

基于小波和 SOM 网络的医学图像融合

王安娜, 杨铭如, 刘坐乾, 王婷君

(东北大学信息科学与工程学院, 沈阳 110004)

摘要:提出一种基于小波变换和自组织特征映射(SOM)神经网络的医学图像融合方法,对图像进行小波变换,以图像的小波系数为特征,采用 SOM 网络对图像进行聚类,并进行模糊分类,从而确定像素融合的权重,得到融合图像。仿真实验结果表明,该方法能够获得良好的性能。

关键词:图像融合;小波变换;自组织特征映射神经网络;聚类分析

Medical Image Fusion Based on Wavelet and SOM Network

WANG An-na, YANG Ming-ru, LIU Zuo-qian, WANG Ting-jun

(School of Information Science and Engineering, Northeastern University, Shenyang 110004)

【Abstract】A medical image fusion method based on the wavelet transformation and Self-Organization feature Map(SOM) neural network is proposed in this paper. Wavelet transformation of image is done. The wavelet coefficients are used as the characteristics. The SOM network is used to realize the cluster of images and the fuzzy classification is done. The image pixels fusion weights are determined according to the classified result. The fusion image is obtained. Simulation experimental results show this method can get better performance.

【Key words】image fusion; wavelet transform; Self-Organization feature Map(SOM) neural network; clustering analysis

近年来,小波变换理论成为研究热点^[1],该理论的不断发展和创新使其在实际中得到越来越广泛的应用。自组织特征映射(Self-Organization feature Map, SOM)网络是种具有无监督自主学习功能的神经网络^[2],可将输入信号各种模式的拓扑关系几乎不变地反映在输出响应上^[3]。本文将小波变换同 SOM 结合,对医学图像进行融合,获得较好的融合效果。

1 小波基的选取

小波变换具有很好的空域和频域特征,在本文方法中,先对待融合图像分别进行小波变换,建立图像的小波塔式分解。小波基的选取在一定程度上影响着小波系数的分布,因此,小波基的好坏直接影响到融合的效果。小波基有以下 5 个重要指标:

(1)对称性及线性相位

令小波函数 $\psi(t)$ 为平方可积函数,若它的傅里叶变换满足 $\Psi(\omega) = \pm |\Psi(\omega)| e^{-i a \omega}$ (a 为实常数),则称 $\psi(t)$ 有线性相位。具有线性相位的小波函数可以避免对图像进行分解和重构时的相位失真。当 $\psi(t)$ 为实值函数时,若满足 $\psi(a+t) = \psi(a-t)$,则称其具有对称性。

(2)正交性和双正交性

小波基从正交性的角度划分有 2 类:正交与双正交。正交小波基对应的低通滤波器 h 和高通滤波器 g 正交。若 C_0 为原信号的最高分辨率的抽样点,则小波分解可描述如下:大部分正交小波基是无限支集的,相应的滤波器 h 和 g 是无限冲激响应的,无法在计算机上实现,一般采用 Daubechies 系的紧支集正交小波作为小波基进行图像处理,最常用的是 DB2 和 DB4 小波。双正交小波基由 2 个小波函数构成,即 $\psi(t)$ 和它的对偶小波,双正交是指低通分析滤波器 h 和高通重建滤波器 \bar{g} 正交,低通重建滤波器 \bar{h} 和高通分析滤波器 g 正交, h 和 g 对应分解小波 Ψ , \bar{h} 和 \bar{g} 对应综合小波 $\bar{\Psi}$ 。目前,著

名且广泛应用的双正交小波基是 Daubechies 双正交小波基。

(3)正则性

函数的正则性的定义为:设 $0 < \alpha < 1$,若对于任意 $t, \beta \in R$,有 $|\psi(t+\beta) - \psi(t)| < c|\beta|^\alpha$ (c 为常数),则称 $\psi(t)$ 的正则性阶数为 α 。若 $\psi(t)$ 的 N 阶导数满足上式,且 $r = N + \alpha$,则称 $\psi(t)$ 的正则性阶数为 r 。正则性表现为小波基的可微性,是小波函数光滑程度的一种描述,对于小波函数 $\psi(t)$,正则性阶数 r 越大,正则性越好,收敛越快,其邻域能量越集中。

(4)消失矩

若小波函数 $\psi(t)$ 满足 $\int_{-\infty}^{+\infty} t^k \psi(t) dt, k=0,1,\dots,N, \psi(t)$ 即有 k 个连续零点,则称 $\psi(t)$ 具有 N 阶消失矩。消失矩的大小决定了用小波逼近光滑函数时的收敛率。当图像光滑时,越大的消失矩将导致越小的的小波系数,而对不光滑的图像,将会有更多更大的小波系数。

