

基于稀疏表示的多示例图像分类

宋相法^{1,2} 焦李成²

(河南大学计算机与信息工程学院 开封 475004)¹

(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)²

摘要 为了有效地解决多示例图像分类问题,基于稀疏表示提出了一种新的多示例图像分类方法。该方法将图像看作多示例包,图像中的区域作为包中示例,利用示例嵌入策略计算包特征;然后将待分类图像包特征表示为训练图像包特征集上的稀疏线性组合,利用 ℓ_1 优化方法求得稀疏解;最后根据稀疏系数提出一个为待分类图像预测标记的方法。在 Corel 数据集上的实验结果表明,与其他方法相比,所提方法具有更高的分类精度。

关键词 图像分类,多示例学习,稀疏表示

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.1.065

Classification of Multi-instance Image Based on Sparse Representation

SONG Xiang-fa^{1,2} JIAO Li-cheng²

(School of Computer and Information Engineering, Henan University, Kaifeng 475004, China)¹

(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education, Xidian University, Xi'an 710071, China)²

Abstract In order to effectively solve the problem of multi-instance image classification, a novel classification method of multi-instance image was proposed which is based on sparse representation. The whole image is regarded as a bag and each region as an instance of that bag. The image bag feature is computed based on instance embedded strategy. Next, the test image bag feature is regarded as sparse linear combination of training image bag feature set and the sparse solution can be obtained by ℓ_1 optimization method. Finally, sparse coefficients are utilized to predict the label of the test image. Experimental results on the Corel image data show that the proposed method is superior to the state-of-art methods in terms of classification accuracy.

Keywords Image classification, Multi-instance learning, Sparse representation

1 引言

随着成像技术及互联网技术的快速发展,图像分类引起了研究人员的极大重视并在许多领域得到了广泛应用^[1-6]。为了构建一个图像分类系统,首先需要一定数量的有标记的训练样本集,然后利用机器学习算法基于训练样本集进行训练得到一个分类器,最后图像分类系统利用该分类器对未知图像进行分类。通常情况下,人们是对整幅图像进行标注,而不是对图像中的每个区域进行标注。另外,在一幅图像中,除了包含与标记对应的区域外,还包含其他与标记无关的区域,这些无关的区域往往会成为“噪声”,对训练高性能的分类器不利。为了去除这些噪声区域的影响,一种方法是对图像进行精确标注,即对图像中的区域进行标注。但是这种方法所需人力花费大,耗时长,人们难以接受。如果把图像中的每个区域看作是一个示例(instance),把图像看作包(bag),则图像分类问题可以在多示例学习(Multi-instance Learning, MIL)框架下解决^[7]。

1997年 Dietterich 等人^[7]在对麝香分子活性的研究中提出了多示例学习框架,在该框架下,一个样本被表示为由多个示例组成的包,一个包被标记为正包当且仅当其中至少有一个样例为正例;一个包被标记为反包当且仅当其中所有的样例均为反例。数据集中包有标记,包中的示例没有标记。这一特性使多示例学习比传统监督学习具有更大的歧义性。多示例学习作为一种新的学习框架,引起了研究者的极大重视^[7-18]。例如, Dietterich 等人^[7]提出了 IAPR(interactive axis parallel hyper-rectangle)算法; Maron 等人^[8]提出了多样性密度(Diverse Density, DD)算法并将其用于自然场景分类; Zhang 等人^[9]把 EM 算法(expectation-maximization, EM)和 DD 方法相结合,提出了 EM-DD 算法; Chen 等人^[10]提出了 DD-SVM 算法,该算法利用 DD 方法搜索到示例原型,然后在这些示例原型所构成的特征空间中计算包特征,从而把多示例问题转化为单示例问题,最后利用 SVM 进行求解; Chen 等人^[11]在文献^[10]的基础上提出了 MILES 算法,该算法直接利用训练包中的示例构成特征空间,然后在该空间中计算包

到稿日期:2014-03-16 返修日期:2014-06-22 本文受国家重点基础研究发展计划(973计划)(2013CB329402),国家自然科学基金(61305042,61272282,61173090,61072106,61072108),教育部“长江学者和创新团队发展计划”(IRT1170)资助。

宋相法(1975-),男,博士,副教授,CCF 会员,主要研究方向为计算机视觉与机器学习, E-mail: xiangfasong@163.com; 焦李成(1959-),男,博士,教授,博士生导师,主要研究方向为自然计算、信号和图像处理、智能信息处理。

