

# 复杂场景下结合 SIFT 与核稀疏表示的交通目标分类识别

王 瑞, 杜林峰, 孙 督, 万旺根

(上海大学通信与信息工程学院, 上海 200444)

**摘 要:** 针对复杂场景下的交通目标分类识别难点, 提出一种基于尺度不变特征转换(SIFT)与核稀疏表示的分类识别算法. 该算法首先利用 SIFT 分别提取训练样本和待测目标局部特征信息, 通过核方法将特征样本映射到核空间, 构建完备字典, 最后通过待测目标在字典中的稀疏度与重构误差对交通目标类别进行判定. 同时, 分析了随机投影下的核稀疏表示分类与特征维数之间的关系. 实验结果表明, 与 SVM、稀疏表示分类(SRC)相比, 该方法增强了交通目标特征层的类别判别能力, 具有较好的识别率和鲁棒性.

**关键词:** 核稀疏表示; 尺度不变特征转换; 交通目标识别; 压缩感知; 随机投影

**中图分类号:** TN911.23

**文献标识码:** A

**文章编号:** 0372-2112 (2014)11-2129-06

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

**DOI:** 10.3969/j.issn.0372-2112.2014.11.001

## Traffic Object Recognition in Complex Scenes Based on SIFT and Kernel Sparse Representation

WANG Rui, DU Lin-feng, SUN Du, WAN Wang-gen

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

**Abstract:** A novel approach based on scale-invariant feature transform (SIFT) and kernel sparse representation for traffic object recognition in complex traffic scenes is proposed in this paper. First, SIFT is introduced for feature extraction from samples and test targets, respectively. The features are mapping to the kernel space, then we construct an over-complete dictionary based on kernel sparse representation, traffic objects are recognized by computing sparsity and reconstruction residuals in the dictionary. We also analyze the relationship between recognition rate and dimensionality reduction of the SIFT descriptor using random projection. Experiment results show that the proposed approach enhances the class discriminant ability using traffic features with higher recognition preciseness and robustness in complex traffic scenes compared with SVM, SRC.

**Key words:** kernel sparse representation; scale-invariant feature transform (SIFT); traffic object recognition; compressive sensing; random projection.

## 1 引言

复杂交通场景下交通目标监控与识别是智能交通系统研究的重要课题, 具有广泛应用. 由于车辆所处背景和光照复杂, 车型种类繁多, 如何正确地从图像中特别是复杂交通场景的图像中识别车辆目标一直是尚未完全解决的问题. 主要面临以下挑战: (1) 车辆外观多样性, 如颜色, 形状, 尺寸等. 在不同光照和视觉条件下, 车辆外观区别很大; (2) 易受天气状况影响, 如晴天时, 车辆的金属表面有强烈反光, 雨雪天以及有雾的情况下, 车辆图像不清晰; (3) 交通背景复杂, 如车辆之间互相遮

挡, 道路树木阴影等. 传统的研究工作都是围绕着提高车辆分类识别率而展开, 采用了各种模式识别方法, 如最大似然估计法(ML)、最近邻分类法(Nearest Neighbor, NN)<sup>[1]</sup>、最近子空间分类法(Nearest Subspace, NS)<sup>[2]</sup>、支持向量机(SVM)<sup>[3,4]</sup>、人工神经网络(ANN)<sup>[5]</sup>以及模糊方法<sup>[6]</sup>等.

近年来出现的压缩感知理论(Compressed Sensing)<sup>[7,8]</sup>广泛应用于信号处理领域. 基于信号稀疏性的压缩感知理论成功实现了信号的同时采样与压缩, 通过采集少量的信号投影值就可重建原始信号. 但是有许多信号处理的最终目的并不是重构信号, 而是为了得到有

关目标的信息,比如信号分类、目标检测等,可以直接利用少量的测量值来进行如信号分类等各种信号处理任务.2009年,Wright和Yang等<sup>[9]</sup>首次将稀疏表示分类思想(Sparse Representation Classification, SRC)成功应用到人脸识别,验证了SRC方法在人脸识别方面有很好的鲁棒性,在大量噪声和遮挡的情况下皆可得到很好的识别.此后的相关应用如视觉分类<sup>[10,11]</sup>,SAR目标识别<sup>[12]</sup>,车辆目标识别<sup>[13]</sup>等都是基于该思想提出的.

