

# 用自产生和自组织神经网络对 超声医学图像进行自动分割<sup>1</sup>

汪天富 李德玉 郑昌琼 郑 翊\* 冉均国

(四川联合大学高新技术研究院 成都 610065)

\*(St.Cloud State University, St.Cloud, MN 56301, USA)

**摘 要** 本文研究用自产生和自组织神经网络方法进行超声心脏图像的自动分割。这种无监督的聚类方法能够自动搜索最佳的网络输出节点数而获取图像中的目标数，从而完成对图像的自动分割。实验结果表明，与自组织特征映射方法相比，本文的方法具有许多重要的优点。

**关键词** 自组织特征映射，自产生和自组织神经网络，自动分割，医学超声图像

**中图分类号** TN911.73, TN-052

## 1 引言

多维超声成像技术能够动态实时地显示出人体内部器官及其真实活动情况，不会对人体造成损害，是一种十分有效的诊断手段，并已广泛用于心脏和心血管疾病的诊断。然而，多维重建中的关键技术——图像自动分割问题一直未能得到解决，限制了它的临床应用。

图像分割是图像处理和模式识别等领域十分重要且十分困难的问题，在没有任何先验知识的情况下，对图像进行自动分割更是困难。现有的许多无监督分割方法如文献 [1] 必须首先给出分割图像中的目标数，只有极少数的方法能够自动确定图像中的目标类别数。在文献 [2] 中，A. K. Jain 等通过检查表现指数的特殊性如修改 Hubert 指数来获得图像中的目标数。在文献 [3] 中 C. Bouman 等则用求最小代价函数的方法来确定类别数。本文提出一种更为自然的方法，用自产生和自组织神经网络方法自适应寻找图像中的目标数，并同时完成分割过程，将确定类别数与分割过程合二为一。

## 2 自组织特征映射 (SOFM)

首先，我们回顾一下 SOFM。T. Kohonen<sup>[4]</sup> 认为一个神经网络接受外界刺激时将分为不同的区域，各区域对输入模式有不同的响应特征，同时，这一过程是自动完成的，从而提出了自组织特征映射模型。SOFM 是一种无监督的聚类方法，它所形成的聚类中心能够映射到一个平面或曲面上而保持拓扑结构不变，可以对目标固有特征作客观的划分。

## 3 自产生和自组织神经网络 (SCONN)

尽管自组织特征映射具有一定的优点，但也存在一些不足之处。首先，它不能自动调节输出层节点数，必须先确定输出层节点数，才能进行学习过程。其次，由于边界节点学习的次数比中心节点学习次数多，存在边界效应。此外，当输入模式分布为圆形时，中心节点会成为死节点。为了解决上述问题，D.I. Choi 和 S.H. Park<sup>[5]</sup> 提出了自产生和自组织神经网络模型。

假设初始时刻只有极少数神经元，各神经元具有较宽的动态响应范围，响应阈值随时间递减。因此，网络中的最大输出节点（获胜节点）对一定的阈值不会被激活（响应），但可以产生一自相似的子节点（家族节点），从而使输出节点数逐渐增多，最终稳定在一个确定的值，由此可得出 SCONN 的学习算法如下：

<sup>1</sup> 1997-04-22 收到，1998-06-05 定稿  
国家自然科学基金资助课题

- 第一步 初始化权系数、学习参数和激活阈值。
- 第二步 输入一新的模式。
- 第三步 计算模式和各输出节点权矢量的距离。
- 第四步 选择竞争获胜节点(距离最小)。
- 第五步 判断竞争获胜节点是否被激活, 若未被激活, 转第七步。
- 第六步 调整竞争获胜节点和家族节点权系数, 减小所有节点激活阈值, 转第二步。
- 第七步 由竞争获胜节点产生一子节点, 减小所有节点激活阈值, 转第二步。