特征,最后利用 ℓ_1 范数 SVM 进行求解;Zhou 等人^[12]提出了半监督 SVM 的多示例学习分类方法;Zhou 等人^[13]考虑到了包中示例之间的非独立性,设计了两种计算包之间相似度的图核;Fu 等人^[14]提出了基于示例选择策略的多示例学习算法;Li 等人^[15]利用稀疏 ϵ -图来表示每个包中示例之间的上下文结构,然后提出了一个基于图核的稀疏分类器;Feng 等人^[16]提出了一个基于分层稀疏表示的半监督多示例学习分类方法;张等人^[17]提出了半监督多示例核;李等人^[18]提出了基于 EMD 距离的多示例聚类。迄今为止,多示例学习已经被成功用于药物活性预测^[7]、图像分类^[8,10,16]和文本分类^[13]等领域。

近年来,稀疏表示因为能够有效模拟生物视觉感知特性^[19],受到了研究人员的广泛关注,并在压缩感知、图像处理和模式识别等领域得到了成功的应用^[3,20-24]。本文基于稀疏表示提出了一种新的多示例图像分类方法。首先,利用训练包中的示例构成特征空间,在该空间中基于示例嵌入策略^[11]计算包特征;然后将待分类包特征表示为训练包特征集上的稀疏线性组合,利用 ℓ_1 优化方法求得稀疏解;最后根据稀疏系数所包含的判别信息提出了一个为待分类包预测标记的方法。在 Corel 图像数据集上的实验结果表明,所提方法能够有效地解决多示例图像分类问题,与其他方法相比有更高的分类精度。

2 所提方法

令 $X = \mathcal{R}^k$ 代表 k 维的示例空间, $Y = \{1, 2, \dots, c\}$ 代表 c 个类别的标记空间,训练集 $\Omega = \{(\mathbf{B}^1, y_1), (\mathbf{B}^2, y_2), \dots, (\mathbf{B}^n, y_n)\}$, 其中 $y_i \in Y$ 是包 \mathbf{B}^i 的类别标记。每个包 $\mathbf{B}^i = \{x^{i1}, x^{i2}, \dots, x^{in_i}\}$ 包含 n_i 个示例,每个示例 $x^{ij} \in \mathcal{R}^k$ 是一个 k -维特征向量,不同的包由不同个数的示例组成。为了方便,我们把包中所有示例排列在一起,得到一个数据矩阵 $\mathbf{X} = [x^1, x^2, \dots, x^m] \in \mathcal{R}^{k \times m}$, 其中, $m = \sum_{i=1}^n n_i$ 。

2.1 计算包特征

在多示例学习框架下,每个样本可表示为由多个示例组成的包,包有类别标记,而示例没有标记。本文利用训练包中的示例构成特征空间,在该空间基于示例嵌入策略^[11]计算包特征,把多示例学习问题转化为单示例学习问题,然后利用稀疏表示方法进行分类。

具体地讲,把每个包 \mathbf{B}^i 嵌入到由训练集合中 m 个示例集 $\{x^1, x^2, \dots, x^m\}$ 所构成的空间,其中包 \mathbf{B}^i 的包特征 $s(\mathbf{B}^i)$ 的第 l 维特征可以通过式(1)求解。

$$d_l(\mathbf{B}^i, x^l) = \max_j \exp\left(-\frac{\|x^{ij} - x^l\|^2}{\sigma^2}\right) \quad (1)$$

这里 $x^l \in \{x^1, x^2, \dots, x^m\}$, x^{ij} 是包 $\mathbf{B}^i = \{x^{i1}, x^{i2}, \dots, x^{in_i}\}$ 中的示例, σ 是尺度因子。根据式(1)可得包 \mathbf{B}^i 的包特征向量:

$$s(\mathbf{B}^i) = [d_1(\mathbf{B}^i, x^1), \dots, d_m(\mathbf{B}^i, x^m)]^T \quad (2)$$

由于 $s(\mathbf{B}^i) \in \mathcal{R}^m$ 是一个高维向量,包含大量的冗余信息^[14],因此利用主成分分析方法进行降维消去冗余信息,得到最终的包特征向量 $s'(\mathbf{B}^i) \in \mathcal{R}^q$ 。

