

## 基于稀疏编码和集成学习的多示例多标记图像分类方法

宋相法\* 焦李成

(西安电子科技大学智能感知与图像理解教育部重点实验室 西安 710071)

**摘要:** 该文基于稀疏编码和集成学习提出了一种新的多示例多标记图像分类方法。首先,利用训练包中所有示例学习一个字典,根据该字典计算示例的稀疏编码系数;然后基于每个包中所有示例的稀疏编码系数计算包特征向量,从而将多示例多标记问题转化为多标记问题;最后利用多标记分类算法进行求解。为了提高分类器的泛化能力,对多个分类器进行集成。在多示例多标记图像数据集上的实验结果表明所提方法与其它方法相比有更好的性能。

**关键词:** 图像分类;多示例多标记学习;稀疏编码;集成学习

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2013)03-0622-05

DOI: 10.3724/SP.J.1146.2012.01218

## A Multi-instance Multi-label Image Classification Method Based on Sparse Coding and Ensemble Learning

Song Xiang-fa Jiao Li-cheng

(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education,  
Xidian University, Xi'an 710071, China)

**Abstract:** This paper presents a novel multi-instance multi-label image classification method based on sparse coding and ensemble learning. First, a dictionary is learned based on all the instances in the training bags, and the sparse coding coefficient of each instance is calculated according to the dictionary; Second, a bag feature vector is computed based on all the sparse coding coefficients of the bag. Multi-instance multi-label issue is transformed into multi-label issue that can be solved by the multi-label algorithm. Ensemble learning is involved to enhance further the classifiers' generalization. Experimental results on multi-instance multi-label image data show that the proposed method is superior to the state-of-art methods in terms of metrics.

**Key words:** Image classification; Multi-instance multi-label learning; Sparse coding; Ensemble learning

### 1 引言

随着数字成像设备(例如数码相机和手机)的普及,图像分类成为当前的一个研究热点<sup>[1-3]</sup>。传统的分类方法是将图像划分到预先设定的不同语义概念(标记)中的一类。但是一幅图像中通常包含多个语义概念,例如“天空”、“大象”和“水”,因此研究者提出了基于多标记学习的图像分类方法<sup>[4]</sup>。另一方面,图像的每一个语义概念实际上与图像中的一个局部区域相关,每个局部区域看作示例,图像看作包,则图像的分类问题可转化为多示例学习问题<sup>[5]</sup>。基于上述原因,研究者提出了基于多示例多标记学习框架的图像分类方法<sup>[6,7]</sup>。

在多示例多标记学习框架下,一个样本被表示为由多个示例组成的包,同时该样本属于多个类别

标记,包有标记,示例没有标记。多示例多标记学习是一个有潜力的面向多义性对象的学习框架,引起了研究者的极大重视,提出了一些算法。例如,文献[6]以多示例学习和多标记学习为桥梁,将多示例多标记问题转化为传统监督学习问题进行求解,提出了MIMLBOOST算法和MIMLSVM算法;文献[8]提出了基于神经网络的多示例多标记算法;文献[9]提出了基于k-近邻的MIML-kNN算法;文献[10]将类别不平衡学习策略和MIMLSVM相结合提出了MIMLSVM<sup>+</sup>算法,然后在MIMLSVM<sup>+</sup>算法的基础上,考虑到类别标记之间的相关性,结合多任务学习思想,又提出了E-MIMLSVM<sup>+</sup>算法;另外文献[11]探索了多示例多标记的可学习性。

本文基于稀疏编码<sup>[12]</sup>和集成学习<sup>[13]</sup>,提出了一种新的基于稀疏编码和集成学习的多示例多标记分类方法SCELMIML(Sparse Coding and Ensemble Learning based Multi-Instance Multi-Label classification)并将其用于图像分类。首先,基于稀疏编码计算包特征向量,将多示例多标记问题转化为多标记问题,从而利用多标记分类算法进行求解。