然而SRC模型存在局限性:(1)模型必须是线性的,即各类样本可以用线性子空间建模,同类的样本属于同一个子空间;(2)SRC是通过选择部分训练本来实现的,需要找到能很好表示各类子空间的字典原子,使得测试样本可用该类的原子有效表示或逼近;(3)模型计算复杂度高.

因此,本文针对复杂交通场景下交通目标识别问题,将目标局部不变特征与核稀疏表示分类相结合,利用核方法将线性稀疏表示扩展到核域空间,把训练特征样本与测试样本映射到核空间,在核空间中构造结构化的字典,在非线性的特征空间中利用核函数推导进行稀疏表示,从而增强字典及重构误差在特征层的类别判别能力,提高基于交通目标图像重构的分类器性能.

## 2 问题描述与稀疏表示

车辆目标识别本质是对通过图像传感器获取车辆目标的图像信号进行预处理、特征提取与选择,最后根据提取的特征对车辆目标进行分类和识别.稀疏表示分类(SRC)需要对从目标中所得到的特征进行稀疏表示,即训练出基于目标特征的过完备字典,然后利用训练得到的字典重构样本,并根据待测目标与重构样本之间的残差最小原则对目标进行分类识别.假设现有  $n$  类目标样本,则对于第  $i$  类样本对应的字典  $D$  来说  $D_i = [d_{i,1}, \dots, d_{i,m}] \in R^m$ . 将  $D = [D_1, D_2, \dots, D_n] \in R^{m \times n}$ , ( $m \ll n$ ) 作为字典,  $y \in R^m$  作为目标信号,  $C$  为稀疏矩阵,则:

$$y = D \cdot C \quad (1)$$

由于  $m$  远小于  $n$ , 式(1)是个欠定方程,所以使稀疏矩阵  $C$  最稀疏的解即为所求解.则稀疏编码  $l^0$  范数最优化问题为:

$$\min_c J(C) = \frac{1}{2} \|y - DC\|_2^2 + \lambda \|C\|_0 \quad (2)$$

其中  $\lambda$  为折衷权值,  $\|\cdot\|_0$  为非零数字的个数.  $l^0$  范数的计算是一种无法在多项式里求解的 NP-hard 问题,而 E. Candes 证明如果式(2)的解足够稀疏,则  $l^0$  范数可以用  $l^1$  范数代替<sup>[14]</sup>. 所以最优化问题转化为:

$$\min_c J(C) = \frac{1}{2} \|y - DC\|_2^2 + \lambda \|C\|_1 \quad (3)$$

## 3 基于核稀疏表示分类的识别框架

针对复杂交通场景下交通目标识别问题,将目标局部不变特征与核稀疏表示分类<sup>[15,16]</sup>相结合,利用SIFT进行局部特征提取,将训练特征样本与测试样本映射到核空间,在核空间中构造结构化的字典,在非线性的特征空间中利用核函数推导进行稀疏表示.具体系统框图如图1所示.




图1 SIFT与核稀疏表示相结合的交通目标分类识别框架

### 3.1 SIFT特征提取

局部特征提取在目标匹配和识别等都具有广泛的应用<sup>[17]</sup>.与方向特征直方图等全局特征相比,局部特征具有独特性,有效的表达目标特征,并能有效降低部分遮挡、背景杂乱等带来的影响.同时,相比于其他局部特征提取方法,SIFT(Scale-Invariant Feature Transform)方法对于图片旋转,尺寸变换,仿射变换和各种光照条件下都具有很好的适应性,非常适合用于复杂场景下的交通目标识别<sup>[18,19]</sup>.本文将采用SIFT方法进行局部特征提取.具体步骤如下:

(1)空间尺度极值检测.首先生成尺度空间来创建原始图像的多层表示以保证尺度不变性,然后建立高斯金字塔并在一系列的高斯差分图像中寻找极值.