2.2 基于稀疏表示的标记预测

根据 2.1 节提出的包特征计算方法,训练集合 Ω 中的每个包被映射到一个 q -维特征空间中,表示为 $\mathbf{A} = [s'(\mathbf{B}^1), s'(\mathbf{B}^2), \dots, s'(\mathbf{B}^n)] \in \mathcal{R}^{q \times n}$ 。同理,对于测试包 \mathbf{B} 也可以计算

出其包特征向量 $s'(\mathbf{B})$ 。把属于第 r 类所有的包特征向量表示为矩阵 $\mathbf{A}^r = [s'(\mathbf{B}^{r1}), s'(\mathbf{B}^{r2}), \dots, s'(\mathbf{B}^{rn_r})] \in \mathcal{R}^{q \times n_r}$, 则给定第 r 类的测试包 $s'(\mathbf{B}) \in \mathcal{R}^q$, 它可近似表示为该训练包特征向量上的线性组合,即:

$$s'(\mathbf{B}) = \alpha_{r1} s'(\mathbf{B}^{r1}) + \alpha_{r2} s'(\mathbf{B}^{r2}) + \dots + \alpha_{rn_r} s'(\mathbf{B}^{rn_r}) \quad (3)$$

其中, $\alpha_{rl} \in \mathcal{R}$, $l = 1, 2, \dots, n_r$ 。

对于多示例图像分类问题,由于不知道测试包 \mathbf{B} 的类别标记,因此可将包 \mathbf{B} 的包特征向量 $s'(\mathbf{B})$ 表示为所有训练包特征向量上的线性组合:

$$s'(\mathbf{B}) = \mathbf{A}\alpha \quad (4)$$

其中,系数 $\alpha = [0, \dots, 0, \alpha_1, \dots, \alpha_{n_r}, 0, \dots, 0]^T \in \mathcal{R}^n$ 是一个稀疏系数向量,除了与第 r 类有关的系数,其他的系数都为零。因此,测试包 \mathbf{B} 的包特征 $s'(\mathbf{B})$ 可以表示为训练包特征集上的稀疏线性组合。通常情况下 $q < n$, 式(4)是一个线性的欠定系统,在该系统中求稀疏解是 NP 难问题。压缩感知理论^[20]表明,当解 α 充分稀疏时,可用下面的 ℓ_1 -最小化方法求解:

$$\alpha = \min_{\alpha \in \mathcal{R}^n} \|\alpha\|_1, \text{ subject to } s'(\mathbf{B}) = \mathbf{A}\alpha \quad (5)$$

其中, $\|\alpha\|_1$ 是 ℓ_1 范数。

由于真实的数据含有噪声,即

$$s'(\mathbf{B}) = \mathbf{A}\alpha + e \quad (6)$$

其中, e 是一个噪声项且 $\|e\|_2 < \epsilon$, 因此测试包 \mathbf{B} 的包特征 $s'(\mathbf{B})$ 在 \mathbf{A} 上的稀疏线性表示可以通过求解下面的 ℓ_1 -最小化问题来求得,即

$$\alpha = \min_{\alpha \in \mathcal{R}^n} \|\alpha\|_1, \text{ subject to } \|s'(\mathbf{B}) - \mathbf{A}\alpha\|_2 \leq \epsilon \quad (7)$$

式(7)可以转化为一个附加正则项系数的无约束问题:

$$\min_{\alpha} \frac{1}{2} \|s'(\mathbf{B}) - \mathbf{A}\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (8)$$

进行求解。其中, $\lambda > 0$ 是一个正则化参数。式(8)是一个 ℓ_1 范数的最小平方问题,可以利用套索(LASSO)算法^[25]求解 α 。

一旦稀疏解 α 求出,就可以为测试包 \mathbf{B} 预测类别标记。因为每个稀疏系数表示每个训练样本重构测试样本时所做的贡献^[24],所以可以根据每类训练样本对测试包 \mathbf{B} 所作贡献的总和来为测试包 \mathbf{B} 预测正确的类别标记。该方法可以被看作投票决定规则,已被广泛应用于集成学习中,例如 Boosting 和 Bagging。

