

# 基于多小波分析与 SOFM 的 MR 图像分割算法研究

李鑫环,陈立潮,赵红艳,赵 勇

(太原科技大学 计算机科学与技术学院,山西 太原 030024)

**摘 要:**有效地实现 MRI 脑图像的分割是临床疾病诊断的一个难题。针对目前 MRI 脑图像分割算法在图像分割的速度和精度上不理想的问题,提出了一种将多小波分析与 SOFM 相结合的 MWSOFM 算法。该算法先对 MRI 脑图像进行多小波分解得到小波系数金字塔,再用 SOFM 算法对图像从塔顶开始从上往下逐层进行聚类,最终得到分割结果。对不同分辨率的 MRI 脑图像的仿真实验表明,在高分辨率的情况下,MWSOFM 不但加快了分割的速度,而且提高了聚类精确度,分割效果得到明显改善。

**关键词:**图像分割;多小波分析;自组织特征映射;核磁共振图像

**中图分类号:**TP183

**文献标识码:**A

**文章编号:**1673-629X(2009)09-0104-04

## Research on MR Image Segmentation Based on Multi-wavelet Analysis and SOFM

LI Xin-huan, CHEN Li-chao, ZHAO Hong-yan, ZHAO Yong

(Institute of Computer Sci. and Techn., Taiyuan Univ. of Sci. and Techn., Taiyuan 030024, China)

**Abstract:** MRI brain image segmentation is an important precondition for medical diagnosis and therapy. In this paper, a method based on the multi-wavelet and SOFM (MWSOFM) is proposed to improve the speed and the precision of the segmentation. Firstly a multi-wavelet transform is adopted to decompose the MRI images to get the wavelet coefficient pyramid, and then uses SOFM to cluster from the transform layer to the bottom; finally the segmented image is got. MRI brain images of different resolution are used in the experiment, and are segmented by the method of MWSOFM and the traditional SOFM. Compared the results, it is indicated that MWSOFM not only mends the speed of the segmentation, but also enhances the accuracy in clustering, and excels the traditional SOFM at the result.

**Key words:** image segmentation; multi-wavelet transform; self-organizing feature map; magnetic resonance imaging

## 0 引 言

图像分割技术是图像处理和分析中的关键技术<sup>[1]</sup>。医学图像通常由感兴趣区域和背景区域构成,感兴趣区域包含重要的诊断信息,能为临床诊疗和病理学研究提供可靠的依据,所以把感兴趣区域从图像中分离出来就成了图像分析与识别首要解决的问题,也是制约医学图像处理中其它相关技术发展和应用的瓶颈。核磁共振成像(MRI, Magnetic Resonance Imaging)没有任何的辐射危险,可以对身体的任意部位进行平面成像,而且对软组织的影像对比度高,特别适合脑组织成像。通过对 MR 脑图像中脑白质(WM)、脑灰质(GM)和脑脊液(CSF)等组织结构的准确分割在医学应用中具有重要意义<sup>[2]</sup>。由于在成像过程中会受

到许多因素的影响,导致 MRI 脑图像模糊和不均匀,这给准确分割带来很多困难,使用单一的分割方法往往存在这样或那样的不足。因此人们致力于将多种方法相结合,发挥各自的优势,以取得较好的分割结果。

目前国内外对于自动或半自动 MR 图像分割方法的研究主要集中在统计方法、c 均值聚类方法、k 近邻方法和神经网络方法等方面<sup>[3]</sup>。但是由于磁共振图像的内在不确定性,导致一些半自动和全自动分割技术的临床应用效果不太理想。多小波变换不仅具有单小波变换的优点,还具有光滑性、紧支性、对称性等特点,在图像处理方面越来越受到专家和学者的重视。而自组织特征映射神经网络(Self-Organizing Feature Map, SOFM)是一种无导师的聚类方法,能把高维的信息数据以有序方式映射到低维空间上,形成一种拓扑意义上的有序图,它比传统的有监督分类法更有优势<sup>[4]</sup>。文中将两者结合起来,提出了一种将多小波分析和 SOFM 相结合的 MWSOFM(Multi-Wavelet Self-Organizing Feature Map)算法,先对图像进行预滤