(2)特征点定位.选择子像素尺度下的极值点为特征点,去除不稳定的特征点(如具有边缘特征或是低对比度的特征点).

(3)为特征点赋值一个方向.利用每个关键点周围的像素的梯度大小和方向来确定它的方向:

$$m(x, y) = \frac{1}{\sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2}} \quad (4)$$

$$\theta(x, y) = \arctan\left(\frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)}\right) \quad (5)$$

对于每一张图像样本,  $m(x, y)$  为梯度的幅值,  $\theta(x, y)$  为方向.

特征点描述.基于相邻窗口的梯度大小和方向,对所选特征点计算出SIFT描述子,并对其进行归一化处理.图2为采用SIFT方法得到的特征点描述子,其中箭头方向代表主方向,箭头的起点为关键点的位置,箭头的长度代表所检测关键点的尺度.




图2 SIFT特征分析

### 3.2 随机投影

尽管通过 SIFT 算法能够得到具有位置稳定、尺度不变性、旋转不变性和较少亮度依赖的 SIFT 描述子,但是描述子的维数为 128 维,在训练局部特征数据库和特征识别时运算量很大.为了能够快速地进行分类识别,本文采用随机投影(Random Projection, RP)<sup>[20]</sup>对数据进行降维处理,设计满足约束等距性(RIP)条件的投影矩阵,利用一个  $k \times 128$  的随机矩阵  $\mathbf{R}$  将原始的 128 维的 SIFT 描述子投影到一个  $k$  维( $k \ll 128$ )的子空间中:

$$\mathbf{X}_{k \times N} = \mathbf{R}_{k \times 128} \mathbf{X}_{128 \times N} \quad (6)$$

其中  $\mathbf{X}_{k \times N}$  为投影后的数据,  $\mathbf{R}_{k \times 128}$  为投影矩阵.

随机投影的关键是投影矩阵  $\mathbf{R}$  的选择.一般来说,  $\mathbf{R}$  中的元素  $r_{ij}$  是高斯分布的,满足  $r_{ij} \sim N(0, 1/k)$ . 本文利用一种随机投影快速算法<sup>[21]</sup>,使得高斯分布能被另一种更简单的分布所代替:

$$r_{ij} = \sqrt{3} \cdot \begin{cases} +1, & P = \frac{1}{6} \\ 0, & P = \frac{2}{3} \\ -1, & P = \frac{1}{6} \end{cases} \quad (7)$$

此时的  $\mathbf{R}$  投影矩阵为一个只有  $-1, 0, +1$  三种元素的稀疏的随机矩阵,大大降低了计算机运算时间.本文结合分类识别精度要求及数据库大小,调整随机投影矩阵,在达到一定目标识别率的同时满足计算时间的要求.

### 3.3 核稀疏表示分类识别

设第  $i$  个交通目标的 SIFT 特征的向量表示为  $\mathbf{A}_i = [a_1, a_2, \dots, a_n]$ ,并将字典  $\mathbf{A}$  初始化为  $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_n] \in \mathbf{R}^{m \times n}$ .核函数将特征向量从低维空间投影到高维核空间,增加不同类之间集合距离,此时,式(3)变为:

$$\min_c J(\mathbf{C}) = \frac{1}{2} \left\| \boldsymbol{\phi}(\mathbf{y}) - \sum_{i=1}^n \boldsymbol{\phi}(\mathbf{a}_i) \cdot c_i \right\|_2^2 + \lambda \|\mathbf{C}\|_1 \quad (8)$$

其中  $\boldsymbol{\phi}(\cdot)$  是特征向量在核空间的投影.假设  $\boldsymbol{\phi}(\cdot)$  满足当  $\|\mathbf{a}_i\|_2 = 1$  时  $\boldsymbol{\phi}(\mathbf{a}_i)^T \boldsymbol{\phi}(\mathbf{a}_i) = 1$ . 本文采用 KCD<sup>[22]</sup>算法来求解式(7).