上述算法的停止有三个准则: 迭代次数  $T$ 、激活阈值  $\theta$  以及输出节点数。为了自动获得输出节点数, 用  $T$  或  $\theta$  作为终止算法的准则较恰当。在第七步中, 子节点的权系数由 (1) 式确定:

$$W_{i,S_j} = W_{ij}(t) + R(t)(X_i(t) - W_{ij}(t)), \quad (1)$$

其中  $j$  为获胜节点,  $S_j$  为产生的子节点,  $X_i(t)$  为  $t$  时刻的输入模式,  $R(t)$  为相似系数,  $W_{ij}(t)$  为  $t$  时刻输入节点  $i$  与输出节点  $j$  的连接权系数。

#### 4 基于自产生和自组织神经网络的图像自动分割方法

图像自动分割分为两步: 首先抽取图像特征, 再进行目标类别数的搜索, 同时分割标记出不同的区域代表不同的目标。我们将 SCONN 的输入层节点数设置为特征矢量的个数, 输出层节点数表示目标类别数, 则可将 SCONN 当作一个自动聚类网络。然而, 从实质上说 SCONN 是一个映射网络而非聚类网络, 它的权矢量修改规则是基于保持拓扑结构不变的特征映射。因此, 为了使 SCONN 成为一个真正的聚类网络应对它进行修改。

设  $X = (x_1, x_2, \dots, x_M)$  为特征矢量,  $W = (w_1, w_2, \dots, w_c)$  为权矢量, 为了获得与  $X$  最佳匹配的  $W$ , 应使下式的代价函数最小:

$$L = \sum_{r=1}^c g_{ir} \|X - W_r\|^2, \quad (2)$$

其中

$$g_{ir} = \begin{cases} 1, & r = i; \\ 1 / \left( \sum_{j=1}^c \|X - W_j\|^2 \right), & r \neq i. \end{cases} \quad (3)$$

上述两式中  $\|\cdot\|$  为欧氏距离运算,  $i$  为竞争获胜节点。将 (3) 式代入 (2) 式得

$$\begin{aligned} L &= \sum_{r=1}^c g_{ir} \|X - W_r\|^2 = \|X - W_i\|^2 + \left( \sum_{\substack{r=1 \\ r \neq i}}^c \|X - W_r\|^2 \right) / \left( \sum_{j=1}^c \|X - W_j\|^2 \right) \\ &= \|X - W_i\|^2 + \left( \sum_{r=1}^c \|X - W_r\|^2 \right) / \left( \sum_{j=1}^c \|X - W_j\|^2 \right) - \|X - W_i\|^2 / \left( \sum_{j=1}^c \|X - W_j\|^2 \right) \\ &= \|X - W_i\|^2 + 1 - \|X - W_i\|^2 / \left( \sum_{j=1}^c \|X - W_j\|^2 \right) \end{aligned} \quad (4)$$

令  $D = \sum_{r=1}^c \|X - W_r\|^2$ , 将 (4) 式对  $W_i$  求微分得

$$\nabla_v L(W_i) = -2(X - W_i)(D^2 - D + \|X - W_i\|^2)/D^2. \quad (5)$$

将 (4) 式对  $W_j (j \neq i)$  求微分得

$$\nabla_v L(W_j) = -2(X - W_j)\|X - W_i\|^2/D^2. \quad (6)$$

基于 (5)、(6) 两式就得到了权矢量迭代修改公式, 对于竞争获胜节点  $i$  用下式修改:

$$W_i(t+1) = W_i(t) + \alpha(t) \cdot (X - W_i(t)) \cdot (D^2 - D + \|X - W_i(t)\|^2)/D^2. \quad (7)$$

对于非竞争获胜节点  $j$  则用下式进行修改:

$$W_j(t+1) = W_j(t) + \alpha(t) \cdot (X - W_j(t)) \cdot (\|X - W_i(t)\|^2)/D^2. \quad (8)$$

