

• 多媒体技术 •

基于 l^∞ 范数的稀疏 ICA 和 FCM 的自然图像特征提取

尚 丽¹, 杜吉祥^{2,3,4}

(1. 苏州市职业大学 电子信息工程系, 江苏 苏州 215104; 2. 中国科学技术大学 自动化系, 安徽 合肥 230026; 3. 中国科学院 合肥智能机械研究所, 安徽 合肥 230031; 4. 华侨大学 计算机科学与技术系, 福建 泉州 362021)

摘 要: 为了保证图像特征系数的稀疏性和加快寻找最优基的收敛速度, 提出了一种基于 l^∞ 范数的稀疏独立分量分析(SICA)的算法。该 SICA 算法采用 l^∞ 范数作为 ICA 的稀疏性度量标准, 用模糊 C 均值聚类算法初始化独立分量的特征基, 有效地实现了自然图像的特征提取; 而且, 该 SICA 方法不需要优化高阶的非线性函数和密度估计, 因而计算简单、且收敛速度较快; 同时, 利用提取的图像特征成功地实现了图像恢复, 通过图像恢复对比实验表明了该方法在特征提取方面的合理性和实用性。

关键词: 独立分量分析; l^∞ 范数; 模糊 C 均值聚类; 自然图像; 特征提取

中图分类号: TN911.73 文献标识码: A 文章编号: 1000-7024(2010)04-0783-05

Image feature extraction based on sparse ICA with l^∞ norm and FCM

SHANG Li¹, DU Ji-xiang^{2,3,4}

- (1. Department of Electronic Information Engineering, Suzhou Vocational University, Suzhou 215104, China;
2. Department of Automation, University of Science and Technology of China, Hefei 230026, China;
3. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031, China;
4. Department of Computer Science and Technology, Huaqiao University, Quanzhou 362021, China)

Abstract: To ensure the sparsity of image feature coefficients and improve the convergence speed of finding the optimized features, a method of sparse independent component analysis (SICA) based on l^∞ norm is proposed. Features of natural images is extracted efficiently by this SICA algorithm, which utilizes the l^∞ norm as the sparse measurement criterion of ICA and the fuzzy C-mean clustering (FCM) method to initialize feature basis vectors of independent components. Moreover, this SICA method does not need optimizing the high-order non-linear functions and density estimation, therefore, it is very simple in computing and its convergent speed is also very quick. At the same time, the image restoration work is successfully implemented by using these features extracted. Further, compared with other methods of image restoration, the experimental results testify that this feature extraction is also reasonable and practical in application.

Key words: independent component analysis; l^∞ norm; fuzzy C-mean clustering; natural images; feature extraction

0 引 言

人类视觉系统对自然图像的表达采用的是稀疏编码模型^[1-5], 而使用独立分量分析^[6-7](independent component analysis, ICA)方法进行自然图像特征提取后得到的系数也恰恰具有稀疏分布的形式, 符合人眼视觉系统模型^[8-9]。而且, 将 ICA 算法用于自然图像的特征提取时, 所得到的 ICA 基函数在变换域中具有局部性、带通性和方向性, 对不同方向的细节特别敏感, 较好地符合人眼视觉的生理特性, 而其叠加系数可同时实现图像的稀疏编码。换句话说, 当 ICA 用于处理自然图像时,

ICA 就是一种稀疏编码算法^[2,5], 所以, 其对比函数的优化问题应该是解决最大化稀疏性的问题^[5,10]。目前以最大化稀疏性为目的 ICA 方法大多数采用最大化非高斯性的稀疏性度量准则。

本文则以 l^∞ 范数作为 ICA 算法稀疏性度量的标准^[10], 在此基础上提出了一种稀疏独立分量分析(sparse independent component analysis, SICA)方法。该 SICA 方法可以同时保证图像特征系数的独立性和稀疏性; 同时, 采用模糊 C 均值算法初始化 ICA 的特征基矩阵, 提高了该 SICA 算法的收敛速度。仿真实验分析表明, 该 SICA 算法能够有效地提取自然图像的特

收稿日期: 2009-03-11; 修订日期: 2009-05-14。

基金项目: 江苏省“青蓝工程”基金项目(QL08030); 国家自然科学基金项目(60805021、60970058); 中国博士后科学基金项目(20060390180、200801231); 福建省自然科学基金项目(A0810010、A0740001); 江苏省自然科学基金项目(BK2009131)。

