

基于图的脑组织磁共振图像分割方法^{*}

张竞丹^{1,2}

(1. 中山大学数学与计算科学学院, 广东 广州 510275;
2. 深圳信息职业技术学院 电子通信技术系, 广东 深圳 518029)

摘 要: 提出一种基于图的层次聚类算法实现脑组织磁共振图像的自动分割。首先, 采用基于图的分割方法对脑组织 MR 图像进行初始分割。由于脑组织 MR 图像各类组织结构分布复杂, 尤其是脑脊液和灰质区域细节信息丰富、结构变化多样, 分割结果中存在过分割现象。因此, 利用对偶树复小波变换高频子带信息构造基于图的分割方法中参数 k 的自适应取值函数, 避免图像平滑区域分割后产生大量小区域。然后, 以层次聚类算法合并分割得到的小区域, 解决基于图的方法分割脑组织 MR 图像中存在的过分割问题。最后, 通过大量真实脑组织 MR 图像实验证明该方法在脑组织 MR 图像分割中的准确性和稳定性。

关键词: 基于图的算法; 对偶树复小波变换; 图像分割; 脑组织 MR 图像; 层次聚类算法

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 0529-6579(2010)02-0053-07

Graph-Based Hierarchical Clustering Method for Automatic Brain MR Image Segmentation

ZHANG Jingdan^{1,2}

(1. Department of Mathematics, Sun Yat-sen University, Guangzhou 510275, China;
2. Department of Electronic Communication Technology, Shenzhen Institute of Information Technology, Shenzhen 518029, China)

Abstract: A graph-based hierarchical clustering (GBHC) method for brain MR image segmentation is presented. Firstly, the standard graph-based method is applied to produce a coarse segmentation of brain MR image. However, the segmentation result of the graph-based method is over-segmentation because of the complicated structure of brain. So, we apply an adaptive function to control the value of parameter k in the graph-based method, which integrates the information from the high-frequency subbands of dual-tree complex wavelet transform. Then, the hierarchical clustering method is used to merge the over-segmented regions in the segmentation result. The method is validated by extensive experiments using real T1-weighted MR images, and compared with the state-of-the-art algorithms.

Key words: graph-based method; dual-tree complex wavelet transform; image segmentation; brain MR image; hierarchical clustering method

医学图像分割是高层次医学图像理解和分析的前提条件, 在医学研究、临床诊断、病理分析、手术计划、影像信息处理, 计算机辅助手术等方面应用广泛, 已成为医学图像分析领域中一个具有挑战

性的研究课题。磁共振成像(MRI)是现代重要的医学成像技术, 能够提供丰富的三维人体软组织解剖信息, 具有其它影像设备无法比拟的优势。脑组织 MR 图像具有一些特殊的性质, 例如无纹理、组

* 收稿日期: 2009-04-22

基金项目: 国家自然科学基金资助项目(10771220); 教育部高校博士点科研基金资助项目(SRFDP-20070558043)

作者简介: 张竞丹(1979年生), 女, 博士生; E-mail: zhangjd@szit.com.cn

织类别较少、每种组织中像素的灰度值差别较小、不同组织间的对比度较大等特点。然而,由于噪声、场偏移效应、以及局部体效应的影响,实际获取的脑组织 MR 图像常表现为组织特征具有可变性、不同软组织之间边界模糊、以及各类组织结构分布复杂等特性,这些都对研制自动分割技术造成了极大的困难^[4]。

目前,针对脑组织 MR 图像的分割已经成为医学图像分割中的研究热点,许多方法已经应用于此领域,包括阈值法^[1],区域增长法^[2],以及聚类算法等^[3-4]。近年来,基于图论的图像分割技术成为图像分割领域的一个新的研究热点,涌现出许多新的算法,其中包括最小生成树分割算法^[5]、基于图割理论以及图谱理论的分割算法等^[6-7]。

