

doi:10.3788/gzxb20154402.0210003

基于局部不变特征的目标自动识别

周达标^{1,2}, 霍丽君^{1,2}, 李刚¹, 王德江¹, 贾平¹

(1 中国科学院长春光学精密机械与物理研究所 航空光学成像与测量重点实验室, 长春 130033)

(2 中国科学院大学, 北京 100049)

摘要:为快速、准确地识别图像中的目标,提出一种结合图像熵和加速鲁棒特征算法的目标自动识别方法.首先,分块计算图像的信息熵,根据阈值筛选出纹理丰富区域.然后,结合 Hessian 矩阵和 Harris 算法提取纹理丰富区域的局部特征点.接着,计算特征向量并用主成分分析降低向量维数.最后,采用双向最近距离比例匹配算法进行分类,并用随机抽样一致算法剔除误匹配点.实验结果表明:对仿真数据库中带有视角、光照和尺度变化的图像,识别率分别为 87.12%、75.31%和 84.98%,平均识别时间分别为 70.35 ms、71.27 ms、220.63 ms;对含 8956×6708 像素的航空大面阵图像,正确匹配率为 78.13%,识别时间为 68.09 s.本方法识别率和时间性能均优于加速鲁棒特征算法.

关键词:图像处理;目标自动识别;特征提取;信息熵;分类

中图分类号:TP391.4

文献标识码:A

文章编号:1004-4213(2015)02-0210003-6

Automatic Target Recognition Based on Local Invariant Features

ZHOU Da-biao^{1,2}, HUO LI-jun^{1,2}, LI Gang¹, WANG De-jiang¹, JIA Ping¹

(1 Key Laboratory of Airborne Optical Imaging and Measurement, Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

(2 The University of the Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In order to recognize targets in images fast and truly, an automatic target recognition method was proposed based on image entropy and speed up robust feature. First, image entropy was computed in different blocks, and regions full of texture were filtered out by threshold. The local key points in regions of interest were extracted by incorporating the Hessian and Harris detectors. Then, feature descriptors were established and principle component analysis was employed to reduce the dimensionality. Finally, nearest neighbor distance ratio classifier was explored in double directions and wrong matches were eliminated by random sample consensus. The experiment results demonstrate that the recognition rates for images in simulation database with varied view-points, scales and illuminations are 87.12%, 75.31% and 84.98%, and the computing time is 70.35 ms, 71.27 ms and 220.63 ms, respectively. Moreover, the correct matching rate for an aerial large planar array image of 8 956×6 708 pixels is 78.13% and the computing time is 68.09 s. Compared with speed up robust feature, the proposed method performs better both in recognition rates and computing time.

Key words: Image processing; Automatic target recognition; Feature extraction; Information entropy; Classification

OCIS Codes: 100.2960; 100.3008; 100.5010; 100.5760; 330.5000

0 引言

目标识别是计算机视觉领域中最基础而又最富有

挑战的技术之一,在军事领域中应用尤为突出,如精确制导武器和火控系统等.

目标识别主要包括特征提取和特征分类两部分.

基金项目:国家自然科学基金(No. 61308099)和吉林省重大科技攻关专项(No. 11ZDGG001)资助

第一作者:周达标(1990—),男,博士研究生,主要研究方向为图像处理和模式识别. Email:dabiao@mail.ustc.edu.cn

导师(通讯作者):贾平(1964—),男,研究员,博士,主要研究方向为光学动态成像控制和图像处理技术. Email:jiap@ciomp.ac.cn

收稿日期:2014-06-27;录用日期:2014-09-02

<http://www.photon.ac.cn>

特征提取包括特征点检测和特征描绘. 一般通过检测尺度空间的极值点定位特征点, 而特征描述向量需要具有独特性、紧凑性以及尺度、视角和照度等变化的不变性. 特征分类器包括线性分类器、神经网络分类器和支持向量机等.