2012-09-19收到,2012-12-11改回

国家自然科学基金(61272282, 61173090, 61072106, 61072108, 60970067, 60971112, 60971128),国家973计划项目(2013CB329402),教育部“长江学者和创新团队发展计划”(IRT1170)和高等学校学科创新引智计划(111计划)(B07048)资助课题

\*通信作者: 宋相法 xiangfason@163.com

另外, 为了提高分类器的泛化能力, 通过改变稀疏编码的字典大小, 得到不同长度的包特征向量, 在该向量上训练得到多个多标记分类器, 并对这些分类器进行集成。实验结果表明, 所提方法 SCELMIML 能够有效地解决多示例多标记图像分类问题, 与现有的方法相比有更好的性能。

## 2 SCELMIML 算法

在多示例多标记学习框架下, 每个样本可表示为由多个示例组成的包, 并且该样本具有多个类别标记。形式化地说, 令  $\chi = \mathbb{R}^d$  表示示例空间,  $\gamma = \{y_1, y_2, \dots, y_C\}$  为  $C$  个类别的标记空间, 则给定一个训练集  $\Omega = \{(B^1, Y^1), (B^2, Y^2), \dots, (B^n, Y^n)\}$ , 其中包  $B^i$  为一组示例  $\{x^{i1}, x^{i2}, \dots, x^{in_i}\}$ ,  $x^{ij} \in \mathbb{R}^d$  ( $j = 1, 2, \dots, n_i$ ),  $Y^i \subseteq \gamma$  为  $B^i$  的一个合适类别标记集  $\{y_{ik} \mid y_{ik} \in \gamma, k = 1, 2, \dots, l_i\}$ , 这里  $n_i$  是包  $B^i$  中的示例个数,  $l_i$  是类别标记集  $Y^i$  中的标记个数。 $Y^i$  通常表示为一个向量  $[y_{i1}, y_{i2}, \dots, y_{il_i}]$ , 其中  $y_{ic} = 1$  表示包  $B^i$  属于标记  $c$ , 否则  $y_{ic} = -1$ 。多示例多标记学习系统的目的是学得多示例多标记分类器  $f: 2^\chi \rightarrow 2^\gamma$ , 该分类器将所有合适的类别标记赋予未知包。为了方便, 对训练集中的所有示例重新排列, 得到一个数据矩阵  $X = [x^1, x^2, \dots, x^m] \in \mathbb{R}^{d \times m}$ , 这里  $m = \sum_{i=1}^n n_i$ 。

### 2.1 基于稀疏编码的多示例多标记问题转化

稀疏编码是一种模拟哺乳动物视觉系统主视皮层 V1 区简单细胞感受野的方法<sup>[12]</sup>, 它已在图像处理和模式识别等领域取得了一些进展<sup>[3,5,14-24]</sup>, 是当前学术界的研究热点。数据经稀疏编码后仅有少数分量同时处于明显激活状态, 该编码能够捕获数据的高层语义特征, 是一种恰当的特征表示方法<sup>[19]</sup>。因此利用稀疏编码方法可以有效地计算包特征向量, 从而把多示例多标记问题转化为多标记问题, 然后利用已有的多标记算法 MLSVM (Multi-Label Support Vector Machine)<sup>[4]</sup>进行求解。

令输入数据矩阵  $X = [x^1, x^2, \dots, x^m]$ , 字典矩阵  $D = [d^1, d^2, \dots, d^s] \in \mathbb{R}^{d \times s}$ , 每一列为一个基原子,  $s$  是字典大小, 系数矩阵  $\alpha = [\alpha^1, \alpha^2, \dots, \alpha^m] \in \mathbb{R}^{s \times m}$ , 每一列为一个数据的稀疏编码系数。稀疏编码的目的就是把数据  $x^e$  表示为  $D$  中基原子的一个稀疏线性组合。根据文献<sup>[24]</sup>, 稀疏编码的数学表达式为

$$\min_{D, \alpha} \left\{ \sum_{e=1}^m (\|x^e - D\alpha^e\|_2^2 + \lambda \|\alpha^e\|_1) \right\} \quad (1)$$

