

文章编号 1004-924X(2015)02-0550-07

纹理引导的稀疏张量表示及在肺 CT 图像中的应用

李 勇¹, 苗 壮², 王青竹^{3*}

(1. 吉林工程技术师范学院 信息工程学院, 吉林 长春 130052;

2. 吉林大学 中日联谊医院 神经外科, 吉林 长春 130033;

3. 东北电力大学 信息工程学院, 吉林 吉林 132012)

摘要: 基于张量理论在高维图像处理中的应用, 提出一种张量模式的稀疏表示方法, 以便有效地去除肺部 CT 序列图像的噪声, 增强图像的有用信息。首先, 设计了张量模式的正交匹配追踪法(TOMP)来表达稀疏系数; 构建了高维 K-奇异值分解法(HOK-SVD)用于字典更新。然后, 对张量乘法的参数进行优化, 即通过构造三维灰度共生矩阵, 建立三维纹理特征与张量乘法模式之间的数学模型。最后, 将这种方法应用于 LIDC 数据库的 150 组 CT 序列图像的预处理, 对各算法的稀疏表示效果进行评价。与当前应用的其他方法相比, 本文提出的高维 K-SVD 算法的峰值信噪比提高了 1.5%, 平均误差降低了 1.2%; 在此预处理基础上进行的图像分割结果表明: 图像的边缘偏移误差下降了 3.0%, 体积重叠率提高了 1.2%。上述结果显示基于张量的方法可以更精确地完成对三维 CT 图像序列的稀疏表示。

关键词: 计算机辅助诊疗; CT 图像; 稀疏表示; 张量理论; 灰度共生矩阵

中图分类号: R814.42; TP391 **文献标识码:** A **doi:** 10.3788/OPE.20152302.0550

Texture-guided sparse tensor representation and its application in lung CT images

LI Yong¹, MIAO Zhuang², WANG Qing-zhu^{3*}

(1. College of Information Engineering, Jilin Teachers' Institute of Engineering & Technology, Changchun 130052, China;

2. Department of Neurosurgery, China-Japan Union Hospital of Jilin University, Changchun 130033, China;

3. School of Information Engineering, Northeast Dianli University, Jilin 132012, China)

* Corresponding author, E-mail: wangqingzhu198339@163.com

Abstract: On the basis of tensor-based theory applied to the high-dimensional image processing, a tensor-based sparse representation algorithm was proposed to preprocess lung CT images and to enhance the useful information for the images. Firstly, a Tensor-based Orthogonal Matching Pursuit (TOMP) was designed for sparse representation and a Higher-order K-Singular Value Decomposition (K-HOSVD) was constructed for updating the dictionary. Then, the main parameters of the tensor multiplication was optimized. It means that the 3D gray-level co-occurrence matrix was constructed and the rela-

收稿日期: 2014-08-19; 修订日期: 2014-09-18.

基金项目: 国家自然科学基金资助项目(61301257); 吉林省科技发展计划资助项目(No. 201201107)

relationship between tensor multiplication model and texture features was established. Finally, the proposed method was used in 150 sets of lung CT images from LIDC database and the sparse representation performance of the proposed scheme was evaluated. The results from proposed algorithm show that the Peak Signal to Noise Ratio (PSNR) is increased by 1.5% and the Mean Square Error (MSE) is decreased by 1.2% as compared with that of other common schemes. Furthermore, the edge bias error is decreased by 3.0% and the volume overlap is increased by 1.2% as compared with that of pre-processing segmentation result. The conclusion indicates that the proposed algorithm is more suitable for the sparse representation of three-dimensional images.

