

# 一种肺部肿瘤 CT 图象序列的自动分割方法

姜晓彤<sup>1)</sup> 罗立民<sup>1)</sup> 汪家旺<sup>2)</sup> 潘晓敏<sup>1)</sup> 周正东<sup>1)</sup>

<sup>1)</sup>(东南大学生医系影像实验室, 南京 210096) <sup>2)</sup>(南京医科大学一附院, 南京 210029)

**摘 要** 肺部肿瘤序列图象的自动分割是计算机肺部肿瘤三维辅助诊断系统的关键技术之一, 肿瘤与周围组织关系的复杂性造成分割困难. 为了给医生提供准确的肺部肿瘤影像, 运用纹理分析和径向基神经网络实现了肺部肿瘤 CT 图象序列的自动分割, 并根据相邻层肿瘤图象灰度、位置的相关性, 提出了一种自动获取多层肿瘤区域神经网络训练样本的阈值分割算法. 该算法首先计算图象纹理统计参数, 以组成特征矢量空间, 然后利用自适应径向基神经网络对特征矢量进行分类来实现肿瘤序列图象的自动分割. 实验结果表明, 与基于灰度的区域增长法和基于梯度算子和形状算子的最优阈值的分割方法相比较, 该方法不仅能充分利用肺部肿瘤序列图象的三维信息, 还可最大限度地减少人工干预, 且分割结果较好地表现了肿瘤形态特征, 经临床医生评估, 具有较好的临床指导价值.

**关键词** 计算机图象处理(520·6040) 肺部肿瘤分割 纹理分析 径向基神经网络

**中图法分类号:** TP391.41 R445-39 **文献标识码:** A **文章编号:** 1006-8961(2003)09-1028-06

## An Automatic Segmentation Approach for CT Serial Images of Lung Tumors

JIANG Xiao-tong<sup>1)</sup>, LUO Li-ming<sup>1)</sup>, WANG Jia-wang<sup>2)</sup>,  
PAN Xiao-ming<sup>1)</sup>, ZHOU Zheng-dong<sup>1)</sup>

<sup>1)</sup>(Lab Of Image Science and Technology, Southeast University, Nanjing, 210096)

<sup>2)</sup>(The First Affiliated Hospital, Nanjing medical University, Nanjing, 210029)

**Abstract** The segmentation of lung tumor serial images is one of the key techniques of Computer Lung Tumor Three-dimensional Aided Diagnosis System. The complex relation between tumor and its adjacent tissue makes it difficult to get good result. For providing doctors more accurate lung image, an automatic segmentation of lung tumor in CT serial images is presented based on texture analysis and radial basis function(RBF) neural network. With the correlation of tumor's gray level and position in sequential slices, we got the training swatch of tumor region automatically. Some second-order statistical texture parameters were computed for composing feature space; a classification procedure based on RBF neural network was applied to this space to segment the tumor. Compared with region growth algorithm and the multi-criterion segmentation algorithm, the experiment demonstrates that the proposed method can make full use of three-dimensional information of tumor serial images, and reduce manual intervention as possible. The segment results also confirm the validity and the clinical value of the proposed method.

**Keywords** Computer image processing, Lung tumor segmentation, Texture analysis, Radial basis function neural network

## 0 前 言

肺部恶性肿瘤一直严重威胁着人类的生命健康, 而恶性肿瘤的早期发现却可以大大提高治愈率, 但如何准确、方便、迅速地确诊肿瘤则是医学界长期

存在的一个难题. 随着高速多排 CT 的广泛应用和计算机图象处理技术的发展, 计算机辅助诊断系统为准确、方便、定性、定量地诊断肿瘤提供了新的手段. 而在该系统中, 三维肿瘤图象的分割则是关键技术之一, 由于它直接影响着肿瘤体积、表面粗糙度等重要诊断信息的获取, 因而进行三维肿瘤图象分割

技术的研究具有重要的意义。

肺部肿瘤的分割一直是医学图象处理方面的难题,这是由于:

(1)由于肺部各组织的CT影像灰度值分布较广,且部分重叠,某些组织,如软组织、血管等又与肿瘤影像的灰度值相似,因此仅考虑灰度信息将无法准确分割。

(2)由于肺部肿瘤本身形状、大小各异,生长环境复杂,无具体规则可言,且肿瘤影像本身虽灰度相对较高,但其边缘处往往较为模糊,因此难以准确分割。

国外相关学者在这方面做了较广泛的研究,已提出一些分割方法,如基于梯度算子和形状算子的最优阈值的分割方法<sup>[1]</sup>,该方法虽能较好地将与肿瘤相连的血管等组织分离出来,但由于其仅依据获取的最优阈值来对图象进行分割,因而对边界模糊的肿瘤分割效果不佳;又如基于弹性模型的分割方法<sup>[2,3]</sup>,该方法虽能够保证得到封闭的轮廓,并且对图象噪声和对比度不敏感,且计算量小,但其对初始轮廓敏感,并可能陷入局部最小而需较多的人工干预;而且以上方法均将每幅断层图象看作是孤立的图象进行处理,并没有利用断层图象序列之间的相似信息。据研究,CT断层序列数据反应了肿瘤组织的三维空间信息,这就为直接进行肿瘤影像的三维分割创造了条件,文献<sup>[4]</sup>阐述了一种基于动态曲面模型的三维对象分割方法,文献<sup>[5]</sup>提出了一种基于最优阈值的三维肿瘤分割方法。这些方法均能够充分利用CT数据的三维信息,并具有较高的分割效率,但是由于设备条件的限制,断层序列图象往往是异分辨率的,即虽然层内分辨率较高(如 $0.33 \times 0.33\text{mm}$ ),但由于层间距离一般较大(如 $3 \sim 10\text{mm}$ ),如果采用薄层扫描的方式,也只能达到 $1 \sim 1.5\text{mm}$ ,因此即使通过层间插值处理,也会丢失许多层间信息,这就大大影响了肿瘤影像直接三维分割的分割效果。

尽管肺部肿瘤影像区域的灰度值和其他某些组织相差不大,然而由于它们纹理之间的差异比灰度值差异显著得多,因而基于纹理分析的分割方法更适合于CT图象的分割<sup>[6,7]</sup>,因为纹理是视觉感知的图象局部特征的综合。对于非结构化纹理,一般采用统计的方法来描述其特征。有关纹理分割的纹理局部特征的选用应根据具体的对象而定,即可通过学习样本来选定,以获得理想或最佳的分割效果。在纹理特征矢量获取后,图象区域的分割可归结为经

典的模式识别的分类问题,为了快速分类,可采用径向基神经网络来实现特征矢量的分类。

神经网络方法因其具有非线性特点和自学习功能而被广泛应用于医学图象的分割,该方法可分为以下两种情况:(1)有监督型,如文献<sup>[6]</sup>运用BP神经网络提取CT图象肝脏区域,但这需事先提供训练样本;(2)无监督型,如文献<sup>[7]</sup>运用HNN神经网络实现CT图象各组织的分离。本文研究的对象为CT肿瘤图象,鉴于肿瘤及其周围组织的特点,如单纯依靠神经网络的竞争机制来实现无监督分割难度较大;如采用有监督型神经网络来实现分类则必须提供足够的训练样本。这样对于体积较小肿瘤而言,每层图象所能提供的训练样本往往不足以正确分割本层肿瘤区域。CT断层数据反映了肿瘤组织的三维空间信息,而且肿瘤往往涉及多层CT图象,由于各层肿瘤图象具有很强的位置、灰度、纹理相关性,因此可以通过综合各层肿瘤区域的训练样本来对神经网络进行训练,以实现肿瘤序列图象的分割。本文提出一种基于相邻层肿瘤图象灰度、位置相关性的阈值分割算法,用来自动获取整个肿瘤序列纹理分割的训练样本,这样不仅可以充分利用CT断层数据所提供的肿瘤信息,并可最大限度地减少人工交互。

