

Abstract

Title: ROI's segmentation and visualization in radiotherapy Treatment Planning System

Author: Zhou Jian

Thesis Supervisor: Professor Luo Limin

School: Southeast University

Region of Interest's (ROI) segmentation and visualization are studied in this thesis. In order to set radiologists free from the tedious work of locating the ROI, we propose two methods, which *segment objects semi-automatically or automatically. The first one: using watershed algorithm coupled with manually incorporation. Several filters and gradient formation methods have been considered during the pre-processing stage. In the meanwhile a fast watershed method based on chain code has been introduced and the traditional watershed method base on flood has been improved to suppress the over-segmentation greatly without increasing computing time. 3 incorporation rules have been compared to process the segmentation. The second one: using SOM and contextual neural networks to segment image and recognizing objects by judging rules. Besides, for the purpose of improve the ROI's visual effect, visualization technology is also introduced. We reconstruct 3-D human body model using contours to help radiologists observing the appearance, position and size of the focus and organs, and implemented the Digitally Reconstructed Radiographs (DRR) and Beam's eye view (BEV) which are important in CT simulations. To enhance the effect of BEV, we blend the 3-D image of the ROI into DRR using image fusion to get the 3-D BEV image.*

Keywords: Radiotherapy, TPS, ROI, segmentation, visualization, watershed, neural network

第一章 绪论

§ 1.1 课题背景

§ 1.1.1 放射治疗计划系统

放射治疗是利用放射线治疗肿瘤的一种方法,它仅有几十年的历史,但发展很快。近年来,放射治疗在肿瘤治疗中的地位愈显重要。统计表明,目前大约 60%~70%的肿瘤患者在病程的不同时期因不同的目的需要接受放射治疗。

理论上讲,如果放射剂量不受限制,那么病人的任何肿瘤组织都会被彻底杀灭。但是肿瘤细胞被正常组织所包围,杀死肿瘤的同时会损伤正常组织。另外,由于肿瘤位置、病人呼吸等原因,普通放射的定位比较困难,治疗的同时也会将部分正常组织杀死,而且定位欠精确也会影响肿瘤的治疗效果。因此,如何借助各种辅助工具和技术最大限度地提高肿瘤组织放射剂量,最大限度地减少正常组织的放射剂量,同时保证肿瘤组织所受剂量的均匀性是治疗肿瘤的关键问题,而这正是放射治疗计划系统的作用所在。

放射治疗技术的快速发展和计算机信息处理技术相结合,产生了放射治疗计划系统。它的出现不仅使得物理师从繁琐的手工计算中解脱出来,而且治疗的速度、准确性都有很大提高,放射治疗计划系统已经成为放射治疗中不可或缺的一个部分。放射治疗计划系统的主要功能是接受 CT / MRI / PET 输出的图像(通过网络、中介介质等),病变组织(靶区)及重要器官和组织轮廓的勾画及重建,建立患者治疗坐标系,制订一个优化的治疗方案,输出治疗方案实施的细节到治疗机的控制计算机,以及到为实施该治疗方案所需要的治疗辅助工具(如挡块、组织补偿等)制作器上。

§ 1.1.2 放疗感兴趣区域的分割与可视化

在制定放疗计划过程中,医生必须清楚地了解病人病灶、周边组织等感兴趣区域的空间位置、范围和发展状况,以正确地安排射野,确保靶区位置和形状的准确性。放疗感兴趣区域的分割与可视化技术可以准确地构建出感兴趣区域三维模型,它已经成为放射治疗计划系统中一项关键技术。感兴趣区域分割与可视化主要包括两方面的内容:首先,利用分割方法,分割出二维切片上的感兴趣区域,并得到相应的轮廓线;继而利用可视化技术中的表面重建算法,重建出感兴趣区域的三维模型。

§ 1.2 图像分割和可视化的发展现状

§ 1.2.1 图像分割

医学图像分割到今天仍然没有得到圆满解决,一个重要的原因是医学图像的复杂性和多样性。由于医学图像的成像原理和组织本身的特性差异,而且图像的形成受到诸如噪音、场偏移效应、局部体效应和组织运动等影响,医学图像和普通图像比较,不可避免地具有模糊、不均匀性等特点。另外,人体解剖组织的结构和形状复杂,而且人与人之间有相当大的差别,

这些都给医学图像分割带来了困难。传统的分割技术或者完全失败,或者需要一些特殊的处理技术。因此,我们有必要针对医学应用这个领域,对图像分割方法进行研究。为了解决医学图像分割问题,近几年来,很多研究人员做了大量工作,提出了很多实用的分割算法,随着统计学理论、模糊集理论、神经网络、形态学理论、小波理论等在图像分割中的应用日渐广泛,遗传算法、尺度空间、多分辨率算法、非线性扩散方程等新方法和新思想也不断被用于解决分割问题^[5,6]。下面我们列举了一些常用的医学图像分割方法。

