptors[C]. Conference on Computer Vision and Pattern Recognition, USA, 2004: 506–513.
- [11] Ambai M and Yoshida Y. CARD: Compact and Real-time Descriptors[C]. Proceedings of the 13th IEEE International Conference on Computer Vision, Spain, 2011: 97–104.
- [12] Bay H, Tuytelaars T, and Van Gool L. SURF: Speeded Up Robust Features[C]. Proceedings of the 9th European Conference on Computer Vision, Austria, 2006: 404–417.
- [13] Fragoso V, Turk M, and Hespanha J. Locating binary features for keypoint recognition using noncooperative games [C]. 19th IEEE International Conference on Image Processing, Orlando, Florida, 2012: 2389–2392.
- [14] Saha S and Demoulin V. ALOHA: an efficient binary descriptor based on Haar features[C]. 19th IEEE International Conference on Image Processing, Orlando, Florida, 2012: 2345–2348.
- [15] Calonder M, Lepetit V, Strecha C, *et al.* BRIEF: Binary Robust Independent Elementary Features[C]. Proceedings of the 11th European Conference on Computer Vision, Greece, 2010: 778–792.
- [16] Rublee E, Rabaud V, Konolige K, *et al.* Orb: an efficient alternative to SIFT or SURF[C]. Proceedings of the 13th IEEE International Conference on Computer Vision, Spain, 2011: 2564–2571.
- [17] Alahi A, Ortiz R, and Vandergheynst P. FREAK: fast retina keypoint[C]. Conference on Computer Vision and Pattern Recognition, USA, 2012: 510–517.
- [18] Rosten E, Porter R, and Drummond T. Faster and better: a machine learning approach to corner detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(1): 105–119.
- [19] Quinlan J R. Induction of decision tree[J]. *Machine Learning*, 1986, 1(1): 81–106.
- 高洪波: 男, 1979年生, 博士生, 研究方向为视频跟踪、模式识别.
- 王洪玉: 男, 1968年生, 教授, 博士生导师, 研究方向为无线传感器网络、多媒体通信.
- 刘晓凯: 女, 1987年生, 博士生, 研究方向为视频跟踪、模式识别.