目前, 应用最广泛的局部特征提取和描述方法是LOWE提出的尺度不变特征变换算法(Scale Invariant Feature Transform, SIFT)^[1], 该算法通过统计特征点邻域的灰度直方图构建128维特征向量, 对光照、尺度和视角等变化具有一定的不变性, 但其计算复杂度很高, 无法满足实时要求^[2]. YAN等提出的PCA-SIFT算法在特征点提取上与SIFT相同, 特征描述则利用主成分分析(Principle Component Analysis, PCA)算法去除描绘向量中的干扰信息, 将特征向量降低到20维, 相比SIFT有更好的鲁棒性^[3], 但当图像旋转角度较大时, 该方法性能下降较快. BAY等提出的加速鲁棒特征(Speed Up Robust Feature, SURF)是对SIFT特征的改进, 其匹配率与SIFT接近, 快速Hessian矩阵和积分图像的引入使其运算速度提高约三倍^[4]. LEUTENEGGER等提出的二值特征(Binary Robust In Variant Scalable Keypoints, BRISK)^[5]和ALAH等提出的快速视网膜特征(Fast Retina Keypoint, FREAK)^[6]比SURF更快速, 但不具有尺度不变性. 此外, 翟优等在SURF算法基础上, 通过改变特征点局部邻域的形状获得低维的特征描述向量, 具有较强的鲁棒性^[7]. 黄伟国等提出的PCA-SC算法特征定位准确, 识别速度快, 但当目标被部分遮挡时识别率低^[8].

为了缩短目标识别时间, 提高识别率, 本文提出一种结合图像信息熵和SURF特征的目标识别方法. 首先, 分块计算图像信息熵, 提取出纹理丰富的区域; 结合快速Hessian矩阵和Harris算法提取该区域局部特征点, 计算特征向量并使用主成分分析降维; 最后利用双向最近邻比例匹配(Nearest Neighbor Distance Ratio, NNDR)算法进行匹配. 该方法计算速度快, 在尺度、视角和照度变化时的识别率高于SURF算法.

1 SURF 算法原理

1.1 特征点检测

SURF算法利用快速Hessian矩阵检测特征点, 具有准确度高、速度快等优点. 在点 $\mathbf{x}=(x, y)$ 处, 尺度为 σ 的Hessian矩阵 $\mathbf{H}_e(\mathbf{x}, \sigma)$ 的定义为

$$\mathbf{H}_e(\mathbf{x}, \sigma) = \begin{bmatrix} L_{xx}(\mathbf{x}, \sigma) & L_{xy}(\mathbf{x}, \sigma) \\ L_{xy}(\mathbf{x}, \sigma) & L_{yy}(\mathbf{x}, \sigma) \end{bmatrix} \quad (1)$$

式中, $L_{xx}(\mathbf{x}, \sigma)$ 是高斯二阶导数 $\frac{\partial^2}{\partial x^2}g(\sigma)$ 和图像 $I(x, y)$ 的卷积. 在实际计算中, 用盒子滤波器近似高斯二阶导数模板, 并采用积分图像技术, 提高计算速度. 图1是

$\sigma=1, 2$ 的 y 方向高斯二阶导数模板及其近似模板.

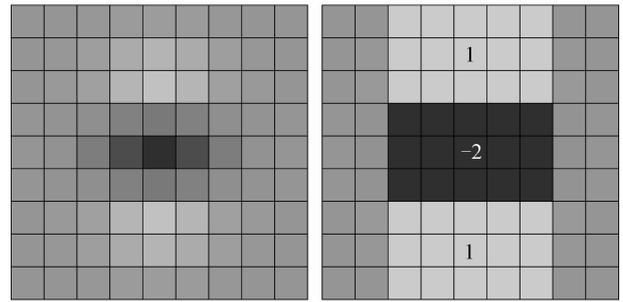


图1 y 方向高斯二阶导数模板和近似模板

Fig. 1 Gaussian second derivatives and its approximate template in y -direction

通过不断增大高斯模板的尺寸和采样间隔, 得到尺度空间金字塔. 在尺度空间进行非极大值抑制, 若 $3 \times 3 \times 3$ 立方体中心点Hessian矩阵行列式的值大于其他的点, 则该点被选为候选特征点. 为了获得空间亚像素级准确度和更精细的尺度, 对尺度空间的Hessian值进行三维二次泰勒函数展开, 即

$$\mathbf{H}_e(\mathbf{x}) = \mathbf{H}_e + \frac{\partial \mathbf{H}_e^T}{\partial \mathbf{x}} \mathbf{x} + \frac{1}{2} \mathbf{x}^T \frac{\partial^2 \mathbf{H}_e}{\partial \mathbf{x}^2} \mathbf{x} \quad (2)$$