根据上述分析,如果训练包属于 c 类,则可以定义 c 个判别函数,如下式所示:

$$f_r(\mathbf{B}) = 1^T \phi_r(\alpha), r = 1, \dots, c \quad (9)$$

其中, 1^T 是一个元素全为 1 的 n -维向量, $\phi_r(\alpha)$ 在系数 α 中选取与第 r 类有关的元素项,其中除了与第 r 类有关的元素为非零外,其余元素为零。因此, $f_r(\mathbf{B})$ 表示与第 r 类有关的系数对包 \mathbf{B} 所做的贡献总和,可以根据贡献总和最大为测试包 \mathbf{B} 预测标记,如下式所示:

$$\text{label}(\mathbf{B}) = \arg \max_r f_r(\mathbf{B}), r = 1, 2, \dots, c \quad (10)$$

2.3 算法步骤

综上所述,本文算法步骤描述如下:

Step 1 根据式(1)计算训练包 \mathbf{B}^i 的包特征向量 $s(\mathbf{B}^i)$, $i = 1, 2, \dots, n$;

Step 2 利用主成分分析方法对训练包 \mathbf{B}^i 的包特征向量 $s(\mathbf{B}^i)$ 进行降维,得到最终的包特征向量 $s'(\mathbf{B}^i)$, $i = 1, 2, \dots, n$;

Step 3 利用所有训练包的包特征向量得到 $\mathbf{A} =$

$[s'(B^1), s'(B^2), \dots, s'(B^m)]$;

Step 4 对测试包 B 计算其包特征向量 $s'(B)$;

Step 5 利用式(8)求解 $s'(B)$ 在 A 上的稀疏系数向量 α ;

Step 6 利用式(10)为测试包 B 预测所属类别标记。

3 实验结果和分析

为了对本文算法的分类效果进行评估,使用了多示例学习算法常用的 Corel 图像数据集。该数据集由 2000 幅图像组成,来自于 20 个 CD-ROM,内容包括 African, beach, building, bus, dinosaur, elephant, flower, horse, mountain, food, dog, lizard, model, sunset, car, waterfall, antique, ship, skiing and dessert 等,共包含 20 类,每类有 100 幅图像,图 1 给出了这 20 类图像的一些样例。本文采用文献[10]提出的图像自动分割算法和底层特征抽取方法把每幅图像分割为若干个区域,每个区域被表示为一个 9 维的特征向量,由 3 维 LUV 颜色特征、3 维小波纹理特征和 3 维形状特征组成。



图 1 Corel 图像集中的一些例子

在实验中,按照文献[10-14]所提供的方法,从实验数据集中随机选取每类图像的 50% 组成训练数据,余下的 50% 作为测试数据,取 5 次随机实验的平均值作为最终结果。对于 1000 幅图像数据集,式(1)中的尺度因子 $\sigma^2=9$,字典 A 的维数 $q=300$,式(8)中的正则化参数 $\lambda=2^{-6.5}$;对于 2000 幅图像数据集,式(1)中的尺度因子 $\sigma^2=10$,字典 A 的维数 $q=300$,式(8)中的正则化参数 $\lambda=2^{-8.5}$ 。表 1 给出了本文算法在 1000 幅图像数据集和 2000 幅图像数据集上的平均分类精度

和 95% 的置信区间,同时也给出了其它算法的分类结果,这些算法包括 DD-SVM^[10]、MILES^[11]、MissSVM^[12]、MiGraph^[13]、miGraph^[13]、MILIS^[14]、HSR-MIL^[15] 和 SG-SVM^[15],最优结果用粗体表示。

表 1 各种多示例算法在 Corel 图像数据集上的实验结果

Algorithms	1000-Image data set	2000-Image data set
本文方法	84.4 : [83.7, 85.1]	72.6 : [72.1, 73.0]
DD-SVM ^[10]	81.5: [78.5, 84.5]	67.5: [66.1, 68.9]
MILES ^[11]	82.6: [81.4, 83.7]	68.7: [67.3, 70.1]
MissSVM ^[12]	78.0: [75.8, 80.2]	65.2: [62.0, 68.3]
MiGraph ^[13]	83.9: [81.2, 85.7]	72.1: [71.0, 73.2]
miGraph ^[13]	82.4: [80.2, 82.6]	70.5: [68.7, 72.3]
MILIS ^[14]	83.8: [82.5, 85.1]	70.1: [68.5, 71.8]
HSR-MIL ^[15]	81.2: [80.8, 82.2]	67.7: [66.2, 68.4]
SG-SVM ^[15]	82.8: [81.9, 83.2]	69.2: [66.5, 69.8]