基于图理论的图像分割方法通常是将图像的分割问题转化为图的分割问题,即首先将一幅图像表示成一个图 $G = (V, E)$, 其中图的每个顶点 $v_i \in V$ 对应着图像中的像素,而每条边 $(v_i, v_j) \in E$ 连接两个相邻(空间 4-邻域或 8-邻域)的像素。每条边通常会分配一个权值,这个权值表示边所连接的两个像素的关系,例如灰度或者颜色的相似度。所构造的图中不一定每对顶点都有连接的边,通常是 4-邻接或者 8-邻接的像素点对应的顶点之间有边。最早的图的分割方法就是设置一个固定的阈值,割断权值小于这个阈值的边,将图分割成一个一个的子图。

Zahn^[5]提出了一种基于图的最小生成树分割方法,其做法也是简单地将图中权值最小(对应于图像像素灰度差别最大)的边割断来构造子图,达到分割的目的。但是,这种简单的割断最小权值边的方法存在很大的缺陷。因为图像中往往灰度变化剧烈的区域其像素之间灰度差别很大,所对应的图中边的权值很小,如果简单地设置某个阈值将这些边割断,就会造成错误的分割结果。例如,将灰度变化剧烈的区域分割成很多细小的区域,或者将灰度变化相对小、但是确属边缘的部分融合到一起。Urquhart^[8]以与其相连接各边的最小权值正则化该边的权值,以此解决上述提及问题,但是在应用于图像分割时效果并不理想。

最近出现一种基于直接寻找图中最小割的最优化方法,该方法对图的划分原则就是使所划分的各个子图间相似性最小。Wu 等^[6]基于这一原则提出了一种划分方法,但是他们的方法偏向于寻找小子图,通常会将一个大的图划分为一个极小的子图和另一个很大的图,划分偏向过于明显。Shi 等^[9]的

方法很好的解决了这个问题,他们的方法被称作归一化割(Normalized Cut)算法。这种方法中考虑到所分子区域的自相似性,并采用“归一化”的方法使算法的分割效果大大改善。这些基于割(cut)的图像分割方法与早期的基于图论的分割方法相比更侧重于图像的全局性质,而不是局部特征。然而,归一化割方法是一个 NP 完全问题^[10],计算复杂度过高。虽然 Shi 和 Malik 提出了计算归一化割的一种近似计算方法,但是这种近似计算所产生的误差还不能被很好地理解。考虑到图片的尺寸和计算机的实际计算能力,在实际应用中这些近似计算方法很难实现,这就将算法限制在只能计算小尺寸图片,或者要求高性能的计算设备。

Felzenszwalb 等^[10]提出了一种新的基于最小生成树的图像分割方法,用于分割户内、外场景图像。该方法根据图像全局特征划分各场景中对象的区域,计算效率高,在几乎是图中边数的线性时间内完成分割,并且可以保留图像特征变化缓慢区域中的细节信息。目前,一些研究者渐渐将基于图的分割方法应用于医学图像分割中^[11-13],但在脑组织 MR 图像分割中,基于图论的分割方法寥寥无几。根据 Felzenszwalb 基于最小生成树分割方法的优点,采用此方法自动分割脑组织 MR 图像。不过,由于脑组织 MR 图像各类组织结构分布复杂,尤其是脑脊液和灰质区域细节信息丰富、结构变化多样,分割过程产生大量的分割区域,造成过分割问题。

本文提出一种基于图的层次聚类算法实现脑组织磁共振图像的自动分割。首先,采用基于最小生成树的分割方法对脑组织 MR 图像进行初始分割,并结合对偶树复小波变换(DT-CWT)构造基于最小生成树算法中参数 k 的自适应取值函数,避免图像平滑区域在分割中产生大量小区域。然后,以层次聚类算法合并小区域,解决分割脑组织 MR 图像中存在的过分割问题。

1 基于图的层次聚类算法

本小节将详细介绍本文所提出的自动的、无监督的基于图的脑组织 MR 图像聚类算法。在预处理阶段使用 EMS 软件包^①提取脑组织区域,校正图像中的灰度偏移。接下来简要介绍基于最小生成树的分割方法^[10],并分析其在脑组织 MR 图像分割中存在的问题。然后,结合对偶树复小波变换

