

# 基于结构信息的RPCA图像去噪

郑秀清<sup>1</sup> 何坤<sup>2</sup> 张健<sup>3</sup>

(四川师范大学信息技术学院 广汉 618300)<sup>1</sup> (四川大学计算机学院 成都 610065)<sup>2</sup>

(四川师范大学网络与通信技术研究所 成都 610066)<sup>3</sup>

**摘要** 图像在采集、存储和传输过程中不可避免地受到噪声攻击。鉴于无噪声图像对象形成的物理机理,在灰度图像中不同对象总是通过子块结构及其空间分布特性表征出来。子块结构具有某种规律或周期的像素变化,而噪声的分布表现出随机特性。为了在抑制噪声的同时保护对象结构,文中提出基于结构信息的鲁棒主成分分析(RPCA)图像去噪方法。该方法从高质量的图像集中提取结构信息样本,建立结构信息基元库,对不同结构信息基元集分别进行RPCA变换,挖掘其稀疏表示的变换核函数,用于图像去噪。实验表明,基于结构信息的RPCA图像去噪方法在去除噪声的同时,能有效保护图像的结构信息。

**关键词** 结构信息, RPCA, 图像去噪

**中图分类号** TP39 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.08.064

## Image Denoising by Principal Component Analysis with Structural Information

ZHENG Xiu-qing<sup>1</sup> HE Kun<sup>2</sup> ZHANG Jian<sup>3</sup>

(College of Information Technology, Sichuan Normal University, Guanghan 618300, China)<sup>1</sup>

(College of Computer Science, Sichuan University, Chengdu 610065, China)<sup>2</sup>

(Institute of Computer Network & Communication Technology, Sichuan Normal University, Chengdu 610066, China)<sup>3</sup>

**Abstract** The noise is inevitable in the process of image acquisition, image storage and image transmission. To suppress the noise effectively and preserve the structural information of the image, a new method based on structural information was presented. The method extracts the sub-block sample from the pure image to build the structural element library. The structure elements are regarded as the sample of the same general. By RPCA transform, the sparse representation kernel function of the structure element library of the same type samples is built adaptively which can smooth the image and preserve the edge effectively. The method analyses the distributions of noise and structure information in kernel space from the theory. Experimental results show that the proposed algorithm can suppress the noise of the image and protect the structural information of the image more effectively.

**Keywords** Structural information, RPCA, Image denoising

## 1 引言

图像在采集、传输和存储过程中不可避免地受到噪声污染,为了减少噪声对图像分析处理的影响,需要对图像进行去噪处理。最简单的去噪算法是根据噪声和图像主要内容属于不同频段对其作滤波处理,滤波本质是对图像进行各向同性扩散,该方法在去噪的同时也将图像边缘严重损失<sup>[1]</sup>。为了保护对象的边缘信息,运用数学形态学对图像进行非线性去除噪声处理,相对于各向同性扩散,该算法在一定程度上保护了边缘,但其形态结构元素难以根据图像内容及噪声污染程度自适应构造<sup>[2]</sup>。以上算法及其改进方法均是运用固定核函数对图像进行分析处理,未考虑图像信号与噪声之间的统计特性。根据两者之间的统计无关性,假设图像信号为平稳信号的前提下,运用Wiener滤波对噪声图像进行数据驱动型的自适应处理。该方法不需要人工干预。但实际上图像信号并

非平稳信号,这使得Wiener滤波的前提条件不成立<sup>[3]</sup>。

根据图像的冗余特性,常运用固定核函数对图像进行稀疏表示<sup>[4]</sup>,在变换域中进行阈值去噪。固定核函数图像变换方法在图像的阶跃边缘易出现“Gibbs”现象<sup>[5]</sup>。为了克服“Gibbs”现象,结合图像的空间和像素邻域提出了BM3D去噪算法<sup>[6]</sup>。以上算法及其改进算法均是以变换系数稀疏性为前提的,但并非所有图像固定核变换的系数都表现出稀疏性<sup>[7]</sup>。本文从图像结构信息出发提出了基于结构信息的鲁棒主成分分析(RPCA)图像去噪算法,该方法在去除噪声的同时能有效保留图像的边缘和结构信息。

