

一种基于局部排序的约束稀疏编码的 图像分类方法

曹 晔

(南昌大学信息工程学院,江西南昌 330031)

摘 要: 图像分类作为计算机视觉分析领域一个重要的研究方向,其分类性能很大程度上取决于图像的特征表示. 为了能够更好地进行图像分类,本文提出了一种基于局部约束稀疏编码的神经气算法(Neural Gas based Locality-constrained Sparse Coding, NGLSC)用来实现图像分类. 引入局部排序适配器作为距离正则化约束项已经应用在神经气(Neural Gas, NG)的算法矢量量化中,旨在通过软竞争学习算法来弥补K均值聚类(K-means)算法的不足. 在稀疏编码阶段此算法可求解得到封闭解. 此外,字典更新一般由目标函数的误差项来决定,已有一些经典的算法采用这种方式更新字典. 本文使用ORL数据库和COIL20数据库将所提出算法和现有算法局部约束线性编码(Locality-constrained Linear Coding, LLC),脸元数据学习方法(Metaface Learning, MFL)进行比较. 实验结果证明本文所提出的算法在图像分类上准确率可达95%以上. 可以看出,本文为计算机视觉图像分类工作提供了一种有价值的解决思路.

关键词: 图像分类; 邻域排序; 局部约束; 字典学习

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2019)04-0832-05

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.04.010

An Image Classification Method Based on Locality-Constrained Sparse Coding with Ranking Locality Adaptor

CAO Ye

(Information Engineering School of NanChang University, Nanchang, Jiangxi 330031, China)

Abstract: Image classification is an important research direction in the field of computer vision analysis. The key to classification depends largely on the feature representation of the image. In order to be able to classify images better, this paper presents a locality-constrained sparse coding for image classification by introducing ranking locality adaptor as distance regularization. The proposed ranking locality adaptor has previously been used in Neural Gas (NG) method for vector quantization, which originally remedies the K-means by using this soft-competitive learning scheme. In the new proposed method, a closed-form solution can be derived at sparse coding step. In addition, dictionary updates are generally determined by the error term of the objective function. Some classical algorithms have used this method to update the dictionary. This paper uses the ORL database and COIL20 database to compare the proposed algorithm with the existing algorithm Locality-constrained Linear Coding, and Metaface Learning algorithm. The experimental results show that the proposed algorithm has an accuracy of more than 95% in image classification and has stronger performance than the current excellent algorithms. In addition, the recognition rate of the algorithm does not change greatly with the change of the data feature dimension. It can be seen that this paper provides a valuable solution for the classification of computer vision images.

Key words: image classification; neighborhood-ranking; locality-constrained; dictionary learning

1 引言

图像分类是信息领域里一类基本问题,有着广泛的应用. 将高维图像数据转换到低维特征空间后(如特征脸)^[1],大量的方法已经发展到能识别投影数据^[2,3].

稀疏编码^[4]是一种基于超完备字典的稀疏线性组合来重构目标样本的技术,该技术日益受到关注并已成功应用到人脸识别. Wright等^[3]提出一个基于稀疏表示分类(Sparse Representation based Classification, SRC)的人脸识别方法,将测试人脸图像转换为训练图像的稀疏

线性组合,并利用 L1 范数约束求解稀疏系数,在人脸识别中取得了很好的效果;Yang 等^[5]提出了脸元数据学习方法(Metaface Learning, MFL),从训练样本中提取出优化的字典用于稀疏表示和人脸识别。

基于稀疏表示的分类方法主要的局限是相似的图像样本产生的编码结果具有偶然性,得到的结果不能保证其相似性,因此对于稀疏编码,Wang^[6]提出了一种局部约束线性编码(Locality-constrained Linear Coding, LLC)方法,并且引入一个距离正则化.最近,Wei 等^[7]延伸了 LLC 的局部性适配器,从指数形式到 L2 范数形式,提出高效的算法来求解由此产生的优化问题。