1. 阈值分割。它的优点是简单,对于不同类的物体灰度值或其他特征值相差很大时,它能很有效的对图像进行分割。阈值分割通常作为预处理,在其后应用其他一系列分割方法进行处理,它常被用于CT图像中皮肤、骨骼的分割。缺点是不适用于多通道图像和特征值相差不大的图像,对于图像中不存在明显的灰度差异或各物体的灰度值范围有较大重叠的图像分割问题难以得到准确的结果。它仅仅考虑了图像的灰度信息而不考虑图像的空间信息。阈值分割对噪声和灰度不均匀很敏感。针对阈值分割方法的缺点,不少学者提出了许多改进方法。在噪声图像的分割中,一些阈值分割方法还利用了一些像素邻域的局部信息,如基于过渡区的方法,还有利用像素点空间位置信息的变化阈值法,结合局部灰度和连通信息的阈值方法。

2. 并行微分算子。并行微分算子法对图像中灰度的变化进行检测,通过一阶导数极值点或二阶导数过零点来检测边缘。通常用的一阶导数算子有梯度算子、Prewitt和Sobel算子;二阶导数算子有Laplacian算子、Kirsch算子、Walls算子等非线性算子。梯度算子不仅对边缘信息敏感,而且对图像噪声也很敏感。为了减少噪声对图像的影响,通常在求导之前先对图像进行滤波。

3. 基于形变模型的方法。基于形变模型的方法综合利用了区域与边界信息,结合了几何学、物理学和近似理论。它们通过使用从图像数据获得的约束信息、目标位置、大小、形状等先验知识,可有效地对目标进行分割、匹配和跟踪分析。从物理学角度,可将形变模型看成是一个在施加外力和内部约束条件下自然反应的弹性物体。

4. 基于模糊集理论的方法。图像分割问题是典型的结构不良问题,而模糊集理论具有描述不良问题的能力,所以模糊理论被引入到图像处理和图像分析领域,其中包括用模糊集理论来解决分割问题。基于模糊理论的图像分割方法包括模糊阈值分割方法、模糊聚类分割方法和模糊连接度分割方法等。模糊阈值技术利用不同的s型隶属函数来定义模糊目标,通过优化过程最后选择一个具有最小不确定性的s函数,用该函数表示目标以及属于该目标像素之间的关系,这样得到的s型函数的交叉点为阈值分割需要的阈值,这种方法的困难在于隶属度函数的选择。模糊C均值聚类(FCM, Fuzzy C-Means)方法通过优化表示图像像素点和C个类中心之间的相似性的目标函数来获得局部极大值,从而得到最优聚类。这种方法的缺点是计算量大。FCM方法常被用于医学图像的分割。

5. 神经网络法。由于神经网络由大量基本处理单元构成,因此可以在某种程度上模拟生物体神经网络的活动。它不仅具有非线性和自学习功能等突出的特点,而且,基于神经网络的医学图像分割系统具有较好的鲁棒性。目前已有各种类型的神经网络应用于医学图像分割,如前向神经网络、反馈网络、自组织神经网络等。

§ 1.2.2 可视化

科学计算可视化在医学领域得到了广泛的应用,并由此发展了一个新的领域:医学数据可视化^[5]。进入70年代以来,随着计算机断层(CT)、核磁共振(MRI)、超声等医学成像技术的产生和发展,人们可以得到人体及其内部器官的二维数字断层图像序列或三维数据(称为医学体数据)。作为科学计算可视化的一个重要研究分支,医学体数据的三维可视化就是要

在计算机上对这些离散数据进行插值,将其转变成为具有直观立体效果的图像,利用人类视觉系统特性来展示物体器官的三维形态,从而提供若干用传统手段无法获得的解剖结构信息,并为进一步模拟操作提供视觉交互手段。

在医学体数据三维可视化技术的发展过程中,与计算机硬件性能的发展密切相关。随着计算速度、内存容量以及其它图象加速设备的发展日新月异,即使面对庞大的医学体数据,可视化速度也不断改善。近年来医学成像设备的物理分辨率不断提高,譬如 MRI 成像分辨率可以达到 $0.2\mu\text{m}$, 这意味着对可视化运算速度的更高要求。与计算机硬件发展相伴而行的三维可视化算法研究也成为热点,而基于现有的硬件环境,根据各种应用的具体需求,在生成图象质量与绘制速度间寻求可能的最佳方案,是三维可视化算法研究与应用的宗旨,目前在此基础上已形成了许多具体算法,较为典型的有:轮廓线表面重建算法,移动立方体算法(Marching Cube),光线跟踪等。