## 2 RPCA分量提取

尽管图像表达的内容千差万别,但图像中不同对象总是通过子块结构及其空间分布特性表征出来,其结构信息主要表现为像素变化,如像素发生突变形成边缘或线段。对大量

到稿日期:2013-10-04 返修日期:2014-01-11 本文受四川省科技支撑计划项目(2013SF0157)资助。

郑秀清(1972-),女,博士,高级工程师,主要研究方向为图像处理与分析、信号处理, E-mail: zxq@sicnu.edu.cn; 何坤(1972-),男,博士,副教授,主要研究方向为智能计算、数字图像处理; 张健(1973-),女,博士,副教授,主要研究方向为智能优化。

图像内容的统计分析表明:图像的微结构可由一小部分结构信息(如边缘、线段和其他基本特征)进行有效表示<sup>[8]</sup>。换言之,内容千差万别的图像可由有限的结构基元表示,进而实现图像的稀疏表示。

图像变换的本质是将图像用固定的函数来表示,如果变换系数的非零个数越少,则表示图像像素变化越缓慢,内容越简单,结构信息越少;反之像素变化较快,内容复杂,结构信息较多。如何实现图像信号的灵活、简洁和自适应的表示,一直是计算机视觉领域的专家们致力研究的内容。基于固定核函数的图像稀疏表示在图像处理领域无论在理论还是从实践上都获得了极大的发展<sup>[9]</sup>。但由于图像内容与结构的丰富,基于固定核函数在图像变换中并不是“最稀疏”的。本文在图像变换的基础上,结合图像对象形成的像素机理,对所有图像  $f(x,y) \in \mathbb{R}^n$  在一个给定结构基元库  $\Phi = [\phi_1, \dots, \phi_m] \in \mathbb{R}^{n \times m}$  上进行稀疏表示,其本质是寻找向量  $\alpha = [\alpha_1, \dots, \alpha_m]$ ,使得  $f \approx \Phi\alpha$ 。图像信号的稀疏性可表征为向量  $\alpha$  非零系数的个数,  $\alpha$  的非零系数个数越少,表示结构基元对图像的稀疏性表达的有效性越好;反之结构基元的有效性越差。在数学上常用表示系数的  $\ell_0$  范式来衡量稀疏性,则图像在结构基元库  $\Phi$  上的稀疏表示问题可转化为:

$$\begin{cases} \min_{\alpha} \|f - \Phi\alpha\|_2^2 \\ \text{s. t. } \|\alpha\|_0 \leq T \end{cases} \quad (1)$$

式中,  $T$  是一个控制图像稀疏表示的尺度。式(1)为约束条件求极值,为了将约束条件的极值问题转化为无约束条件的极值,常常采用最小二乘法将式(1)转化为:

$$\hat{\alpha} = \arg \min \{ \|f - \Phi\alpha\|_2^2 - \lambda \|\alpha\|_0 \} \quad (2)$$

其中,  $\lambda$  是常数。在式(2)中  $\|\alpha\|_0$  为  $\ell_0$  范式,含有  $\ell_0$  范式的函数是非凸的。该函数最小化问题是一个非确定性问题,极值的求解容易陷入局部极小值,传统方法常常采用计算复杂度较大的贪婪算法。为了弥补这一不足,本文采用  $\ell_1$  范式代替  $\ell_0$  范式,将式(2)转化为凸函数优化问题:

$$\hat{\alpha} = \arg \min \{ \|f - \Phi\alpha\|_2^2 - \lambda \|\alpha\|_1 \} \quad (3)$$

由图像稀疏表示的数学模型式(3)可知,为了实现所有图像运用结构基元表示具有稀疏性,其图像“能量”集中在少数几个系数中,关键是选择一个有效的结构基元库  $\Phi$ 。有效的结构基元应具有普适性和有效性,其普适性就是对所有图像均能实现稀疏表示,而向量  $\alpha$  的  $\ell_0$  范式较小,实现图像“能量”集中;有效性要求运用结构基元对图像表示的残差较小。从结构基元的普适性和有效性来看,如果把图像看成一个整体挖掘结构基元,得到的结构基元仅能对训练集合(分析结构基元的图像集)中的图像实现有效稀疏表示,而对训练集以外的图像其稀疏性降低,其结构基元缺乏普适性<sup>[10]</sup>。通过对大量图像进行统计分析发现:图像结构信息主要表现为图像像素的局部特性。根据结构信息的局部性,从高清图像中的局部像素变化角度分析构建具有普适性的结构基元库。