受到局部数据的重要性的启发,本文提出一种新的距离正则化——局部排序适配器稀疏编码.其中局部排序适配器已用在通过软竞争学习算法来弥补 K-means 算法的不足的 NG 的算法矢量量化中^[8].基于局部约束稀疏编码的神经气算法(Neural Gas based Locality-constrained Sparse Coding, NGLSC)有两个优势:一是在适当的假设下,字典的更新只取决于目标函数的误差项,因此可直接结合这个算法更新字典;二是在稀疏编码过程中可推导出一个封闭解。

本文提出一种局部约束稀疏编码的新型图像分类方法,并引入局部排序适配器作为距离正则化.简单介绍了局部约束稀疏编码和 Neural Gas 算法,并在 ORL 和 COIL20 这两个数据库中,将 NGLSC 算法与把局部性和稀疏性先验信息作为正则化的 LLC 和 MFL 算法进行了对比。

2 相关工作

2.1 局部约束稀疏编码的分类算法

由 Wright^[3]等提出的稀疏表示分类算法在人脸识别的应用中具有很好的鲁棒性.将所有训练样本作为字典,稀疏表示分类决定输入图像 y 和分配该输入 y 到最小重构误差所对应的图像类中.更特别地,假设 J 类总共有 N 个训练样本,第 j 类有 N_j 个训练样本,设定训练集 $X = [X_1, X_2, \dots, X_j] \in R^{d \times N}$,其中 $X_j \in R^{d \times N_j}$ 表示第 j 类训练样本作为列向量所形成的训练子集; X 的每个训练子集 X 归一化处理为单位 L2 范数.给定测试图像样本 $y \in R^{d \times 1}$,通过稀疏表示系数 a 稀疏表示分类方法进而实现测试样本 y 的分类,执行以下 2 个步骤:

(1) 在实际稀疏编码过程中,最小化 L1 范数可降低解的空间维度,极大地降低了求解的计算空间复杂度和时间复杂度,故常用 L1 范数作为局部约束项,即通过 L1 范数最小化求解稀疏表示系数:

$$a = \arg \min_a \{ \|y - Xa\| + \lambda_s \|a\|_1 \} \quad (1)$$

(2) 根据最小重构误差分到对应的类别:计算重构样本的残差:

$$j^* = \arg \min_j \{ \|y - X\delta_j(a)\|_2 \} \quad (2)$$

其中, $\delta_j(a)$ 是特征函数,其选择与第 j 类相关的系数,它是一个新向量,其非 0 元素为 a 中与第 j 类相关的条目。

考虑到使用字典学习比训练样本能让稀疏表示具有更好的性能,Yang^[5]等人提出基于 Metaface 字典学习的图像分类方法.该算法首先对每类样本学习得到优化字典:

$$\hat{D}_j = \arg \min_D \{ \|X_j - D_j a_j\|_2^2 + \lambda_D \|a_j\|_1 \} \quad (3)$$

其次固定学习字典 $\hat{D}_j = [\hat{D}_1, \hat{D}_2, \dots, \hat{D}_j]$,利用 L1 范数最小化求解稀疏表达系数

$$a = \arg \min_a \{ \|y - \hat{D}a\|_2^2 + \lambda_D \|a\|_1 \} \quad (4)$$

最近提出的局部约束字典学习法便是通过局部数据约束提高分类性能^[6,7].特别地,在求解下列目标函数最小化的时候引入距离正则化:

$$\{\hat{D}_j, a_j\} = \arg \min_{D_j, a_j} \left\{ \|X_j - D_j a_j\|_2^2 + \lambda_D \sum_{i=1}^{N_j} \|p_{ji} \cdot a_{ji}\|_2^2 \right\} \quad (5)$$

其中, $a_j = [a_{j1}, a_{j2}, \dots, a_{jN_j}]$ 是第 j 类样本相应的矩阵, $p_{ji} = [p_{1,i}, p_{2,i}, \dots, p_{K,i}]$ 是局部适配器,其表示 x_i 和列向量 D_j 之间的距离, \cdot 表示逐元素相乘.此外,在文献[7]中还详细介绍了两个局部适配器:L2 范数和指数的局部性适配器。

