

文章编号 1004-924X(2013)07-1898-08

## 基于局部特征提取的目标自动识别

贾 平<sup>1</sup>, 徐 宁<sup>1,2\*</sup>, 张 叶<sup>1</sup>

(1. 中国科学院 长春光学精密机械与物理研究所

中国科学院航空光学成像与测量重点实验室, 吉林 长春 130033;

2. 中国科学院大学, 北京 100039)

**摘要:**提出一种基于局部特征提取的目标识别方法,用于自动识别不同尺度,视角和照度条件下的目标。首先,建立图像的尺度空间;结合海森矩阵和 Harris 算法提取局部特征点,计算该特征区域的方向和灰度梯度及方向;统计出每块子区域的标准灰度梯度直方图,得到 128 维的特征向量。然后,基于主成分分析的降维算法来降低特征向量的维数,加快识别的计算速度。最后,采用特征空间分类器增加目标识别的速度。实验结果表明:基于局部特征提取的目标识别达到了较高的识别率,在视角、尺度和照度变化下的识别率分别为 61.9%, 80.5% 和 84.4%, 平均识别时间为 130.9 ms。与尺度不变特征变换(SIFT)和加速鲁棒特征(SURF)算法相比,本算法不仅在不同的视角,目标尺度及照度条件下具有较高识别率,而且识别速度比 SIFT 方法高。

**关键词:**目标自动识别;局部特征提取;主成分分析;最近特征空间分类器

**中图分类号:**TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20132107.1898

## Automatic target recognition based on local feature extraction

JIA Ping<sup>1</sup>, XU Ning<sup>1,2\*</sup>, ZHANG Ye<sup>1</sup>

(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. University of Chinese Academy of Sciences, Beijing 100039, China)*

*\* Corresponding author, E-mail: xning@mail.ustc.edu.cn*

**Abstract:** A target recognition method was proposed to recognize targets with different scales, view-points and illuminations automatically. First, a scale space of images was established, and the local key points in the scale space were extracted by incorporating the Hessian and Harris scale-space detectors. Then, the main orientations of the key points and orientation histograms were calculated and 128 element feature vectors for each key point were established, in which these feature vectors were invariant in different rotations and illuminants. To reinforce the performance, principle component analysis was incorporated to reduce the dimensionality of feature vectors and improve calculating speeds for the recognition. The nearest feature space classifier was used for increasing the recognition speeds in robustness. Experiment results show that this proposed method achieves a significant improvement in automatic target recognition rate, and the recognition rates for varied view-points, scales and illuminations are 61.9%, 80.5%, and 84.4%, respectively. Compared with the Scale Invariant Feature Transform(SIFT) and Speeded Up Robust Features (SURF), the proposed method achieves a signifi-

收稿日期:2012-04-30;修订日期:2012-06-07.

基金项目:国家自然科学基金青年基金资助项目(No. 60902067);吉林省重大科技攻关资助项目(No. 11ZDGG001)

cant improvement in automatic target recognition rate in presence of varying viewpoints, scales and illuminations.

**Key words:** automatic target recognition; local feature extraction; principle component analysis; nearest feature space classifier

## 1 引言

视觉系统是人类获取外界信息的最主要途径,而目标识别是机器视觉和模式识别领域的重要课题,具有广泛的应用前景。在国防建设中,目标识别是训练、侦察、防御体系中的关键技术。如防御系统多采用目标识别技术对移动军事目标进行跟踪、识别以及导弹制导;各种高技术武器系统及其模拟训练器也通过目标识别技术实现对目标的捕获及跟踪测量,以此来提高武器系统的机动攻击性能及作战指标<sup>[1-2]</sup>。

目标自动识别的主要难点是目标图像的多变性,背景条件的多变性,照度条件的变化以及视角的变化等对目标识别的影响。因此,一个好的目标自动识别方法必须能够提取出稳定的目标特征<sup>[3]</sup>。