## 2.1 结构信息库

尽管不同图像的内容千差万别,从图像稀疏表示的数学模型可见稀疏表示的有效性取决于结构基元。本文基于结构信息表现为像素变化,具有一定“能量”的角度,从纹理和边缘子块中提取结构基元。为了抑制噪声对结构基元的影响,本文收集一组边缘和纹理丰富的高质量自然图像,将收集的图像分割成尺寸为  $m \times m$  的图像子块  $Ib_i$ 。

为了排除平滑子块对结构基元的影响,本文根据平滑子

块的二阶统计矩较小的特点,运用统计特性分析判断图像块  $Ib_i$  的“能量”大小。

子块结构均值:

$$E(Ib_i) = \frac{1}{m^2} \sum_{k=0}^{m-1} \sum_{l=0}^{m-1} Ib_i(k,l) \quad (4)$$

得到子块结构能量信息  $s_i(k,l)$ :

$$s_i(k,l) = Ib_i(k,l) - E(Ib_i) \quad (5)$$

子块结构的判断依据:

$$\text{var}(s_i) = \frac{1}{m^2} \sum_{k=1}^{m-1} \sum_{l=0}^{m-1} [s_i(k,l)]^2 \quad (6)$$

如果图像块  $s_i$  的方差  $\text{var}(s_i) > \mathbf{V}$ ,则该子块结构具有“能量”,可以作为稀疏表示的结构基元;否则认为该子块不含有结构信息。

实现对图像不同结构信号的有效稀疏表示,本文根据局部边缘方向对结构样本进行分类,将方向相同的图像子块归为同一类结构样本,假设从一组高质量的自然图像的中选择  $n$  个子块  $B = \{b_1, b_2, \dots, b_n\}$ ,再将  $n$  个子块结构运用  $k$  均值聚类(k-means)算法划分为  $k$  类。

为了构建一个有效的结构信息库,实现对自然图像有效稀疏表示,本文从高清图像中提取结构信息样本,其中部分结构基元样本如图1所示。




图1 部分结构基元样本

## 2.2 鲁棒数据标准化

每类结构基元样本间具有大量的冗余信息,为了从每类结构基元样本集挖掘表征该类结构的特征向量,对该类结构进行稀疏表示。本文定义如下目标函数:

$$(\hat{\Phi}_k, \hat{\Lambda}_k) = \arg \min_{\Phi_k, \Lambda_k} \{ \|S_k - \Phi_k \Lambda_k\|^2 + \lambda \|\Lambda_k\|_1 \} \quad (7)$$

式中,  $\Lambda_k$  是同类子块结构样本集  $S_k$  稀疏表示的系数矩阵。 $\hat{\Phi}_k$  的有效性性与样本集  $S_k$  的容量有关,如果样本集  $S_k$  是过完备集合,  $\hat{\Phi}_k$  的有效性和普适性较好。本文样本集  $S_k$  是经过  $k$  均值聚类后得到的子数据集,对每个子数据集  $S_k$  运用鲁棒性主成分分析构建图像结构系数表示向量。

传统的主分量分析在子块结构样本标准化过程中常常使用均值估计来自同一总体随机变量的真实值  $\mu_k$ :

$$\mu_k = \min_{\mu} \sum_{i=1}^m (s_k^i - \mu_k)^2 \quad (8)$$

结构信息集合中可能存在奇异样本(异类子块结构样本),而  $\ell_2$  范数估计的均值  $\mu$  对奇异类样本较敏感。为了克服子块结构的错误分类,抑制样本集  $S_k$  中奇异类样本对该类子块结构均值估计的影响,本文使用中位数代替  $\ell_2$  范数对均值  $\mu_k$  进行估计:

$$\hat{\mu}_k = \text{median}(S_k) = \text{median} \sum_{i=1}^m |s_k^i - \hat{\mu}_k| \quad (9)$$

对奇数个样本的子块结构集,其中位数即为中间的样本;有偶数个样本的子块结构集,中间样本即为离中间位置最近的

两个样本的平均值。中位数是对含有奇异样本均值的鲁棒估计, 奇异样本对中位数影响较小, 对  $l_2$  范数的均值影响较大。

主分量分析常常用随机变量的标准差和方差对数据进行归一化, 定义为:

$$\sigma(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu(x))^2} \quad (10)$$

$$v(x) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu(x))^2 \quad (11)$$

为了克服奇异样本对子块结构样本归一化的影响, 根据样本集的中心样本对方差估计影响较小, 排除中心样本, 仅仅运用距中心较远的样本进行估计, 即样本鲁棒跨度测量  $\sigma_{s_k}$ :

$$\sigma_{s_k} = C \times \text{median}_i \{ \text{median}_j | s_k^i - s_k^j | \} \quad (12)$$