§ 1.4 论文内容及章节安排

本文主要研究了放射治疗计划系统中感兴趣区域的分割和可视化。包括感兴趣区域的半自动、自动分割技术,分割结果的轮廓线表面重建,以及重建结果在 CT 模拟中的应用。

论文共分为五章,各章节安排如下:

- 第一章 绪论:介绍了课题背景,讨论了分割和可视化技术的发展现状。
- 第二章 放疗感兴趣区域的半自动分割:首先研究了分水岭算法的预处理技术。使用强滤波器滤波,多尺度形态学梯度算法求梯度图,并确定了滤波器和梯度算法各自所用模板的参数范围;继而改进了传统的 VS 分水岭算法,并实现了一种新颖的基于链码的改进 BM 分水岭算法,前者一定程度上减轻了过分割,后者的处理速度更快;然后比较了几种去过分割的区域合并方法,并提供了手动合并过分割块的实现方式,最终标识出了放疗感兴趣区域。
- 第三章 腹部感兴趣区域的自动识别:提出了 SOM 神经网络和基于多模型的图像上下文相关神经网络相结合的图像分割方法,得到分割结果后,再利用判定准则对腹部感兴趣器官进行自动识别。
- 第四章 放疗感兴趣区域可视化:运用轮廓线表面重建算法构建出放疗感兴趣区域的三维人体模型,以帮助医生直观地观察人体内部病灶及组织器官的形态、位置和尺寸;基于光线跟踪实现了 CT 模拟技术的两个重要应用:数字重建射线图像(DRR)和射野方向观视(BEV)。为了增强 BEV 的效果,提出了通过图像融合,把感兴趣区域的三维图像融入到 DRR 中,得到了具有立体效果的 BEV 图。
- 第五章 总结和展望:总结论文的研究工作并提出了今后的研究方向。

本文的分割算法和重建算法都在微机(P4 2.8G,内存 512M)上实现。

参考文献

- [1] 胡逸民. 肿瘤放射物理学. 原子能出版社, 1999.
- [2] 章毓晋. 图象分割. 北京:科学出版, 2001.
- [3] Pal N R, Pal S K. A review on image segmentation technique. *Patern Recognition*, 1993, 26(9): 1277~1294.
- [4] 章毓晋. 图象处理和分析. 清华大学出版社, 1999.
- [5] 李燕, 谭鸥, 段会龙. 三维医学图象可视化技术综述. *中国图象图形学报*, 2001, 6(2): 103~110.
- [6] 赵志峰, 张尤赛. 医学图像分割综述. *华东船舶工业学院学报(自然科学版)*, 2003, 17(3): 43~48.

第二章 放疗感兴趣区域的半自动分割

§2.1 引言

人体是一个整体,为了治疗某部位的肿瘤而损坏了周围组织特别是一些具有重要功能的器官,由此引起的并发症同样会极大地影响人体的健康。敏感组织(危及器官)指可能卷入射野内的重要组织或器官^[1],由于它们对人体的重要性,我们必须保证它们的安全,因此它们的放射敏感性(耐受剂量)将显著地影响治疗方案的设计或靶区处方剂量的大小。几种器官和组织的耐受剂量列于表 2.1 中。

表 2.1 器官和组织的耐受剂量和损伤表现^[1]

器官	TD _{5/5} (单位: cGy)			TD _{50/5} (单位: cGy)			放射损伤
	1/3	2/3	3/3	1/3	2/3	3/3	
肾	5000	3000	2300	—	4000	2800	临床性肾炎
股骨头	—	—	5200	—	—	6500	坏死
心脏	6000	4500	4000	7000	5500	5000	心包炎
胃	6000	5500	5000	7000	6700	6500	溃疡穿孔
肝	5000	3500	3000	5500	4500	4000	肝衰
耳(中/外)	3000	3000	3000	4000	4000	4000	急性浆液性耳炎
脑干	6000	5300	5000	—	—	6500	坏死、梗塞
膀胱	N/A	8000	6500	N/A	8500	8000	膀胱挛缩和变小

放疗计划设计过程中,根据得到的关于患者的肿瘤分布情况,结合具体肿瘤的临床表现,如肿瘤的类型和期别及其所在部位,放疗医生勾画出靶区和计划区的范围,并预计出靶的致死剂量和周围正常组织特别是敏感组织的最大允许剂量等(为了尽可能减轻对敏感组织的伤害,在选择照射野时应尽量不包括或少包括敏感组织,不得不包括时则应满足各器官或组织耐受剂量的要求),然后借助计算机进行治疗计划的设计。