KCD 算法首先计算当  $c_i \neq 0$  时  $J(\mathbf{C})$  的偏导:

$$\frac{\partial J(\mathbf{C})}{\partial c_j} = \boldsymbol{\phi}(\mathbf{a}_j)^T \left[ \sum_{i=1}^n c_i \boldsymbol{\phi}(\mathbf{a}_i) - \boldsymbol{\phi}(\mathbf{y}) \right] + \lambda \text{sign}(c_j) \quad (9)$$

令式(9)为 0 得到  $c_j$  的更新:

$$c_j \leftarrow \text{sign}(\alpha) (|\alpha| - \lambda)_+ \quad (10)$$

其中  $\alpha = \boldsymbol{\phi}(\mathbf{a}_j)^T \left[ \boldsymbol{\phi}(\mathbf{y}) - \sum_{i=1, i \neq j}^n c_i \boldsymbol{\phi}(\mathbf{a}_i) \right]$  (11)

且当  $s \geq 0$  时  $(s)_+ = s$ , 式(11)可写为

$$\alpha = K(\mathbf{a}_j, \mathbf{y}) - \sum_{i=1, i \neq j}^n c_i K(\mathbf{a}_j, \mathbf{a}_i) \quad (12)$$

其中核函数为  $K(\mathbf{a}, \mathbf{y}) = \boldsymbol{\phi}(\mathbf{a})^T \boldsymbol{\phi}(\mathbf{y})$ . 因此,给定核函数后, KCD 算法能够反复地更新字典.

最后是 KCD 算法的核稀疏表示分类识别方法,若  $r_s$  为第  $s$  类的残差:

$$\begin{aligned} r_s &= \left\| \sum_{i=1}^n c_i \boldsymbol{\phi}(\mathbf{a}_i) - \boldsymbol{\phi}(\mathbf{y}) \right\|_2^2 \\ &= \mathbf{C}_s^T \mathbf{K}(\mathbf{a}_i, \mathbf{a}_j) \mathbf{C}_s - 2K(\mathbf{a}_i, \mathbf{y})^T \mathbf{C}_s \end{aligned} \quad (13)$$

其中  $\mathbf{C}_s$  为第  $s$  类对应系数.当第  $s$  类的残差  $r_s$  最小时,则该交通目标样本属于第  $s$  类.

## 4 实验分析

为验证本文方法在复杂场景下的交通目标分类识别能力,实验所用素材全部拍摄于上海大学附近街道,包含 490 张 4 类(中小型汽车,大型汽车,摩托车,自行车)交通目标.首先对图像进行灰度化处理,利用 Wiener 滤波算法对图像进行滤波,并分割出图像中的交通目标,尺寸大小为  $240 \times 180$ . 本文实验环境为 CPU: SU3500, 2G 内存,采用 Matlab R2010b 仿真实验.图 3 为在不同干扰条件下(从左至右依次为最佳场景,不同视角,不同噪声、光照强度,以及遮挡)的车辆情况.

本文着重探讨 SIFT 特征提取法与方向梯度直方图特征提取法(Histograms of Oriented Gradient, HOG)对识别的影响,以及 KSRC、SRC 与 SVM 三种识别方法的识别准确率对比.首先分析在最佳场景中的不同分辨率的图像信号情况下,本文所提方法 SIFT-KSRC 与其他方法的比较.如表 1 所示, SIFT-KSRC 具有较好的识别准确率,同时在图像信号分辨率大幅降低的情况下, SIFT-KSRC 的识别率下降幅度远小于相比于其它方法,且仍具有很好的分类识别能力.