① <http://www.medicalimagecomputing.com/EMS/>

(DT-CWT) 构造基于最小生成树算法中参数 k 的自适应取值函数, 最后以层次聚类算法解决分割脑组织 MR 图像中存在的过分割问题。

1.1 基于最小生成树的分割方法

在所有图像分割方法中, 最重要的是如何选取分割准则。最小生成树的形成过程类似于区域的生长过程, 在分离集森林的实现形式下, 森林中的每棵树代表一个由连通节点形成的集合, 在图像中就映射为一个同质区域。一般而言, 局部区域中同质区域内部各个像素间的变化 (偏移) 小于非同质区域之间的变化。Felzenszwalb 根据这种差异提出基于最小生成树的分割准则, 而且这种分割准则在某种程度上可以获取全局特征。

图中边权重可以定义为节点之间的差异, 这种差异对应图像像素特征之间的差异, 比如灰度、颜色、纹理、距离等。在不考虑空间距离的邻域系统里, 可以简单地把权重定义为空间 4-邻域中相邻像素特征之间的绝对差值 $w(u, v) = |F(u) - F(v)|$, 其中顶点 u, v 对应于图像中相邻的像素点。对于灰度图像来说, $F(u) = I(u)$ 。

假设 $C \neq V$ 为分离集森林中的每个集合, 那么对应的最小生成树为 $MST(C, E)$, Felzenszwalb 定义这个集合的内部差异 (Intra-difference) 为最小生成树中的最大的权重

$$Int(C) = \max_{e \in MST(C, E)} w(e)$$

而两个集合 $C_1, C_2 \in V$ 之间的差异 (Inter-difference) 为连接这两个集合的边的最小权重

$$Dif(C_1, C_2) = \min_{v_i \in C_1, v_j \in C_2, (v_i, v_j) \in E} w((v_i, v_j))$$

如果 C_1 与 C_2 之间没有边连接, 则定义 $Dif(C_1, C_2) = \infty$ 。虽然 $Dif(C_1, C_2)$ 只考虑了 C_1 与 C_2 之间最小权重的边, 但是实际上效果很好。如果考虑其它边, 就会把问题变得很困难, 不能在多项式时间 (Polynomial Time) 内完成问题求解过程, 从而出现 NP-complete 或者 NP-hard 问题。

定义了区域的内部差异和区域之间的差异之后, Felzenszwalb 给出区域比较准则:

$$D(C_1, C_2) = \begin{cases} \text{true} & \text{if } Dif(C_1, C_2) > MInt(C_1, C_2) \\ \text{false} & \text{otherwise} \end{cases}$$

其中

$$MInt(C_1, C_2) = \min \{ Int(C_1) + \tau(C_1), Int(C_2) + \tau(C_2) \}$$

阈值函数 τ 定义为

$$\tau(C) = \frac{k}{|C|}$$

其中 k 为常数, $|C|$ 为集合 C 中元素的数目。

Felzenszwalb 提出的比较准则取两个区域内部差异较小的那个值, 与区域之间的差异进行比较, 如果前者比后者小, 那么比较准则成立, 说明两个区域之间存在边界; 否则, 比较准则不成立, 应该将两个区域合并起来。阈值函数 $\tau(C)$ 控制过分割产生的小区域, k 取值越大, 抑制小区域的效果越明显。算法实际运行中, k 越大, 越容易产生大区域; 但是 k 不是指最小区域的大小, Felzenszwalb 算法允许小区域的出现。

下面给出基于最小生成树的分割算法:

输入: $G = (V, E), |V| \rightarrow n, |E| \rightarrow m$

Step 0: 将 E 按权值非递减顺序排序为 $\pi(e_1, e_2, \dots, e_m)$ 。

Step 1: 初始化分割集 S^0 , 其中图中每个顶点 v_i 各自构成一个集合。

Step 2: 根据分割集 S^q 构造 S^{q+1} , $q = 1, \dots, m$ 。循环下述操作:

如果 $e_q = (v_i, v_j)$, $v_i \in C_i^{q-1}$, $v_j \in C_j^{q-1}$, $C_i^{q-1} \neq C_j^{q-1}$,

并且 $w(e_q) \leq MInt(C_i^{q-1}, C_j^{q-1})$, 合并 C_i^{q-1}, C_j^{q-1} 得到分割集 S^q ;