Key words: computer-aided diagnosis; CT image; sparse representation; tensor theory; gray-level co-occurrence matrix

1 引言

计算机辅助肺部CT(Computed Tomography)诊疗中,CT图像序列的预处理是后期分割、疑似病灶提取、病灶识别的重要前提^[1]。近年来,稀疏表示方法由于具有去除噪声、增强有用信息^[2-4]的有效性能而被应用于医学图像的预处理中^[5-6]。传统稀疏表示方法是基于向量模式的,即需将二维或更高维的图像转换成一维向量进行逐个处理。这种向量化方法存在一些问题:(1)需要将矩阵逐行/列转换成为向量,这将生成过大量,难于估计且增加内存占用。(2)矩阵转换成为向量时,矩阵原有的空间关系将被破坏。

在模式识别和图像处理的其他领域,很多学者提出基于张量(大于等于二维的矩阵)理论的处理方法,并得到成功应用。这些方案可以直接处理大于等于二维的目标而且避免了从高维到一维的向量化,在提高处理精确度的同时节省了内存占用。如 Vasilescu 等人提出了著名的张量脸,并将其应用于人脸识别^[7];之后, Lu 等人提出张量模式主成分分析^[8]; Nie 等人提出张量模式线性判别分析^[9];陶大成等人提出支持张量机^[10-11];侯臣平等提出多线性支持张量机^[12]。但目前尚没有一种有效的基于张量模式的稀疏表示方法。

本文旨在引用张量理论^[13-14]构造出稀疏张量表示方法,并将其应用于肺部CT图像序列(三维图像)的预处理,以便有效去除噪声(小的病灶,血管、支气管细枝等),对进一步肺区分割的影响。文中首先将张量乘法、分解方法引入到字典学习中,构造出三维稀疏表示方法和三维字典更新方法,可以直接处理三维对象,从而避免了从三维到

一维的向量化。其次,构造了三维灰度共生矩阵,建立了三维纹理特征与张量乘法模式之间的数学模型,采用寻找最优的张量乘法模式,避免了大规模的重复计算。

2 相关理论

2.1 字典学习

对于二维原始信号 $\mathbf{Y} \in \mathbf{R}^{n \times N}$, 字典 $\mathbf{D} \in \mathbf{R}^{n \times K}$, 字典学习的目的即为寻找

$$\min_{\mathbf{D}, \mathbf{X}} \{ \|\mathbf{Y} - \mathbf{D}\mathbf{X}\|_F^2 \}, \quad (1)$$

$$\text{s. t. } \|\mathbf{x}_i\|_0 \leq T_0$$

其中: \mathbf{X} 为稀疏系数矩阵。字典学习的主要环节为以下 2 部分的交替执行:

(1) 计算稀疏系数

固定字典,更新稀疏系数矩阵 \mathbf{X} , 通常应用 OMP 方法。传统 OMP 是基于向量的,即依次处理 \mathbf{Y} 的每一列 $\{\mathbf{y}_i\}_{i=1}^N$:

①令 $k=1$, 初始残差 $\mathbf{r} = \mathbf{y}_i$, $I = \{0\}$, 寻找 $j^k = \arg\max_j |\mathbf{d}_j^T \mathbf{r}|$, 记录 $I = [I, j^k]$ 。其中 \mathbf{d}_j 是字典 \mathbf{D} 的一列。

②令 $\mathbf{a} = (\mathbf{D}(:, I))^+ \mathbf{y}_i$, 更新残差 $\mathbf{r} = \mathbf{y}_i - \mathbf{D}(:, I) \cdot \mathbf{a}$, $k = k + 1$ 。其中 $(\cdot)^+$ 表示广义逆矩阵。

重复以上步骤直至残差 \mathbf{r} 达到阈值或达到限定值。

(2) 计算字典

固定稀疏系数矩阵 \mathbf{X} , 更新字典 \mathbf{D} 。首先计算当前误差:

$$\mathbf{E}_k = \mathbf{Y} - \sum_{j \neq k} \mathbf{d}_j \mathbf{x}_j^T, \quad (2)$$

对当前误差进行奇异值分解

$$\mathbf{E}_k = \mathbf{U}\mathbf{\Delta}\mathbf{V}^T. \quad (3)$$

然后,根据 \mathbf{U} 和 \mathbf{V} 更新 \mathbf{d}_k 和 \mathbf{x}_k 。以上概念在文献[13]、[14]中有具体阐述。