式中 $\mathbf{x}=(x, y, \sigma)^T$ 是精确定位的特征点相对于候选特征点的偏移量, \mathbf{H}_e 是候选特征点的Hessian值. 对式(2)求导并令导数为零即可确定更精确的特征点位置和尺度, 即

$$\hat{\mathbf{x}} = -\frac{\partial^2 \mathbf{H}_e^{-1}}{\partial \mathbf{x}^2} \frac{\partial \mathbf{H}_e}{\partial \mathbf{x}} \quad (3)$$

1.2 特征描绘

以特征点为圆心, 6σ 为半径, 计算圆域内每个像素处的Haar小波响应, 得到 (dx, dy) . 使用张角为 $\pi/3$ 的扇形按照一定间隔逆时针转动, 计算扇形区域所有向量 $\sum dx$ 和 $\sum dy$ 的值, 幅值最大的区域为最终选取的区域, 向量 $(\sum dx, \sum dy)$ 的幅角作为主方向.

选取边长为 20σ 的正方形特征点邻域, 其中正方形邻域的边和主方向平行或垂直. 将正方形邻域平均分成16个子块, 计算每个子块的Haar小波响应得到 $(\sum dx, \sum dy, \sum |dx|, \sum |dy|)$ 四维描述符. 16个子区域得到64维特征向量.

1.3 SURF算法存在的问题

实际识别应用对时间复杂度有较高的要求. 对于一幅分辨率为 8956×6708 的航空大面阵图像, SURF算法运行时间是138.12 s. 为了更清晰地显示图像中的细节, 截取其中一个子块, 如图2. 其特征点分布如图3.

从图3中可以看出, 特征点主要分布在纹理较强的区域, 如围墙和汽车等. 在平滑区域如屋顶、道路基本没有特征点分布. 而航空图像由于探测距离远, 分辨率低, 往往存在大面积的平坦区域. SURF算法需要遍历图像中的每一个像素点, 构建尺度空间, 检测极值点

并进行特征描绘,时间复杂度高,不能满足实际识别应用对时间的要求.



图2 剪裁并放大的航空大面阵图像

Fig. 2 A cropped and magnified aerial large planar array image



图3 航空大面阵图像 SURF 特征点分布

Fig. 3 SURF point distribution of aerial large planar array image

2 SURF 算法的改进

2.1 非平滑区域提取

SURF 算法检测到的特征点主要分布在纹理较强区域.这里使用图像熵来估计图像的纹理变化特性^[9].信息熵表征了信源整体的统计特征,是总体平均不确定性的量度.图像一维熵定义为

$$H = -\sum p_i \log p_i \quad (4)$$

式中 p_i 是图像中灰度值为 i 的像素出现的概率,可以通过统计图像的灰度直方图求得.

为了确定非平滑区域,本文分块计算图像的信息熵,分块原则是不重不漏,为了方便起见,每 16×16 个像素作为一个子块.分别计算每一子块的信息熵后,采用阈值法,提取非平滑区域.根据大量实验数据验证,阈值一般取 $12.0 \sim 12.70$ 比较合适,阈值可以根据实际需要灵活调整.

由于平滑区域几乎没有特征点分布,因此只在非平滑区域提取特征点,可以有效缩短计算时间.

2.2 结合 Harris 算法提取特征点

由信息熵选取非平滑区域可能忽略掉一些特征点,信息量变少,识别率降低.为了在纹理丰富的区域提取更多的特征点,为后续识别提供更多信息,降低误匹配率,本文在特征点提取过程中再加入 Harris 多尺度检测器,和 Hessian 多尺度检测器构成 Harris-Hessian 双通道检测器^[10].