2.2 基于‘Neural Gas’的矢量量化算法

本节简要概述基于神经网络的矢量量化算法,矢量量化是基于一系列码书向量.每次量化由最匹配的码书向量来编码.因此,对于系数 a 有:

$$a_{i_k} = 1, \quad (6)$$

$$a_{ij} = 0 \quad \forall j \neq k \text{ where } k = \arg \min_j \|d_j - x_i\|_2$$

矢量量化的目的是在式(6)约束下找到一系列的码书向量.K-means 算法就是求解这优化问题的方法之一.然而,由于学习方案的硬竞争本质,K-means 算法会导致码书的次优利用.此外,K-means 算法对初值敏感,收敛速度慢.NG 算法^[8]可以通过软竞争学习方法弥补这些不足,改善鲁棒收敛达到码书向量的最优分布的数据流学习,即:

$$\min_d \sum_{i=1}^N \sum_{j=1}^M h_{\lambda_{NG}}(q_i(x_j)) \|d_i - x_j\|_2^2 \quad (7)$$

其中, $h_{\lambda_{NG}}(q_i(x))$ 定义为:矢量 x 与参考矢量 d_i 间距离的排列顺序为 $(d_{i_0}, d_{i_1}, \dots, d_{i_{N-1}})$ 间,而参考向量 d_{i_0} ($0 \leq q \leq N-1$) 和 q 维矢量 d_n 满足条件 $\|d_n - x\| < \|d_{i_q} - x\|$, 排列序号 q 是和 $q_i(x)$ 的每个矢量 d_i 相关联,具体是由 x 和参考向量的全集 $(d_{i_0}, d_{i_1}, \dots, d_{i_{N-1}})$ 来决定.此外, $h_{\lambda_{NG}}(q_i(x)) = \exp(-q_i(x)/\lambda_{NG})$ 是排列序号 $q_i(x)$ 的指

数函数,若距码书向量相邻,则权重更大.

3 NGLSC 算法

本节介绍基于局部约束稀疏编码的神经气算法,受 NG 算法引入邻域排序所获得优良的鲁棒性的启发,本文建立如下模型:

$$\{\hat{\mathbf{D}}_j, \mathbf{a}_j\} = \arg \min_{\mathbf{D}_j, \mathbf{a}_j} \left\{ \|\mathbf{X}_j - \mathbf{D}_j \mathbf{a}_j\|_F^2 + \lambda_D \sum_{i=1}^{N_j} \|p_{ji} \cdot \mathbf{a}_{ji}\|_2^2 \right\} \quad (8)$$

s. t. $d_{jk2} = 1; \mathbf{1}^T \mathbf{a}_{ji} = 1$

其中, $\mathbf{1}^T = \underbrace{[111 \cdots 1]}_i^T$, 局部排序适配器为:

$$p_{k,i} = \sqrt{\exp(q_k(x_i)/\lambda_{NG})} \quad (9)$$

值得注意的是,上式中的 $q_k(x_i)$ 的定义与式(7)的相同;局部排序适配器 $p_{k,i}$ 的作用是针对稀疏系数 \mathbf{a}_{ji} 而言,如果相应原子 d_{jk} 与输入 x_i 远离所对应的非零项 $a_{k,i}$ 为非零,则最小化公式(8)中更大的 $p_{k,i}$ 会强迫 $a_{k,i}$ 趋近于零,从而实现了局部稀疏正则化.