一般情况下,目标自动识别包括两部分:(1)目标图像的特征提取;(2)训练分类器。有一些识别方法直接使用匹配方法而没有使用分类器<sup>[4]</sup>,而一些自动识别方法可以提取整个目标的特征<sup>[5-10]</sup>。显然,这类方法要么在特征提取部分耗用时间较多<sup>[11]</sup>,要么由于特征向量维数过高导致分类耗时过多。另外一些方法将图像分成若干子块<sup>[12-13]</sup>,再使用级联分类器分别检测每个子块。这类方法具有较高的识别速度,但是当视角变化时,该方法的识别率低。

局部特征<sup>[14]</sup>一般具有尺度,旋转及照度不变特性,在图像匹配和重构中有着广泛的应用<sup>[15]</sup>。尺度不变特征变换(SIFT)方法<sup>[16]</sup>通过统计特征点附近 $4 \times 4$ 个子区域的灰度梯度方向直方图构建128维特征向量,这种方法具有视角,尺度,亮度不变特性,但实时性能较差,并且当视角变化较大和照度变化较大时,该方法识别率较低。加速鲁棒特征(SURF)<sup>[17]</sup>算法利用 Haar 小波的局部响应建立128维特征向量,具有较好的实时性,但当视角和照度变化较大时效果不好。

本文提出了一种基于局部特征提取的目标自动识别方法,该方法在较大视角和照度变化时有

较高识别率。首先使用快速海森阵<sup>[18]</sup>和 Harris 算法提取出目标局部特征点;接着使用方向计算方法<sup>[19]</sup>提取出特征点的方向;然后使用灰度梯度和标准灰度梯度直方图构建128维特征向量;因为该特征向量维数较高,本文使用主成分分析方法<sup>[20-21]</sup>来降低特征向量的维数,并且提取出数据集的主要特征<sup>[3,22]</sup>;最后,介绍了近邻分类器和近邻直线分类器,并且使用近邻特征空间分类器以达到较快的识别速度。

## 2 特征提取

### 2.1 特征点检测

多尺度海森检测具有不变特性,并且计算速度较快,故本文用该方法检测特征点。设点 $\mathbf{x} = (x, y)$ 是图像 $I$ 中的一点,在点 $\mathbf{x} = (x, y)$ 的尺度为 $\sigma$ 的海森矩阵 $\mathbf{H}(\mathbf{x}, \sigma)$ 的定义如下:

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

其中, $L_{xx}(\mathbf{x}, \sigma)$ 是高斯二阶导数 $\frac{\partial^2}{\partial x^2}g(\sigma)$ 和图像 $I$ 的卷积,同 $L_{xy}(\mathbf{x}, \sigma)$ 和 $L_{yy}(\mathbf{x}, \sigma)$ ,即:

$$L_{xx}(\mathbf{x}, \sigma) = \frac{\partial^2}{\partial x^2}(G(\mathbf{x}) * I(x, y)) = \frac{\partial^2}{\partial x^2}G(\mathbf{x}) * I(x, y). \quad (2)$$

在实际使用中,需要使用高斯模板来代替高斯二阶导数,图1是 $9 \times 9$ 的 $\sigma = 1.2$ 的高斯二阶导数模板。




图1  $y$ 方向和 $xy$ 方向的高斯二阶导数

Fig. 1 Gaussian second derivatives in  $x$ -direction and  $xy$ -direction




图 2 y 方向和 xy 方向的高斯二阶导数近似模板

Fig. 2 Approximate templates of Gaussian second derivatives in x-direction and xy-direction

为了提高计算速度,本文采用高斯二阶导数的近似模板  $D_{xx}, D_{yy}$  和  $D_{xy}$ , 如图 2 所示。因为经验公式  $\frac{|L_{xy}(1.2)|_F |D_{xx}(9)|_F}{|L_{xx}(1.2)|_F |D_{xy}(9)|_F} = 0.912 \dots \approx 0.9$ , 其中  $|x|_F$  是 Frobenius 式<sup>[17]</sup>, 因此近似的海森矩阵行列式计算公式为:

$$\det(H_{\text{approx}}) = D_{xx}D_{yy} - (0.9D_{xy})^2. \quad (3)$$

尺度空间一般是重复使用高斯平滑和降采样得到的。由于使用了高斯近似模板和积分图像,只需要使用不同尺度的模板就可以取代尺度空间。因此,尺度空间分析是由提高高斯模板的尺度来取代原先的降低图像的尺度。