作者简介: 尚丽(1972-), 女, 安徽砀山人, 博士, 副教授, 高级工程师, 研究方向为人工智能和数字图像处理; 杜吉祥(1977-), 男, 山东高唐人, 博士, 硕士生导师, 研究方向为图像处理、模式识别和机器学习。E-mail: sl0930@jssvc.edu.cn

征,进一步地,和使用最大化非高斯性作为对比函数的ICA方法相比,本文提出的基于SICA算法的自然图像特征提取方法是可行的、有效的。

1 l^p 范数稀疏性度量标准

稀疏度量标准一般被定义为下式^[5]

$$\text{Sparse}(u) = -\sum_i S(u_i) \quad (1)$$

式中: $\text{Sparse}(u)$ 被定义为随机矢量 u 的稀疏性;稀疏惩罚函数 $S(u_i)$ 是一个非线性函数, u_i 是随机矢量 u 中的第 i 个变量。Olshausen和Field建议函数 $S(u_i)$ 应该采用一个偶的非负函数,例如 $-e^{-u_i^2} \log(1+u_i^2)$ 或 $|u_i|$ 。

直观地说,随机矢量 u 中的非零元素(神经元)越多(即活动的神经元越多), $\sum_i S(u_i)$ 的值越大,而稀疏性越小。这样,最大化等式(1)即等于最大化稀疏性。

Karvanen和Cichocki则提出了如下的基于 l^p 范数的稀疏性度量标准^[6]

$$\text{Sparse}(u) = -E\left\{\left(\sum_i |u_i|^p\right)^{\frac{1}{p}}\right\} \quad (2)$$

显然,当 $p=1$ 时,等式(1)中Olshausen和Field提出的稀疏性度量标准是 l^p 范数的一个特殊形式,此时稀疏惩罚函数为 $S(x)=|x|$ 。当 $p=4$ 时, l^p 范数则和广泛使用的非高斯性度量标准——峭度相联系,当随机矢量 u 具有零均值和单位方差时,峭度的公式为 $\text{Kurt}(u) = E\{u^4\} - 3$ 。

p 的范围选择为(0,1],特别地,应该选择一个较小的 p 值,如 $p=0.1$ 或 $p=0.01$ 。

但是,当 $p \rightarrow \infty$ 时, l^p 范数同样可以提供一个好的稀疏性度量。假设我们已知两个独立的随机矢量的联合分布,而且每一个矢量具有Laplace先验分布,每一个样本通过使用一个旋转矩阵进行旋转。旋转样本的 l^p 范数的均值很容易计算得到,图1给出了具有不同旋转角度的样本在不同 p 值下的 l^p 范数的均值。

从图1中可以明显看出 l^p 范数是一条直线,这是因为旋转并不会改变Euclidean距离。 l^p 范数曲线的极值在 l^p 范数的两边是反向的。然后,为了找到独立的成分(此时独立成分的方向在 20° 和 110° 之间),我们需要找到满足 $p < 2$ 的 l^p 范数的极小值和满足 $p > 2$ 的 l^p 范数的极大值。必须注意,上述的情况仅对超高斯对称分布的数据是有效的。另外,从图1中可以看出,除了 l^p 范数以外,所有的范数曲线具有一致的最佳位置,但是,在噪声存在的情况下,在最大值和最小值之间有较大偏差的范数曲线将具有更强的鲁棒性,因此 p 的选择可以接近于零或接近无穷大。

如果令 $p \rightarrow \infty$ $\left(\sum_i |u_i|^p\right)^{\frac{1}{p}}$ 的极限为

$$\lim_{p \rightarrow \infty} \left(\sum_i |u_i|^p\right)^{\frac{1}{p}} = \max_i \{ |u_i| \} \quad (3)$$

这种处理使计算过程大大简化,而且无穷大范数的梯度也有一个简化的形式,因此,当利用 l^p 范数稀疏性度量标准作为优化问题的目标函数时,优化问题的求解过程也是相对易于实现的。