$$\text{s.t. } \|d^g\|_2 \leq 1, \quad g = 1, 2, \dots, s$$

这里  $\lambda > 0$  为正则参数,  $\|\alpha^e\|_1$  表示系数  $\alpha^e$  的  $\ell_1$ -范数。

式(1)中字典  $D$  和系数矩阵  $\alpha$  是被优化的变量。当字典  $D$  或系数矩阵  $\alpha$  固定时, 式(1)是一个凸优化函数, 否则非凸, 通常情况下采用迭代方法求解式(1)。当字典  $D$  不变时, 则系数矩阵  $\alpha$  可以通过式(2)

$$\min_{\alpha^e} \|x^e - D\alpha^e\|_2^2 + \lambda \|\alpha^e\|_1 \quad (2)$$

求解每个稀疏编码系数  $\alpha^e$  得到。式(2)是一个  $\ell_1$ -范数的最小平方问题, 可以利用套索(LASSO)算法<sup>[25]</sup>求解。然后固定系数矩阵  $\alpha$ , 则式(1)转化为一个关于字典  $D$  的带二次约束的最小平方凸优化问题, 如式(3)所示:

$$\min_D \left\{ \|X - D\alpha\|_F^2 \right\} \quad (3)$$

$$\text{s.t. } \|d^g\|_2 \leq 1, \quad g = 1, 2, \dots, s$$

可以利用在线学习算法<sup>[24]</sup>求解式(3)。

得到字典  $D$  后, 对于给定的包  $B = \{x^1, x^2, \dots, x^j\}$ , 根据式(2)可以求得包  $B$  中每一个示例  $x^j$  的稀疏编码系数  $A^j$ , 为了方便, 令  $A = [A^1, A^2, \dots, A^j] \in \mathbb{R}^{s \times j}$ 。根据包  $B$  中所有示例的稀疏编码系数利用式(4)

$$z = \Phi(A) \quad (4)$$

计算包  $B$  的特征向量  $z \in \mathbb{R}^s$ 。 $\Phi(\cdot)$  是合并函数(pooling function), 该函数定义在稀疏系数矩阵  $A$  的每一列上。不同的合并函数可以计算出不同的包特征向量, 本文采用定义在稀疏编码系数绝对值上的最大合并函数<sup>[5,21,26]</sup>来计算包特征向量, 如式(5)所示。

$$z_g = \max \{|A_g^1|, |A_g^2|, \dots, |A_g^j|\} \quad (5)$$

$z_g$  是  $z$  的第  $g$  个元素,  $A_g^j$  是稀疏系数矩阵  $A$  的第  $g$  行第  $j$  列的元素。

利用式(2), 式(4)和式(5)计算出包  $B$  的特征向量  $z$  后, 就可以把多示例多标记问题转化为多标记问题, 然后利用 MLSVM<sup>[4]</sup>算法进行求解。

### 2.2 分类器集成

在 2.1 节中, 字典  $D$  的大小  $s$  不同, 就可以得到不同长度的包特征向量, 而不同长度的包特征向量具有不同的表示能力, 可以训练出不同的分类器。因此, 一个更好的方法是改变字典的大小, 得到不同长度的包特征向量, 在该向量上训练得到多个 MILSVM 分类器, 最后将这些分类器集成对未知样本预测其类别标记集合  $Y$ 。

综上所述, 本文所提 SCELMIML 算法描述如表 1。

## 3 实验结果和分析

为验证本文所提 SCELMIML 算法的性能, 在场景图像数据集<sup>[6]</sup>和 Corel 图像数据集<sup>[27]</sup>上进行了实

表1 SCELMIML 算法

输入:

训练集:  $\Omega = \{(B^1, Y^1), (B^2, Y^2), \dots, (B^n, Y^n)\}$

标记集:  $\gamma = \{y_1, y_2, \dots, y_C\}$

$P$ : 集成系统中分类器的数目

$S = \{s_1, s_2, \dots, s_p\}$ : 集成系统中字典大小的集合

未见包:  $B$

步骤:

(1) 将训练集中包的示例组成示例集合  $X = [x^1, x^2, \dots, x^m]$ ;

(2) For  $S$  中的每个字典大小  $s_p$ ;

(3) 利用 2.1 节所提算法和示例集合  $X$  学的字典  $D^p$ ;

(4) 利用 2.1 节的式(2)、式(4)和式(5)把多示例多标记训练数据

$(B^i, Y^i)$  转换为多标记训练数据  $(z^i, Y^i)$  ( $i = 1, 2, \dots, n$ );

(5) 对于每个类别  $y_c \in \gamma$  ( $1 \leq c \leq C$ ), 利用式(6)

$$\psi(Y^i, y_c) = \begin{cases} +1, & y_c \in Y^i \\ -1, & y_c \notin Y^i \end{cases} \quad (6)$$

得到一个数据集  $\Omega_c = \{(z^i, \psi(Y^i, y_c)) \mid 1 \leq i \leq n\}$ , 然后在  $\Omega_c$

上训练得到一个  $h_{p,c} = \text{SVMTrain}(\Omega_c)$ ;

(6) End For

(7) 对于未见包  $B$ , 首先利用 2.1 节的式(2)、式(4)和式(5)计算

它的包特征向量  $z$ , 然后利用式(7)预测其类别标记集合  $Y$ :

$$Y = \left\{ y_c \mid \frac{1}{P} \sum_{p=1}^P h_{p,c}(z) > 0, 1 \leq c \leq C \right\} \\ \cup \left\{ y_{c^*} = \arg \max_{1 \leq c \leq C} \frac{1}{P} \sum_{p=1}^P h_{p,c}(z) \right\} \quad (7)$$

输出: 未见包  $B$  的类别标记集合  $Y$ .

验。其中场景图像数据集包含 2000 张内容不同的自然图像, 5 个类别标记, 每幅图像利用 SBN(Single Blob with Neighbors)方法被分割为 9 个子区域, 每个区域被表示为一个 15 维的特征向量, 每幅图像所有子区域对应的示例组成该幅图像对应的包。Corel 图像数据集包含 5000 张图像, 采用聚类算法把每幅图像分割为若干区域, 每个区域被表示为一个 36 维的特征向量, 每幅图像所有子区域对应的示例组成该幅图像对应的包。过滤掉出现次数少于 100 次的标记后, 得到 4800 幅图像, 43 个类别标记。

因为多示例多标记算法的任务是为未知包预测一个类别标记集, 因此用 5 个流行的多标记评价指标<sup>[5]</sup>: 汉明损失(hamming loss)、1-错误率(one-error)、覆盖率(coverage)、排序损失(ranking loss)和平均精度(average precision)来评价所提算法 SCELMIML 的性能。其中前 4 个指标的值越小, 则算法的性能越好; 平均精度的值越大, 则算法的性能越好。实验采用 10 倍交叉验证的方法对算法的性能进行估计。在场景图像数据集上的集成系统中分

类器的数目  $P = 20$ , 集成系统中字典大小的集合  $S = \{15, 30, \dots, 300\}$ 。在 Corel 图像数据集上的集成系统中分类器的数目  $P = 25$ , 集成系统中字典大小的集合  $S = \{36, 18, \dots, 468\}$ 。

实验中将所提算法 SCELMIML 和另外其它几种多示例多标记算法的分类结果性能指标进行比较, 包括 MIMLBOOST<sup>[6]</sup>, MIMLSVM<sup>[6]</sup>, MIMLRBF<sup>[8]</sup>, MIML-kNN<sup>[9]</sup>, MIMLSVM<sup>+[10]</sup> 和 E-MIMLSVM<sup>+[10]</sup>; 同时也给出了 SCELMIML 算法中单个分类器的最好结果, 用最好单个分类器表示。表 2 给出了采用 10 倍交叉验证方法在场景图像数据集上的平均实验结果。因为 MIMLBOOST 在合理的时间内没有给出结果, 因此表 3 给出了其它 7 种算法采用 10 倍交叉验证方法在 Corel 图像数据集上的平均实验结果。对于每个评价指标, “↓”表示该性能指标越小越好, “↑”表示该性能指标越大越好, 最优结果用粗体表示。