2.2 张量理论

以一大小为 $I_1 \times I_2 \times \dots \times I_M$ 的 M 维张量 $\boldsymbol{\varepsilon}$ 为例,将其高维张量奇异值分解 (Higher-order Singular Value Decomposition, HOSVD) 为:

$$\boldsymbol{\varepsilon} = \mathbf{S} \times_1 \mathbf{U}^{(1)} \times_2 \mathbf{U}^{(2)} \dots \times_M \mathbf{U}^{(M)}. \quad (4)$$

令 $m \in \{1, 2, \dots, M\}$, \times_m 表示 m 模式乘法。通常这个分解过程通过下式实现:

$$\mathbf{E}_{(m)} = \mathbf{U}^{(m)} \cdot \mathbf{S}_{(m)} \cdot (\mathbf{U}^{(m+1)} \otimes \mathbf{U}^{(m+2)} \otimes \dots \otimes \mathbf{U}^{(M)} \otimes \mathbf{U}^{(1)} \otimes \mathbf{U}^{(2)} \otimes \dots \otimes \mathbf{U}^{(m-1)})^T, \quad (5)$$

其中: $\mathbf{E}_{(m)}$ 为 $\boldsymbol{\varepsilon}$ 的第 m 种展开模式; $\mathbf{U}^{(m)}$ 为其酉矩阵; \mathbf{S} 为奇异值张量; ‘ \otimes ’ 表示张量乘法 (Kronecker 乘法)。以三维矩阵为例,其各种模式的展开如图 1 所示。




图 1 三维张量展开示意图

Fig. 1 Unfolding diagram of a 3D tensor

公式(5)对应的奇异值张量构成方式为:

$$\mathbf{S}_{(m)} = \mathbf{U}^{(m)T} \cdot \mathbf{E}_{(m)} \cdot (\mathbf{U}^{(m+1)} \otimes \mathbf{U}^{(m+2)} \otimes \dots \otimes \mathbf{U}^{(M)} \otimes \mathbf{U}^{(1)} \otimes \mathbf{U}^{(2)} \otimes \dots \otimes \mathbf{U}^{(m-1)}). \quad (6)$$

以上概念在文献[13-14]中进行了详细阐述。

3 纹理引导的稀疏张量表示

3.1 张量模式稀疏表示

将张量理论引入字典学习,设计稀疏张量表示方法。

3.1.1 稀疏系数张量

固定字典,更新稀疏系数张量。对于三维张量 $\mathbf{y} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$,字典 $\mathbf{D}_1 \in \mathbf{R}^{I_1 \times M_1}$, $\mathbf{D}_2 \in \mathbf{R}^{I_2 \times M_2}$, $\mathbf{D}_3 \in \mathbf{R}^{I_3 \times M_3}$,寻找稀疏表示:

$$\mathbf{y} = \mathbf{x} \times_m \mathbf{D}_m^T, \quad (7)$$

$$s. t. \|\mathbf{x}\|_0 \leq T_0,$$

其中: $m \in \{1, 2, 3\}$,具体步骤如下:

①令 $k=1$,初始残差张量 $\mathbf{R} = \mathbf{y}$, $I = \{0\}$,寻找 $j^k = \arg\max_j |\mathbf{R} \times_m \mathbf{D}_{m,j}^T|$,记录 $I = [I, j^k]$ 。

②令 $\mathbf{A} = \mathbf{y} \times_m (\mathbf{D}_m(:, I))^+$,更新残差张量 $\mathbf{R} = \mathbf{y} - \mathbf{A} \times_m \mathbf{D}_m(:, I)$, $k = k + 1$ 。