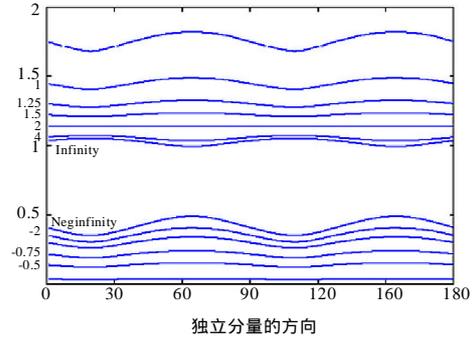


图1 不同 p 值下的 l^p 范数的均值

2 以 l^p 范数为稀疏性度量标准的ICA算法

2.1 目标函数

当使用 l^p 范数作为稀疏性度量标准时,所构造的目标函数 $J(u)$ 的简化形式为

$$J(u) = E\left\{\lim_{p \rightarrow \infty} \left(\sum_i |u_i|^p\right)^{\frac{1}{p}}\right\} = E\{\max_i \{ |u_i|^2 \}\} \quad (4)$$

这样,最大化式(4)就相当于解决最大化稀疏性的优化问题,式(4)的随机矢量 u_j 就代表稀疏分量,而在ICA模型中, u_j 即代表独立的源信号。为了便于计算,令 $|u_j|^2 = (w_j^T X)^2$,其中 w_j 是 $n \times m$ 维分离矩阵 $W = [w_1, w_2, \dots, w_m]$ 的第 j 列, $X = [x_1, x_2, \dots, x_n]^T$ 是 n 维混合信号, u_j 是 m 维矩阵 $U = [u_1, u_2, \dots, u_m]^T$ 中的第 j 行源信号。则式(4)可以被写成如下形式

$$J(W) = E\{\max_j [(w_j^T X)^2]\} = \max_j [(w_j^T X)^2] p(x) dx \quad (5)$$

因此,求解式(4)的最大优化问题就转化为求解使式(5)最大化的最优权值矩阵 W 的问题。在求解过程中遇到的一个难题是由最大化函数 $\max_j [(w_j^T X)^2]$ 导致的不连续性问题,然而,利用 $\max_j \{ |u_j| \} = \lim_{p \rightarrow \infty} \left(\sum_j |u_j|^p\right)^{\frac{1}{p}}$ 的关系,可以避免这个问题。令 $c = \arg \max_j [(w_j^T X)^2]$,此式即定义了一个竞争的学习过程,此时ICA算法的目的是找到赢家(Winner) w_c ,然后利用此权值 w_c 进行权值矩阵 W 的更新。又最大化部分 $\max_j [(w_j^T X)^2]$ 可以写为如下形式

$$(w_c^T X)^2 = \max_j (w_j^T X)^2 = \lim_{r \rightarrow \infty} \left[\sum_j (w_j^T X)^{2r} \right]^{\frac{1}{r}} \quad (6)$$

式中:令 $Q = \sum_j (w_j^T X)^{2r}$,则有 $(w_c^T X)^2 = \lim_{r \rightarrow \infty} Q^{\frac{1}{r}}$ 成立。

2.2 基于遗忘均值的权值更新规则

使用标准的自然梯度下降算法求解式(5)的最优化问题,则有

$$\frac{\partial J}{\partial w_j} = \int \lim_{r \rightarrow \infty} \left\{ \frac{\partial \left[\sum_j (w_j^T X)^{2r} \right]^{\frac{1}{r}}}{\partial w_j} \right\} p(x) dx = \int \lim_{r \rightarrow \infty} \frac{\partial Q^{\frac{1}{r}}}{\partial w_j} p(x) dx \quad (7)$$

由于 $Q = \sum_j (w_j^T X)^{2r}$,则 $\partial Q / \partial w_j = 2r (w_j^T X)^{2r-1} X$,故 $\partial Q^{1/r} / \partial w_j$ 推导如下

$$\frac{\partial Q^{\frac{1}{r}}}{\partial w_j} = \frac{1}{r} Q^{\frac{1}{r}-1} \cdot \frac{\partial Q}{\partial w_j} = 2 Q^{\frac{1}{r}-1} \cdot \frac{(w_j^T X)^{2r-1}}{Q} X \quad (8)$$

式(8)即是权值 W 的更新规则。

由于 $\lim_{r \rightarrow \infty} [(w_j^T X)^{2r-1} / Q] = \delta_{ij} (w_j^T X)^{-1}$ 成立,其中 δ_{ij} 是Kronecker变

量的增量,当 $c=j$ 时 $\delta_{c_j}=1$;反之 $\delta_{c_j}=0$ 。把上述关系代入式(8)并取 $r \rightarrow \infty$ 的极限,则得到下式

$$\lim_{r \rightarrow \infty} \frac{\partial Q_r}{\partial w_j} = 2\delta_{c_j}(w_j^T x) x \quad (9)$$