为了得到更多的局部特征点,为后续识别环节提供更多信息以提高识别率,本文在特征点检测中加入了 Harris 多尺度检测<sup>[23]</sup>。如图 3 所示,在高斯尺度空间中,一阶导数  $L_x(x, \sigma)$  为:

$$L_x(x, \sigma) = \frac{\partial}{\partial x}(G(x) * I(x, y)) = \frac{\partial}{\partial x}G(x) * I(x, y). \quad (4)$$

使用近似模板来替代一阶高斯函数,如图 4 所示。




图 3 x 方向和 y 方向的高斯一阶导数

Fig. 3 Gaussian first derivatives in x-direction and y-direction




图 4 x 方向和 y 方向的高斯一阶导数近似模板

Fig. 4 Approximate templates of Gaussian first derivatives in x-direction and y-direction

特征点提取是从尺度空间中的子区域  $\Delta x \times \Delta y \times \Delta s$ (图 5)取得海森行列式或者 Harris 算子的最大值,即:

$$r = \max_{x_i \in S} \{ \det(H_{\text{approx}}(x_s)) \text{ or } C_{\text{approx}}(x_s) \}. \quad (5)$$

其中,  $S$  是尺度空间中的子区域  $\Delta x \times \Delta y \times \Delta s$ (图 4),  $x_s(x, y, s)$  是尺度空间的一点,  $s$  是尺度因子  $\sigma$  的步长,  $C_{\text{approx}}(x_s)$  是 Harris 算子。在提取样本集合的特征点时,提取顺序是尺度空间中的子区域的排列顺序,以达到较好的聚类性。




图 5 尺度空间分割

Fig. 5 Scale space division

### 2.2 特征点方向

为了使得局部特征具有旋转不变性,需要一个可以重复的特征点方向提取。首先,以特征点为圆心,  $6s$  为半径,提取出圆形局部区域。计算  $x$  和  $y$  方向的 haar 小波变换。水平方向小波变换后的向量按照横坐标表示,竖直方向的小波变换按照纵坐标表示。该特征点的主体方向是用一个滑动方向窗口来计算的。在窗口内的水平和竖直

方向的小波变换结果将产生一个新的向量<sup>[17]</sup>。其中最长的向量表示了该特征点的方向 $\theta_{ori}$ 。

### 2.3 特征向量表述

首先以特征点为中心,按照特征点方向提

$$m(x, y) = \sqrt{(I(x+1, y) - I(x-1, y))^2 + (I(x, y+1) - I(x, y-1))^2}, \quad (6)$$

$$\theta(x, y) = \tan^{-1}((I(x, y+1) - I(x, y-1))/(I(x+1, y) - I(x-1, y))). \quad (7)$$

为了使特征向量具有旋转不变性,本文使用特征点方向对梯度方向修正,即计算相对梯度方向:

$$\theta_r(\mathbf{X}_R) = \theta(\mathbf{x}_R) - \theta_{ori}. \quad (8)$$

统计出每块子区域的方向灰度梯度直方图,因此可以得到128维的特征向量,low

取边长为20 s的正方形特征区域 $R$ 。将特征区域均分成 $4 \times 4$ 个子块,分别计算这些子区域的图像梯度和方向,灰度梯度和方向计算公式如下:

确定使用128维向量是最优的<sup>[16]</sup>。该特征向量表述方法具有旋转及尺度不变性,且对于照度线性变化时,具有照度不变性。当照度非线性变化时,为了提取稳健的特征向量,本文使用标准灰度梯度代替SIFT中的灰度梯度。

$$m(x, y)_{nor} = \sqrt{\left(\frac{I(x+1, y) - I(x-1, y)}{I(x+1, y) + I(x-1, y)}\right)^2 + \left(\frac{I(x, y+1) - I(x, y-1)}{I(x, y+1) + I(x, y-1)}\right)^2}, \quad (9)$$