在点 $\mathbf{x}=(x,y)$ 处,尺度为 σ 的 Harris 矩阵 $\mathbf{H}_a(\mathbf{x}, \sigma)$ 的定义为

$$\mathbf{H}_a(\mathbf{x}, \sigma) = \begin{bmatrix} L_x^2 & L_x L_y \\ L_y L_x & L_y^2 \end{bmatrix} \quad (5)$$

式中 $L_y(\mathbf{x}, \sigma)$ 是 Gauss 一阶导数 $\frac{\partial}{\partial y} G(\sigma)$ 和图像 $I(x,y)$ 的卷积,即

$$L_y(\mathbf{x}, \sigma) = \frac{\partial}{\partial y} G(\sigma) \otimes I(x,y) \quad (6)$$

为了利用积分图像加快计算速度,与快速 Hessian 矩阵类似,采用近似模板代替 Gauss 一阶导数模板^[11],如图 4.

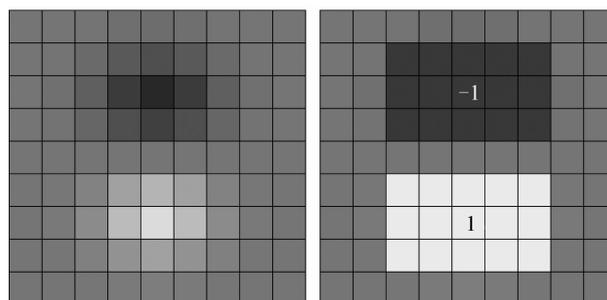


图4 y 方向 Gauss 一阶导数模板和近似模板

Fig. 4 Gaussian first derivatives and its approximate template in y -direction

利用 Hessian 矩阵和 Harris 算法构建尺度空间后,用非极大值抑制粗略确定特征点位置,利用插值算法确定特征点亚像素级位置和精细尺度,完成特征点检测.

2.3 主成分分析降维

特征向量维数高会增加计算的复杂度,给后续的分类带来负担,同时需要更多的训练样本.因此需要对特征向量降维.主成分分析的实质是在尽可能好地代表原始数据的前提下,通过线性变换将高维空间中的样本数据投影到低维空间.利用主成分分析对 64 维特征向量 $\mathbf{x}_1, \mathbf{x}_2 \dots \mathbf{x}_N$ 降维的具体步骤是

Step1: 计算 N 个特征向量 \mathbf{x}_i 的平均向量 $\boldsymbol{\mu}$;

Step2: 构建协方差矩阵 \mathbf{C} , 并求 \mathbf{C} 的特征值和特征向量 \mathbf{w}_i .

$$\mathbf{C} = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T \quad (7)$$

Step3: 选取特征值较大的 $m(m < 64)$ 个特征向量

w_i , 令 $W=[w_1, w_2, \dots, w_m]$, 则可以得到 m 维特征向量 y_i , 即

$$y_i = W^T(x_i - \mu) \quad (8)$$

主成分分析降低了特征向量维数, 滤除了特征向量中的干扰信息, 增强了特征的鲁棒性。

2.4 特征分类

对于得到的特征向量 y_i , 进行特征匹配。为了提高匹配的可靠性, 本文采用基于欧式距离的 NNDR 双向匹配算法进行特征分类。

双向匹配算法的基本思想是, 取测试样本中的某个特征点 A 与训练样本中的特征点匹配, 在训练样本中匹配得到的特征点记为 B ; 取训练样本中的特征点 B 与测试样本中的特征点匹配, 在测试样本中匹配得

到的特征点记为 C ; 如果特征点 A 和特征点 C 是同一个特征点, 则匹配成功, 否则剔除这组匹配。

传统匹配算法只是单向配准, 而通过双向匹配策略可以剔除大量误匹配点, 降低误匹配率。为了进一步提高匹配的可靠性, 采用随机抽样一致算法(Random Sample Consensus, RANSAC) 进一步筛选正确匹配点。

图 5 是利用本文算法进行特征提取和分类流程图。分别对训练样本和测试样本分块计算信息熵, 筛选出大于阈值的图像块, 结合 Hessian 矩阵和 Harris 算法检测特征点, 计算特征向量并利用 PCA 降维, 最后利用双向 NNDR 分类器分类, 并使用 RANSAC 算法剔除误匹配点。