其中,  $C$  为常数, 本文取 2.4。

为了提高预处理的鲁棒性, 用中位数  $\hat{\mu}_k$  代替均值, 利用样本鲁棒跨度的测量代替标准差, 对子块结构样本集  $S_k$  的样本  $s_k^i$  进行归一化处理得到  $\tilde{s}_k^i$ :

$$\tilde{s}_k^i = \frac{s_k^i - \hat{\mu}_k}{\sigma_{s_k}} \quad (13)$$

### 2.3 鲁棒主分量提取

主分量分析主要是去除样本集相关性, 提取样本主要能量所在的核空间。信号分析时将信号在核空间进行投影变换, 使得信号能量集中在少数几个系数中。因此, 图像的主分量分析可以较好地地区分图像内容和噪声。

$m$  个同类结构的标准化子块结构  $\tilde{S}_k = [\tilde{s}_k^1, \tilde{s}_k^2, \dots, \tilde{s}_k^m]^T$  的矩阵表示为:

$$\tilde{S}_k = \begin{bmatrix} \tilde{s}_k^1 & \tilde{s}_k^1 & \dots & \tilde{s}_k^1 \\ \tilde{s}_k^2 & \tilde{s}_k^2 & \dots & \tilde{s}_k^2 \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{s}_k^m & \tilde{s}_k^m & \dots & \tilde{s}_k^m \end{bmatrix} \quad (14)$$

协方差为:

$$\Omega_{\tilde{S}_k} = \frac{1}{m} \tilde{S}_k \tilde{S}_k^T \quad (15)$$

鲁棒主分量分析的目标是找到一个正交矩阵  $\phi$  来表征协方差矩阵的主要“能量”, 为此将  $\Omega_{\tilde{S}_k}$  表示为:

$$\Omega_{\tilde{S}_k} = \Phi_{\tilde{S}_k} \Lambda_{\tilde{S}_k} \Phi_{\tilde{S}_k}^T \quad (16)$$

式中,  $\Lambda_{\tilde{S}_k}$  是特征矩阵, 其中  $\lambda_{s_k^1}^1 \geq \dots \geq \lambda_{s_k^1}^m \geq \dots \geq \lambda_{s_k^m}^1 \geq \dots \geq \lambda_{s_k^m}^m$ ,  $\Phi_{\tilde{S}_k} = [\Phi_{\tilde{S}_k}^1, \dots, \Phi_{\tilde{S}_k}^i, \dots, \Phi_{\tilde{S}_k}^m]$  是  $m \times m$  的特征向量矩阵。  $\Phi_{\tilde{S}_k}^1, \dots, \Phi_{\tilde{S}_k}^i, \dots, \Phi_{\tilde{S}_k}^m$  向量两两正交。特征值  $\lambda_{s_k^i}^i$  反映了  $\tilde{S}_k$  在其对应的特征向量  $\Phi_{\tilde{S}_k}^i$  的能量大小, 最大特征值  $\lambda_{s_k^1}^1$  对应的特征向量  $\Phi_{\tilde{S}_k}^1$  主要反映该类结构信息样本的整体信息。运用特征向量将样本表示为  $\tilde{Y}_{\tilde{S}_k}$ :

$$\tilde{Y}_{\tilde{S}_k} = \Phi_{\tilde{S}_k}^T \tilde{S}_k \quad (17)$$

特征向量个数的选取与传统主分量分析类似, 都是基于变换核空间能量大小(特征值)进行选择, 本文依据最大能量占全部能量的 85% 进行选择。

如果高清图像受到轻微噪声攻击, 从该图像中提取的子块结构  $S_k$  也含有噪声, 含噪声的子块结构标准化后  $\tilde{S}_k^N$  为:

$$\tilde{S}_k^N = \tilde{S}_k + N \quad (18)$$

通过式(15)计算  $\tilde{S}_k^N$  的协方差:

$$\begin{aligned} \Omega_{\tilde{S}_k^N} &= \frac{1}{m} \tilde{S}_k^N (\tilde{S}_k^N)^T = \frac{1}{m} [(\tilde{S}_k + N)(\tilde{S}_k + N)^T] \\ &= \frac{1}{m} [\tilde{S}_k (\tilde{S}_k)^T + \tilde{S}_k N^T + N (\tilde{S}_k)^T + NN^T] \end{aligned} \quad (19)$$