最后,将特征向量标准化,即:

$$\mathbf{W}_{nor} = \frac{\mathbf{W}}{|\mathbf{W}|}. \quad (10)$$

该方法能够有效提高照度变化的目标识别率。

### 2.4 主成分分析

为了降低运算时间,本文使用主成分分析<sup>[24]</sup>来降低特征向量的维数。首先计算特性向量集合 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$ 的协方差矩阵 $\mathbf{C}$ :

$$\mathbf{C} = \frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T = \mathbf{A}\mathbf{A}^T. \quad (11)$$

其中, $\boldsymbol{\mu} = E(\mathbf{x})$ ,特征向量集合 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$ 的维数是 $n$ 。因此,协方差矩阵 $\mathbf{C}$ 是 $n \times n$ 的矩阵。计算矩阵 $\mathbf{C}$ 的本征值,选择 $m$ 个( $m < n, m$ 是训练的样本数目)最大的本征值并且计算这些本征值对应的本征向量 $\{\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m\}$ 。这些向量是正交向量,可以构成本征空间。令 $\mathbf{W}_{pca} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]$ ,可得到 $m$ 维向量 $\mathbf{y}$ :

$$\mathbf{y} = \mathbf{W}_{pca}^T (\mathbf{x} - \boldsymbol{\mu}). \quad (12)$$

这样, $n$ 维特征向量转换为 $m$ 维特征向量。

矩阵 $\mathbf{C}$ 是 $n \times n$ ,计算该矩阵的本征值较为困难。可以计算较小的 $m \times m$ 维矩阵 $\hat{\mathbf{C}} = \mathbf{A}^T \mathbf{A}$ 。因此有:

$$\mathbf{A}\mathbf{A}^T \mathbf{w}_k = \lambda_k \mathbf{w}_k. \quad (13)$$

$$\mathbf{A}^T \mathbf{A} (\mathbf{A}^T \mathbf{w}_k) = \lambda_k (\mathbf{A}^T \mathbf{w}_k).$$

也就是:

$$\mathbf{Y}_k = \mathbf{A}^T \mathbf{w}_k, \quad (14)$$

$$\mathbf{A}^T \mathbf{A} \mathbf{Y}_k = \lambda_k \mathbf{Y}_k. \quad (15)$$

设 $\mathbf{X}_k = \alpha_k \mathbf{Y}_k$ 是矩阵 $\mathbf{A}^T \mathbf{A}$ 的本征向量,则

$$\mathbf{X}_k^T \mathbf{X}_n = (\alpha_k \mathbf{A}^T \mathbf{w}_k)^T (\alpha_n \mathbf{A}^T \mathbf{w}_n) = \alpha_k \alpha_n \lambda_n \mathbf{w}_k^T \mathbf{w}_n. \quad (16)$$

因此当 $k=n$ 时, $\lambda_n \alpha_k^2 = 1$ 。即 $\alpha_k = \frac{1}{\sqrt{\lambda_k}}$ ,同时得

到

$$\mathbf{A}\mathbf{Y}_k = \mathbf{A}\mathbf{A}^T \mathbf{w}_k, \quad (17)$$

$$\mathbf{A}\mathbf{Y}_k = \lambda_k \mathbf{w}_k, \quad (18)$$

$$\mathbf{w}_k = \frac{\mathbf{A}\mathbf{Y}_k}{\lambda_k} = \frac{\mathbf{A}\mathbf{X}_k}{\lambda_k \alpha_k} = \frac{\mathbf{A}\mathbf{X}_k}{\sqrt{\lambda_k}}. \quad (19)$$

所以 $\mathbf{C}$ 的 $m$ 个最大本征向量为:

$$\mathbf{w}_k = \frac{\sum_{i=1}^M (\mathbf{x}_i - \boldsymbol{\mu}) \mathbf{X}_{ki}}{\sqrt{\lambda_k M}}. \quad (20)$$