在表 1 中,前一个 1000 幅图像的数据集由图像 0-9 类组成,后一个为整个 2000 幅的图像集。由表 1 可知,本文算法在 1000 幅图像数据集上的分类效果好于其他 8 种算法,分类精度提高了 0.5%~6.4%,在 2000 幅图像数据集上的分类效果也好于其它 8 种算法,分类精度提高了 0.5%~7.4%,95% 的置信区间也小于其它算法的置信区间。这些现象表明本文所提方法与其它方法相比可以提高图像的分类精度。

为了详细分析算法性能,表 2 给出了在 1000 幅图像数据集上本文算法对每一类图像的分类情况。在表 2 中,每一行表示测试图像被分到每一类的平均百分比。该表对角线上的值表示每一类的正确分类精度,其他值表示错分率。由表 2 可以发现:(1)类 3 (bus),类 4 (dinosaur),类 6 (flower) 和类 7 (horse) 的分类精度最高,超过了 90%;(2)类 1 (beach) 和类 8 (mountain) 之间的分类错误率最高,其中类 1 图像中的 12.8% 被误分为类 8,类 8 图像中的 14.2% 被误分为类 1。该发现与文献[10-14]所得到的结果是一致的。其原因是在这两类图像中有很多视觉上相似、语义上相关的图像区域,如高山、河流等,如图 2 所示,因此本文算法出现这样的错误也是可以理解的。

表 2 所提方法在 1000 幅图像数据集上的分类结果

	Cat. 0	Cat. 1	Cat. 2	Cat. 3	Cat. 4	Cat. 5	Cat. 6	Cat. 7	Cat. 8	Cat. 9
Cat. 0	71.4	1.2	7.2	0.4	1.8	9.8	0.4	3.8	0.8	3.2
Cat. 1	2.2	70.4	4.0	2.6	1.2	4.6	1.0	0.0	<u>12.8</u>	1.2
Cat. 2	5.2	3.2	76.6	3.1	0.5	5.6	1.6	0.0	3.2	1.0
Cat. 3	0.0	1.6	2.2	92.8	0.0	0.2	0.0	0.0	1.6	1.6
Cat. 4	0.0	0.0	0.0	0.0	99	1.0	0.0	0.0	0.0	0.0
Cat. 5	2.8	0.4	4.8	0.0	2.5	81.3	0.0	3.4	3.6	1.2
Cat. 6	1.8	0.0	0.0	0.0	0.0	0.0	98	0.0	0.0	0.2
Cat. 7	0.0	0.4	1.0	0.0	0.0	0.4	1.0	97.2	0.0	0.0
Cat. 8	1.8	<u>14.2</u>	3.8	0.6	4.0	4.2	1.2	0.8	69.2	0.2
Cat. 9	5.2	1.4	0.0	1.4	0.8	0.2	1.6	0.5	0.8	88.1




图 2 “beach”与“mountain”中的例子

结束语 为了有效地解决图像分类问题,本文基于稀疏表示提出一种多示例图像分类方法。该方法将图像当作包,图像中的区域视为包中的示例,利用训练包中的示例构成特征空间,在该空间中基于示例嵌入策略计算包特征向量,把多示例表示转换为单示例表示;然后利用训练包特征构建字典,并把待分类包特征表示为其上的稀疏线性组合,利用 ℓ_1 方法求得稀疏解;最后根据稀疏系数提出一种为待分类包预测标