从表 2 中可以看出, 所提算法 SCELMIML 在汉明损失、1-错误率、覆盖率和排序损失上远低于其它 7 种算法, 在平均精度上远高于其它 7 种算法。同时最好单个分类器的结果也好于其它 6 种算法。从表 3 中可以看出, 所提算法 SCELMIML 在汉明损失、1-错误率、覆盖率和排序损失上远低于其它 6

表2 各种多示例多标记算法在场景图像上的实验结果(均值)

	汉明 损失 ↓	1-错 误率 ↓	覆盖 率 ↓	排序 损失 ↓	平均 精度 ↑
SCELMIML	<b>0.144</b>	<b>0.239</b>	<b>0.794</b>	<b>0.129</b>	<b>0.843</b>
最好单个分类器	0.153	0.260	0.857	0.133	0.826
MIMLSVM <sup>[10]</sup>	0.185	0.347	1.031	0.191	0.774
MIMLBOOST <sup>[10]</sup>	0.189	0.335	0.947	0.172	0.785
MIMLRBF <sup>[13]</sup>	0.165	0.302	0.894	0.158	0.806
MIML-kNN <sup>[15]</sup>	0.165	0.310	0.896	0.159	0.801
MIMLSVM <sup>+[19]</sup>	0.197	0.276	0.863	0.148	0.821
E-MIMLSVM <sup>+[19]</sup>	0.199	0.278	0.855	0.146	0.821

表3 各种多示例多标记算法在 Corel 图像上的实验结果(均值)

	汉明 损失 ↓	1-错 误率 ↓	覆盖 率 ↓	排序 损失 ↓	平均 精度 ↑
SCELMIML	<b>0.046</b>	<b>0.409</b>	<b>8.068</b>	<b>0.099</b>	<b>0.608</b>
最好单个分类器	0.048	0.453	9.768	0.125	0.566
MIMLSVM <sup>[10]</sup>	0.059	0.624	14.747	0.217	0.405
MIMLRBF <sup>[13]</sup>	0.051	0.555	12.466	0.165	0.490
MIML-kNN <sup>[15]</sup>	0.053	0.617	13.606	0.190	0.438
MIMLSVM <sup>+[19]</sup>	0.198	0.626	10.767	0.152	0.445
E-MIMLSVM <sup>+[19]</sup>	0.195	0.616	10.723	0.151	0.454

种算法, 在平均精度上远高于其它 6 种算法。同时最好单个分类器的结果也好于其它 5 种算法。

根据本文算法在场景图像数据集和 Corel 图像数据集上的实验结果可得如下结论, 与经典的 MIMLSVM 算法, MIMLBOOST 算法, MIMLRBF 算法, MIML-kNN 算法, 及最新的 MIMLSVM<sup>+</sup>算法和 E-MIMLSVM<sup>+</sup>算法相比, 本文算法提高分类精度, 且其它各项性能指标也都达到较高水平, 能够有效解决多示例多标记图像分类问题。这些实验结果表明利用稀疏编码方法可以很好地把多示例多标记问题转换为多标记问题, 结合集成学习可以进一步提高算法的性能。

另外, 为了考察字典大小和集成系统中分类器的数目对单个分类器和所提算法 SCELMMIL 性能的影响, 以场景图像分类和性能评价指标汉明损失为例, 图 1 给出了单个分类器在场景图像上的结果, 其中  $x$  轴为字典大小, 其范围为 15~600, 步长为 15,  $y$  轴为评价指标; 图 2 给出了所提算法 SCELMMIL 在场景图像上的结果, 其中  $x$  轴为集成系统中分类器的数目, 其范围为 5~40, 步长为 5,  $y$  轴为评价指标。