具体到应用,为了明确地识别出各组织和器官,传统的方法是应用一些简单的计算机画图工具在 CT 图片上手动勾画。这样的工作不仅耗时长久而且极为枯燥^[2]。图像分割是一个可行的解决方法,大量研究者对其做了工作^[3]。我们参考文献^[21],开发了一套分割与手动识别相结合的实现方法:利用速度快、分割完全的分水岭算法得到初始分割,然后手动合并过分割区域并标识出感兴趣区域(在应用中,即放疗敏感组织),效果得到保证的同时,极大地提高了分割效率。

§ 2.2 分水岭分割基本原理

由于图像分割的目的是将一幅图像划分成若干个具有某种均匀一致性的区域,并尽可能精确地定位该区域的边缘,进而把人们“感兴趣的目标物”从复杂的场景中提取出来,以便作进一步的分析和处理,因此,图像分割是图像分析、图像理解以及视频编码前期处理的一个重要步骤。至今,人们已提出了多种图像分割技术和算法^[4],其中,基于分水岭变换的图像分割方法具有计算负担轻、分割精度高的优点^[5]。

分水岭 (watershed) 和集水盆地 (catchment basin) 的概念在地形学中是人所共知的。分水岭线分开了每个集水盆地。例如美国的洛基山脉分水岭 (the Great Divide)，它将美国分成两个区域，落在这个分水岭一边的雨滴往下流最终会到达大西洋，但是落在另一边的雨滴往下流最终会到达太平洋。可以将图像的梯度信息理解为地形表面，其中梯度值表示高程。因此，区域边缘对应高的分水岭线，而低灰度的区域内部对应集水盆地。同时，分水岭分割是一种基于区域的分割，它的目标是创建一致性区域。在分水岭分割中，地形表面的集水盆地在如下含义下是一致的：同一集水盆地的所有像素都与该盆地的最小高程（灰度）区域有一条像素的简单路径 (simple path) 相连，沿着该路径的高程（灰度）是单调递减的。这样的集水盆地表示了分割后图像的区域，如图 2.1。尽管分水岭和集水盆地的概念是很直接了当的，但是设计分水岭分割算法是一个复杂的任务，很多早期的方法不是太慢就是不太精确。




图 2.1 分水岭分割的一维例子：(a) 图像数据的灰度剖面；(b) 分水岭分割，灰度（高程）的局部极小产生了集水盆地，局部极大定义了分水岭线

分水岭最初的算法始于 1975 年 Collins 的算法，它是针对地形数学高地模型设计的。多数现有的算法从使用局部 3×3 操作抽取潜在的分水岭线开始，然后在后续的步骤中将它们连接成地形网络。由于第一步的局限性，这些方法常常不精确^[6]

在数字图像处理中，分水岭的研究有些独立性。在 Meyer 和 Beucher^[7]的论文中，在数学形态学的范畴内介绍了分水岭变换。不幸的是，如果没有特殊的硬件，基于形态学的分水岭变换计算负担重、时间耗费多。

有两种分水岭图像分割的基本方法。一种方法是开始于寻找从图像的每个像素到图像表面高程的局部极小的下游 (downstream) 路径。定义集水盆地为满足以下条件的所有像素的集合：这些像素的下游路径终止于同一个高程极小点。另一种方法始于 Vincent 和 Soille 1991 的论文^[5]，该方法基本上是第一种方法的对偶，代替确定下游路径的是从底开始填充集水盆地。

下面将首先阐述分水岭算法的预处理，继而介绍关于上述两种方法的具体实现及改进。分别是基于 Vincent 和 Soille 浸水模型算法 (VS 算法) 和基于 Bieniek 和 Moga 连通分支的算法 (BM 算法)。这两种算法分别对应于前述第二和第一种分水岭分割方法。

§ 2.3 分水岭分割预处理

§ 2.3.1 形态学滤波器滤波

§ 2.3.1.1 形态学滤波器

在分割之前,输入图像的噪声必须被有效的滤除,以便能够准确计算图像的梯度。传统的分水岭算法常采用线性滤波器,如均值滤波、高斯滤波器等,它们可以滤除图像的高频分量、平滑图像、消除噪声,但是不能有效地抑制纹理细节带来的过分割。相比传统的线性滤波方法,数学形态学的非线性滤波方法更适合于诸如图像分割等与图像几何特性(如大小、形状、连通性)相关的应用。Salember 等^[8]基于连通算子的形态滤波近年来得到了广泛的关注。连通算子的实质在于扩张平坦区域(像素灰度值一致的区域,也可以只包含单个像素),仅将图像中的一个平坦区域合并到另一个平坦区域,简化图像的同时,不会丢失形状信息。这种形状保持特性使基于连通算子的滤波器较其它滤波器更适用于分水岭变换。