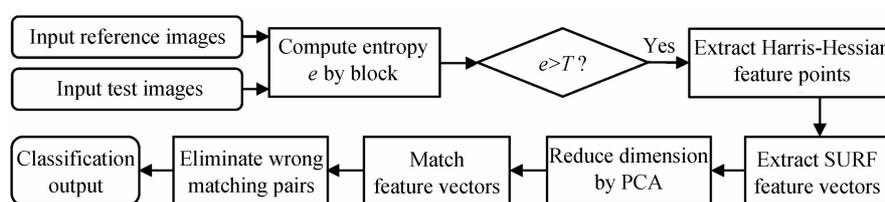


图 5 特征提取和训练流程图
Fig. 5 Flow chart of feature extraction and training

3 实验与结果

为了验证本文方法的有效性, 在 Intel Core i3-2120 3.3 GHz 的计算机 Matlab 软件平台上, 利用 SIFT 算法、SURF 算法和本文算法对仿真图像和实际航空大面阵图像进行识别实验, 并利用识别率、识别时间和正确匹配率等多种指标定量评价目标识别性能。

3.1 视角、光照和尺度变化识别实验

为验证本文算法对视角、光照和尺度变化的不变性, 对 Amsterdam 数据库中的目标图像 (Amsterdam Library of Object Images, ALOI) 进行目标识别实验。从 ALOI 数据库中选取 8 组有代表性玩偶图像, 每幅图像分辨率为 192×144 , 如图 6。



图 6 八组基准图
Fig. 6 Eight groups of reference images

对于视角变化实验, 每隔 5° 对玩偶拍摄一幅图像^[12], 每隔 45° 选取一幅图像作为训练图, 其余图像作为测试图, 其中一组训练图如图 7。对于光照变化实验, 改变光照的角度和强度, 每组玩偶得到 8 幅不同的图像, 其中一组如图 8 所示, 选取光照均匀的一幅图像作为训练图, 其余图像为测试图。对于尺度变化实验,

对分辨率为 768×576 的原始图像进行两次降采样, 并用高斯滤波器平滑^[12], 以每组分分辨率为 192×144 的图像为训练图像, 其他图像为测试图像。



图 7 不同视角的玩偶目标
Fig. 7 A group of doll targets of different view-points



图 8 不同照度环境下的玩偶目标
Fig. 8 A group of doll targets under different illuminations

分别利用 SIFT 算法、SURF 算法和本文算法进行识别实验, 识别结果如表 1。其中 FPN 代表特征点个数 (Feature point number), RR 代表识别率 (Recognition rate)。从表 1 可以看出, 与 SIFT 和 SURF 算法相比, 本文算识别时间最短, 识别率高于 SURF 算法, 略低于 SIFT 算法。

本文算法根据信息熵的大小剔除了大量平滑区域, 特征提取部分需要处理的数据量减少。对于分辨率为 192×144 的图像, 每幅图像的特征提取和分类时间

表 1 仿真图像识别结果

Table 1 Recognition results of simulation images

Change	Method	Time/ms	FPN	RR/%
View-point	SIFT	408.66	707	95.56
	SURF	150.88	334	83.43
	Proposed	70.35	452	87.12
Illumination	SIFT	589.08	113	90.24
	SURF	154.30	45	67.53
	Proposed	71.27	70	75.31
Scale	SIFT	981.78	273	99.12
	SURF	486.05	153	82.62
	Proposed	20.63	206	84.98

降低到 70 ms 左右. 本文算法结合了 Harris 和 Hessian 特征点检测算法, 比 SURF 算法检测到更多的特征点, 为后续分类提供更多信息, 有助于提高识别率. 算法中采用 PCA 技术对特征向量降维, 剔除了特征向量中的冗余信息, 增强了特征向量的鲁棒性; 双向匹配策略和 RANSAC 算法降低了误匹配率.

与 SURF 算法相比, 本文算法识别率最高提高 7.78%; 与 SIFT 算法相比, 本文算法识别率稍低, 但识别时间大大减少. 对于时间性能要求较高的航空大面阵图像识别, 本文算法有重要的工程实际意义.