收稿日期:2008-12-30;修回日期:2009-03-09

作者简介:李鑫环(1982-),女,河南商丘人,硕士研究生,CCF 会员,研究方向为人工智能与模式识别;陈立潮,教授,博士,研究方向为模式识别、人工智能、数据挖掘。

波,对预处理后的图像进行多小波分解,得到小波系数金字塔;再用 SOFM 对小波系数金字塔进行处理;然后对处理后的系数进行小波逆变换;最后对逆变换得到的数据进行后置滤波处理,最终得到分割结果。

## 1 自组织特征映射

自组织特征映射神经网络是一种前馈式无监督的聚类算法,它可以将任意维的输入信号变换到一维或二维的离散网格上,并保持一定的拓扑有序性。SOFM 网络由输入层和输出层组成,如图 1 所示,输入为  $n$  维,输出为二维。输入层又称匹配层,计算输入模式向量与权向量之间的距离,即匹配程度;输出层又称竞争层,各神经元以匹配程度为依据进行竞争,确定匹配程度大(距离小)的神经元获胜<sup>[5]</sup>。获胜的神经元及其领域内的神经元权向量朝与模式向量更靠近方向更新,经过多次这种反复的竞争与更新,最终神经元就会学会模式向量,并以权向量形式保存下来,从而实现模式向量的聚类、识别与拓扑不变性映射等,这一过程就是自组织学习(映射)。可见自组织映射学习包括两部分:最佳匹配神经元的选择和权向量的更新。




图1 自组织特征映射神经网络模型

基本的 SOFM 算法的步骤可归纳如下,主要由竞争、协作和自适应调整三个过程组成<sup>[6]</sup>。

a) 权值初始化,用小的随机数对各权向量赋初值  $w_j(0)$ ;

b) 在样本集中随机选一个样本  $X$  作为输入;

c) 在时刻  $n$ ,选择最佳匹配单元  $i$ (竞争过程),即  $i(x) = \arg \min_j \|x(n) - w_j\|, j = 1, 2, \dots, N$  (1)

d) 确定邻域函数  $\Lambda_i(n)$ (协作过程);

e) 修正权值(自适应调整过程):

$$w_j(n+1) = \begin{cases} w_j(n) + \eta(n)[x(n) - w_j(n)], & j \in \Lambda_i(n) \\ w_j(n), & \text{其它} \end{cases} \quad (2)$$

f)  $n \leftarrow n+1$  返回 b),直到形成有意义的映射图。

## 2 多小波分析

多小波的基本思想是将单小波中由单个尺度函数生成的多分辨率分析空间,扩展为由多个尺度函数生成,以获得更大的自由度<sup>[7]</sup>。多小波具有单小波所没有的一些优点,尤其是在图像处理应用中,可以把光滑性、紧支性、对称性等完美结合在一起:对称性(线性相位)既符合人眼的视觉系统,又使信号边缘易于处理;紧支性使得相应的快速小波变换的和是有限和,在保留精细图像的细节方面效果显著;高阶消失矩能提高多项式逼近度,使图像变得平滑。由于多小波同时拥有上述多种特性,所以它在信号逼近和边界处理上能获得更优越的效果<sup>[8]</sup>。

定义1:一组函数  $\Psi = \{\Psi_1, \dots, \Psi_r\} (r > 1)$ ,如果其伸缩、平移  $\Psi_{i,j} = (\Psi_i(2^{-j}x - k), \dots, \Psi_r(2^{-j}x - k))^T (j, k \in \mathbb{Z})$  是  $L^2(\mathbb{R})$  的一组正交基,则称函数  $\Psi$  为  $r$  阶正交多小波。与单小波类似,生成正交多小波  $\Psi$  相应的多尺度函数  $\Phi = (\Phi_1, \dots, \Phi_r)^T$  满足  $r$  阶的多分辨率分析 MRA  $\{V_j\}$ 。对于一个由  $\Phi$  生成的  $r$  阶的多分辨率分析 MRA  $\{V_j\}$ ,令  $W_j = V_j \oplus V_{j+1}$  是  $V_{j+1}$  在  $V_j$  中的正交补空间。由多分辨率分析(MRA)的定义可以知道:存在  $r \times r$  的矩阵  $H_k, G_k$ ,使得尺度方程(3)、(4)成立。