否则, $S^q = S^{q-1}$ 。

Step 3: 返回 $S = S^m$ 。

基于最小生成树算法使用区域比较准则, 极大化了区域内部的相似性与区域之间的差异性, 随着图像内容的变化能够自适应地改变, 因此在分割准则和理论上具有优势: ① 可以获取图像的全局特征; ② 算法的运算效率高, 可以在图中边数目的几乎线性时间内完成分割; ③ 能够保留特征缓慢变化区域的细节; ④ 算法的数据结构简单。

基于最小生成树分割算法的一个优势在于能够保留特征缓慢变化区域的细节, 这恰巧可以解决脑组织 MR 图像中由于噪声、场偏移效应、局部体效应的影响在不同组织之间产生的模糊、不均匀的问题。故此, 采用基于最小生成树算法自动分割脑组织 MR 图像, 不过它的这个优点也使得分割过程产生大量的分割区域, 造成过分割问题。而且, 脑组织 MR 图像各类组织结构分布复杂, 尤其是脑脊液和灰质区域细节信息丰富、结构变化多样。如果 k 取值较大, 则分割区域面积较大, 会丢失脑组织 MR 图像在组织边界区域的细节信息; 反之, 如果 k 取值较小, 则分割区域面积较小, 其中大部分白质组织区域将被分割为大量小区域。因此, k 的取

值在分割过程中变得尤为重要。这些都给图像自动分割造成一定困难。

1.2 k 的自适应取值函数

采用基于最小生成树算法分割脑组织 MR 图像的一个困难在于如何找到一个合适的 k 值。我们期望在图像组织边界区域(不同组织过渡区域), k 取值较小, 保留图像边界区域细节特征; 而在图像组织区域内部(尤其是连续的白质区域), k 取值较大, 不至于将其分割为大量小区域。故此提出一种动态取值方法, 根据图像局部区域内容自适应决定 k 的取值。

首先, 要确定图像中哪些像素点(图中的顶点)位于组织边界区域, 哪些位于组织内部平滑区域。由于对偶树复小波变换(DT-CWT)^[14]能够在不同方向上检测图像中线、曲线(边界)信息, 我们采用 DT-CWT 高频子带信息提取脑组织 MR 图像中组织边界区域。实验中以二层到四层 DT-CWT 中的高频子带重构图像组织边界区域信息, 一层 DT-CWT 高频子带中含有较高噪声, 所以重构中丢弃这部分信息。其它较高尺度的 DT-CWT 高频子带所包含的边界区域信息不断减少, 故此也不再考虑。假设 DT-CWT 高频子带重构后灰度图像 I' , $I'_{\max}, I'_{\min}$ 分别表示其中最大和最小灰度值(背景和其它额外脑组织区域除外), k 的自适应函数为:

$$k = k_0 * \exp\left(-\alpha \frac{|I'_i - I'_j|}{|I'_{\max} - I'_{\min}|}\right)$$

其中, I'_i 为图中顶点 v_i 的灰度值, α 为常数值, k_0 为 k 初始值。实验中, α 默认取值为 3.5, k_0 默认值为 10。

如果边 (v_i, v_j) 的两个顶点 v_i 和 v_j 都属于图像某类组织内部的像素, 或者边界区域像素, 那么 I'_i 与 I'_j 相近, k 的取值趋近 k_0 。如果顶点 v_i 和 v_j 分别属于不同组织, 那么 I'_i 与 I'_j 差值较大, k 的取值小于 k_0 , 分割区域变小, 可以更好地保留图像细节信息。

1.3 基于层次聚类的区域合并法

虽然使用自适应函数调整 k 的取值, 但是由于脑组织 MR 图像中各类组织分布较为复杂, 分割后的结果仍存在过分割问题。我们以分割后区域灰度均值为区域特征, 通过层次聚类算法聚类各个区域。层次聚类算法基本思想是: 首先计算各个区域之间的距离, 将每个区域看作一个类, 然后将距离最近的两类合并成为新类, 并计算新类与其它类间距离, 再按最小距离准则合并。这样每次都缩小一类, 直到类别数目为 3 类, 分别对应于脑组织 MR