由于子块结构和噪声不相关, 因此式(19)中  $\tilde{S}_k N^T$  和  $N (\tilde{S}_k)^T$  接近于零矩阵,  $\Omega_{\tilde{S}_k^N}$  可简化为:

$$\begin{aligned} \Omega_{\tilde{S}_k^N} &= \frac{1}{m} \tilde{S}_k^N (\tilde{S}_k^N)^T = \frac{1}{m} [(\tilde{S}_k + N)(\tilde{S}_k + N)^T] \\ &= \frac{1}{m} [\tilde{S}_k (\tilde{S}_k)^T + \tilde{S}_k N^T + N (\tilde{S}_k)^T + NN^T] \end{aligned}$$

$$\Omega_{\tilde{S}_k^N} = \frac{1}{m} [\tilde{S}_k (\tilde{S}_k)^T + NN^T] = \Omega_{\tilde{S}_k} + \Omega_N \quad (20)$$

根据噪声的统计特性可知,  $\Omega_N$  为对角矩阵:

$$\Omega_N = \sigma^2 I \quad (21)$$

其中  $I$  是单位矩阵,  $\sigma^2$  表示噪声方差。

$\Omega_{\tilde{S}_k^N}$  可分解成:

$$\Omega_{\tilde{S}_k^N} = \Phi_{\tilde{S}_k^N} \Lambda_{\tilde{S}_k^N} \Phi_{\tilde{S}_k^N}^T \quad (22)$$

$\Lambda_{\tilde{S}_k^N}$  是一个对角向量矩阵,  $\Phi_{\tilde{S}_k^N}$  是一个  $m \times m$  正交矩阵。

根据  $\Phi_{\tilde{S}_k} \Phi_{\tilde{S}_k}^T = I$ ,  $\Omega_N$  可以表示为:

$$\Omega_N = (\sigma^2 I) \Phi_{\tilde{S}_k} \Phi_{\tilde{S}_k}^T \quad (23)$$

由式(20)、式(22)和式(23)得到:

$$\Phi_{\tilde{S}_k^N} \Lambda_{\tilde{S}_k^N} \Phi_{\tilde{S}_k^N}^T = \Omega_{\tilde{S}_k^N}$$

$$\Phi_{\tilde{S}_k^N} \Lambda_{\tilde{S}_k^N} \Phi_{\tilde{S}_k^N}^T = \Omega_{\tilde{S}_k} + \Omega_N$$

$$\Phi_{\tilde{S}_k^N} \Lambda_{\tilde{S}_k^N} \Phi_{\tilde{S}_k^N}^T = \Phi_{\tilde{S}_k} \Lambda_{\tilde{S}_k} \Phi_{\tilde{S}_k}^T + (\sigma^2 I) \Phi_{\tilde{S}_k} \Phi_{\tilde{S}_k}^T \quad (24)$$

$$\Phi_{\tilde{S}_k^N} \Lambda_{\tilde{S}_k^N} \Phi_{\tilde{S}_k^N}^T = \Phi_{\tilde{S}_k} [\Lambda_{\tilde{S}_k} + (\sigma^2 I)] \Phi_{\tilde{S}_k}^T$$

从式(2)一式(24)可以推出:

$$\Phi_{\tilde{S}_k} \equiv \Phi_{\tilde{S}_k^N} \quad (25)$$

式(25)表明主分量对噪声不敏感。

### 3 基于方向结构的 RPCA 图像去噪

该算法首先对图像进行无重叠的分块, 分成尺寸为  $m \times m$  的子块  $x(i, j)$ , 计算子块均值  $\mu_x$ :

$$\mu_x = \frac{1}{m^2} \sum_{i=0}^{m-1} \sum_{j=0}^{m-1} x(i, j) \quad (26)$$

根据结构信息主要表现为像素的变化, 提取子块结构  $\hat{x}(i, j)$ :

$$\hat{x}(i, j) = x(i, j) - \mu_x \quad (27)$$

分析子块结构的能量:

$$\sigma_x^2 = \frac{1}{m^2} \sum_{i=0}^{m-1} \sum_{j=0}^{m-1} \hat{x}^2(i, j) \quad (28)$$