假设 $(w_j^T X)X$ 是一个“观测量”,其中约束条件是 $w_i = 1$ 。这种假设的目的是在递增估计 w_i 的情况下得到观测量的均值。因此,我们可以通过观测量 $(w_j^T X)X$ 的采样均值来估计一个独立向量 w_i ,而且样本均值使用一个批处理的方法。对递增估计的权值矩阵 W 而言,在 W 被连续增加时,我们使用一个所谓的遗忘均值作为动态的学习速率来实现权值矩阵 W 的更新过程。假设 x_k 是第 k 个采样样本, \bar{x}_k 表示第 k 次迭代的样本均值,则有

$$\bar{x}_k = \alpha(k)\bar{x}_{k-1} + \beta(k)x_{k_0} \quad (10)$$

式中 $\alpha(k)$ $\beta(k)$ 被称为遗忘权值,分别被定义如下

$$\begin{cases} [k-1-\mu(k)]/k \\ \beta(k) = 1+\mu(k)/k \end{cases} \quad (11)$$

式中 $\mu(k)$ ——一个较小的非负值,被称为遗忘参数^[6]。此参数为在 $t=k$ 采样时刻得到的新观测量 x_{k_0} 提供更大的权值,而使在 $t=k$ 时刻之前得到的样本均值的影响逐渐减弱或消失。一般情况下 $\mu(k)$ 按照下列规定选取

$$\begin{cases} 0 & i < k_1 \\ 2(i-k_1)/(k_1-k_2) & k_1 \leq i < k_2 \\ 2+(i-k_2)/m & i \geq k_2 \end{cases} \quad (12)$$

式中 i ——在选取第 k 个观测量(即第 k 次迭代)时由关系式 $|W^T X(:,k)|$ 计算得到的列向量中的最大元素所对应的行标号,而且符号 i 的最大值对应独立分量的数目 k_1 、 k_2 和 m 是任意设定的正整数。

根据权值矩阵的更新规则式(8)和遗忘均值的定义式(10),则基于遗忘均值的权值矩阵 W 的更新规则定义如下

$$w_j(k+1) = \alpha(k)w_j(k) + \beta(k) \frac{w_j(k)^T v_i}{w_j(k)} v_i \quad (13)$$

式中 k ——当前的迭代次数; $w_j(k)$ ——第 k 次迭代得到的权值向量 w_j ,其下标 j 对应向量 $|w_j(k)^T v_i| / |w_j(k)|$ 中的最大值所对应的索引号 $\alpha(k)$ 和 $\beta(k)$ 根据式(9)式(11)确定, v_i 是当前使用的第 i 个白化样本(即是白化矩阵 W 的第 i 列)。

3 基于 FCM 初始化的 ICA 特征基

应用 ICA 算法提取自然图像的特征时,ICA 可看成是一种聚类算法,训练得到的特征基函数必将指向各个类的中心,这样提取的特征有利于识别过程。那么,如果能对特征基函数设置一个利于聚类的初始值,就能得到一组分类能力更强的特征。

为了达到这个目的,可利用模糊 C 均值(fuzzy C-means, FCM)算法来初始化特征基函数。FCM 算法的目的是把 n 个样本划分成 c 个类别,使

$$J_f = \sum_{j=1}^c \sum_{i=1}^n [\mu_j(x_i)]^b |x_i - m_j|^2$$

所定义的聚类损失函数达到最小。其中 x_i ($i=1, 2, 3, \dots, n$) 是 n 个样本组成的样本集合, c 是预定的类别数目, m_j 是每个聚类的中心, $\mu_j(x_i)$ 是第 i 个样本对第 j 类的隶属度函数,它要求一个样本对各个聚类的隶属度之和为 1,即

$$\sum_{j=1}^c \mu_j(x_i) = 1 \quad i = 1, 2, 3, \dots, n \quad (14)$$

令 J_f 对 m_j 和 $\mu_j(x_i)$ 的偏导为 0,可得到必要条件

$$m_j = \frac{\sum_{i=1}^n [\mu_j(x_i)]^b x_i}{\sum_{i=1}^n [\mu_j(x_i)]^b} \quad j = 1, 2, 3, \dots, c \quad (15)$$

$$\mu_j(x_i) = \frac{(1/|x_i - m_j|^2)^{1/(b-1)}}{\sum_{k=1}^c (1/|x_i - m_k|^2)^{1/(b-1)}} \quad (16)$$