图像组织类别: 脑脊液、灰质和白质。一般而言, 以层次聚类算法实现图像分割, 其时间和空间代价较大。但是, 以层次聚类算法解决基于最小生成树分割方法的过分割问题, 以区域为聚类对象, 降低了运算开销。

2 实验

通过大量真实数据的分割实验验证基于图的层次型聚类(GBHC)算法的实用性与有效性。分割处理过程中, 脑组织分割为三类: 脑脊液、灰质和白质, 其中背景和其它组织在分割之前已经被去除。文献[15-16]中所介绍的方法均可自动去除额外的脑组织(如大脑皮层、脂肪等)。

2.1 数据集及相似性指数

为了全面、准确的分析实验结果, 我们选用来自 IBSR^① 图像数据库中 20 个 T1 权值的真实脑组织 MR 图像数据集, 切片厚度 3.1 mm。上述的数据集都提供了由相关领域医学专家手工分割的标准结果(ground truth)用于衡量分割效果。

为了准确的衡量算法的分割性能, 本文采用 Tanimoto 相似性指数来量化计算分割结果与标准分割结果之间的相似程度。对于给定的脑组织 j , $j = 1, 2, 3$ 分别表示脑脊液、灰质和白质。假设 A_j 表示标准结果图像中标记为组织类别 j 的像素集合, B_j 表示分割结果图像中标记为组织类别 j 的像素集合。Tanimoto 相似性指数^[17]

$$\rho = \frac{|A_j \cap B_j|}{|A_j \cup B_j|}$$

其中 $|A_j \cap B_j|$ 是在标准结果图像和分割结果图中都被标记为组织类别 j 的像素个数, 而 $|A_j \cup B_j|$ 为在标准结果图像或者分割结果图中被标记为组织类别 j 的像素个数。

2.2 真实脑组织 MR 图像分割实验

真实数据实验中, 我们使用 IBSR 数据库中 20 个正常的 T1 权值脑组织 MR 图像数据集为实验数据, 其中每个数据集切片厚度 3.1 mm。这部分图像数据具有组织间对比度较低、场偏移效应引起灰度偏移程度大的特点, 分割中难度较大。

图 1 中以真实脑组织 MR 图像 100_23 中 4 张切片的分割结果展示 GBHC 算法的分割效果, 其中第一行分别为切片 $x = 15$ 、 $x = 25$ 、 $x = 35$ 、以及 $x = 45$ 的原图像, 第二行是各个切片对应的 GBHC 算法分割结果图。为了便于衡量本章提出的

① <http://www.cma.mgh.harvard.edu/ibsr>

GBHC 算法分割结果的准确性, 图 1 第三行给出相应的由医学专家手工标记的标准分割结果。




图 1 GBHC 算法在真实脑组织 MR 图像 100_23 中四张切片上的分割结果图

第一行: 切片图像, 第二行: GBHC 算法分割结果图像, 第三行: 专家手工标记标准分割结果图像
列: (a) 切片 $x = 15$, (b) 切片 $x = 25$, (c) 切片 $x = 35$, (d) 切片 $x = 45$

Fig. 1 The segmentation results of four slices from the real brain MR image 100_23 using GBHC method

Upper row: slice images. Second row: GBHC segmentation results. Third row: ground truth

Columns: (a) slice $x = 15$, (b) slice $x = 25$, (c) slice $x = 35$, (d) slice $x = 45$

为了验证本章所提出的 GBHC 算法的分割性能, 本小节将 GBHC 算法与其它脑组织 MR 图像分割方法进行比较。IBSR 网站提供了 6 个经典的分割方法——自适应 Map (amap)、偏移 Map (bmap)、模糊 C 均值 (fuzzy)、最大后验概率 (map)、树型 K 均值 (tskm)、以及最大相似性 (mlc) 算法的分割结果用于实验比较分析。IBSR 数据库使用 Tanimoto 相似性指数衡量分割结果与标准分割结果 (医学专家手工分割结果) 之间的相似程度。图 2 中给出 GBHC 算法与这 6 种经典算法在 20 个真实脑组织 MR 图像数据集上的分割结果与标准分割结果的 Tanimoto 相似性指数比较结果, 其中 x 轴标记各个图像数据的标号, y 轴给出