$$\Phi(x) = \sqrt{2} \sum_k \Phi(2x - k) \quad (3)$$

$$\Psi(x) = \sqrt{2} \sum_k G_k \Phi(2x - k) \quad (4)$$

设  $H(\omega) = \frac{1}{\sqrt{2}} \sum_k H_k e^{-ik\omega}, G(\omega) = \frac{1}{\sqrt{2}} \sum_k G_k e^{-ik\omega}$  则(3)、(4)等价于

$$\Phi(2\omega) = H(\omega) \Phi(\omega) \quad (5)$$

$$\Psi(2\omega) = G(\omega) \Phi(\omega) \quad (6)$$

定义2:若  $H_k = 0, G_k = 0 (k < 0, k > N)$ ,则称  $\{\Phi, \Psi\}$  是紧支集。类似的,称  $\{H, G\}$  为 FIR 矩阵滤波器组。由 MRA 的性质及其两尺度方程(3)、(4),用类似单小波的推导方法容易得到如下的多小波分解算法(DMWT)(5)、(6)和多小波重构算法(IDMWT):

$$C_{i,j} = \sum_k H_{k-2j} C_{i-1,k} \quad (7)$$

$$D_{i,j} = \sum_k G_{k-2j} D_{i-1,k} \quad (8)$$

$$C_{n,k} = \sum_j H_{k-2j}^T C_{n-1,j} + \sum_j \sum_{i=1}^r G_{k-mj}^T D_{n-1,j} \quad (9)$$

基于多小波变换的图像  $f(x, y)$  分解与重构的主要步骤,详细的过程参见文献[9]。

## 3 MWSOFM 算法

### 3.1 算法基本思想

多小波变换是空间、时间和频率的局部变换,能够

有效地从信号中提取有用信息,通过对紧支撑小波基的伸缩和平移等运算功能,实现对信号的多尺度细化分析,而 SOFM 是一种无导师的聚类方法,网络具有自稳定性,抗噪音能力强,无需提供理想输出模式,在分类过程中可避免人为因素,这些都有利于图像的聚类分析。结合两种算法的优点,针对脑部 MR 图像的特点及分割要求,提出一种将多小波分析与 SOFM 相结合的 MWSOFM 算法:先对图像进行预滤波多小波分解,再用 SOFM 对所得小波系数金字塔进行处理,然后对处理后的系数进行小波逆变换,最后对逆变换得到的数据进行后置滤波处理,最终得到分割结果。图 2 为 MWSOFM 算法的流程图。




图 2 MWSOFM 算法流程图

### 3.2 算法流程

算法的具体步骤描述如下:

Step1:对图像进行预滤波,对预处理后的图像进行多小波分解,得到小波系数金字塔,这里采用经典的 GHM 多小波对图像进行分解,GHM 滤波器组系数为:

$$\begin{aligned}
 h_0 &= \begin{bmatrix} \frac{3\sqrt{2}}{10} & \frac{4}{5} \\ \frac{-1}{20} & \frac{-3\sqrt{2}}{20} \end{bmatrix} & h_1 &= \begin{bmatrix} \frac{3\sqrt{2}}{10} & 0 \\ \frac{9}{20} & \frac{\sqrt{2}}{2} \end{bmatrix} \\
 h_2 &= \begin{bmatrix} 0 & 0 \\ \frac{9}{20} & \frac{-3\sqrt{2}}{20} \end{bmatrix} & h_3 &= \begin{bmatrix} 0 & 0 \\ \frac{-1}{20} & 0 \end{bmatrix} \\
 g_0 &= \begin{bmatrix} \frac{-1}{20} & \frac{-3\sqrt{2}}{20} \\ \frac{\sqrt{2}}{20} & \frac{3}{10} \end{bmatrix} & g_1 &= \begin{bmatrix} \frac{9}{10} & \frac{-\sqrt{2}}{2} \\ \frac{-9\sqrt{2}}{20} & 0 \end{bmatrix}
 \end{aligned}$$

$$\begin{aligned}
 g_2 &= \begin{bmatrix} \frac{9}{20} & \frac{-3\sqrt{2}}{2} \\ \frac{9\sqrt{2}}{20} & \frac{-3}{10} \end{bmatrix} & g_3 &= \begin{bmatrix} \frac{-1}{20} & 0 \\ \frac{\sqrt{2}}{20} & 0 \end{bmatrix}
 \end{aligned}$$