依据子块能量判断其是否含有局部结构信息。如果  $\sigma_x^2 \leq \Delta$ , 则表示该块来自于图像的平滑区域, 对其进行 DCT 变换去噪; 反之来自于图像纹理或边缘区域, 对其采用鲁棒主成分分析算法进行去噪。

本文对噪声图像子块结构进行模式判别, 选用最小欧氏距离对子块进行模式识别, 假设结构子块  $\hat{x}(i, j)$  属于  $k$  类结构信息:

$$k = \arg \min_l \left\{ \sum_{i=0}^{m-1} \sum_{j=0}^{m-1} [\hat{x}(i, j) - \hat{\mu}_l(i, j)]^2 \right\}, l = 0, 1, \dots, M \quad (29)$$

通过式(29)得到结构信息子块  $\hat{x}(i, j)$  所属的结构基元库, 将结构信息  $\hat{x}(i, j)$  向该类结构信息稀疏表示的特征空间  $\Phi_k$  进行投影得到  $\lambda_{\hat{x}}$ :

$$\lambda_{\hat{x}} = (\hat{x} - \mu_k)^T \Phi_k \quad (30)$$

从训练库中挖掘特征向量仅仅表示了该类结构的主要能

量,将有噪声子块投影到特征空间, $\lambda_{\Delta}$  只能反映出该块的主要结构信息,噪声在该空间中不能或者不完全表现出来。去噪后结构子块为:

$$\hat{y} = \hat{\mu}_k + \lambda_{\Delta} \Phi_k \quad (31)$$

去噪后图像子块的像素值为:

$$y(i, j) = \hat{y}(i, j) + \mu_{\epsilon} \quad (32)$$

## 4 实验结果及分析

### 4.1 训练集的选择

尽管图像的内容千差万别,但人体视觉系统使用稀疏编码策略来代表图像,也就是说视觉系统总能从一个完备代码集中选出少量的基函数对图像内容进行有效地表示。本文在实验中采用两种内容完全不同的训练图像集合,每个集合由5幅高质量边缘纹理较丰富的图像(来源于 Internet)组成,如图2所示。从每个训练图像的集合中随机分割出一个大小为 $7 \times 7$ ,总数为627815的块,通过 $k$ 均值聚类得到合适的组数,最终得到128个结构类别。




图2 不同训练集

为了测试不同训练集对图像稀疏表示的影响,同时验证内容千差万别的图像可由有限的结构基元表示,本文对结构方向较复杂的原始图像(见如图2(a))迭加上不同的高斯噪声,运用不同的训练集(见图3)对含噪图像进行去噪处理。从图像整体质量上看,训练集对图像去噪质量影响不大,也表明了图像结构基元的有限性。从图像的细节来看,两种训练集的结构基元对尺度较大的边缘和纹理信息保护较好,对尺度较小的边缘和纹理均存在一定程度的模糊。

为了进一步验证不同训练集提取的结构基元对去除噪声的影响,本文分别对“Lena”、“Peppers”和图3(a)迭加不同的高斯噪声,两种训练集的结构基元部分结果如表1所列。两种训练集得到的结构基元去噪结果最大峰值信噪比的绝对差值为0.62dB,这表明了虽然图像的内容千变万化,但表征内容的结构基元是有限的。