式中 $i=1, 2, 3, \dots, n$ $j=1, 2, 3, \dots, c$ 。用迭代法求解式(15)和(16) FCM 算法的步骤如下:

- (1) 设定聚类数目 c 和参数 b ;
- (2) 初始化各个聚类中心 m_j ;
- (3) 重复下面的运算,直到各个样本的隶属度值稳定:用当前的聚类中心根据式(16)计算隶属度函数,用当前的隶属度函数按照式(15)更新计算各类聚类中心。

当算法收敛后,把得到的各个聚类中心作为 ICA 算法特征基函数的初始值。对此特征基函数求其逆阵(或伪逆阵),即得到分离矩阵 W 的初始值。

4 实验结果分析

4.1 特征基函数

实验中随机选取 10 幅尺寸相同的测试图像,采用子图像块分割的方法,把每一幅图像随机分割成 10 000 个 8×8 像素的子图像,组成一个 64 维的训练数据集 X 。采用主分量分析(PCA)的方法对图像数据进行预处理。用输入数据 X 作为 FCM 算法的样本集合进行训练,得到的聚类中心作为本文 ICA 算法的初始特征基函数,其逆阵或伪逆阵即是 ICA 算法的初始权值矩阵 W 。

使用该矩阵 W 作为基于 l^∞ 范数的稀疏 ICA 算法的初始权值矩阵,训练得到的特征基函数如图 2 所示。可以看到,迭代过程中获得了具有各种方向、方位和尺度的类似于 Gabor 特征基的函数。这与文献[2, 5-7]所得到的特征基函数相比,这些基函数表现出的特性和主视觉皮层 V1 区简单细胞的感受野特性是一致的。由此也证明了本文所提出的 ICA 算法作为视觉皮层简单细胞工作机制的模型是可行的。

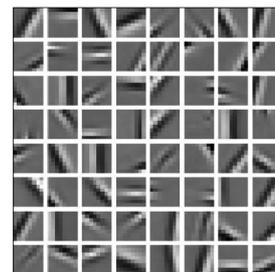


图 2 使用基于 l^∞ 的稀疏 ICA 算法得到的 ICA 特征基

4.2 图像恢复

选择如图 3 所示的一幅自然图像作为测试图像。图像大小为 256×512 pixels。对测试图像采用图 2 的特征基向量进行图像恢复实验。为了保证图像像素坐标的正确性,对每一幅子图像的位置必须加以记录,同时采用所有恢复像素的平均



图3 原始自然图像

值作为该位置上的像素灰度值。

在图3的自然图像中分别随机采样3 000、5 000、10 000、15 000、20 000、...、50 000个8(8像素的子图像块,就得到几个不同的输入数据集合;然后利用图2得到的基图像进行图像恢复,对应不同的图像块,进行图像恢复所得到的部分实验结果如图4所示。由图4可以看出,图像块数为3 000、5 000、10 000、15 000时,重构的图像不是很清晰,有些区域不能够恢复;当图像块数超过20 000时,图像的主要内容都能得到恢复。而且图像块数越多,恢复效果越清晰。当图像块数为50 000时,可以看到,重构的图像目视效果非常接近原始图像。因此,该图像恢复实验证实了基于 l^∞ 的SICA算法能够成功地提取自然图像的特征。

针对图3的原始图像,采用相同的图像预处理方式,在相同的实验条件下,本文给出了采用标准ICA算法进行图像恢复的对比实验,以进一步说明本文提出的算法在图像恢复中的有效性。

基于标准ICA算法的图像恢复结果如图5所示。对比图4和图5,可以得到相似的实验结论,即随着子图像的增多,基于ICA的图像恢复效果从目视效果上越来越好。当图像块数为50 000时,从目视效果很难区分重构的图像和原始图像。因此,仅从主观上很难区分图3和图4(h)、图5(h)的优劣,故文中借助逼真度的概念来验证提出的ICA算法处理的效果以及和标准ICA算法进行对比的实验结果。

在图像处理中,通常采用均方差(mean square error, MSE)、信噪比(signal noise ratio, SNR)和峰值信噪比(peak signal noise ratio, PSNR)等作为处理后图像质量的客观评价标准。本文采