本文基于纹理分析和自适应径向基神经网络的肿瘤序列图象分割方法分如下3个部分:(1)对原始CT图象进行预处理,首先获取感兴趣的区域(Region of Interest, ROI),然后根据相邻层图象之间的相关性获取整个瘤序列的神经网络训练样本;(2)给出5个纹理特征参量,用来组成与像素对应的5维特征矢量;(3)用自适应径向基神经网络来对特征矢量进行分类,以实现肿瘤序列图象的自动分割。

## 1 CT图象的预处理

本文所处理的CT图象数据取自西门子公司高速双排CT机,层内分辨率为 $0.33 \times 0.33\text{mm}$ ,层间厚度 $1.5\text{mm}$ ,图象灰度范围 $-2000 \sim 2000$ ,去除干扰噪声后,进行预处理,预处理分如下两个步骤:

### 1.1 确定图象感兴趣区

为了提高分割效率,可允许用户使用鼠标来交互式地选择适当的矩形感兴趣区(ROI),以使每层的肿瘤都包含在ROI中,这样就将分割的对象限定在ROI中。

### 1.2 获取神经网络的训练样本

本文提出了一种自动获取训练样本的算法。该算法基于以下两个事实：

①肿瘤区域，特别是肿瘤内部的像素灰度明显高于其背景及其他大部分组织。

②相邻层肿瘤图象在灰度、形状、位置上有很强的相关、相似性。

算法实现如下：

(1)以  $5 \times 5$  的模板卷积 ROI 区域的每个像素，并将求取得到的模板内像素的平均值作为输出，若获得的像素输出值最大，则可以认定该像素位于肿瘤内部(临床经验表明，肿瘤内部通常发生钙化，其 CT 值明显高于周围组织)，可将该像素作为下面进一步处理的初始像素，这个过程也可由用户直接指定实现。

(2)以像素所在层作为初始层来求得该层图象灰度直方图(如图 1 所示)。




图 1 CT 图象灰度直方图

为反映组织分布趋势，该直方图曲线已经过平滑处理，X 轴代表 CT 图象灰度值，Y 轴代表像素数目，其中，a 区对应着空气、脂肪、气管等组织；b 区对应着血管、软组织、肌肉等成分；c 区主要对应着肿瘤部分，由于 b 和 c 区没有明确的界限，即血管、软组织与肿瘤边缘灰度值很接近，很难通过阈值分割直接分离，因此训练时，可取 a 区的全部，b 区面积的三分之二部分(该比例由试验确定)作为非肿瘤样本区间(低灰度值优先)，并将该区间的像素直接作为非肿瘤神经网络训练样本像素。以 c 区面积的三分之二的像素为肿瘤样本像素(如图 1 所示)。分割时，以初始像素为种子点，以像素灰度是否属于肿瘤样本区间为增长准则，并用区域增长法确定神经网络的肿瘤训练样本像素来得到肿瘤样本区域。

(3)计算该层肿瘤训练样本区域的重心坐标：

$$x = \frac{m_{1,0}}{m_{0,0}}, y = \frac{m_{0,1}}{m_{0,0}}$$

其中， $m_{p,q}$  是  $(p+q)$  阶中心矩，其表达式为

$$m_{p,q} = \sum_x \sum_y x^p y^q f(x,y).$$

$$\begin{cases} f(x,y) = 1 & (x,y) \in \text{肿瘤样本区域} \\ f(x,y) = 0 & (x,y) \notin \text{肿瘤样本区域} \end{cases}$$