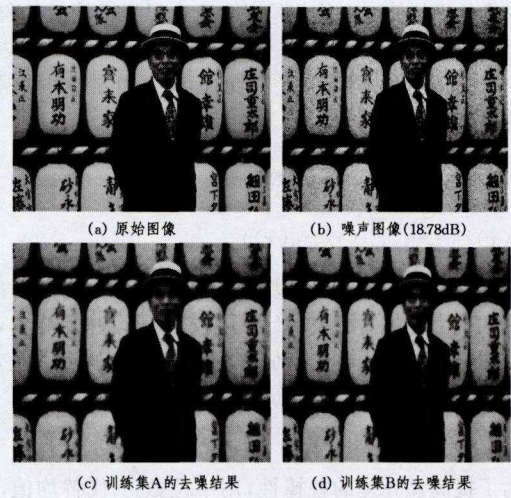


图3 不同训练集的去噪结果

表1 不同训练集的部分去噪结果

原始图像	含噪图像 (dB)	训练集 A (dB)	训练集 B (dB)	绝对差值 (dB)
Lena	22.19	29.54	29.77	0.23
	20.99	28.80	29.08	0.28
	17.14	26.33	26.02	0.31
	15.36	23.81	24.43	0.62
	12.29	21.99	21.61	0.32
Peppers	14.08	18.72	18.89	0.17
	12.91	16.57	16.11	0.46
	11.90	15.28	15.67	0.39
	10.06	15.04	15.09	0.05
	9.75	13.78	13.33	0.45
图3(a)	20.78	29.75	29.67	0.08
	19.02	27.84	27.53	0.31
	15.35	24.99	24.83	0.16
	13.05	21.76	20.51	0.25
	11.95	17.60	18.08	0.48

### 4.2 与传统方法之比较

为了验证本文算法的去噪效果,分别对各类图像加入不同强度的高斯白噪声,运用各向同性的高斯平滑算法、基于内容的PCA<sup>[11]</sup>算法和各向异性的传统TV算法<sup>[12]</sup>进行去噪处理,并与不同算法进行比较分析。

表2 不同算法的去噪结果

原始图像	含噪图像 (dB)	高斯平滑 (dB)	传统TV (dB)	PCA (dB)	本文算法 (dB)
Lena	24.29	25.54	27.17	27.34	29.58
	22.51	24.80	26.08	26.87	28.67
	19.14	21.33	24.72	25.68	26.89
	18.36	20.81	24.13	25.21	25.94
	17.29	19.39	23.61	24.96	25.34
Peppers	12.18	14.75	17.89	22.78	25.02
	11.19	13.57	16.11	21.37	24.75
	10.09	12.28	14.67	18.67	23.08
	9.06	11.14	13.09	17.07	21.85
	8.75	10.78	12.33	14.11	19.19
baboon	18.21	19.75	21.67	26.11	28.79
	16.02	17.84	20.13	22.31	22.47
	15.35	16.99	17.13	20.02	20.60
	14.05	15.76	16.51	17.23	17.32
	12.95	13.60	15.78	16.12	16.43

本文方法对边缘较明显的“Lena”和“Peppers”图像去噪效果相对于高斯平滑、传统TV和PCA效果较好,高斯平滑对边缘和纹理均存在一定程度的损失,传统TV算法虽具有

一定的保边性,但仍然存在平滑。传统 PCA 算法由于没有考虑结构信息的方向,对部分结构信息进行了平滑。“baboon”图像的纹理较多,并且纹理结构的方向较复杂,所以本文算法和传统 PCA 去噪结果差异不大。

**结束语** 本文从图像稀疏表示的角度出发对图像进行处理,将图像结构相似看作来自同一总体的非平稳随机信号,建立图像结构信息库,对图像结构信息库进行统计分析,挖掘结构相似信号稀疏表示的变换核函数,使其变换核随着结构信息变化而不同,提出了基于方向结构信息的 RPCA 图像去噪方法。从理论上分析噪声和结构信息在核变换空间的分布情况,自适应确定阈值。实验结果表明,本文所提出的算法相对于高斯平滑、传统 TV 和 PCA 等图像去噪算法,去噪后图像的整体质量与传统算法差异不大,但在结构信息保护方面优于传统算法。本算法由于变换核函数依赖于结构信息的方向,在去除图像噪声的同时能有效保护图像结构信息。

## 参考文献

[1] Stanimirova I, Walczak B, Massart DL, et al. A three-way method for data analysis[C]// Application to environmental data, Chemometrics and Intelligent Laboratory Systems. 2004(73):219-233

[2] 黄宝贵,马春梅,卢振泰. 新的形态学图像降噪方法[J]. 计算机应用,2011(3):757-759

[3] Tatsuoka K S, Tyler D E. The uniqueness of S and M-functionals under non-elliptical distributions[C]// The Annals of Statistics. 2000,28:1219-1243

(上接第 292 页)

法、PSO+EM 算法<sup>[15]</sup>和文献[12]中算法的结果。上述结果表明,将本文所提出的方法用于户外场景的地形分类是可靠有效的,并且在 GMM 的参数估计中改进的混合 PSO 算法较其它已有算法能较好地改善优化性能。

## 参考文献

[1] Christopher A B, Karl I. Self-supervised terrain classification for planetary surface exploration rovers[J]. Journal of Field Robotics, 2012, 29(3):445-468