开重建及其相应的闭重建^[8,9]滤波器就是一种常用的基于连通算子的形态滤波器:

$$\begin{cases} \text{开重建} & \tilde{\gamma}_n(f) = \gamma^{(rec)}(\gamma_n(f), f) \\ \text{闭重建} & \tilde{\phi}_n(f) = \phi^{(rec)}(\phi_n(f), f) \end{cases} \quad (2.1)$$

其中, γ , ϕ 分别表示数学形态学中的开运算和闭运算; f 表示重建图像; (rec) 表示重建运算; n 表示运算使用的结构元素的尺寸。开(闭)重建在对图像进行开(闭)运算的基础上增加了重建过程(rec)。而重建过程可恢复图像中那些没有完全被开(闭)运算所滤除的成分的边界,即开重建(闭重建)仅仅削去(填平)那些完全被结构元素所包含的“山峰”(“低谷”)。开一闭(闭一开)重建滤波器可以由开重建和闭重建滤波器组合而得。显然,在开一闭(闭一开)重建滤波器的滤波过程中,细密纹理同噪声一起被开闭运算所剔除,而物体显著轮廓却在重建过程中得以恢复,使图像在简化的同时保持主要对象的形状信息。

需要说明的是,由于目标图像是灰度图像,因此所用的开(闭)重建是灰度级重建。所用到的开闭运算可表示为:

$$\begin{cases} \text{开运算} & C = A \oplus B \\ \text{闭运算} & C = A \ominus B \end{cases} \quad (2.2)$$

\oplus 和 \ominus 分别表示灰度膨胀和灰度腐蚀。利用“最大化”和“最小化”运算,可以很容易地将作用于二值图像的二值形态学运算推广到灰度图像上。对一幅图像的腐蚀(或膨胀)运算定义为对每个像素赋值为某个领域内输入图像灰度级的最小值(或最大值)。灰度级变换中的结构元素比二值变换有了更多的选择。二值变换的结构元素只代表一个邻域,而在灰度级变换中,结构元素是一个二元函数,它规定了希望的局部灰度性质。

§ 2.3.1.2 多尺度形态学滤波器

开一闭(闭一开)重建滤波器是单一尺度的形态滤波器,它的性能与结构元素的尺寸密切相关,大的结构尺寸可能会将小而重要的物体完全删除,无法重建;相反,小的结构尺寸

无法对大而复杂的物体进行足够的简化,从而导致过分割。为了弥补它们的缺点,将大、小结构尺寸结合起来, Salembie 等^[8]提出了一种多尺度的形态滤波器:强滤波器(strong filter)。

定义1 滤波器 Ψ 是强滤波器当且仅当 Ψ 满足 $\Psi = \Psi(I \wedge \Psi) = \Psi(I \vee \Psi)$ 。其中, \wedge 表示 inf 算子; \vee 表示 sup 算子; I 表示 identity 算子。对任意 f , 有 $I(f) = f$ 。

可以看出,强滤波器具有鲁棒性,因为对于在范围 $[f \wedge \Psi(f), f \vee \Psi(f)]$ 波动的输入信号(如随机噪声),该滤波器的输出是一致的。本文采用两类强滤波器。

$$\wedge_i^n = \prod_{i=1}^n \tilde{\phi}_i \tilde{\gamma}_i \quad (2.3)$$

$$\vee_i^n = \prod_{i=1}^n \tilde{\gamma}_i \tilde{\phi}_i \quad (2.4)$$

其中, $\tilde{\phi}_i$ 和 $\tilde{\gamma}_i$ 的定义如式(2.1)所示。式(2.3), (2.4)中的滤波器是强滤波器,证明见文献^[10]。可以看到,当 $n=1$ 时,该滤波器就是开-闭(闭-开)滤波器;当 $n \geq 2$ 时,滤波器为多尺度形态滤波器。


§ 2.3.1.3 滤波结果及分析

首先,我们对一腹部 CT 图片分别用高斯滤波器和强滤波器(用(2.3)式,分别取 $n=1, 2, 3$)滤波,并附上了 VS 法分水岭分割结果。滤波结果见图 2.2。