(4)计算相邻层图象灰度直方图。由于相邻两层图象灰度直方图，其肿瘤样本区间的峰值灰度具有很强的相似性，因此利用这种相似性就可由上一层肿瘤样本区间的峰值来确定本层肿瘤样本区间。同时可利用相邻层肿瘤影像区域重心之间的相关性来确定本层肿瘤样本区间。如果与上层重心坐标对应的本层像素的灰度值属于肿瘤样本区间，则将该像素作为本层肿瘤影像区域增长的生长点；如不属于肿瘤样本区间，则寻找与该像素距离最近，且属于肿瘤样本区间的像素作为肿瘤影像区域增长的生长点。与步骤 2 方法类似，由该生长点和肿瘤样本区间，不仅可获得本层神经网络的肿瘤训练样本像素，同时也可获得非肿瘤神经网络训练样本像素。最后计算该层肿瘤样本区域的重心坐标，以便为处理下一相邻层图象作准备。

这样直至处理完所有层图象，就可获得各层神经网络的非肿瘤训练样本像素和肿瘤训练样本像素，以及各种肿瘤样本区域的重心坐标，这就为下面的神经网络分割提供了必要的条件。

## 2 纹理特征参数的选取

大家知道，能表述纹理特征的参数很多，其中灰度共生矩阵作为描述图象灰度的空间相关性和空间分布特性的方法已被广泛采用，由此又导出许多有关纹理的二阶统计参数。为便于简便完整地描述灰度共生矩阵，这里采用一种各向同性的共生矩阵，通过多次实验比较，确定了下述 3 个由灰度共生矩阵衍生的分割效果较好的参量：

均匀度

$$H = \sum_m \sum_n \frac{p(m,n)}{1 + |m - n|} \quad (1)$$

能量

$$E = \sum_m \sum_n p^2(m,n) \quad (2)$$

对角矩

$$E = \sum_m \sum_n \sqrt{0.5|m - n|} p(m,n) \quad (3)$$

其中,  $m$  和  $n$  可作为参量坐标的有序灰度值.

这 3 个纹理特征量和纹理窗口内像素灰度的均值和像素的灰度值可作为神经网络分类器的输入量来实现图象的分割.

### 3 纹理特征的计算

由于单个像素无法计算纹理特征,因此通常以某像素为中心的矩形区域的纹理特征作为该像素的特征,这样对于计算边界像素纹理就会产生一个问题(如图 2 所示).




图 2 纹理特征的计算示意图

由于窗口中心点  $E$  的纹理特征受到病灶边界两侧的像素灰度值影响,因而计算出来的纹理参数具有较大的不确定性,这将会影响后面神经网络分类的效率,并可使边界变模糊.为解决这一问题,本文采用一种优化的方法,如图 2 所示,围绕中心点  $E$  的 4 个矩形区域(标为  $A, B, C, D$ )至少有一个基本属于病灶区或背景区.由于 CT 图象同一类型(同属于病灶区或背景区)像素的灰度值相对均匀,而非同一类型像素的 CT 灰度值则相差较大,因而就可以通过均匀性来确定和计算纹理特征的矩形区域,以获得较稳定的纹理特征.算法如下:

首先将图 2 的 5 个矩形区域( $A, B, C, D, E$ )分成 4 个子区域;然后

(1) 计算 CT 图象每个子区域内像素灰度平均值  $\bar{g}_1, \bar{g}_2, \bar{g}_3, \bar{g}_4$ , 如图 2 所示.

(2) 计算每个矩形区域的均匀度  $H$ .

$$H = |(\bar{g}_1 + \bar{g}_4) - (\bar{g}_2 + \bar{g}_3)| + |(\bar{g}_3 + \bar{g}_4) - (\bar{g}_1 + \bar{g}_2)|$$

(3) 计算具有最小  $H$  值的矩形区域的纹理特征值,即为该像素的纹理特征.

纹理窗口大小的选择也影响纹理特征的正确获得,一般尺寸大的窗口有利于纹理特征的计算,因为它包含了更多的像素点,其可以获得较准确的纹理特征,但太大的纹理窗口将不利于计算边界处的纹理,甚至会掩盖一些小的组织结构(如果窗口的尺寸

大于组织本身),通过试验,选择固定尺寸( $5 \times 5$ )的窗口来计算纹理特征比较合适.