[2] Marcel H, Marc A, Nicolai W, et al. Probabilistic terrain classification in unstructured environments[J]. Robotics and Autonomous Systems, 2013, 61(10):1051-1059

[3] Nguyen D V, Kuhnert L, Jiang T, Kuhnert, et al. A novel approach of terrain classification for outdoor automobile navigation [C]// Proceedings of the 2011 IEEE International Conference on Computer Science and Automation Engineering. 2011, 3:609-616

[4] Rana H, Adrian P, Carlos E O, et al. A support vector machine for terrain classification in on-demand deployments of wireless sensor networks[C]// Proceedings of the 2013-7th Annual IEEE International Systems Conference. 2013:841-846

[5] Haselich M, Eggert S, Paulus D. Parallelized Energy Minimization for Real-Time Markov Random Field Terrain Classification in Natural Environments[C]// Proceedings of the 2012 IEEE International Conference on Robotics and Biomimetics. 2012

[6] Thomas J P, Keith C C, William A M, et al. An improved simple morphological filter for the terrain classification of airborne LIDAR data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 77:21-30

[4] 焦峰,毕硕本,赵英男,等. 基于自相似性和小波分析的图像增强与去噪[J]. 计算机科学, 2010, 37(10):242-245

[5] Hubert M, Rousseeuw P J, Verboven S. fast method for robust principal components with application to chemo metrics[C]// Chemometrics and Intelligent Laboratory Systems, 2002, 60:101-111

[6] Croux C, Ruiz-Gazen A. High breakdown estimators for principal components: the projection-pursuit approach revisited[J]. Journal of Multivariate Analysis, 2005, 67(4):206-226

[7] 焦李成. 图像多尺度几何分析理论与应用[M]. 西安:西安电子科技大学出版社, 2008

[8] Peña D, Prieto F J. Multivariate outlier detection and robust covariance estimation[C]// Technometrics. 2001, (41):286-300

[9] 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):1129-1159

[10] Askari E, Moghadam A M E. A fuzzy measure for objective evaluation of interactive image segmentation algorithms[C]// IEEE International Conference on Signal and Image Processing Applications (ICSIPA). 2011:260-264

[11] Jia R Q, Zhao H. A fast algorithm for the total variation model of image denoising[J]. Advances in Computational Mathematics, 2010, 33(2):231-241

[12] Zhang Lei, Dong Wei-sheng, Zhang D. Two-stage image denoising by principal component analysis with local pixel grouping [J]. Pattern Recognition, 2010, 43(4):1531-1549

[7] Li W, Prasad S, Fowler J E. Hyperspectral Image Classification Using Gaussian Mixture Models and Markov Random Fields [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 11(1):153-157

[8] Al-Jubouri, H, Du H, Sellaheewa H. Applying Gaussian mixture model on discrete cosine features for image segmentation and classification[C]// Proceedings of the 2012 Computer Science and Electronic Engineering Conference. 2012:194-199

[9] Manduchi R. Obstacle detection and terrain classification for autonomous off-road navigation[J]. Autonomous Robots, 2005, 18(1):81-102

[10] 韩光. 面向非结构环境图像理解的算法研究[D]. 南京:南京理工大学, 2010

[11] Eberhart R C, Shi Y. Particle swarm optimization: Developments, applications and resources[J]. The 2001 Congress on Evolutionary Computation, Seoul, Korea, IEEE Press, 2001(1):81-86

[12] 陈允杰, 张建伟, 韦志辉, 等. 基于高斯混合模型的活动轮廓模型脑 MRI 分割[J]. 计算机研究与发展. 2007, 44(9):1595-1603

[13] 高尚, 韩斌, 吴小俊, 等. 求解旅行商问题的混合粒子群优化算法[J]. 控制与决策, 2004, 19(11):1286-1289

[14] Castano R, Manduchi R, Fox J. Classification experiments on real-world texture[C]// Proceedings of the Third Workshop on Empirical Evaluation Methods in Computer Vision. Pasadena, CA: Jet Propulsion Laboratory, 2001:3-20

[15] Fan S, Lin Y. A multi-level thresholding approach using a hybrid optimal estimation algorithm[J]. Pattern Recognition Letters, 2007, 28(5):662-669

[16] Kim S C, Kang T J. Texture classification and segmentation using wavelet packet frame and Gaussian mixture model[J]. Pattern Recognition, 2007, 40(4):1207-1221