(5)紧支性

紧支性指的是若小波函数 $\psi(t)$ 在区间 $[a, b]$ 外恒为 0,则称该小波函数在这个区间上具有紧支性,这样的小波基称为紧支集小波基,区间 $[a, b]$ 称为小波基的紧支集,区间的宽度称为小波基的支撑宽度。支撑宽度越小,小波基的局部化能力越强,小波变换的计算复杂度越低,便于快速实现。

本文依据平均误差选择小波基函数,设原图像为 A ,大小为 $M \times N$,小波反变换后得到得图像为 B ,平均误差可以用

基金项目:东北大学“985 工程”项目“信息化基础结构关键技术科技创新平台”

作者简介:王安娜(1956-),女,教授、博士、博士生导师,主研方向:图像处理,信息融合,图像融合;杨铭如、刘坐乾、王婷君,硕士

收稿日期:2009-05-20 **E-mail:** wanganna@mail.neu.edu.cn

下式计算：

$$\bar{E} = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N (B(i, j) - A(i, j))^2}{M \times N}} \quad (1)$$

表 1 给出了相应的图像小波变换的平均误差,可以看出,双正交小波基 bior2.2 和 bior4.4 的性能较好,coif2 和 coif4 小波比较差,而 DB2, DB4, sym2 和 sym4 小波性能相近。因此,本文选取 bior2.2 作为小波变换的基函数。

表 1 基于不同小波基函数的图像小波变换平均误差

函数名称	平均误差
DB2 小波	2.35e-13
DB4 小波	5.02e-13
sym2 小波	2.35e-13
sym4 小波	2.02e-13
coif2 小波	4.13e-12
coif4 小波	1.36e-11
bior2.2 小波	2.21e-16
bior4.4 小波	3.73e-15

2 SOM 网络

2.1 SOM 网络拓扑结构

SOM 网络^[4-5]结构如图 1(a)所示,输出按二维平面组织是 SOM 网最典型的组织方式,该组织方式更具有大脑皮层的形象,输出层的每个神经元同它周围的其他神经元侧向连接,排列成棋盘状平面,结构如图 1(b)所示。




图 1 SOM 网的输出阵列

2.2 SOM 网络学习算法

SOM 网采用的学习算法称为 Kohonen 算法,按如下步骤进行:

Step1 初始化:对输出层各权向量赋小随机数并进行归一化处理,得到 $\hat{W}_j, j=1,2,\dots,m$; 建立初始化优胜邻域 $N_{j^*}(0)$; 学习率 η 赋初始值。

Step2 接受输入:从训练集中随机选取一个输入模式并进行归一化处理,得到 $\hat{X}^p, p \in \{1,2,\dots,P\}$ 。

Step3 寻找获胜节点:计算 \hat{X}^p 与 \hat{W}_j 的点积 $j=1,2,\dots,m$, 从中选出点积最大的获胜节点 j^* ,如果输入模式未经归一化,应计算欧式距离,从中找出距离最小的获胜节点。

Step4 定义优胜邻域 $N_{j^*}(t)$:以 j^* 为中心确定 t 时刻的权值调整域,一般初始邻域 $N_{j^*}(0)$ 较大,训练过程中 $N_{j^*}(t)$ 随训练时间逐渐收缩。

Step5 调整权值:对优胜邻域 $N_{j^*}(t)$ 内的所有节点进行权值调整:

$$\omega_{ij}(t+1) = \omega_{ij}(t) + \eta(t, N)[x_i^p - \omega_{ij}(t)] \quad (2)$$

其中, $i=1,2,\dots,n; j \in N_{j^*}(t)$; $\eta(t, N)$ 是训练时间 t 和邻域内第 j 个神经元与获胜神经元 j^* 之间的拓扑距离 N 的函数,该函数一般有以下规律: $t \uparrow \rightarrow \eta \downarrow, N \uparrow \rightarrow \eta \downarrow$ 。

Step6 结束检查:SOM 网的训练不存在类似 BP 网中的输出误差概念,训练何时结束是以学习率 $\eta(t)$ 是否衰减到 0 或某个预定的正小数为条件,不满足结束条件则回到 Step2。

3 基于小波和 SOM 网络的医学图像融合方法

本文提出基于小波变换和 SOM 神经网络^[5]的医学图像融合新方法。根据 SOM 神经网络的应用特点,可以把该方法分为 2 个阶段,即 SOM 网络的训练阶段和 SOM 网络的应用阶段。应用 SOM 神经网络进行图像融合过程如图 2 所示。