### 4 运用神经网络实现分割

神经网络是运用生物神经网络的机理,即通过大量相对简单的非线性神经单元之间复杂而又灵活的联结关系来模仿人脑的智能化信息处理过程,由于其中的径向基神经网络具有局部收敛迅速的特点,因此本文采用自适应径向基神经网络来实现纹理特征的分类.

该神经网络由 3 层组成(如图 3 所示),其中输入层包含 5 个节点,它们与输入的纹理特征矢量相对应;输出层包含一个节点,其输出值与分类区域相对应;在兼顾效率和精度的原则下,隐层神经元的数目可由自适应算法决定.<sup>[8]</sup>




图 3 神经网络结构图

#### (1) 训练样本

由 1.1 节可知,肿瘤训练样本像素点和非肿瘤训练样本像素点已从各层 ROI 区中获得.若将这些计算得到的像素纹理特征量,经过归一化处理后,即可获得神经网络第  $i$  个像素的输入向量  $F_i = (x_1, x_2, x_3, x_4, x_5)$ ,而其对应的期望输出:肿瘤训练样本为 0.9,非肿瘤训练样本为 0.1.

#### (2) 训练模式

对神经网络进行训练,同时比较系统输出与期望输出,如果误差超出了误差界,则修正网络参数向量,同时自适应地调节隐层节点的数目以达到最优<sup>[8]</sup>.

#### (3) 识别模式

神经网络训练完成后,再对 ROI 区所有像素进行识别;识别结果为系统输出小于或等于某阈值的像素为非肿瘤区域像素;大于该阈值的像素为肿瘤

区像素。由于某些恶性肿瘤与周围组织相浸润,使肿瘤周边模糊,因而要正确划分出肿瘤组织,则应尽量把这部分模糊区域作为肿瘤对待。本文是通过设置适合的阈值(该阈值由试验确定)来使模糊区域尽量落在肿瘤区。然后通过将肿瘤区域像素值置为 1,将非肿瘤区像素值域置为 0 来将 CT 灰度图象转变为二值图象,即可清晰地识别肿瘤。


(4) 图象分割

识别过程完成后,肿瘤图象已转换为二值图象。由于 ROI 区可能有些与肿瘤不相连的组织因性质与肿瘤相近而当作肿瘤部分保留了下来,为了消除这些非肿瘤组织影像,以 2.1 节所获的各层肿瘤样本的重心为种子点,利用简单的区域增长法来获取肿瘤部分的影像,即可实现最终的分割。

### 5 实验结果


为了验证本文方法的有效性,选取了某肺癌断层 CT 图象序列数据,按上述方法进行了实验,实验平台为 Pentium4 1.5G CPU,128M 内存。该肺癌

CT 图象共 13 层,由实验结果可见,获取整个肿瘤的训练样本耗时 18s;神经网络的学习过程耗时为 71s;神经网络的分割过程耗时 21s,整个分割过程共耗时 110s,可见其在实际应用中可以接受的。图 4 为其中具有代表性的一层图象的实验结果。图 4(a)是原始 CT 图象,由图 4(a)可见,肿瘤边界较模糊,部分与血管相连,血管与肿瘤边缘的灰度值很接近;图 4(b)是采用基于灰度的区域增长法分割所获得的结果,显然该方法将血管误分为肿瘤;图 4(c)是基于梯度算子和形状算子的最优阈值分割方法<sup>[1]</sup>的分割结果,由于加入了形状约束因子,肿瘤与血管部分分开了,然而,具有重要临床价值并能体现肿瘤特征的形态特征,如毛刺,却无法体现出来;图 4(d)是基于纹理分析的神经网络方法得到的分割结果,由图 4(d)可见,肿瘤与血管相分离且肿瘤轮廓信息清晰可见。图 5(a)是某肿瘤原始 CT 图片,由该图可见,肿瘤某些部分与周围软组织相连,且灰度值相近;图 5(b)是采用基于纹理分析的神经网络方法得到的分割结果。经临床医生鉴别,这两例肿瘤的分割结果均较好地反映了肿瘤的形态特征。