3.2 航空大面阵图像识别实验

为验证本文算法对航空大面阵图像识别的有效性, 选取某型号航空相机拍摄到的大面阵图像进行识别实验. 该图像分辨率为 8956×6708 , 如图 9.



图 9 航空大面阵图像和剪裁出的汽车细节

Fig. 9 Aerial large planar array image and details of cropped vehicles

从图 9 中可以看出, 图像中的场景十分复杂, 包含房屋、人工湖、汽车、草地和道路等. 图像中含有 58 辆不同种类的汽车, 包括卡车、货车和轿车等. 为更清晰地显示图像中的细节, 将图 9 中矩形内的子图像放大显示, 如图 2 所示.

为了剔除平滑区域, 将图像分割成大小为 16×16 的子图像, 计算每一个子图像的信息熵. 对于信息熵小

于阈值 12.5 的子图像, 其纹理不丰富, 图像较为平滑, 几乎不存在特征点, 如图 10.



图 10 利用信息熵剔除的平滑区域

Fig. 10 Smooth regions eliminated by information theory

图 10 中黑色区域代表被剔除的平滑区域, 其占整幅图像的比例高达 54.14%. 平滑区域主要分布在屋顶、道路等. 航空图像探测距离远, 往往存在大面积的平滑区域, 因此只需要对非平滑区域提取特征点, 可以有效缩短计算时间.

以图 9 中大面阵图像为测试图像, 选取另一幅航拍的轿车图像作为训练图像. 训练图像和测试图像航拍高度、拍摄视角都不相同, 同时还受随机噪音的影响. 利用典型算法分别进行识别实验, 部分识别结果如图 11, 图中的线段表示匹配的特征点. 图中左下角、右下角和右上角分别为利用 SIFT 算法、SURF 算法和本文算法识别结果. 客观评价指标如表 2.

可以看出, SIFT 算法的正确匹配率(准确度)最高, 可以计算出目标和模板之间的变换矩阵, 有效地识别出航空大面阵图像中的汽车目标, 但特征提取时间高达 205.95 s, 无法满足实际识别需要. SURF 算法将特征提取时间降低到 138.12 s, 但存在大量的误匹配特征点对, 正确匹配率降低到 48.39%, 无法计算出目标和模板之间的变换矩阵. 本文算法由于采用了

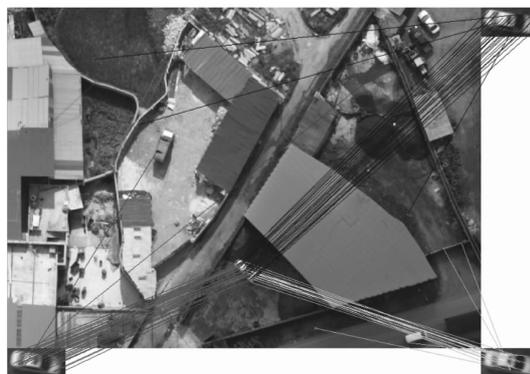


图 11 三种方法对汽车目标的识别结果

Fig. 11 Recognition results for vehicle target by three methods

表 2 客观评价指标对比表

Table 2 Comparison of evaluation indexes for aerial large planar array images

Method	Feature extraction time/s	Feature matching time/s	Feature point number	Total matching number	Correct matching number	Correct matching rate/%
SIFT	205.95	1.92	207774	41	37	90.24
SURF	138.12	1.44	101126	31	15	48.39
Proposed	66.30	1.79	143288	32	25	78.13

Harris-Hessian 双通道检测器,相比于 SURF 算法提取出了更多的特征点;由于采用了基于信息熵的特征提取策略,只在纹理较强区域提取特征点,特征提取时间降低到 66.30 s,相比于 SURF 算法减少 71.82 s. 本文算法利用 PCA 算法降低了特征向量维数,并采用双向匹配策略和 RANSAC 算法进行特征匹配,正确匹配率达到 78.13%,略低于 SIFT 算法. 本文算法在保证目标识别有效性的基础上,可以有效缩短目标识别时间.