前置滤波系数:

$$P_1(0) = \begin{bmatrix} \frac{3}{8\sqrt{2}} & \frac{3}{8\sqrt{2}} \\ 0 & 0 \end{bmatrix} \quad P_1(-1) = \begin{bmatrix} \frac{3}{8\sqrt{2}} & 0 \\ 1 & 0 \end{bmatrix}$$

后置滤波系数:

$$P_2(1) = \begin{bmatrix} 0 & 1 \\ 0 & \frac{-3}{10} \end{bmatrix} \quad P_2(0) = \begin{bmatrix} 0 & 0 \\ \frac{4\sqrt{2}}{5} & \frac{-3}{10} \end{bmatrix}$$

Step2:聚类从多小波系数金字塔的最上层开始,找出最上层的低通子带图。

Step3:用 SOFM 对多小波系数金字塔的同一层上的低通子带进行聚类处理。处理时先确定进行聚类处理时的输入矢量。在本算法中输入矢量由图像在  $(i, j)$  像素点(图像的第  $i$  行  $j$  列像素点)的特征属性组成,选取以下 7 个特征属性  $X1 \sim X7$  组成一个 7 行 1 列的矢量,作为 SOFM 网络的输入矢量:

$X1$ :像素点的灰度值  $f(i, j)$ ;

$X2$ :像素点的水平  $X$  方向一阶梯度  $G_x(i, j)$ :

$$G_x(i, j) = f(i+1, j) - f(i, j) \quad (10)$$

$X3$ :像素点的垂直  $Y$  方向一阶梯度  $G_y(i, j)$ :

$$G_y(i, j) = f(i, j+1) - f(i, j) \quad (11)$$

$X4, X5$ : 像素点的两个对角方向的一阶梯度  $G_{d1}(i, j)$  和  $G_{d2}(i, j)$ :

$$G_{d1}(i, j) = f(i+1, j+1) - f(i, j) \quad (12)$$

$$G_{d2}(i, j) = f(i+1, j-1) - f(i, j)$$

$X6$ :像素点的 8 邻域灰度均值  $M(i, j)$ :

$$M(i, j) = \frac{1}{9} \sum_{k=-1}^1 \sum_{l=-1}^1 f(i+k, j+l) \quad (13)$$

$X7$ :像素点的 8 邻域灰度方差  $C(i, j)$ :

$$C(i, j) = \frac{1}{9} \sum_{k=-1}^1 \sum_{l=-1}^1 (f(i+k, j+l) - M(i, j))^2 \quad (14)$$

在确定完输入矢量之后,利用 SOFM 神经网络对多小波系数金字塔同一层的各个低通子图进行聚类。

Step4:聚类完成后,对上层进行多小波逆变换,得到下层的低通子图。

Step5:判断此时图像是否为最底层图像。如果是,转向 Step6;否则转向 Step3。

Step6:得到分割图像。

### 4 仿真结果与分析

实验的环境为:主频 1.8G 的 CPU, 512M 内存, 仿

真环境为 Matlab7.1。实验采用分辨率为  $256 \times 256$  和  $512 \times 512$  的脑部 MR 图像,分类数为 4,对应聚类类别数,初始学习率取定为 0.5,实验训练次数均采用 1000 次。分别采用基本 SOFM 和 MWSOFM 两种算法对两种不同分辨率的 MRI 图像做分割。

实验表明,在分辨率为  $256 \times 256$  时,MWSOFM 算法所用时间比基本的 SOFM 算法稍微多点,因为 MWSOFM 算法的复杂度较高(对图像先处理后聚类),而基本 SOFM 算法则是直接对图像进行聚类分析。在分辨率为  $512 \times 512$  时,基本 SOFM 算法的所需分割时间明显增加,但 MWSOFM 分割速度明显加快,这是因为多小波分析可以将高分辨率的图像分解为几个低分辨率图像,从而减少了 SOFM 聚类算法处理的维数,因此在高分辨率下,明显地提高了分割的速度。在不同的分辨率下两种算法时间的对比见表 1。