记的方法。在 Corel 数据集上的实验结果表明,所提方法的分类精度高于其他的算法。

参考文献

- [1] Yu Jun, Tao Da-cheng, Wang Meng. Adaptive hypergraph learning and its application in image classification [J]. IEEE Transactions on Image Processing, 2012, 21(7): 3262-3272
- [2] 王宇新, 郭东, 何昌钦, 等. 用于图像场景分类的空间视觉词袋模型[J]. 计算机科学, 2011, 38(8): 265-268
- [3] 元晓振, 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
- [4] 孙锋利, 何明一, 高全华. 基于自适应脊波网络的高光谱遥感图像分类[J]. 计算机科学, 2011, 38(8): 260-264
- [5] 李峰, 孙启艳. 基于图像边界特征的人体寄生虫虫卵形状分类算法研究[J]. 计算机科学, 2014, 39(5): 261-265
- [6] 黄剑华, 丁建睿, 刘家锋, 等. 局部特征与多示例学习结合的超声图像分类方法[J]. 自动化学报, 2013, 39(6): 861-867
- [7] Dietterich T G, Lathrop R H, Lozano-Perez T. Solving the multiple instance problem with axis-parallel rectangles [J]. Artificial Intelligence, 1997, 89 (1/2): 31-71
- [8] Maron O, Ratan A L. Multiple-instance learning for natural scene classification [C]// International Conference on Machine Learning. 1998: 341-349
- [9] Zhang Qi, Goldman S A. EM-DD: an improved multiple-instance learning technique [C]// International Conference on Neural Information Processing Systems. 2002: 1073-1080
- [10] Chen Yi-in, Wang Ze. Image categorization by learning and reasoning with regions [J]. Journal of Machine Learning Research, 2004, 5(8): 913-939
- [11] Chen Yi-xin, Bi Jin-bo, Wang Ze. MILES: multiple-instance learning via embedded instance selection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (12): 1931-1947
- [12] Zhou Zhi-hua, Xu Jun-ming. On the relation between multi-instance learning and semi-supervised learning [C]// International

(上接第 271 页)

- [8] 邱飞岳, 吴裕市, 邱启仓, 等. 基于双极偏好占优的高维目标进化算法[J]. 软件学报, 2013, 24(3): 476-489
- [9] Agrawal G, Lewis K, Chugh K, et al. Intuitive Visualization of Pareto Frontier for Multi-Objective Optimization in n-Dimensional Performance Space [C]// 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference. New York, 2004: 1523-1533
- [10] 崔逊学. 多目标进化算法及其应用 [M]. 北京: 国防工业出版社, 2006
- [11] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究 [J]. 软件学报, 2009, 20(2): 271-289
- [12] Molina J, Santana L V, Hernández-Díaz A G, et al. g-dominance: Reference point based dominance for multiobjective metaheuris-

Conference on Machine Learning. 2007: 1167-1174

- [13] Zhou Zhi-hua, Sun Yu-yin, Li Yu-feng. Multi-instance learning by treating instances as non-i. i. d. samples [C]// International Conference on Machine Learning. 2009: 1249-1256
- [14] Fu Zhou-yu, Robles-Kelly A, Zhou Jun. Multiple instance learning with instance selection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 958-977
- [15] Li Bing, Xiong Wei-hua, Hu Wei-ming. Context-aware multi-instance learning based on hierarchical sparse representation [C]// IEEE Conference on Data Mining. 2011: 370-377
- [16] Feng Song-he, Xiong Wei-hua, Li Bing, et al. Hierarchical sparse representation based multi-instance semi-supervised learning with application to image categorization [J]. Signal Processing, 2014, 94(1): 595-607
- [17] 张钢, 印鉴, 程良伦, 等. 半监督多示例核 [J]. 计算机科学, 2011, 38(9): 220-223
- [18] 李展, 彭进业, 温超. 基于 EMD 距离的多示例聚类 [J]. 计算机科学, 2011, 38(7): 235-239
- [19] Olshausen B A, 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
- [20] 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
- [21] 黄克斌, 胡瑞敏, 韩镇, 等. 基于 K 近邻稀疏编码均值约束的人脸超分辨率算法 [J]. 计算机科学, 2013, 40(5): 271-274
- [22] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 201-227
- [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
- [24] Qiao Li-shan, Chen Song-can, Tan Xiao-yang. Sparsity preserving projection with applications to face recognition [J]. Pattern Recognition, 2010, 43(1): 331-341
- [25] Tibshirani R. Regression shrinkage and selection via the LASSO [J]. Journal of the Royal Statistical Society B, 1996, 58(1): 267-288

tics [J]. European Journal of Operational Research, 2009, 197 (2): 685-692

- [13] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197
- [14] Agrawal G, Bloebaum C L, Lewis K. Intuitive Design Selection Using Visualized n-Dimensional Pareto Frontier [C]// 1st AIAA Multidisciplinary Design Optimization Specialist Conference. Austin, Texas, 2005: 1-4
- [15] Ben Said L, Bechikh S, Ghédira K. The r-dominance: a new dominance relation for interactive evolutionary multicriteria decision making [J]. IEEE Transactions on Evolutionary Computation, 2010, 14(5): 801-818