4 结论

为快速、准确地识别图像中的目标,本文提出一种结合图像熵和 SURF 算法的快速目标识别方法. 分块计算图像信息熵,提取出纹理较强的区域. 只在该区域提取特征点,减少了计算量;结合 Hessian 矩阵和 Harris 算法增加了特征点数量,降低误匹配率;利用主成分分析对特征向量降维,降低特征描述复杂度,提高了特征分类速度;双向匹配策略和 RANSAC 算法降低了误匹配率. 实验结果证明,本方法计算速度快,鲁棒性强,对 ALOI 数据库中的图像,在视角、光照和尺度变化下的识别率分别为 87.12%、75.31%和 84.98%,平均识别时间分别为 70.35 ms、71.27 ms、220.63 ms;对分辨率为 $8\ 956 \times 6\ 708$ 的航空大面阵图像,识别时间为 68.09 s. 与 SURF 算法相比,本算法提高了识别率和计算速度.

参考文献

- [1] LOWE D G. Distinctive image feature from scale invariant keypoints[J]. *International Journal of Computer Vision*, 2004, **60**(2): 91-110.
- [2] MIKOLAJCZYK K, SCHMID C. A performance evaluation of local descriptors[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2005, **27**(10): 1615-1630.
- [3] YAN K, SUKTHANKAR R. PCA-SIFT: a more distinctive representation for local image descriptors [C]. *Computer Vision and Pattern Recognition*, 2004: 506-513.
- [4] BAY H, TUYTELAARS T, GOOL L V. SURF: Speed-up robust features [C]. *Proceedings of the 9th European Conference on Computer Vision*, 2006: 404-417.
- [5] LEUTENEGGER S, CHLI M, SIEGWART R Y. BRISK: Binary robust invariant scalable keypoints[C]. *International Conference on Computer Vision*, 2011: 2548-2555.
- [6] ALAHI A, ORTIZ R, VANDERGHEYNST P. FREAK: Fast retina keypoint [C]. *Computer Vision and Pattern Recognition*, 2012: 510-517.
- [7] ZHAI Ying, ZENG Luan, XIONG Wei. Performance analysis of SURF descriptor with different local region partitions[J]. *Optics and Precision Engineering*, 2013, **21**(9): 2395-2404. 翟优, 曾峦, 熊伟. 不同局部邻域划分加速鲁棒特征描述符的性能分析[J]. *光学精密工程*, 2013, **21**(9): 2395-2404.
- [8] HUANG Wei-guo, GU Chao, ZHU Zhong-kui. PCA-SC shape matching for object recognition[J]. *Optics and Precision Engineering*, 2013, **21**(8): 2103-2110. 黄伟国, 顾超, 朱忠奎. 用于目标识别的 PCA-SC 形状匹配算法[J]. *光学精密工程*, 2013, **21**(8): 2103-2110.
- [9] LI Xiao-chang, ZHU Dan. Image registration method based on region selection and scale-invariant feature[J]. *Infrared and Laser Engineering*, 2012, **41**(2): 537-542. 李小昌, 朱丹. 采用尺度不变特征和区域选择的图像配准方法[J]. *红外与激光工程*, 2012, **41**(2): 537-542.
- [10] HARRIS C, STEPHENS M. A combined corner and edge detector [C]. *Proceedings of the Fourth Alvey Vision Conference*, 1988: 147-151.
- [11] JIA Ping, XU Ning, ZHANG Ye. Automatic target recognition based on local feature extraction[J]. *Optics and Precision Engineering*, 2013, **21**(7): 1898-1905. 贾平, 徐宁, 张叶. 基于局部特征提取的目标自动识别[J]. *光学精密工程*, 2013, **21**(7): 1898-1905.
- [12] GEUSEBROEK J M, BURGHOUTS G J, SMEULDERS A W M. The Amsterdam library of object images [J]. *International Journal of Computer Vision*, 2005, **61**(1): 103-112.
- [13] MIKOLAJCZYK K, SCHMID C. Scale & affine invariant interest point detectors [J]. *International Journal of Computer Vision*, 2004, **60**(1): 63-86.