表 1 两种算法的时间对比表

算法	分辨率	时间(s)
SOFM	$256 \times 256$	19.6213
	$512 \times 512$	102.2225
MWSOFM	$256 \times 256$	21.7705
	$512 \times 512$	34.2454

多小波可以把光滑性、紧支性、对称性等完美结合在一起,而这些特性恰是在图像处理过程中是十分重要的。通过实验可以发现,利用 MWSOFM 算法分割后的图像,无论是在平滑性、细节处理还是在边缘分割方面,都比 SOFM 算法的结果要好,分割的质量和精度都得到了很好的改善。如图 3 至图 5 为实验结果。




图 3 原始图像 图 4 MWSOFM 分割结果图 图 5 SOFM 分割结果

## 5 结束语

MR 脑图像分割是脑神经科学研究的重要环节,目前还没有彻底解决。由于使用单一的分割方法往往存在这样或那样的不足,因此目前的研究热点趋于将多种方法结合起来。

文中提出了一种基于多小波分析与 SOFM 相结合的 MWSOFM 算法,相对于基本的 SOFM 算法,MWSOFM 算法不但提高了图像的分割精度,而且提高了分割的速度。但是由于 MR 图像的复杂性,图像的特征提取对分割的准确率有很大的影响,因此如何提取更有效的图像特征还需进一步研究。

## 参考文献:

- [1] 田捷,包尚联,周明全.医学影像处理与分析[M].北京:电子工业出版社,2003.
- [2] Li Yan, Chi Zheru. MR Brain Image Segmentation Based on Self-Organizing Map Network[J]. International Journal of Information Technology, 2005, 11(8): 45-53.
- [3] 杨占华,杨燕. SOM 神经网络算法的研究与进展[J]. 计算机工程, 2006, 32(16): 201-228.
- [4] Gafiychuk V V, Datsko B Y, Izmaylova J. Analysis of data clusters obtained by self-organizing methods[J]. Physica A - statistical Mechanics and It's Applications, 2004, 341(10): 547-552.
- [5] Vesanto J, Alhoniemi E. Clustering of the Self-Organizing Map[J]. IEEE Transactions on Neural Networks, 2000, 11(3): 586-600.
- [6] 王斌. 基于 SOFM 神经网络的数字模式识别方法[J]. 微机发展(现更名: 计算机技术与发展), 2003, 13(8): 6-7.
- [7] 黄明辉,朱维彰. 基于多小波基维纳滤波图像去噪[J]. 微机发展(现更名: 计算机技术与发展), 2004, 14(2): 8-10.
- [8] Strela V, Strang G. The application of multi-wavelet filter banks to image processing[J]. IEEE Trans. Image processing, 1999, 18(4): 548-563.
- [9] Goodman T N T, Lee S L. Wavelets of multiplicity[J]. Trans on Amer Math Soc, 1994, 342: 307-324.

(上接第 103 页)

- [6] 路景,周春燕. 基于遗传算法的混合优化策略研究[J]. 计算机技术与发展, 2007, 17(3): 144-145.
- [7] 刘红,韦穗. 基于遗传算法的布局问题求解[J]. 计算机技术与发展, 2007, 17(1): 74-75.
- [8] 王良俊. 蚁群算法理论、应用及其与其它算法的混合[D]. 南京: 南京邮电学院, 2005.
- [9] 吴迪. 蜂群遗传算法的研究[D]. 延吉: 延边大学, 2006.
- [10] 熊敏,刘玉树. 基于协同进化遗传算法的地域选取方法

[J]. 计算机技术与发展, 2006, 16(6): 174-176.

- [11] 王凌. 智能优化算法及其应用[M]. 北京: 清华大学出版社, 2001.
- [12] 葛继科,邱玉辉,吴春明,等. 遗传算法研究综述[J]. 计算机应用研究, 2008, 25(10): 2911-2915.
- [13] Borisovsky P, Dolgui A, Ereemeev A. Genetic algorithms for a supply management problem: MIP-recombination vs greedy decoder[J]. Science Direct, 2007, 195: 770-779.