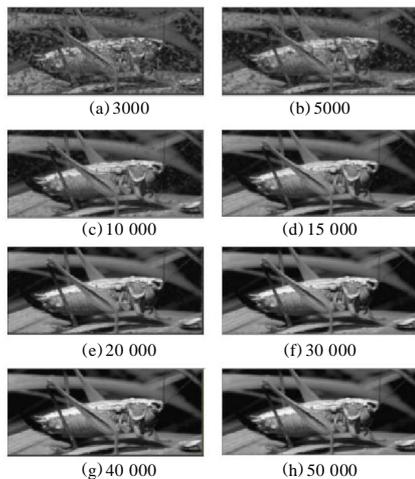
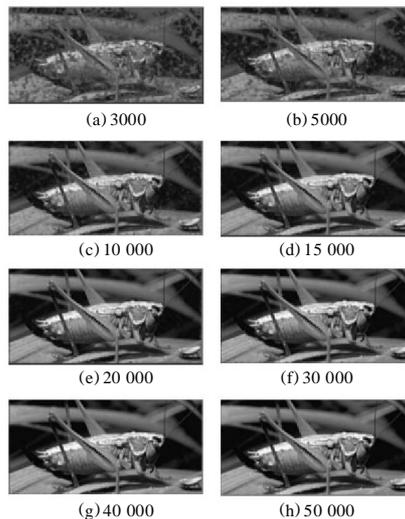
图4 不同图像块数时,利用基于 l^∞ 的稀疏ICA法得到的重构图像

图5 不同图像块数时,利用基于标准ICA法得到的重构图像

用SNR评价标准。假设输入图像为 $f(x, y)$,输出图像为 $\hat{f}(x, y)$,两幅图像大小均为 $M \times N$,则SNR的定义如下

$$SNR = 10 \log \frac{\sum_{x=1}^M \sum_{y=1}^N \hat{f}(x, y)^2}{\sum_{x=1}^M \sum_{y=1}^N [\hat{f}(x, y) - f(x, y)]^2} \quad (17)$$

根据公式(16),使用基于 l^∞ 的稀疏ICA算法和标准ICA对随机采样不同图像块数的情况计算SNR值,所得到的结果如表1所示。显然,对任一种算法而言,图像块数越多,SNR值越大,图像重构的效果就越好。而且,在子图像块数相同时,采用基于 l^∞ 的稀疏ICA算法计算得到的SNR值明显优于标准ICA算法得到的SNR值,由此证明了应用于图像重构处理时,本文提出的算法要优于标准ICA算法。另外,在实验中,我们也发现,基于 l^∞ 的稀疏ICA算法的收敛速度也比标准ICA算法稍快。

表1 不同算法对应不同图像块数的SNR值

图像块数	使用本文算法 SNR	标准ICA 算法 SNR
3 000	8.9617	8.9194
5 000	11.2176	11.1761
10 000	15.4164	15.3086
15 000	17.6838	17.3423
20 000	18.8469	18.2700
25 000	19.8105	18.9763
30 000	20.0342	19.2947
35 000	20.6669	19.5544
40 000	21.0240	19.7601
45 000	21.2412	19.8614
50 000	21.3639	19.9617

5 结束语

本文主要提出了一种基于 l^∞ 稀疏性度量准则和模糊C均值(FCM)聚类的稀疏独立分量分析(SICA)算法,并进一步探讨了该算法在自然图像特征提取中的应用。采用 l^∞ 范数作为稀

疏性度量准则可以保证独立分量系数的稀疏性;利用FCM算法初始化独立分量的特征基能够加快寻找最优特征基的速度,提高算法的收敛速度。仿真实验表明,本文提出的算法可以成功地提取出自然图像的特征,绝大部分基向量在空间频域中体现了方向性和局部性,反映出图像的边缘特性。同时,利用提取到的特征基进行自然图像重构实验,根据图像重构的目视效果和信噪比SNR数据,进一步证实了所提出的SICA算法在自然图像特征提取应用中的有效性,表明了该算法在模拟人类初级视觉系统生理特性方面的合理性和可行性,值得进一步深入研究。

参考文献:

- [1] 尚丽,郑春厚.基于稀疏编码的自然图像特征提取及去噪[J].系统仿真学报,2005,17(7):1782-1784.
- [2] 尚丽,黄德双,郑春厚.非负稀疏编码收缩法的自然图像降噪[J].中国科学技术大学学报,2006,35(5):497-501.
- [3] Shang Li.Non-negative sparse coding shrinkage for image denoising using normal inverse Gaussian density model[J].Image

and Vision Computing,2008,26(8):1137-1147.