图 1 单个分类器在场景图像数据集上的实验结果

从图 1 可以看出, 单个分类器的汉明损失对字典大小比较敏感, 变化区间大, 其变化区间为 0.152~0.195。从图 2 可以看出, 本文所提算法 SCELMMIL 由于采用了集成策略, 性能稳定, 汉明损失的变化区间小, 并且有了很大的改善, 其变化区间为 0.144~0.157。

## 4 结束语

本文以稀疏编码和集成学习为基础, 提出了一种新的对多示例多标记图像分类的方法 SCELMMIL。该方法基于稀疏编码有效地把多示例多标记问题转化为多标记问题, 从而利用多标记算法 MLSVM 进行求解; 同时基于集成策略进一步提高了算法的泛化能力, 可以获得较好的分类性能。在多示例多标记场景图像数据集和 Corel 图像数据集上的实验结果表明, SCELMMIL 算法的性能优于其它多示例多标记算法。本文的研究工作仍有很大的改进空间, 例如采用选择性集成策略<sup>[28]</sup>降低时间复杂度、以及采用其它的多标记算法进一步提高分类效果。




图 2 SCELMMIL 在场景图像数据集上的实验结果

## 参考文献

- [1] Yu Jun, Tao Da-cheng, and Wang Meng. Adaptive hypergraph learning and its application in image classification[J]. *IEEE Transactions on Image Processing*, 2012, 21(7): 3262-3272.
- [2] 贾世杰, 孔祥维. 一种新的直方图核函数及在图像分类中的应用[J]. *电子与信息学报*, 2011, 33(7): 1738-1742.  
Jia Shi-jie and Kong Xiang-wei. A new histogram-based kernel function designed for image classification[J]. *Journal of Electronics & Information Technology*, 2011, 33(7): 1738-1742.
- [3] 亓晓振, 王庆. 一种基于稀疏编码的多核学习图像分类方法[J]. *电子学报*, 2012, 40(4): 773-779.  
Qi Xiao-zhen and Wang Qing. An image classification approach based on sparse coding and multiple kernel learning[J]. *Acta Electronic Sinica*, 2012, 40(4): 773-779.
- [4] Boutell M R, Luo Jie-bo, Shen Xi-peng, et al. Learning multi-label scene classification[J]. *Pattern Recognition*, 2004, 37(9): 1757-1771.
- [5] Song Xiang-fa, Jiao Li-cheng, Yang Shu-yuan, et al. Sparse coding and classifier ensemble based multi-instance learning for image categorization[J]. *Signal Processing*, 2013, 93(1): 1-11.
- [6] Zhou Zhi-hua and Zhang Min-ling. Multi-instance multi-label learning with application to scene classification[C]. *Proceedings of Neural Information Processing Systems*, Vancouver, 2006: 1609-1616.
- [7] Zhou Zhi-hua, Zhang Min-ling, Huang Sheng-jun, et al. Multi-instance multi-label learning[J]. *Artificial Intelligence*, 2011, 176(1): 2291-2320.