重复以上步骤直至 \mathbf{R} 下降到阈值或 k 达到限定值。

3.1.2 K-HOSVD

固定稀疏系数张量,更新字典。传统 K-SVD 方法用 SVD 方法分解误差,本文利用 HOSVD 方法分解误差。对于三维矩阵,即 $m=3$ 时,公式(5)有 3 种表示方式:

$$\begin{cases} \mathbf{E}_{(1)} = \mathbf{U}^{(1)} \cdot \mathbf{S}_{(1)} \cdot (\mathbf{U}^{(2)} \otimes \mathbf{U}^{(3)})^T \\ \mathbf{E}_{(2)} = \mathbf{U}^{(2)} \cdot \mathbf{S}_{(2)} \cdot (\mathbf{U}^{(3)} \otimes \mathbf{U}^{(1)})^T \\ \mathbf{E}_{(3)} = \mathbf{U}^{(3)} \cdot \mathbf{S}_{(3)} \cdot (\mathbf{U}^{(1)} \otimes \mathbf{U}^{(2)})^T \end{cases} \quad (8)$$

从式(7)和式(8)中可以看出, m 取值不同,稀疏表示、字典更新的效果也不同。由于张量乘法会生成超大矩阵,如果分别计算 m 的 3 种形式再选择最佳模式,将耗费很大的内存空间,增加计算量,因此,如何选择 m 是本文算法的关键。

3.2 纹理引导的 Kronecker 乘法

本文旨在建立一种三维纹理特征与张量分解之间的数学关系模型,即用纹理特征判断张量分解的最佳模式。而灰度共生矩阵是反映纹理特征的重要方法^[15-16],其主要特征为:(1)能量,其大小与噪声成反比;(2)信息熵,其与噪声成正比;(3)对比度;(4)相关性。上述特征量可以分别表示为 s_{Energy} , s_{Entropy} , s_{Contrast} 和 $s_{\text{Correlation}}$ 。所期望的高维奇异值分解的最佳展开模式需要具有抑制噪声(即能量大、信息熵小)、增强有用信息、主元(奇异值)集中(对比度大)、各主元之间尽量独立(相关性小)的特点。设 m 模式的得分为 S_m ,则上述表述可以转换成以下数学关系: $S_m \propto s_{\text{Energy}}$, $S_m \propto s_{\text{Contrast}}$, $S_m \propto 1/s_{\text{Entropy}}$, $S_m \propto 1/s_{\text{Correlation}}$ 。

根据各特征公式^[16]及上述比例关系,可推导出如下三维纹理特征:

$$S_m \propto \sum_{i=1}^{l-1} \sum_{j=1}^{l-1} \frac{(i-j)^2 \sigma_x^2 \sigma_y^2}{(i-\mu_x)(i-\mu_y) \log_2 P(i,j)} \quad (9)$$

将其 S_m 作为引导稀疏张量表示的指标,公式(9)中各参数的含义在参考文献[16]中有详细阐述。另外,传统灰度共生矩阵一般在二维平面内具有 4 个方向的灰度特征。扩展到三维空间,本文取与 m 值相对应的 3 个方向的灰度特征,方向如图 1 所示。最后,确定 m 为:

$$m = \underset{m}{\operatorname{argmax}} S_m. \quad (10)$$

因此,可进一步确定公式(7)和公式(8)。

4 实验结果与分析

4.1 实验设置

实验样本来自 Lung Image Database Consortium(LIDC) 国际公开数据库的 150 个病例,每个病例的平均大小为 $512 \text{ pixel} \times 512 \text{ pixel} \times 110 \text{ pixel}$ 。所有病例都含有病灶,将数据库中医生手动标定、分割的结果作为判断的金标准。实验平台是主频为 8 GHz,内存为 8 G 的计算机,编程软件为 Matlab2011 与 VS2010。

选择当前主要的稀疏表示、去噪方法阈值小波^[4]、Contourlet^[5]和 K-SVD^[6]与本文方法进行对比分析。

本文方法主要针对肺 CT 图像进行预处理,为了显示处理效果,对处理后的图像序列进一步做肺区分割,分割方法为 CT 图像分割领域内应用最广的主动形状模型(Active Appearance Model, AAM)^[17]。AAM 方法对初始位置非常敏感,理想的预处理过程中可以去除噪声(小的病灶,血管、支气管细枝等干扰信息),令初始位置更加准确。