由于在实际道路中,车辆会沿各个方向行驶,所以必须考虑到在不同视角条件下对交通目标的分类识别能力.同时在车流量高峰期,交通目标之间不可避免的

存在粘连的情况,所以在遮挡条件下的分类识别鲁棒性极大地影响着分类方法在现实场景中的识别率.图4比较了各个方法在多视角和遮挡条件下的识别率.由

图可见,本文的方法在这两种条件下均具有很好的鲁棒性.



图3 不同干扰条件下的车辆情况

表1 最佳场景下不同图像分辨率下的识别率对比

| 图像信号      |       | 分类识别方法    |          |          |          |         |         |
|-----------|-------|-----------|----------|----------|----------|---------|---------|
|           |       | SIFT-KSRC | SIFT-SRC | SIFT-SVM | HOG-KSRC | HOG-SRC | HOG-SVM |
| 240 × 180 | 中小型汽车 | 98.60%    | 96.74%   | 92.56%   | 91.63%   | 85.58%  | 83.26%  |
|           | 大型汽车  | 97.14%    | 93.33%   | 92.38%   | 90.47%   | 84.76%  | 81.90%  |
|           | 摩托车   | 95.79%    | 91.58%   | 88.42%   | 85.26%   | 82.11%  | 81.05%  |
|           | 自行车   | 93.33%    | 89.33%   | 86.67%   | 82.67%   | 78.67%  | 77.33%  |
|           | 平均    | 96.94%    | 93.87%   | 90.81%   | 88.78%   | 83.67%  | 81.63%  |
| 120 × 90  | 中小型汽车 | 97.21%    | 93.93%   | 90.79%   | 86.51%   | 81.40%  | 78.60%  |
|           | 大型汽车  | 96.19%    | 91.43%   | 87.62%   | 83.91%   | 79.05%  | 75.24%  |
|           | 摩托车   | 94.74%    | 89.47%   | 86.32%   | 82.11%   | 77.89%  | 74.74%  |
|           | 自行车   | 93.33%    | 88.00%   | 85.33%   | 82.67%   | 77.33%  | 74.67%  |
|           | 平均    | 95.92%    | 91.63%   | 88.37%   | 84.69%   | 79.59%  | 76.53%  |
| 60 × 45   | 中小型汽车 | 93.49%    | 89.77%   | 84.65%   | 78.60%   | 72.09%  | 69.30%  |
|           | 大型汽车  | 93.33%    | 87.61%   | 83.81%   | 79.05%   | 70.48%  | 68.57%  |
|           | 摩托车   | 91.58%    | 88.42%   | 83.16%   | 77.89%   | 70.53%  | 67.37%  |
|           | 自行车   | 90.67%    | 85.33%   | 81.33%   | 76.00%   | 70.67%  | 66.67%  |
|           | 平均    | 92.65%    | 88.16%   | 83.67%   | 78.16%   | 71.22%  | 68.37%  |

光照条件也是影响识别率的一个重要因素,有时

同一张图像不同光照条件之间的差别甚至能大于不同

图像<sup>[23]</sup>. 本文以光源与拍摄设备的主光轴间的夹角范围为 $[0^\circ \sim 12^\circ]$ 、 $[12^\circ \sim 25^\circ]$ 、 $[25^\circ \sim 50^\circ]$ 、 $[50^\circ \sim 77^\circ]$ 分别划出四个子集, 每个子集中含有的 15 张图片. 由图 5 可见, 在光照夹角较大的时候, 与 SRC 和 SVM 方法, 本文方法具有明显的优势.