3.1 稀疏编码阶段

固定字典,其稀疏系数可通过式(10)来求解:

$$\arg \min_{\mathbf{a}_j} \left\{ \|\mathbf{X}_j - \mathbf{D}_j \mathbf{a}_j\|_2^2 + \lambda_D \|\mathbf{p}_{ji} \cdot \mathbf{a}_j\|_2^2 \right\} \quad \text{s. t. } \mathbf{1}^T \mathbf{a}_j = 1 \quad (10)$$

式(10)结合拉格朗日函数 $L_\eta(\mathbf{a}_j)$, 则可得到:

$$\|\mathbf{X}_j - \mathbf{D}_j \mathbf{a}_j\|_2^2 + \lambda_D \|\mathbf{p}_{ji} \cdot \mathbf{a}_j\|_2^2 + \eta(\mathbf{1}^T \mathbf{a}_j - 1) \quad (11)$$

求解 $L_\eta(\mathbf{a}_j)$ 关于 \mathbf{a}_j 的微分并使它等于 0, 得到:

$$\Phi \mathbf{a}_j + \eta \mathbf{1} = 0 \quad (12)$$

其中

$$\Phi = 2(C + \lambda D \text{diag}(p_{ji})^2), C = (\mathbf{X}_j \mathbf{1}^T - \mathbf{D}_j)^T (\mathbf{X}_j \mathbf{1}^T - \mathbf{D}_j)$$

从式(12)可得到 $\eta = -(\mathbf{1}^T \Phi^{-1} \mathbf{1})^{-1}$. 此外,将其代入式(12)可得到式(10)的解析解为:

$$\tilde{\mathbf{a}}_j = (C + \lambda D \text{diag}(p_{ji})^2)^{-1} \mathbf{1}; \mathbf{a}_j = \tilde{\mathbf{a}}_j / (\mathbf{1}^T \tilde{\mathbf{a}}_j) \quad (13)$$

从式(13)可以看出推导出的 \mathbf{a}_j 与局部排序适配器 $p_{k,i}$ 是成反比,这也就表明通过加入局部惩罚因子可以得到稀疏解.

3.2 字典更新阶段

首先,计算目标函数式(8)与 d_k 有关的项,即:

$$\frac{\partial \left\{ \|\mathbf{x}_{ji} - \mathbf{D}_j \mathbf{a}_j\|_2^2 + \lambda \sum_{i=1}^{N_j} \|p_{ji} \cdot \mathbf{a}_{ji}\|_2^2 \right\}}{\partial d_k} \quad (14)$$

$$= \frac{\partial \|\mathbf{x}_{ji} - \mathbf{D}_j \mathbf{a}_j\|_2^2}{\partial d_k} + \lambda \frac{\partial \sum_{i=1}^{N_j} \|p_{ji} \cdot \mathbf{a}_{ji}\|_2^2}{\partial d_k}$$

令 $p_{s,i}^2 = h_{s,i}$, 则有:

$$\frac{\partial \sum_{i=1}^{N_j} \|p_{ji} \cdot \mathbf{a}_{ji}\|_2^2}{\partial d_k} = \frac{\partial \left(\sum_{i=1}^{N_j} \sum_{s=1}^K p_{s,i}^2 a_{s,i}^2 \right)}{\partial d_k} \quad (15)$$

$$= \sum_{s=1}^K \sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 \frac{\partial q_s(x_i)}{\partial d_k}$$

对于 $q_s(x_i)$, 有:

$$q_s(x_i) = \sum_{l=1}^N \theta(g_{s,i}^2 - g_{l,i}^2), g_{s,i}^2 = x_i - d_s$$

其中 $\theta(v) = \begin{cases} 1, & v > 0 \\ 0, & v \leq 0 \end{cases}$ 是阶跃函数,其导数是冲激函数:

$$\delta(v) = 0, v \neq 0; \int \delta(v) dv = 1.$$

继续对式(15)求导:

$$\sum_{s=1}^K \sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 \frac{\partial q_s(x_i)}{\partial d_k} \quad (16)$$

$$= - \sum_{i=1}^N h_{s,i} a_{s,i}^2 \sum_{l=1}^K g_{k,i} \delta(g_{s,i}^2 - g_{l,i}^2)$$

$$+ \sum_{s=1}^K \sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 \delta(g_{s,i}^2 - g_{k,i}^2)$$