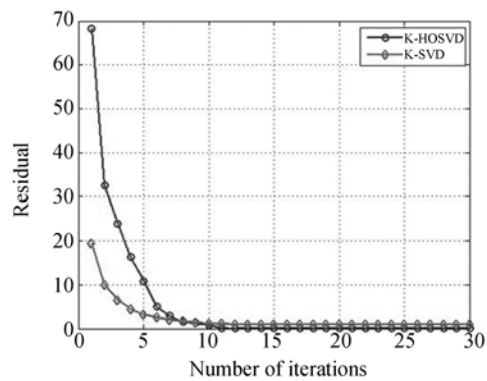
4.2 实验结果与分析

从误差收敛的迭代次数和去噪效果两个方面分析算法性能。

4.2.1 迭代效果

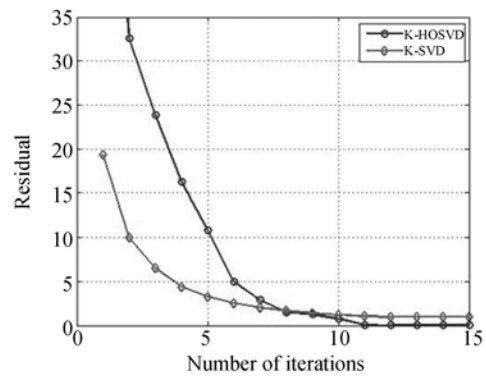
K-奇异值分解法(K-SVD)与本文高维 K-奇异值分解法(K-HOSVD)的收敛效果图如图 2 所示。

图 2(a)为原始对比图,图 2(b)为局部放大图。由图 2 可以看出,虽然 K-HOSVD 开始误差比较大,但其收敛速度比 K-SVD 快,并最终实现



(a) 原始图

(a) Original image



(b) 局部放大图

(b) Partially enlarged view of (a)


图 2 K-SVD 和 K-HOSVD 的收敛示意图

Fig. 2 Convergence schematics of K-SVD and K-HOSVD

了更小重构误差。

4.2.2 去噪效果

选取一组 CT 图像序列为例,如图 3(彩图见期刊电子版)所示。图 3(a)为其三维示意图,病灶用白色箭头标出,其中分别用蓝、绿、红色线标明横截面、冠状面、矢状面的截取位置。横截面和冠状面分别如图 3(b)和 3(c)所示。由图 3(b)可以清楚地看到病灶,即白色箭头标出的位置。图 4 显示了上述 4 种方法的稀疏表示结果,其中图 4(a)是原始图像。将小病灶和血管、支气管细枝作为噪声,各算法的去噪效果如白色箭头指出区域所示。由图 4 可以看出,图 4(e)的去噪效果最佳。图 5 显示了利用各算法去噪后的肺区中心位置,即后期分割 AAM 的初始位置。其中图 5(a)是作为金标准的人为标定位置。图 6 是在预处理基础上对肺区进行 AAM 分割的结果。其中图 6(a)是作为金标准的人为分割结果。



(a) 三维 CT 序列
(a) 3D CT sequence

(b) 横切面
(b) Cross section

(c) 冠状面
(c) Coronal lane

图 3 病例
Fig. 3 Case



(a) 原图像
(a) Original image

(b) Contourlet
(b) Contourlet


(c) 小波
(c) Wavelet

(d) K-SVD
(d) K-SVD

(e) K-HOSVD
(e) K-HOSVD

图 4 稀疏表示结果

Fig. 4 Sparse representation results



(a) 手动标定
(a) Manual calibration

(b) Contourlet
(b) Contourlet


(c) 小波
(c) Wavelet

(d) K-SVD
(d) K-SVD

(e) K-HOSVD
(e) K-HOSVD

图 5 预处理后的质心位置

Fig. 5 Centroid positions after pretreatment



(a) 手动分割
(a) Manual segmentation

(b) Contourlet
(b) Contourlet

(c) 小波
(c) Wavelet

(d) K-SVD
(d) K-SVD

(e) K-HOSVD
(e) K-HOSVD

图 6 预处理后的分割结果

Fig. 6 Segmentation results after pretreatment

在此基础上进行定量分析,各算法对于所有图像序列的平均重构均方误差(MSE)和峰值信噪比(PSNR)结果如表 1 所示。对于预处理图像的分割结果评价如表 2 所示。方法 1 为基于 Contourlet 的方法;方法 2 为基于小波的方法;方法 3 为基于 K-SVD 的方法;