加入主成分分析后,本文的目标识别效率得以提高,图6是训练样本和目标图像的特征提取以及训练的预处理流程图。

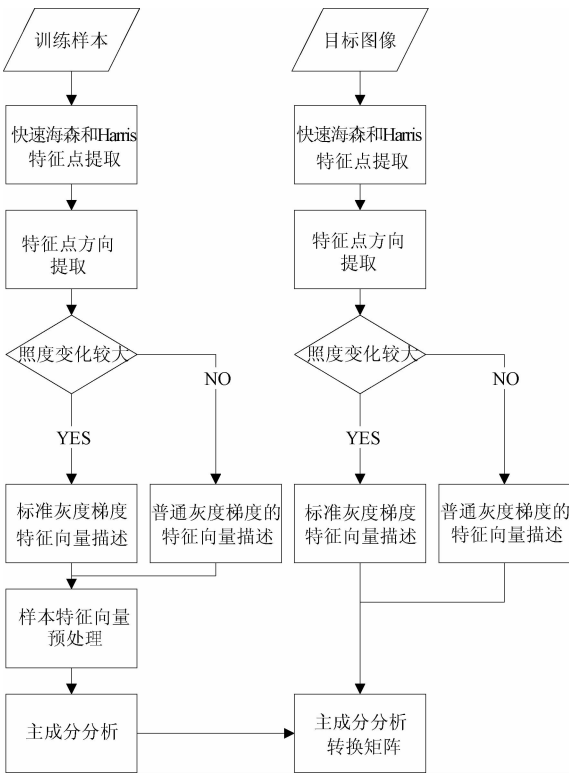


图 6 特征提取和训练预处理流程图

Fig. 6 Flow chart of feature extraction and training preprocessing

### 3 分类器设计

#### 3.1 最佳近邻分类器

近邻决策是一个简单的无参数分类器,如果目标属于某类别  $c$ ,那么在所有类别中,原型  $\{y_d, 1 \leq c \leq N, 1 \leq l \leq M\}$  中与目标向量  $y$  的距离最小。即:

$$d(y, y_{cl}^*) = \min_{1 \leq c \leq N, 1 \leq l \leq M} d(y, y_{cl}) = \min_{1 \leq c \leq N, 1 \leq l \leq M} \|y - y_{cl}\|. \quad (21)$$

其中,  $N$  表示类别的数目,  $M$  是每个类别的特征向量数目。该算法的计算次数是  $N_m = \sum_{c=1}^N n_c = \bar{n}$ 。

#### 3.2 最近特征直线分类器

Li 和 Lu<sup>[25]</sup> 中提出最近特征直线分类器 (Nearest Feature Line, NFL), 该分类器是近邻分类器的拓展。设  $y_d$  和  $y_{ck}$  是类别  $c$  的 2 个原型特征向量, 通过  $y_d$  和  $y_{ck}$  的直线为  $L_{lk}^c$ 。目标向量  $y$  在直线  $L_{lk}^c$  上的投影点  $P_{lk}^c$ :

$$P_{lk}^c = y_d + \frac{(y - y_d)(y - y_{ck})}{\|y_{ck} - y_d\|^2} (y_{ck} - y_d). \quad (22)$$

目标向量与直线的距离为  $d(y, L_{lk}^c) = \|y - P_{lk}^c\|$ , 所以 NFL 的最短距离为:

$$d(y, \hat{L}_{lk}^c) = \min_{1 \leq c \leq N, 1 \leq l, k \leq M, l \neq k} d(y, L_{lk}^c). \quad (23)$$

NFL 的距离计算次数为  $N_{nfl} = \sum_{c=1}^N n_c(n_c - 1)/2$ 。相对于 NN 分类器, NFL 额外计算了投影点  $P_{lk}^c$ , 但减少了目标向量的距离计算次数。