相似性指数值, 图中黑色粗线对应于本章所提出 GBHC 算法在各个图像数据上的分割结果。比较结果表明在大部分数据集中, GBHC 算法在各类组织分割准确性上优于其它 6 种方法。

为了从统计分析的角度说明 GBHC 算法的分割稳定性和准确性, 我们以均值和方差统计所提出的聚类算法、IBSR 提供的 6 种经典分割方法在 20 个真实脑组织 MR 图像数据集上分割结果与标准结果图像的 Tanimoto 相似性指数。表 1 中列出了多种分割方法分割脑组织 MR 图像的统计结果。GBHC 算法在均值上均高于其它分割方法, 这表明 GBHC 算法具有较高的分割准确性; 另外, 在方差统计值上, GBHC 算法在灰质和白质上统计结果小于其它

分割方法，验证了 GBHC 算法在分割不同图像过程中性能稳定。由于真实图像 100_23, 7_8, 191_3 等灰度偏移程度较高，预处理阶段采用 EMS 软件包不能完全校正其灰度偏移，故此，GBHC 算法

分割脑脊液（CSF）的结果虽然较其它分割方法好，但比 GBHC 算法在 20 个数据集上的平均分割结果低，因此使得其方差略大。




图 2 基于图的层次聚类算法与六种经典算法在真实脑组织 MR 图像数据集上的分割结果与标准分割结果的 Tanimoto 相似性指数比较结果

Fig. 2 Comparing GBHC algorithm and six different algorithms with ground truth on 20 real MR data sets from IBSR with Tanimoto performance metric. (a) CSF, (b) GM, (c) WM

表 1 基于图的层次聚类算法和其它多种分割方法在 20 个真实脑组织 MR 图像数据集上与标准分割结果 Tanimoto 相似性指数比较结果的均值和方差

Table 1 Mean and standard deviation of Tanimoto performance metric for various segmentation methods, calculated over 20 real brain MR data from IBSR repository

方法	来源	脑脊液		灰质		白质	
		均值	方差	均值	方差	均值	方差
Adaptive MAP	IBSR	0.07	0.03	0.56	0.13	0.57	0.18
Biased MAP	IBSR	0.07	0.03	0.56	0.17	0.56	0.21
Fuzzy c-means	IBSR	0.05	0.02	0.47	0.12	0.57	0.20
Maximum a Posteriori Probability	IBSR	0.07	0.04	0.55	0.16	0.55	0.21
Tree-structure k-means	IBSR	0.06	0.03	0.54	0.16	0.55	0.21
Maximum-Likelihood	IBSR	0.05	0.02	0.48	0.12	0.57	0.20
Our proposed method (GBHC)		0.12	0.04	0.63	0.06	0.66	0.06

3 结 语

本文提出一种基于图的层次聚类（GBHC）算法实现脑组织 MR 图像的自动分割。我们将对偶树复小波变换（DT-CWT）与基于最小生成树算法相结合，构造参数 k 的自适应取值函数，避免图像中平滑区域分割后产生过多小区域；并以层次聚类算法解决基于最小生成树算法分割脑组织 MR 图像中存在的过分割问题。通过大量真实脑组织 MR 图像实验证明该方法在脑组织 MR 图像分割中的准确性和稳定性。

致 谢

感谢戴道清教授对本文的指导 and 帮助。

参考文献：

[1] ZHOU Z, RUAN Z. Multicontext wavelet-based thresholding segmentation of brain tissues in magnetic resonance images [J]. Magn Reson Imag, 2007, 25: 381 – 385.

[2] POHLE R, TOENNIES K K. Segmentation of medical images using adaptive region growing [C]. Proc SPIE-Med Imag, 2001, 4322: 1337 – 1346.