- [4] 凌洁,刘璐,赵彩华,等.基于稀疏编码的语音增强算法研究[J].电路与系统学报,2008,13(6):136-140.
- [5] 尚丽.稀疏编码算法及其应用研究[D].合肥:中国科学技术大学,2006.
- [6] 黄启宏,王帅,刘钊,等.改进的基于独立成分分析的图像特征提取算法[J].光电工程,2007,34(1):121-125.
- [7] 陈密,恽建辉,李德仁,等.独立分量分析的图像融合算法[J].光电工程,2007,34(6):82-87.
- [8] Shi Zhen-wen,Tang Huan-wen,Tang Yi-yuan,et al.A new fixed-point algorithm for independent component analysis[J].Neuro-computing,2004,56:467-473.
- [9] 李鸿燕,郝润芳,马建芬,等.基于独立分量分析的图像增强[J].弹箭与制导学报,2007,27(5):299-302.
- [10] Shang Li,Huang De-shuang,Du Ji-xian,et al.Palmprint recognition using ICA based on winner-take-all network and radial basis probabilistic neural network[C].Lecture Notes in Computer Science.Berlin Heidelberg:Springer-Verlag,2006:216-221.

(上接第 782 页)

2.3 计 数

- (1)将二次分割得到的图像转换为灰度图像;
- (2)将(1)得到的灰度图像转化成二值图像;
- (3)去除(2)得到的二值图像中面积过小明显不属于计数目标的干扰目标;
- (4)对经(3)处理后的二值图像进行腐蚀操作,将其中的粘连目标分离;
- (5)对(4)处理后的二值图像进行膨胀操作;
- (6)对(5)处理后的二值图像中的孔洞进行填充,得到用于计数的最终二值图像;
- (7)标记(6)得到的二值图像的连通域并计数。

3 算法的实验仿真

为验证本文所提算法的有效性,选用图 1(a)所示的一幅 24 位 RGB 真彩图像作为实验用图,以对图中黄豆进行计数为例,采用 Matlab7.0 为编程工具,对本文的算法进行了实验仿真。采用本文记数算法的计数结果为 83 粒,人工计数的结果也为 83 粒,可见该算法对图 1(a)中黄豆的计数准确率为 100%,证明该算法对处理此类问题有效。

4 结束语

对图像中的某类目标实现自动计数,关键是把计数目标从原始图像中有效地分割出来。在分割时如何做到分割结果中不遗漏计数目标、不出现错误分割是本文的研究重点。经过多次实验,不断修正分割方案,提出了基于色相及灰度的彩

色图像的二次分割方案,较好地解决了彩色图像中的目标分割问题。在本文二次分割方案对图像中的目标有效分割基础之上,对分割出的图像进行腐蚀操作将图像中的粘连计数目标分离开,而后采用 Matlab 的 bwlable 函数对计数目标标记计数,达到了对目标对象精确计数的目的。

参考文献:

- [1] 基于边缘检测的多文本页图像分割方法[J].计算机工程与设计,2007,28(8):1161-1163.
- [2] 蒋小标,汤光明,徐蕾.基于模糊理论的图像分割方法[J].计算机工程与设计,2007,28(16):3940-3942.
- [3] 林开颜.彩色图像分割方法综述[J].中国图像图表学报: A 辑,2005,10(1):1-11.
- [4] 赵志峰,张尤赛.医学图像分割综述[J].华东船舶工业学院学报(自然科学版),2003,17(3):43-48.
- [5] 冈萨雷斯.数字图像处理(Matlab 版)[M].阮秋琦,译.北京:电子工业出版社,2005.
- [6] 韩晓军,苏丽,王晓明.图像处理技术用于批量产品数量自动统计[J].电子器件,2007(3):1031-1033.
- [7] 乔闹生.基于灰度空间自动阈值选取的彩色舌图像分割算法[J].陕西科技大学学报(自然科学版),2005(2):73-77.
- [8] 柯龙章.基于 DSP 的钢材实时自动计数系统设计与实现[J].湖南农机,2009(1):40-43.
- [9] 卢亚玲.基于图像处理的粮虫自动计数系统的研究[J].微机信息,2007,23(8-3):311-312.