(a) 原图

(b) 未滤波的分割结果




(c) 高斯滤波

(d)高斯滤波后分割结果




(e) $n=1$ 强滤波器滤波

(f) 图(e)的分割结果



(g) $n=2$ 强滤波器滤波

(h) 图(g)的分割结果

(i) $n=3$ 强滤波器滤波

(j) 图(i)的分割结果

图 2.2 不同滤波器滤波结果及相应的分水岭分割结果

分析分割后的小块数以及各块灰度方差的累计值（由于累计值很大，故都除以相同的点数 512×512 ）。

为了下面分析方便，我们用两组各十张图分析了同一序列图片分割后块数和方差累计值的稳定性，以便后面分析不同序列 CT 图片时，仅用一张就可以基本表示整个序列。

表 2.2 不同滤波方式不同序列图像下的分割指标值

高斯滤波	腹部	方差	4143	4087	3979	3958	4033	4183	4346	4288	4253	4212
		块数	1700	1725	1686	1657	1645	1720	1612	1649	1688	1645
	胸部	方差	10094	10427	10279	10102	10146	10233	10308	10381	10458	10260
		块数	1668	1631	1683	1640	1668	1661	1647	1662	1684	1622
强滤波 $n=2$	腹部	方差	2473	2444	2572	2459	2429	2864	2583	2705	2593	2592
		块数	2238	2274	2293	2228	2193	2241	2172	2155	2213	2178
	胸部	方差	2405	2521	2506	2411	2417	2524	2387	2445	2312	2445
		块数	2408	2388	2351	2408	2430	2391	2374	2385	2426	2454
强滤波 $n=3$	腹部	方差	2046	2112	2179	2079	2084	2143	1999	2031	2046	2340
		块数	1541	1613	1575	1548	1601	1560	1524	1576	1556	1567
	胸部	方差	2209	2912	2201	2724	2841	2705	2723	2640	2406	3177
		块数	1528	1560	1526	1513	1500	1546	1505	1512	1550	1481

从表 2.2 可以看出，在不同滤波方式不同序列图像下，每一组指标（指行数据）都相对稳定并且组间有明显区别，因此可以用序列中一张图片的指标基本表示整个序列的相应指标。利用这一点，我们接下去针对 7 组不同 CT 序列各一张固定的图片做了同样的实验，得到表 2.3 的数据。

表 2.3 不同滤波器用于分水岭分割的性能比较

		Thorax1	Thorax2	Sinus	Larynx	Abdomen	Head1	Head2
高斯滤波	方差	4483	10458	9751	8172	4143	9637	4281
	块数	1449	1684	1762	1407	1700	1126	585
强滤波 $n=2$	方差	2543	2312	8967	5143	2473	3050	2980
	块数	1927	2426	2175	1912	2238	1551	885
强滤波 $n=3$	方差	2707	2046	8336	5040	2209	1841	2500
	块数	1297	1556	1549	1346	1528	1051	666
强滤波 $n=4$	方差	2591	1934	7334	4465	2105	1572	2175
	块数	998	1132	1191	1066	1130	800	548
强滤波 $n=5$	方差	2560	1898	9489	4174	1992	1401	1809
	块数	818	862	991	902	904	646	468

可以看出, 强滤波后的两个分割指标随着 n 的增大而减小; $n=2$ 的强滤波分割所得结果虽然方差较高斯滤波小很多, 但由于块数亦多于高斯滤波分割所得结果, 故没有分析价值 (考虑极限情况, 把图像分为 512×512 块, 即每一点为一块, 这时方差为零, 故方差小的优势必须在块数也少的情况下才能体现); $n \geq 3$ 时强滤波分割同高斯滤波分割相比, 具有较小的分块数目, 但 $n \geq 5$ 时图像中很多细节被大尺度模板滤掉, 鉴于运算时间随 n 的变大而迅速增加, 因此我们认为在 $n=2, 3, 4$ 时, 强滤波器比高斯滤波器更适用于分水岭分割的预处理。




图 2.3 强滤波器 $n=5$ 时的 VS 分割, 很多细节被滤去, 如肝的右边缘 (图上显示为左)

§ 2.3.2 形态学多尺度梯度算法

由于分水岭变换的目的就是求出梯度图像的“分水岭线”，因此，基于分水岭变换的图像分割方法，其性能在很大程度上依赖于用来计算待分割图像梯度的算法。但对于基于分水岭变换的图像分割而言，由于传统的形态梯度算法有一个严重的缺点，即它们会受噪声和量化误差的影响，在均匀一致的区域内部产生过多的局部“谷底”，而梯度图像的每个“谷底”在分水岭变换中将引入一个“集水盆地”。因此，这些梯度算子最终将导致“过分割”，即一个均匀一致的区域可能被分成多个区域，以致产生大量虚假的边缘，而无法确认哪些是真正的边缘。人们提出了几种解决方法，包括对梯度信号进行取阈值运算和标记提取，但都存在缺陷^[1]。卢官明^[1]提出了一种基于形态算子的多尺度梯度算法。由于该算法首先对“模糊”边缘进行了有效的增强，因而使得“模糊”边缘上像素的梯度值大于因噪声或量化误差引起的梯度值，然后再用形态重构等算法去除因噪声或量化误差造成的局部“谷底”，这样，即使不进行区域合并，也能产生有意义的分割，并且减轻了后续计算的负担。