家族节点权值修改方法与竞争获胜节点相同, 非竞争获胜节点则指除此以外的所有其它节点。

## 5 实验结果和讨论

图 1 为一幅  $256 \times 256$  像素的原始超声心脏图像, 为了减少运算量, 先将它分成  $2 \times 2$  的不重叠区域, 并以此为中心计算  $7 \times 7$  邻域内  $0^\circ$  与  $90^\circ$  方向的游程长度矩阵, 并由此得到短游程优势, 长游程优势, 灰度的不均匀性变量、游程长度的不均匀性变量和游程长度总数的百分数等共 10 个特征值。试验表明  $7 \times 7$  的邻域较为理想, 太大会造成图像边界的模糊, 太小会使图像噪声较大。用 SCONN 对各区域特征矢量进行自动分割, 得到的目标数为 3, 此时选取的参数为  $R(t)=0.85$ ,  $\theta(t) = \theta_0 e^{-0.5t}$ , 并取  $\theta_0$  为初始时刻节点间距离的最大值以保证所有竞争获胜节点都响应。分割结果如图 2 所示, 从中可以看出心脏的四个腔边界保持了较好的连续性, 这也是现有的许多边界跟踪方法难以解决的问题。在类别标记中, 用较低类别号表示弱信号, 用较高的类别号表示强信号, 图 2 的灰度级别高低很好的反映了图像中信号的强弱。



图 1 原始图像




图 2 SCONN 分割结果

多幅图像的分割结果表明, 与 SOFM 相比, 本文的方法不仅具有自动分割的优点, 还具有以下特点: (1) 分割结果不受初始条件和迭代次数的影响, 具有较强的稳定性; (2) 采用家族节点修改方法, 不存在边界效应和死节点; (3) 分割结果准确, 由于 SOFM 以迭代次

数作为算法的终止条件, 可能会错过最佳结果, 而本文的方法则是以搜索最佳结果为终止条件; (4) 分割速度快, 采用节点分裂方式节点数逐渐增加, 减少了平均每次迭代所需时间。

### 参 考 文 献

- [1] Manjunath B S, Chellappa R. Unsupervised texture segmentation using Markov random models. IEEE Trans. on PAMI, 1991, PAMI-13(5): 478-482.
- [2] Jain A K, Farrokhnia F. Unsupervised texture segmentation using Gabor filters. Pattern Recognition, 1991, 24(12): 1167-1186.
- [3] Bouman C, Liu B. Multiple resolution segmentation of textured images. IEEE Trans. on PAMI, 1991, PAMI-13(2): 99-113.
- [4] Kohonen T. Self-Organization and Associative Memory. 2nd ed., New York: Springer-Verlag, Ch.5: 119-157.
- [5] Choi D I, Park S H. Self-creating and organizing neural network. IEEE Trans. on NN, 1994, NN-5(4): 561-575.

## AUTOMATIC SEGMENTATION OF MEDICAL ULTRASONIC IMAGE USING SELF-CREATING AND ORGANIZING NEURAL NETWORK

Wang Tianfu    Li Deyu    Zheng Changqiong    Zheng Yi\*    Ran Junguo

(High Technology Research Institute of Sichuan Union University, Chengdu 610065)

\*(St. Cloud State University, St. Cloud, MN 56301, USA)

**Abstract** The automatic segmentation of ultrasonic heart image using self-creating and organizing neural network has been studied. This kind of unsupervised clustering method can search for the optimal number of output nodes automatically to get the number of textures in the image, and finish the automatic segmentation. Experimental results show that this method has significant benefits over self-organizing neural network method.

**Key words** Self-organizing feature map, Self-creating and organizing neural network, Image segmentation, Medical ultrasonic image

汪天富: 男, 1966年生, 博士, 主要从事医学图像处理和网络的研究。

李德玉: 男, 1967年生, 博士, 主要从事医学图像处理和小波分析的研究。

郑昌琼: 女, 1931年生, 教授, 博士生导师, 主要从事医学生物工程的研究。