表 1 几种稀疏表示方法效果

Tab.1 Performance of several sparse representation algorithms

方法	方法 1	方法 2	方法 3	方法 4
MSE/%	96.57	96.61	97.72	98.90
PSNR/dB	53.89	54.28	56.75	57.58

表 2 4 种算法分割精确度

Tab.2 Segmentation performance of 4 kinds of algorithms

方法	ϵ_1/mm	ϵ_2/pixel	$\epsilon_3/(\%)$
方法 1	1.96 ± 0.92	4.05 ± 0.58	89.5 ± 2.83
方法 2	1.79 ± 0.59	3.98 ± 0.38	90.8 ± 2.98
方法 3	1.39 ± 0.58	1.85 ± 0.26	95.2 ± 2.89
方法 4	1.35 ± 0.57	1.73 ± 0.23	96.3 ± 2.72

参考文献:

- [1] LEE S L A, KOUZANI A Z, HU E J. Automated detection of lung nodules in computed tomography images: a review [J]. *Machine Vision and Applications*, 2012, 23(1):151-163.
- [2] 彭真明,景亮,何艳敏,等. 基于多尺度稀疏字典的多聚焦图像超分辨率融合[J]. *光学精密工程*, 2014, 22(1): 169-176.
- PENG ZH M, JING L, HE Y M, *et al.*. Superresolution fusion of multi-focus images based on multi-scale sparse dictionary [J]. *Opt. Precision Eng.*, 2014, 22(1): 169-176. (in Chinese)
- [3] 龚卫国,潘飞宇,李进明. 用双层重建法实现单幅图像的超分辨率重建[J]. *光学精密工程*, 2014, 22(3):720-729.
- GONG W G, PAN F Y, LI J M. Single-image super-resolution reconstruction via double layer reconstructing [J]. *Opt. Precision Eng.*, 2014, 22(3): 720-729. (in Chinese)

方法 4 为本文算法。其中 ϵ_1 为平均边缘偏离误差; ϵ_2 为平均标记点偏离误差; ϵ_3 为三维体重叠率^[18]。

5 结 论


本文提出张量模式的稀疏表示方法,旨在对三维肺部 CT 图像序列更好地进行预处理,即去除噪声,增强有用信息。文中首先介绍了相关的稀疏表示、张量理论的基础知识;然后提出了张量模式稀疏表示的基本框架,并借鉴灰度共生矩阵对其中关键参数进行优化;最后将该方法用于肺 CT 序列图像的预处理,并对各算法的稀疏表示效果进行了定性和定量比较。另外,还对预处理图像进行了分割,并评价了各算法的分割结果。

实验结果证明:K-SVD 方法较其他的稀疏方法表示具有优越性,而本文方法的 PSNR 较 K-SVD 的提高了 1.5%,平均误差降低了 1.2%,分割结果在边缘的偏移误差率下降了 3.0%,体积重叠率提高了 1.2%。上述结果显示本文方法用于三维 CT 图像的稀疏表示时,精度更高,可以满足应用要求。