§ 2.3.2.1 多尺度梯度算法

虽然许多梯度算子和边缘检测算法都建立在阶跃边缘模型之上，然而在自然图像中并不存在理想的阶跃边缘，即每一边缘都在不同程度上被“模糊”。卢官明将“模糊”边缘用斜坡边缘来建模，并将边缘两边之间的像素灰度差称为“边缘高度”。对于斜坡边缘，由于传统梯度算子（如 Prewitt 梯度）的输出是边缘的斜率，因此，如果边缘的斜率不大，则无法用取阈值的方法来区分斜坡边缘与噪声或量化误差。对分水岭变换来说，理想梯度算子的输出应等于输入的边缘高度，而不是边缘的斜率。传统的形态梯度算法的形态梯度算子的公式如下：

$$G(f) = (f \oplus B) - (f \ominus B) \quad (2.5)$$

其中 \oplus 和 \ominus 就是 2.3.1.1 中的灰度膨胀和灰度腐蚀运算， B 为结构元素。式(2.5)的梯度算子即称为单尺度形态梯度算子，其性能取决于结构元素“ B ”的大小。如果“ B ”足够大，则对斜坡边缘来说，这个梯度算子的输出即等于边缘高度。




图 2.4 对一维信号使用传统梯度算法的输出结果

这一点我们从图 2.4 可以清楚地看出。图 2.4 右半的表格表示普通梯度算子的输出。对于图中的“ A ”点来说，如果运用形态学梯度算子，结构元素 B 的大小为 3×3 ，则“ A ”点的腐蚀运算和膨胀运算的输出分别为阶跃边缘两边的值，相减得到“ A ”点的梯度输出为边缘高度。遗憾的是，大的结构元素会造成边缘间严重的相互影响，这将导致梯度极大值与边缘的不一致；然而，若结构元素过小，则梯度算子虽有高的空间分辨率，但对斜坡边缘会产生一个很小的输出结果。为了利用大结构元素和小结构元素的各自优点，可以使用以下一种多尺度的形态梯度算法^[1]。设 $B_i (1 \leq i \leq n)$ 为一组正方形的结构元素， B_i 的大小为


$(2i+1) \times (2i+1)$ ，则多尺度梯度定义为：

$$MG(f) = \frac{1}{m} \sum_{i=1}^m [(f \oplus B_i - f \ominus B_i) \ominus B_{i-1}] \quad (2.6)$$

对于阶跃边缘， $(f \oplus B_i - f \ominus B_i) \ominus B_{i-1}$ 运算即产生一条与边缘重合的两个像素宽的直线，由于该直线的高度等于边缘高度，因此，在这种情形下，多尺度的形态梯度算子即相当于单尺度的形态梯度算子。在实践中，由于多尺度的形态梯度算子使用了取平均运算，所以抗噪声的能力更强。此外，多尺度梯度算法有很强的抗边缘间相互影响的能力，如对应于某一个梯度极大值的位置不会因其他边缘的存在而受到影响。

§ 2.3.2.2 梯度图生成及分析


我们对腹部 CT 图片用 2.3.1 所述形态学强滤波器（取 $n=2$ ）滤波后，利用上述算法生成梯度图（取 (2.6) 式中的 $m=3$ ），并得到了最后的分水岭分割结果：



(a) 图 2.2 中(i)所生成的梯度图 (b) 相应的分水岭分割结果


图 2.5 形态学多尺度梯度算法运用后的分割结果

同传统形态学单尺度生成梯度方法比较如图 2.6 所示（为了单纯的考虑形态学多尺度梯度算法对最后结果的影响，省略滤波过程）：



(a) $m = 3$ 生成梯度图后的分割结果，分成 1653 块

(b) 单一尺度为 3×3 生成梯度图后的分割结果，分成 2149 块



(c) 单一尺度为 5×5 生成梯度图后的分割结果，分成 765 块

(d) 单一尺度为 7×7 生成梯度图后的分割结果，分成 237 块

图 2.6 形态学多尺度梯度算法与传统单一尺度形态梯度算法用于分水岭分割的比较

我们可以看到，正如前文所述，单一尺度生成梯度图时，小的模板会导致严重的过分割（如图 2.6 的(b)），而大的模板会忽略小的结构元素，造成误分割（如图 2.6 的(c), (d)）。比较发现，多尺度梯度算法既抑制了过分割又很好地保留了小结构元素（如图 2.6 的(a)）。

最后做定量分析，以求得到较为合理的参数 m 。为了单纯的考虑形态学多尺度梯度算法对最后结果的影响，我们对未滤波的属于不同序列的 7 张 CT 图分析，分析分割后的小块数以及各块灰度方差的累计值（采用 VS 分水岭分割算法）。