[3] XUE J H, PIZURICA A, PHILIPS W, et al. An integrated method of adaptive enhancement for unsupervised segmentation of MRI brain images [J]. Pattern Recogni-

- tion Letters, 2003, 24: 2549 – 2560.
- [4] PHAM D L, XU C Y, PRINCE J L. Current methods in medical image segmentation [J]. Ann Rev Biomed Eng, 2000, 2: 315 – 337.
- [5] ZAHN C T. Graph-theoretic methods for detecting and describing gestalt clusters [J]. IEEE Trans Comput, 1971, 20: 68 – 86.
- [6] WU Z, LEAHY R. An optimal graph theoretic approach to data clustering: Theory and its application to image segmentation [J]. IEEE Trans Pattern Anal Mach Intell, 1993, 1: 1101 – 1113.
- [7] WEISS Y. Segmentation using eigenvectors: a unifying view [C]. Proceedings of the International Conference on Computer Vision, 1990, 2: 975 – 982.
- [8] URQUHART R. Graph theoretical clustering based on limited neighborhood sets [J]. Pattern Recognition, 1982, 15(3): 173 – 187.
- [9] SHI J, MALIK J. Normalized cuts and image segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1997: 731 – 737.
- [10] FELZENSZWALB P, HUTTENLOCHER D P. Efficient graph-based image segmentation [J]. Int J Comput Vision, 2004, 59(2): 167 – 181.
- [11] BILODEAN G, SHU Y, CHERIET F. Multistage graph-based segmentation of thoraco-scope images [J]. Comput Med Imag Grap, 2006, 30: 437 – 446.
- [12] COCOSCO C A, ZIJDENBOS A P, EVANS A C. A fully automatic and robust brain MRI tissue classification method [J]. Med Image Anal, 2003, 7: 513 – 527.
- [13] ITURRIA-MEDINA Y, CANALES-RODRIGUEZ E J, MELIE-GARCIA L, et al. Characterizing brain anatomical connections using diffusion weighted MRI and graph theory [J]. NeuroImage, 2007, 36: 645 – 660.
- [14] KINGSBURY N G. The dual-tree complex wavelet transform: a new efficient tool for image restoration and enhancement [C]. Proceeding European Signal Processing Conference, 1998: 319 – 322.
- [15] LEEMPUT K V, MAES F, VANDERMEULEN D, et al. Automatic model-based tissue classification of MR images of the brain [J]. IEEE Trans Med Imag, 1999, 18(10): 897 – 908.
- [16] GOLDSZAL A F, DAVATZIKOS C, PHAM D L, et al. An image processing system for qualitative and quantitative volumetric analysis of brain images [J]. J Comput Assist Tomogr, 1998, 22: 827 – 837.
- [17] DUDA R O, HART P E, STORK D G. Pattern classification [M]. New York: Wiley, 2001.

~~~~~

(上接第 52 页)

- [16] HONGLING Z, KUIEHEN D. Global stability and periodic orbits for a two-patch diffusion predator-prey model with time delays [J]. Nonlinear Anal, 2000, 41: 1083 – 1096.
- [17] 张正球, 王志成. 基于比率的三种群捕食者-食饵扩散系统的周期解[J]. 数学学报, 2004, 47(3): 531 – 540.
- [18] CHEN Z J, REG K. A stochastic competing-species model and ergodicity [J]. J Appl Prob, 2005, 42: 738 – 753.
- [19] RYSZARD R. Long-time behaviour of a stochastic prey-predator model [J]. Stochastic Processes and Their Application, 2003, 108: 93 – 107.
- [20] MANTHEY R, MASLOWSKI B. A random continuous model for two interacting populations [J]. Appl Math Optimization, 2002, 45: 213 – 236.
- [21] MAO X R, GLENN M, ERIC R. Environmental Brownian noise suppresses explosions in population dynamics [J]. Stochastic Processes and Their Application, 2002, 97: 95 – 110.
- [22] 郭子君. 随机 Lotka-Volterra 系统的稳定性[J]. 生物数学学报, 2004, 19(2): 188 – 192.
- GUO Z J. The stability of stochastic Lotka-Volterra systems [J]. Journal of Biomathematics, 2004, 19(2): 188 – 192.
- [23] ARNOLD L. Stochastic differential equations: Theory and applications [M]. New York: Wiley, 1972: 45 – 120.
- [24] FRIEDMAN A. Stochastic differential equations and their applications [M]. New York: Academic press, 1976: 42 – 140.
- [25] MAO X R. Stochastic differential equations and applications [M]. New York: Horwood, 1997: 25 – 155.