- [4] CHAVE R H, PONOMARYOV V. Super resolution image generation using wavelet domain interpolation with edge extraction via a sparse representation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10):1777-1781.
- [5] HAO W L, LI J W, QU X B, *et al.*. Fast iterative contourlet thresholding for compressed sensing MRI [J]. *Electronics Letters*, 2013, 49(19): 1206-1208.
- [6] GUO Y, WANG Y Y, NIE S Q, *et al.*. Automatic segmentation of a fetal echocardiogram using modified active appearance models and sparse representation [J]. *IEEE Transactions on Biomedical Engineering*, 2014, 61(4):1121-1133.
- [7] VASILESCU M A O, TERZOPOULOS D. Multilinear subspace analysis of image ensembles [C]. 2003 *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2003, 2: 93-99.
- [8] LU H P, KONSTANTINOS N P, VENETSANO-

- POULOS A N. MPCA: Multilinear principal component analysis of tensor objects [J]. *IEEE Transactions on Neural Networks*, 2008, 19(1): 18-39.
- [9] NIE F P, XIANG SH M, SONG Y Q, *et al.*. Extracting the optimal dimensionality for local tensor discriminant analysis [J]. *Pattern Recognition*, 2009, 42(1):105-114.
- [10] TAO D CH, LI X L, WU X D, *et al.*. Supervised tensor learning [J]. *Knowledge and Information Systems*, 2007, 13(1):1-42.
- [11] TAO D CH, LI X L, WU X D, *et al.*. Tensor rank one discriminant analysis—a convergent method for discriminative multilinear subspace selection [J]. *Neurocomputing*, 2008, 71(10-12): 1866-1882.
- [12] HOU CH P, NIE F P, ZHANG CH SH, *et al.*. Multiple rank multi-linear SVM for matrix data classification [J]. *Pattern Recognition*, 2014, 47(1):454-469.
- [13] LATHAUWER L D, MOOR B D, VANDEWALLE J, *et al.*. A multilinear singular value decomposition [J]. *Siam Journal on Matrix Analysis and Application*, 2000, 21(4):1253-1278.
- [14] VANNIEUWENHOVEN N, VANDEBRI L R, MEERBERGEN K, *et al.*. A New Truncation Strategy for the Higher-order Singular Value Decomposition [J]. *Siam Journal on Scientific Computing*, 2012, 34(2): 1027-1052.
- [15] 郑欣, 彭真明. 基于活跃度的脉冲耦合神经网络图像分割 [J]. *光学精密工程*, 2013, 21(3): 821-827.
- ZHENG X, PENG ZH M. Image segmentation based on activity degree with pulse coupled neural networks [J]. *Opt. Precision Eng.*, 2013, 21(3): 821-827. (in Chinese)
- [16] 桑庆兵, 李朝锋, 吴小俊. 基于灰度共生矩阵的无参考模糊图像质量评价方法 [J]. *模式识别与人工智能*, 2013, 26(5):492-497.
- SANG Q B, LI CH F, WU X J. No-reference blurred image quality assessment based on gray level co-occurrence matrix [J]. *Pattern Recognition and Artificial Intelligence*, 2013, 26(5): 492-497. (in Chinese)
- [17] CHEN X C, UDUPA J K, BAGCI U, *et al.*. Medical image segmentation by combing graph cuts and oriented active appearance models [J]. *IEEE Transactions on Imaging Processing*, 2012, 21(4): 2035-2046.
- [18] IBRAGIMOV B, LIKAR B, PERNUS F, *et al.*. A game-theoretic framework for landmark-based image segmentation [J]. *IEEE Transactions on Medical Imaging*, 2012, 31(9):1761-1776.

作者简介:



李 勇(1970—),女,吉林四平人,博士,副教授,1992年于东北师范大学分别获得学士学位,2002年、2010年于吉林大学分别获得硕士、博士学位,主要从事图像处理方面的研究。E-mail: liyong8113@sina.com



王青竹(1983—),女,吉林长春人,博士,副教授,2006年、2008年、2011年于吉林大学分别获得学士、硕士、博士学位,主要从事机器学习、图像处理方面的研究。E-mail: wangqingzhu198339@163.com



苗 壮(1968—),男,吉林长春人,博士,副教授,1992年、1997年、2007年于吉林大学分别获得学士、硕士、博士学位,主要研究方向为脑血管病手术及介入治疗。E-mail: miao Zhuang99@163.com