可以看出当 x_i 满足 $g_{s,i}^2 = g_{k,i}^2$ 时,式(16)右边第二项的值是不变的. 对于这些 x_i 可得:

$$q_s(x_i) = \sum_{l=1}^N \theta(g_{s,i}^2 - g_{l,i}^2)$$

$$= \sum_{i=1}^{N_j} \theta(g_{k,i}^2 - g_{l,i}^2) = q_k(x_i)$$

此外,当满足 $g_{s,i}^2 = g_{k,i}^2$ 时假设 $a_{s,i}^2 = a_{k,i}^2$, 式(16)可简化为:

$$\sum_{s=1}^K \sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 \frac{\partial q_s(x_i)}{\partial d_k} =$$

$$- \sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 \sum_{l=1}^K g_{k,i} \delta(g_{s,i}^2 - g_{l,i}^2) + \quad (17)$$

$$\sum_{i=1}^{N_j} h_{s,i} a_{s,i}^2 g_{k,i} \sum_{s=1}^K \delta(g_{s,i}^2 - g_{k,i}^2)$$

$$= 0$$

其次,在适当的假设下等式(14)右边第二项为零,更新字典只和等式(14)右边第一项有关,此时我们可利用方向法(Method of Direction, MOD)^[9]或者 K 奇异值分解(K Singular Value Decomposition, K-SVD)算法^[10]对字典进行更新. 为了方便比较,本文选用 MFL 算法^[5]更新字典,其可以看作是 K-SVD 算法的近似^[5].

方便起见,我们重新定义矩阵 $\mathbf{a}^j = [\gamma_1, \gamma_2, \dots, \gamma_K]$, 其中 $\gamma_k, k=1, 2, \dots, K$ 是 \mathbf{a}^j 的列向量. 原子 $\mathbf{D}_j = [d_1, d_2, \dots, d_k]$ 在最小保真度时依次更新,当更新完原子 \mathbf{d}_k 之后,列向量 $d_l, l \neq k$ 均固定,此时式(8)关于 \mathbf{d}_k 简化为:

$$\arg \min_{\mathbf{d}_k} \left\| \mathbf{X}_j - \sum_{l \neq k} d_l \gamma_l - \mathbf{d}_k \gamma_k \right\|_F^2 \quad \text{s. t. } \mathbf{d}_k^T \mathbf{d}_k = 1 \quad (18)$$

$\mathbf{Y} = \mathbf{X}_j - \sum_{l \neq k} d_l \gamma_l$, 式(18)可进一步简化为:

$$\arg \min_{\mathbf{d}_k} \left\| \mathbf{Y} - \mathbf{d}_k \gamma_k \right\|_F^2 + \omega(\mathbf{d}_k^T \mathbf{d}_k - 1) \quad (19)$$

关于 \mathbf{d}_k 对式(18)微分并将其置零,则可得到:

$$\mathbf{d}_k = \mathbf{Y} \gamma_k^T / [\mathbf{Y} \gamma_k^T + \omega] \quad (20)$$

在约束 $d_k^T d_k = 1$, 其解为:

$$d_k = Y\gamma_k^T / \|Y\gamma_k^T\|_2 \quad (21)$$

总之, 本文提出的 NGLSC 算法包含两步轮换步骤: 首先通过稀疏编码步骤得到解析解, 接着利用目前常用的字典更新算法如 K-SVD 算法更新字典^[11].

4 实验结果

本文通过几个实验来评价 NGLSC 算法的性能, 其相应的条件、参数的设置与文献[5]的实验部分相似.