(a) 原始 CT 图象 (b) 基于灰度的区域增长法分割结果 (c) 基于梯度算子和形状算子的最优阈值分割结果 (d) 基于纹理分析的神经网络分割结果

图 4 不同方法肿瘤分割结果 1



(a) 原始 CT 图象 (b) 基于纹理分析的神经网络分割结果

图 5 肿瘤分割结果 2

### 6 结论

本文首先利用相邻层 CT 肺部肿瘤图象灰度、形状、位置的相关性来自动获取肿瘤序列的神经网络训练样本;然后运用纹理分析及径向基神经网络实现肿瘤序列图象的分割,实验结果证明,该方法是有用的,但当肿瘤与周围组织相互渗透时,肿瘤边界的细节较难体现,而且神经网络的效率也有待进一步提高;另外,目前对分割结果有效性的评估主要依赖于临床医生的临床经验,如何从临床的角度对有效性进行定量定性的分析也是一个值得研究的问题。

参 考 文 献

- 1 Zhao Bin-sheng, David Yankelevitz. Two-dimensional multi-criterion segmentation of pulmonary nodules on helical CT images[J]. Medical Physics, 1999,26(6):889~895.
- 2 Ashton F A, Berg M J, Parker K J. Segmentation and feature extration techniques, with applications to MRI head studies[J]. Magnetic Resonance Medicine, 1995,33(5):670~677.
- 3 McInerney T, Terzopoulos D, Medical image segmentation using topologically adaptable snakes [A]. In: Proceedings First International Conference on Computer Vision, Virtual Reality, and Robotics in Medicine (CVRMed'95) [C], Nice, France, 1995,905:92~101.
- 4 Vincent Caselles, Ron Kimmel. Minimal surfaces based object segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997,19(4): 201~209.
- 5 Rafael Wiemkera, Andre Zwartkruisb. Optimal thresholding for 3D segmentation of pulmonary nodules in high resolution CT [A]. In: Proceedings of International Conference Computer Assisted Radiology and Surgery (CARS'01) [C], Berlin, Germany, June 2001:611~616.
- 6 Lee Chien-cheng, Chung Pau-choo, Recognizing abdominal organs in CT images using contextual Neural Network and Fuzzy rules [A]. In: Proceedings of the 22 Annual Engineering of Medicine and Biology Society International Conference [C], Chicago Illinois USA, 2000:1745~1748.
- 7 Koss J E, Newman F D. Abdominal organ segmentation using texture transforms and Hopfield Neural Network [J]. IEEE Transactions on Medical Imaging, 1999,18(7):640~648.
- 8 Kung S Y, Hu Y H. A Frobenius approximation reduction method for determining optimal number of hidden units[A]. In: Proceedings of Internatioanal Joint Conference on Neural Networks[C], Seattle, WA, USA, 1991.



**姜晓彤** 1975 年生,2001 年获东南大学测试技术和智能仪器专业硕士学位,现为东南大学生物医学电子工程系医学影像专业博士研究生.研究方向为医学图象处理,计算机辅助诊治,虚拟现实等.



**罗立民** 1956 年生,1986 年获法国雷恩大学信息处理专业博士学位.现为东南大学教授博士生导师.长期从事医学图象处理和生物医学工程研究,在国内外核心期刊发表论文 70 余篇,主持科研开发 20 多项.



**汪家旺** 1959 年生,1993 年获西安医科大学医学影像专业硕士学位,毕业后分配在南京医科大学一附院从事医学影像研究和教学工作.工作期间,在国家级和省级杂志发表论文 10 余篇.



**潘晓敏** 博士研究生,1970 年生,1991 年获东南大学医学图象处理专业硕士学位.研究方向为计算机图形图象技术、非刚体配准及模式识别等.

**周正东** 1969 年生,博士研究生,1990 年毕业于上海交通大学生物医学工程系,2002 年获东南大学医学图象处理专业硕士学位.研究方向为、放射治疗治疗计划优化、模式识别、科学可视化等.