图4 多视角和遮挡条件下的识别率对比

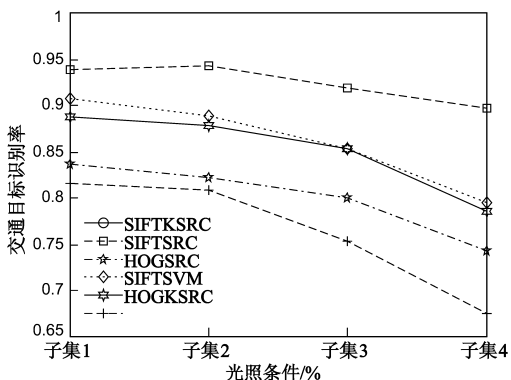


图5 不同光照子集下的识别率对比

在交通目标信息采集的测量过程中, 由于存在各种干扰, 使采集到的图像信号受到噪声污染. 如图 6 所示, 本文在图像上叠加了不同噪声(从左至右依次是高斯噪声、泊松噪声和椒盐噪声)进行测试.



图6 叠加不同噪声的中小型车图像

图 7 为六种方法在不同噪声条件下的识别率. 从中不难发现 SIFT-KSRC 具有较强的抗噪声干扰能力.




图7 不同噪声条件下的识别率对比

复杂场景下交通目标的识别涉及大量的图像数据. 为了使 SIFT-KSRC 方法在实际的智能交通系统中更具有应用性, 实时性与网络能耗也是本文考虑的一个重要因素. 本文将 SIFT 特征提取与随机投影(RP)相结合, 对特征描述子进行降维压缩, 大大减少了需要处理的数据量, 由图 8 可知, 在 SIFT 描述子进行随机投影降维之后仍能保持较高识别率, 从而为探索在达到一定车辆分类识别率的同时降低图像特征维数, 节能通信, 降低数据传输量等方面提供了参考.




图8 不同维度SIFT描述子的识别率

### 5 结论

本文针对复杂交通场景下交通目标识别问题, 将 SIFT 局部特征提取与核稀疏表示分类相结合, 利用核方法把局部特征训练样本与测试样本映射到核空间, 在核空间中构造结构化的字典, 在非线性特征空间中利用核函数推导进行稀疏表示, 从而增强字典及重构误差在特征层的判别能力, 提高基于交通目标图像重构的分类器性能. 同时分析了随机投影下的核稀疏表示分类识别与特征维数之间的关系, 为探索在达到一定车辆分类识别率的同时降低图像特征维数选择与传输等方面提供了参考. 下一步工作将研究核函数及核参数对本文方法的影响.

### 参考文献

[1] 朱明早, 罗大庸, 易励群. 一种序列的加权 k-NN 分类方法 [J]. 电子学报, 2009, 37(11): 2584 - 2588.  
 Zhu Minghan, Luo Dayong, Yi Liqun. A sequential weighted k-nearest neighbor classification method [J]. Acta Electronica Sinica, 2009, 37(11): 2584 - 2588. (in Chinese)

[2] Liu Zhoufeng, Liao Liang, Zhang Yanling. Image classification via nearest subspace and two-dimensional underdetermined random projection [A]. Proceedings of 7th IEEE Conference on Industrial Electronics and Applications (ICIEA) [C]. Singapore: IEEE, 2012. 231 - 236.

[3] Z Chen, N Pears, M Freeman, Austin J. Road vehicle classification using Support Vector Machines [A]. Proceedings of IEEE