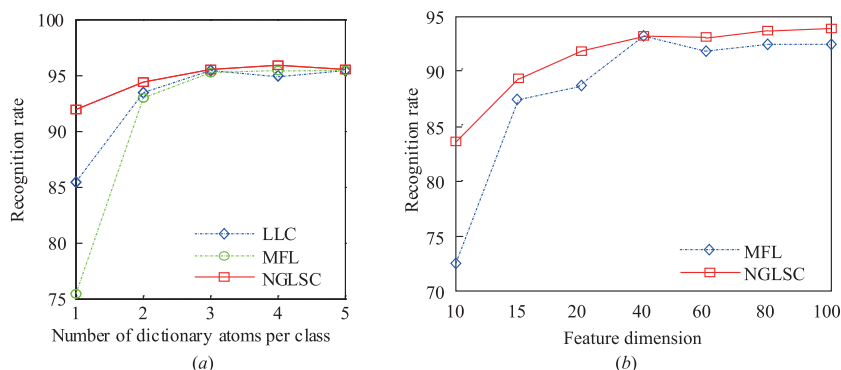


图1 (a) ORL数据库中不同算法的识别率和原子数 K 的关系; (b) ORL数据库中不同算法的识别率和特征维数的关系




图2 $K=2$, 特征维数为20和 $K=20$ 时40个个体不同的 $g_{s,i}^2 - g_{k,i}^2$

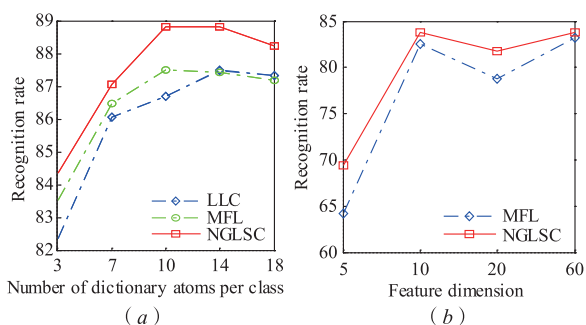


图3 (a) 在COIL数据库中不同算法识别率与原子数 K 的关系; (b) 在COIL数据库中不同算法识别率与特征维数的关系

图1(a)所绘制的是三种算法在特征量维数为100的情况下, 不同的原子数 K 所对应的识别率变化曲线. 从图中可看到当原子数 K 小于3时, NGLSC算法在相

NGLSC算法与分别通过局部性和稀疏性先验信息作为正则化的LLC和MFL算法进行对比.

(1) ORL 数据库

ORL数据库里^[12]的图像取自40个个体, 每个个体有10张不同的图像. 首先我们用每个人的前6张图像作为训练样本, 剩下4张作为测试图像, 参数 λ 和 λ_{NC} 选择相应的数值以使各种方法均能获得其相应最好的性能, 具体选取为: LLC算法中 $\lambda = 0.4$, MFL算法中 $\lambda = 0.05$, NGLSC算法中 $\lambda_D = 0.01$, $\lambda_{NC} = 1$.

同的条件下具有最高的识别率, LLC次之; 当原子数 K 超过3之后, 三种算法的性能基本一致. 图1(b)所绘制的是NGLSC算法和MFL算法在原子数 $K=2$ 情况下不同的特征量维数所对应的识别率变化曲线. 结果表明, 在相同的特征量维数下, NGLSC算法具有更高的识别率.

由于 $g_{s,i}^2 = g_{k,i}^2$ 出现的概率非常小, 我们可以验证想要满足之前假设的 $g_{s,i}^2 = g_{k,i}^2$ 条件, 则在本论文所提出的方法中需要满足 $a_{s,i}^2 = a_{k,i}^2$, 图2所绘制的是 $K=2$, 维数为20时对40个个体不同的差异 $g_{s,i}^2 - g_{k,i}^2$, 从图中可看出 $g_{s,i}^2 = g_{k,i}^2$ 的点几乎为零, 即使出现, 我们可以在迭代过程中设置 $a_{s,i}^2 = a_{k,i}^2$.

(2) COIL20 数据库

COIL20数据库有20个对象, 每个对象有72张 32×32 灰度图像, 总共1440张组成的. 这些图像是围绕对象以 5° 为间隔旋转 360° 拍摄得到的, 每张图像由一个1024维矢量表示. 在每个对象中随机选取36张图像作为训练样本, 剩余的36张作为测试图像. COIL20数据库在算法测试时比ORL数据库更具挑战性.