图 2 应用 SOM 神经网络进行图像融合的过程

3.1 SOM 网络的结构选取

本文采用的 SOM 神经网络的输入层有 2 个神经元 p_1 和 p_2 , 输出层是个二维平面。在输入层中, p_1 代表 $p(i, j)$ 点系数的大小,它反映的是系数图像的灰度值的大小,即该点的明暗程度; p_2 代表以 $p(i, j)$ 为中心的 3×3 邻域内的平均梯度,反映的是系数图像在点 $p(i, j)$ 附近的清晰程度。

系数矩阵中某一点 $p(i, j)$ 的梯度定义为

$$grade(i, j) = \sqrt{(p(i, j) - p(i, j+1))^2 + (p(i, j) - p(i+1, j))^2} \quad (3)$$

以 $p(i, j)$ 为中心的 3×3 邻域内的平均梯度的计算是在系数矩阵的边缘部分舍去 3×3 邻域不存的部分。

在输出层中,输出神经元的个数,即分类的个数 C 的选取是个理论上的难题。本文以头部 CT 和 MR 图像为例进行研究,用 SOM 网络分类的对象是医学图像小波变换后的高频小波系数图像,图 3 为头部 CT 图像的小波变换结果,其中,图 3(a)为原始 CT 图像;图 3(b)为 3 层小波变换的结果,图 3(c)为第 3 层小波变换对角部分的小波系数的统计直方图。

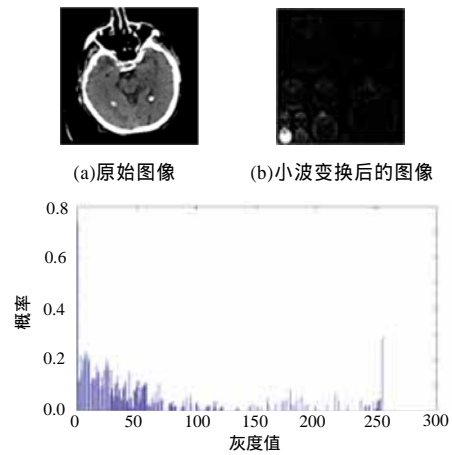


图 3 图像的小波变换

从图 3 可以看出,越接近 0 值直方图越密集,即系数的大小越接近 0,出现的概率越大。这点由图像小波变换后的图像 3(b)也可看出,高频系数的图像都非常暗,就是高频图像的大部分像素值都集中在零值附近的结果。基于以上的分析并考虑 SOM 网络输出层的二维平面机构,选择输出神经元的个数 $C=9$ 。

3.2 SOM 网络的训练

SOM 网络的输入向量为 $P=\{p_1, p_2\}$, 输出神经元 j 与输入神经元的连接权值为 $W_j=\{w_{j1}, w_{j2}, \dots, w_{jn}\}$, 输出神经元有 C 个,即把特征空间分割为 C 类。以欧式距离为测度的 Kohonen 算

法如下：

Step1 初始化，从输入神经元到输出神经元的权值可以随机地取一个较小的值 v_j 且使 $w_{ji}=v_j, j=1,2,\dots,C, i=1,2$ ；确定各个输出神经元 j 的邻接神经元的集合 $NEj(t)$ 。由于选取的输出神经元数等于 9，分类数较小，因此原始输出近邻距离确定为 1。

Step2 提供一个新的输入模式。

Step3 计算输入神经元与输出层神经元之间的欧几里德 (Euclidean) 距离 d_j ，即输入样本与每个输出神经元 j 之间的欧几里德距离为

$$d_{j^*} = \min_{1 \leq j \leq C} d_j = \min_{1 \leq j \leq C} \{\sum_{i=1}^n [x_{ji} - w_j(t)]^2\}, j^* \in [1, C] \quad (4)$$

其中， j 为使欧氏距离最小的输出神经元。

Step4 按照式(5)改变输出神经元与其邻接神经元的相应权值。

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(t)[x_{ji} - w_{ji}(t)] \quad (5)$$

其中， $j \in NEj^*(t)$ ； t 为迭代次数； NEj^* 为 j^* 的邻域，且是 t 的减函数； $\alpha(t)$ 为学习速率因子，一般选 $0 < \alpha(t) < 1$ ，以保证算法的收敛，本文选择 $\alpha(t)=0.5$ 。

Step5 提供一个新的样本重复上面的学习过程，直到兴奋神经元与输入样本稳定对应为止。

3.3 模糊分类

经过训练 SOM 神经网络把图像的像素点分割成 C 类。给定 $X=\{x_1, x_2, \dots, x_N\}$ 是 R^N 空间中的 N 个观测值， x_i 为 X 中的第 i 次采样， x_{ik} 为 x_i 的 k 维特征值，则对于 X 有函数 $f: R^N \rightarrow R^C$ ，取 $U=f(x) \in R^C$ ，则有：

$$U = \{u_1, u_2, \dots, u_N\} = \{f(x_1), f(x_2), \dots, f(x_N)\} \quad (6)$$

此时， $U=\{0,1\}$ 定义为

$$u_j = \begin{cases} 1 & d_j = \min\{d_j, 1 \mid C\} \\ 0 & \text{其他} \end{cases} \quad (7)$$