- International Conference on Intelligent Computing and Intelligent Systems (ICIS)[C]. Shanghai: IEEE, 2009. 214 – 218.
- [4] M Duarte, Y Hu. Vehicle classification in distributed sensor networks[J]. Journal of Parallel and Distributed Computing, 2004, 64(7): 826 – 838.
- [5] 陈曦, 靳东明, 李志坚. 一种多分辨率组合的模糊神经网络分类器[J]. 电子学报, 2002, 30(6): 928 – 933.  
Chen Xi, Jin Dongming, Li Zhijian. A new kind of fuzzy neural network classifier[J]. Acta Electronica Sinica, 2002, 30(6): 928 – 933. (in Chinese)
- [6] 李曙光, 王海涛, 凌杰. 用模糊方法对车型进行模式识别[J]. 西安公路交通大学学报, 2000, 20(2): 81 – 83.  
Li Shuguang, Wang Haitao, Ling Jie. The pattern recognition of automobile type with fuzzy method[J]. Journal of Xi'an Highway University, 2000, 20(2): 81 – 83. (in Chinese)
- [7] DL Donoho. Compressed sensing[J]. IEEE Transaction on Information Theory, 2006, 52: 1289 – 1306.
- [8] E Candès, M Wakin. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21 – 30.
- [9] J Wright, AY Yang, A Ganesh, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210 – 227.
- [10] X T Yuan, S Yan. Visual classification with multi-task joint sparse representation[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)[C]. San Francisco: IEEE, 2010. 3493 – 3500.
- [11] G Obozinski, B Taskar, MI Jordan. Joint covariate selection and joint subspace selection for multiple classification problems[J]. Journal of Statistics and Computing, 2010, 20(2): 231 – 252.
- [12] H Zhang, NM Nasrabadi, TS Huang, et al. Joint sparse representation based automatic target recognition in SAR images[A]. Proceedings of Algorithms for Synthetic Aperture Radar Imagery XVIII[C]. Orlando: SPIE, 2011. 1 – 12.
- [13] 李修志, 吴健, 崔志明, 陈建明. 复杂交通场景中采用稀疏表示的车辆识别方法[J]. 中国图象图形学报, 2012, 17(3): 387 – 392.  
Li Xiuzhi, Wu Jian, Cui Zhiming, et al. Sparse representation method of vehicle recognition in complex traffic scenes[J]. Journal of Image and Graphics, 2012, 17(3): 387 – 392. (in Chinese)
- [14] E Candès, M Wakin. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, March 2008, 25(2): 21 – 30.
- [15] S Gao, IWH Tsang, LT Chia. Kernel sparse representation for image classification and face recognition[A]. Proceedings of the Eleventh European Conference on Computer Vision (EC-CV)[C]. Heraklion: Springer, 2010. 1 – 14.
- [16] 朱杰, 杨万扣, 唐振民. 基于字典学习的核稀疏表示人脸识别方法[J]. 模式识别与人工智能, 2012, 25(5): 859 – 864.  
Zhu Jie, Yang Wankou, Tang Zhenmin. A dictionary learning based kernel sparse representation method for face recognition[J]. Pattern Recognition And Artificial Intelligence, 2012, 25(5): 859 – 864. (in Chinese)
- [17] E Lobaton, R Vasudevan, R Alterovitz, et al. Robust topological features for deformation invariant image matching[A]. Proceedings of IEEE International Conference on Computer Vision (ICCV)[C]. Barcelona: IEEE, 2011. 2516 – 2523.
- [18] D Lowe. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91 – 110.
- [19] K Mikolajczyk, C Schmid. A performance evaluation of local descriptors[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(10), 1615 – 1630.
- [20] S Vitaladevuni, P Natarajan, R Prasad, et al. Efficient orthogonal matching pursuit using sparse random projections for scene and video classification[A]. Proceedings of IEEE International Conference on Computer Vision (ICCV)[C]. Barcelona: IEEE, 2011. 2312 – 2319.
- [21] D Achlioptas. Database-friendly random projections[J]. Journal of Computer and System Sciences, 2003, 66(4): 671 – 684.
- [22] C Kang, S Liao, S Xiang, C Pan. Kernel sparse representation with local patterns for face recognition[A]. Proceedings of the Eighteenth IEEE International Conference on Image Processing (ICIP)[C]. Brussels: IEEE, 2011. 3009 – 3012.
- [23] Y Adini, Y Moses, S Ullman. Face recognition: The problem of compensating for changes in illumination direction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 721 – 732.

### 作者简介



王 瑞 男, 1982 年生于山西运城, 博士, 副教授, 研究方向为压缩感知、多媒体信号处理。  
E-mail: rwang@shu.edu.cn



杜林峰 男, 1988 年生于四川南充, 硕士研究生, 研究方向为压缩感知、图像融合。