- [8] Zhang Min-ling and Wang Zhi-jian. MIMLRBF: RBF neural networks for multi-instance multi-label learning[J]. *Neurocomputing*, 2009, 72(16-18): 3951-3956.
  - [9] Zhang Min-ling. A k-nearest neighbor based multi-instance multi-label learning algorithm[C]. Proceedings of International Conference on Tools with Artificial Intelligence, Arras, 2010: 207-212.
  - [10] Li Ying-Xin, Ji Shui-wang, Kumar S, *et al.* Drosophila gene expression pattern annotation through multi-instance multi-label learning[J]. *ACM/IEEE Transactions on Computational Biology and Bioinformatics*, 2012, 9(1): 98-112.
  - [11] Wang Wei and Zhou Zhi-hua. Learnability of multi-instance multi-label learning[J]. *Chinese Science Bulletin*, 2012, 57(19): 2488-2491.
  - [12] Olshausen B A and Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. *Nature*, 1996, 381(6583): 607-609.
  - [13] Zhou Zhi-hua. Ensemble Methods: Foundations and Algorithms[M]. Boca Raton: CRC Press, 2012: 15-16.
  - [14] Wu Jiao, Liu Fang, Jiao Li-cheng, *et al.* Compressive sensing SAR image reconstruction based on bayesian framework and evolutionary computation[J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 1904-1911.
  - [15] Wu Jiao, Liu Fang, Jiao Li-cheng, *et al.* Multivariate compressive sensing for image reconstruction in the wavelet domain: using scale mixture models[J]. *IEEE Transactions on Image Processing*, 2011, 20(12): 3483-3494.
  - [16] 武昕, 王岩飞, 刘畅. 基于压缩感知理论的随机噪声雷达目标检测算法研究[J]. 电子与信息学报, 2012, 34(7): 1609-1615.  
Wu Xin, Wang Yan-fei, and Liu Chang. A target detection algorithm based on compressive sensing for random noise radar[J]. *Journal of Electronics & Information Technology*, 2012, 34(7): 1609-1615.
  - [17] 焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望[J]. 电子学报, 2011, 39(7): 1651-1662.  
Jiao Li-cheng, Yang Shu-yuan, Liu Fang, *et al.* Development and prospect of compressive sensing[J]. *Acta Elctronica Sinica*, 2011, 39(7): 1651-1662.
  - [18] 江海, 林月冠, 张冰尘, 等. 基于压缩感知的随机噪声成像雷达[J]. 电子与信息学报, 2011, 33(3): 672-676.  
Jiang Hai, Lin Yue-guan, Zhang Bing-chen, *et al.* Random noise imaging radar based on compressed sensing[J]. *Journal of Electronics & Information Technology*, 2011, 33(3): 672-676.
  - [19] Lee H, Battle A, Raina R, *et al.* Efficient sparse coding algorithms[C]. Proceedings of Neural Information Processing Systems, Vancouver, 2006: 801-808.
  - [20] Aharon M, Elad M, and Bruckstein A. K-SVD: an algorithm for designing over-complete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
  - [21] Yang Jian-chao, Yu Kai, and Gong Yi-hong, *et al.* Linear spatial pyramid matching using sparse coding for image classification[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Miami, 2009: 1794-1801.
  - [22] Zhang Hai-chao, Nasrabadi N M, Zhang Yan-ning, *et al.* Joint dynamic sparse representation for multi-view face recognition[J]. *Pattern Recognition*, 2012, 45(4): 1290-1298.
  - [23] 宋相法, 焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. 电子与信息学报, 2012, 34(2): 268-272.  
Song Xiang-fa and Jiao Li-cheng. Classification of hyperspectral remote sensing image based on sparse representation and spectral information[J]. *Journal of Electronics & Information Technology*, 2012, 34(2): 268-272.
  - [24] Mairal J, Bach F, Ponce J, *et al.* Online learning for matrix factorization and sparse coding[J]. *Journal of Machine Learning Research*, 2010, 11(1): 19-60.
  - [25] Tibshirani R. Regression shrinkage and selection via the LASSO[J]. *Journal of the Royal Statistical Society B*, 1996, 58(1): 267-288.
  - [26] Serre T, Wolf L, Bileschi S, *et al.* Robust object recognition with cortex-like mechanisms[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(3): 411-426.
  - [27] Duygulu P, Barnard K, Freitas N, *et al.* Object recognition as machine translation: learning a lexicon for a fixed image vocabulary[C]. Proceedings of European Conference on Computer Vision, Copenhagen, 2002: 97-112.
  - [28] Zhou Zhi-hua, Wu Jian-xin, and Tang Wei. Ensemble neural networks: many could be better than all[J]. *Artificial Intelligence*, 2002, 137(1, 2): 239-263.
- 宋相法: 男, 1975年生, 博士生, 讲师, 从事图像处理、模式识别、机器学习方面的研究。
- 焦李成: 男, 1959年生, 博士生导师, 教授, 从事自然计算、信号和图像处理、智能信息处理方面的研究。