由于图像间的差异，因此硬分类这种非此即彼的分类方法在做融合时往往失去意义。拓展 $U=\{0, 1\} \rightarrow U[0, 1]$ ，即进行模糊分类。

利用 u_{ij} 表示图像中第 i 个像素点对应于类 j 的隶属度，则有：

$$\sum_{j=1}^C u_{ij} = 1, 0 < \sum_{i=1}^N u_{ij} < N \quad (8)$$

当模糊化结束后，每幅图像的每个像素点都有了一个隶属度函数矢量组。

3.4 融合规则

图像在做聚类分析并模糊化后，每幅图像的每个像素点都有一个隶属度。显然，要求多幅图像中的每个像素点具有相同的隶属度及分类是不现实的。对于 N 幅二维图像中点图像 G_i 中点 $P_i(m,n)$ ，记 $U_{(m,n)} = \{u_{1i}, u_{2i}, \dots, u_{mi}\}_{(m,n)}$ 为分类的隶属度函数矢量，其中， $u_{1i}, u_{2i}, \dots, u_{ci}$ 为按照大小排序后的序列，则该点在这幅图像中的灰度值计算如下：

$$P^i(m,n) = (u_{1i}w_{1i} + u_{2i}w_{2i} + \dots + u_{ci}w_{ci})(L-1) \quad (9)$$

其中， w_{ji} 表示对第 i 幅图像进行聚类分析时得到的第 j 类的归一化权值。融合算法采用均值法，则融合后图像对应像素点灰度值如下：

$$P^i(m,n) = \frac{1}{N} \sum_{i=1}^N P_i(m,n) \quad (10)$$

经过上述处理后的图像，再进行聚类分析，最终得到融合结果，至此，整个融合过程完成。

4 仿真实验

为验证算法的有效性和进行相关性能的比较，在 Matlab7.0 仿真环境下进行一系列的实验。先确定小波变换层数，分别采用 2~8 层小波变换对图像进行融合，融合规则选取简单的取绝对值最大法，即选取绝对值最大的小波系数作为融合后的小波系数。图 4 显示了原图像以及融合后的图像，表 2 给出了融合结果的客观指标。




图 4 不同小波分解层数的图像融合

表 2 不同小波分解层数的图像融合评价指标

类型	标准差	平均梯度	信息熵	平均交叉熵
2 层小波	84.828 6	1.03e-21	4.479 0	1.222 1
3 层小波	85.617 5	2.11e-14	4.787 3	1.246 3
4 层小波	88.000 6	6.03e-9	5.196 4	1.351 3
5 层小波	90.279 7	8.28e-7	5.378 0	1.369 3
6 层小波	91.393 1	1.11e-6	5.448 4	1.355 1
7 层小波	91.584 3	2.41e-6	5.416 9	1.363 8
8 层小波	91.745 5	3.16e-6	5.377 5	1.333 4

从图 4 和表 2 可以看出，总体而言，随着小波变换层数的增加，图像的融合效果有所提高，其中，3 层和 4 层小波变换的融合效果相差较大，从 6 层小波变换开始融合效果提高得不明显，而且信息熵和平均交叉熵较 4 层和 5 层小波变换的效果有所下降，5 层小波变换的融合效果较好，4 层小波变换次之。考虑到算法复杂度的因素，本文融合算法选择 4 层小波变换。SOM 神经网络的训练是非常重要的步骤，训练结果直接影响最终的图像融合的效果。本文的 SOM 神经网络的结构为：输入层有 2 个神经元，输出层为 9 个神经元的二维平面结构。SOM 神经网络的权重采用训练 500 次所得到的权值，并采用标准差、平均梯度、信息熵和交叉信息熵作为客观评价指标进行评价，同时将本文的融合方法与其他一些常用方法进行比较。

图 5(a)和图 5(b)分别为待融合的 CT 和 MRI 图像，图 5(c)~图 5(i)分别为采用主成分分析法(PCA)、拉普拉斯(Laplace)金字塔法、形态学金字塔法、比率金字塔法、梯度金字塔法、小波变换的方法和本文所用方法的图像融合结果。表 3 列出了不同融合方法的客观评价指标，结合主观评价和表中给出的测试数据可以看出，应用小波变换方法的融合效果优于 PCA 方法和其他的变换域的方法，而采用本文介绍的方法较小波变换法在视觉效果和性能指标上又有一定程度的提高。

(下转第 205 页)