在实验过程中, 先利用主成分分析(Principal Component Analysis, PCA)算法降低图像维度, 其相应的参数设置为: LLC算法中 $\lambda = 0.2$, MFL算法中 $\lambda = 0.1$, NGLSC算法中 $\lambda_D = 0.1$, $\lambda_{NC} = 0.5$. 图3(a)所绘制的是利用PCA维度为64时不同原子数 K 所对应的识别率曲线, 从图中可看出NGLSC算法的识别性能比LLC和

MFL 高;图 3(b)所绘制的是当原子数 $K=3$ 时, NGLSC 和 MFL 算法在不同维度下的识别率曲线. 结果表明, 在相同的特征量维数下, NGLSC 算法的识别率更高.

5 总结

本文提出了一种局部约束线性编码的图像分类方法, 在通过邻域排序的局部稀疏编码和字典更新迭代方式可获取一个更好的字典. 利用局部正则化可简便地推导出稀疏编码过程中的封闭解. 同时, 在适当的假设下, 经典的算法如 K-SVD 可用于字典更新. 在 ORL 和 COIL20 这两个数据库中的对比实验表明, NGLSC 算法比 MFL 和 LLC 算法的识别率更高. 因此, 本文所提出的算法对图像分类(如人脸识别)是有一定借鉴意义的, 且提高了图像分类精度的鲁棒性. 此外, 该算法的局部排序稀疏性还可应用在其它场合, 如图像重建, 图像处理, 信号处理等, 其可对文献[13, 14]中模型等进行改进, 提高了图像重建质量.

参考文献

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. *J Cogn Neurosci*, 1991, 3(1): 71–86.
- [2] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323–2326.
- [3] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2009, 31(2): 210–227.
- [4] 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.
- [5] Yang M, Zhang L, Yang J, et al. Metaface learning for sparse representation based face recognition[A]. *IEEE International Conference on Image Processing [C]*. IEEE, 2010. 1601–1604.
- [6] Wang J, Yang J, Yu K, et al. Locality-constrained linear coding for image classification[A]. *Computer Vision and Pattern Recognition [C]*. IEEE, 2010. 3360–3367.
- [7] Wei C P, Chao Y W, Yeh Y R, et al. Locality-sensitive dictionary learning for sparse representation based classification[J]. *Pattern Recognition*, 2013, 46(5): 1277–1287.
- [8] Martinez T M, Berkovich S G, Schulten K J. Neural-gas network for vector quantization and its application to time-series prediction [J]. *IEEE Trans Neural Netw*, 1993, 4(4): 558–569.
- [9] Engan K, Aase S O, Husoy J H. Frame based signal compression using method of optimal directions (MOD) [A]. *IEEE International Symposium on Circuits and Systems [C]*. IEEE, 1999. 1–4.
- [10] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311–4322.
- [11] Rubinstein R, Zibulevsky M, Elad M. Efficient implementation of the K-SVD algorithm using batch orthogonal matching pursuit [J]. *CS Technion*, 2008, 40.
- [12] Samaria F S, Harter A C. Parameterisation of a stochastic model for human face identification [A]. *Proceedings of the Second IEEE Workshop on Applications of Computer Vision [C]*. IEEE, 1994. 138–142.
- [13] 邓贞宙, 段志文, 刘晶晶, 谢庆国. 基于一种新型扫描模式的不完全数据 CT 重建 [J]. *核电子学与探测技术*, 2011, 31(1): 53–57.
Z Deng, Z Duan, J Liu, Q Xie. Incomplete data CT image reconstruction based on a new scanning mode [J]. *Nuclear Electronics & Detection Technology*, 2011, 31(1): 53–57. (in Chinese)
- [14] 邓贞宙, 段志文, 谢庆国. 基于微元法的高精度系统响应矩阵建模 [J]. *核电子学与探测技术*, 2011, 31(10): 1125–1130.
Z Deng, Z Duan, Q Xie. System response matrix modeling with high accuracy via infinitesimal analysis [J]. *Nuclear Electronics & Detection Technology*, 2011, 31(10): 1125–1130. (in Chinese)

作者简介



曹 晔 女, 1983 年生于江西南昌, 实验师, 南昌大学信息工程学院. 研究方向为计算机图形图像.

E-mail: caoyencu@sina.com