#### 3.3 最近特征空间分类器

本文采用最近特征空间分类器(NFS)<sup>[26]</sup>来减少目标向量与类别原型向量空间来的距离。原型基向量  $\{y_{c1}, y_{c2}, \dots, y_{cm}\}$  构成了特征空间, 令矩阵  $Y_c = [y_{c1} y_{c2} \dots y_{cm}]$ , 则目标向量  $y$  在特征空间的投影点  $P$  为:

$$P_c = Y_c(Y_c^T Y_c)^{-1} Y_c^T y. \quad (24)$$

NFS 的最近距离是找出目标投影点与目标向量的距离, 即:

$$d(y, \hat{S}^c) = \min_{1 \leq c \leq N} d(y, S^c) = \min_{1 \leq c \leq N} \|y - P_c\|. \quad (25)$$

该分类器减少了识别时间, 提高了识别效率。

## 4 实验与结果

为了分析自动识别方法的效果, 使用在不同角度和照度条件下的目标图像(COIL-100 和 ALOI 数据库)进行实验。实验中, 将每种目标图像的前 4 个角度的目标作为训练样本(如图 7 所示), 其他角度和照度条件下的图像作为识别目标(图 8)。本文使用 SIFT 识别算法和 SURF 识别算法作为对比试验, 所有的实验都在 MATLAB 2011b 中实




图 7 汽车, 坦克和船模型的训练样本示例  
Fig. 7 Training samples: car, tank and boat

现。实验机器配置是 Pentium Dual-core 2.60GHz CPU 和 2 GB 内存。表 1 是对比试验的识别率结果,对比使用近邻分类器的 SIFT 和 SURF 算法,本文方法在角度和照度条件变化时具有较高的识别率。表 2 是对比实验中算法所需时间,由表中数据可知,本文算法的运算时间略高于 SURF 算法,低于 SIFT 算法。



图 8 不同角度下的坦克目标

Fig. 8 Tank targets of different view-points



图 9 不同照度环境下的目标

Fig. 9 Targets under different illuminations

表 1 COIL-100 识别率

Tab. 1 Recognition rate of COIL-100 (%)

算法	视角变化	尺度变化	照度变化
SURF	33.8	52.1	58.9
SIFT	43.3	65.2	57.1
本文算法	61.9	80.5	84.4

表 2 算法运算时间

Tab. 2 Computation time of algorithms (ms)

算法	平均计算时间
SURF	90.2
SIFT	169.8
本文算法	130.9

## 5 结 论

针对目标自动识别中的视角,尺度和亮度条件变化问题及局部特征在较大视角和亮度变化时识别率较低的缺点,本文提出了一种基于局部特征提取的目标识别方法。该方法使用快速海森阵和 Harris 算法提取出目标局部特征点和特征点的方向,并使用标准灰度梯度直方图构建 128 维特征向量,该标准灰度梯度在照度变换较大的条件下有很好的稳定性;然后使用主成分分析方法降低特征向量的维数;最后采用近邻特征空间分类器识别目标,进而提高了识别速度。实验结果表明:视角变化下的识别率为 61.9%;尺度变化下的识别率为 80.5%;照度变化下的识别率为 84.4%,平均识别时间为 130.9 ms。与 SIFT 和 SURF 相比,本算法提高了目标在不同视角和光照条件下的识别率,并且具有较快的识别速度。


## 参考文献:

- [1] RATCHES J A. Review of current aided/automatic target acquisition technology for military target acquisition tasks [J]. *Optical Engineering*, 2011, 50 (7): 072001-8.
- [2] RATCHES J A, WALTERS CP, BUSER R C, et

- al.. Aided and automatic target recognition based upon sensory inputs from image forming systems [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(9): 1004-1019.
- [3] SAUL M D, KOBER V. Nonlinear synthetic discriminant function filters for illumination-invariant

- pattern recognition [J]. *Optical Engineering*, 2008, 47(6): 067201-9.
- [4] ZHANG ZH X, HUANG K Q, WANG Y H, *et al.*. Three-dimensional deformable-model-based localization and recognition of road vehicles [J]. *IEEE Transactions on Image Processing*, 2012, 21(1): 1-13.
- [5] DING Y, JIN W Q, WANG H. A target recognition algorithm based on a support vector machine [C]. 2008 *International Conference on Optical Instruments and Technology: Optical Systems and Optoelectronic Instruments*, 2008, 7156.
- [6] OVEISI F. Tree-structured feature extraction using mutual information[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 23(1): 127-137.
- [7] FENG Z Z, XIAN D, YA F H. Gabor filter approach to joint feature extraction and target recognition [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 45(1): 17-30.
- [8] JI Y, GAOYUN W A, QIU Q R. Independent gabor analysis of discriminant features fusion for face recognition[J]. *Signal Processing Letters, IEEE*, 2009, 16(2): 97-100.
- [9] KEMBHAVI A, HARWOOD D, DAVIS L S. Vehicle detection using partial least squares [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(6): 1250-1265.
- [10] SCHEIRER W J. Meta-recognition: the theory and practice of recognition score analysis [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(8): 1689-1695.
- [11] YAN W P. Fast haar transform based feature extraction for face representation and recognition [J]. *IEEE Transactions on Information Forensics and Security*, 2009, 4(3): 441-450.
- [12] CUI CH H, NGAN K N. Scale- and affine-invariant fan feature[J]. *IEEE Transactions on Image Processing*, 2011, 20(6): 1627-1640.
- [13] CHEN W T, LIU W CH, CHEN M S. Adaptive color feature extraction based on image color distributions [J]. *IEEE Transactions on Image Processing*, 2010, 19(8): 2005-2016.
- [14] LEPETIT V, FUA P. Keypoint recognition using randomized trees [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, 28(9): 1465-1479.
- [15] SEDAGHAT A, MOKHTARZADE M, EBADI H. Uniform robust scale-invariant feature matching for optical remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11): 4516-4527.
- [16] LOWE D. Distinctive image feature from scale-invariant keypoints, cascade filtering approach [J]. *IJCV*, 2004, (60): 91-110.
- [17] BAY H. Speeded-up robust feature(SURF) [J]. *Comput. Vis. Image Understand.*, 2008, 110(3): 346-359.
- [18] Qiaoliang, L., *et al.*. Robust scale-invariant feature matching for remote sensing image registration[J]. *Geoscience and Remote Sensing Letters, IEEE*, 2009. 6(2): 287-291.
- [19] SERRE T. Robust object recognition with cortex-like mechanisms [C]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(3): 411-426.
- [20] DHIR C S, YOUNG L S. Discriminant independent component analysis[J]. *IEEE Transactions on Neural Networks*, 2011, 22(6): 845-857.
- [21] CHEN X H, SCHMID N A. Empirical capacity of a recognition channel for single- and multipose object recognition under the constraint of PCA encoding [C]. *IEEE Transactions on Image Processing*, 2009, 18(3): 636-651.
- [22] YOU D, HAMSICI O C, MARTINEZ A M. Kernel optimization in discriminant analysis [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(3): 631-638.
- [23] HARRIS C, STEPHENS M. A combined corner and edge detector [C]. *In Proceedings of The Fourth Alvey Vision Conference*, 1988, 147-151.
- [24] YAN K, SUKTHANKAR R. PCA-SIFT: a more distinctive representation for local image descriptors. in computer vision and pattern recognition [C]. *Proceedings of the 2004 Conference on IEEE Computer Society, CVPR 2004*.
- [25] LI S Z, LU J. Face recognition using the nearest feature line method [J]. *IEEE Transactions on Neural Networks*, 1999.
- [26] CHIEN J T, WU C C. Discriminant waveletfaces and nearest feature classifiers for face recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(12): 1644-1649.

## 作者简介:



徐宁(1988—),男,江苏南京人,硕士,2010年于中国科学技术大学获得学士学位,主要从事图像处理、模式识别等方面的研究,E-mail: xning@mail.ustc.edu.cn



张叶(1981—),女,吉林长春人,博士,副研究员,主要从事计算机视觉与模式识别方面的研究,E-mail: zhangye@ciomp.ac.cn



贾平(1964—),男,吉林延吉人,博士,研究员,博士生导师,主要从事光学动态成像控制和图像处理技术等方面的研究,E-mail:jiap@ciomp.ac.cn

(版权所有 未经许可 不得转载)