表 2.4 未滤波时形态学多尺度梯度算法运用后的分割指标

$n = 0$		Thorax1	Thorax2	Sinus	Larynx	Abdomen	Head1	Head2
$m = 1$	方差	5736	13477	10710	8631	6036	12184	4505
	块数	2031	2454	2301	1830	2275	1518	770
$m = 2$	方差	5775	13410	10539	8283	5777	11707	4294
	块数	1941	2370	2237	1809	2191	1491	771
$m = 3$	方差	6250	13872	11098	8868	6236	12530	4363
	块数	1554	2006	1879	1481	1846	1292	623
$m = 4$	方差	6641	14342	11676	9529	6839	12314	4884
	块数	1311	1759	1648	1227	1566	1171	504
$m = 5$	方差	6887	14714	11975	10995	7796	13159	5404
	块数	1112	1591	1483	1050	1371	1081	432

从表 2.4 中可以看出,随着 m 的增大分割结果的块数迅速减少。这意味着部分小块合并,减轻了过分割。可以看出方差在 $m = 1, 2, 3$ 时比较稳定,随后开始增大,因而在后面的应用中我们设定 $m = 3$ 。

加入滤波器后的分割结果如表 2.5 所示。可以看到形态滤波和形态多尺度梯度算法的综合使用可以更好地起到减少过分割、提高分割精度的作用。

表 2.5 滤波后形态学多尺度梯度算法运用后的分割指标

$n = 3$		Thorax1	Thorax2	Sinus	Larynx	Abdomen	Head1	Head2
$m = 1$	方差	2392	1983	8224	5152	2214	1809	2568
	块数	1481	1642	1701	1531	1626	1096	754
$m = 2$	方差	2587	1955	8131	4872	2220	1813	2456
	块数	1400	1630	1653	1470	1592	1087	733
$m = 3$	方差	2707	2046	8336	5040	2209	1841	2500
	块数	1297	1556	1549	1346	1528	1051	666
$m = 4$	方差	2828	2174	8187	5146	2259	1847	2524
	块数	1176	1449	1405	1194	1405	948	593
$m = 5$	方差	2549	2295	8344	4800	2100	1870	2642
	块数	1062	1322	1281	1048	1219	888	537

§ 2.4 分水岭算法

§ 2.4.1 VS 分水岭算法及改进

§ 2.4.1.1 VS 分水岭算法

VS 分水岭算法(即 Vinsert-Soille 算法)是 Vinsert 和 Soille 在 1991 年提出的基于浸水模型的分水岭算法^[5]。其步骤分为排序和浸没两个操作:

1. 排序。在逐渐淹没过程中，并非每次均需处理全部像素。为了能直接访问需要处理的像素，将图像像素灰度值以升序排列像素，得到一个排序后的像素灰度列表直方图，使得在淹没步骤中可以直接访问任一次度级的全部像素，这样可以加速计算。利用排序算法，只需要对图像扫描 2 次便可得到排序结构。

2. 淹没。按图像像素灰度值升序访问每一个像素。对每一个集水盆地分配不同的标记。从整个图像的最小像素值开始，分配标记，依次淹没，利用循环队列来扩展标记过的集水盆地。假设淹没过程已经完成到灰度级 k ，即所有不大于 k 灰度级的像素都已标记。对于灰度级为 $k+1$ 的像素，可能会与其相邻像素同属于某集水盆地。计算每个集水盆地对 $k+1$ 灰度级像素的影响范围，即考虑 $k+1$ 灰度级与集水盆地连接的像素，并且与它的距离最小，则赋予与该集水盆地相同的标记。如果没有与集水盆地相邻，则为其分配一个新的标记。

§ 2.4.1.2 算法改进

如 2.3 节所示，分水岭分割遇到的一个主要问题是过分割，而形成过分割的主要原因是该算法对梯度图像中强度变化极为敏感，即使极小的变化也会形成新的集水盆地。鉴于 VS 算法的特殊性，我们试图建立标准去评价各分水岭线重要性的不同。我们认为边界越明显所对应的分水岭线越重要，必须保留；相反，则去除。为此我们分析图像梯度图，首先给出以下两个定义：

定义 2 浸没过程中，每个集水盆地在与相邻集水盆地间形成分水岭前，其包含的所有像素都有一个相同的势能值，该势能值等于该集水盆地形成时第一个像素的梯度值。如果集水盆地合并，则合并后的集水盆地的势能值等于合并前各集水盆地对应的最小的势能值。

定义 3 浸没过程中，当两个集水盆地形成分水岭时，当前水位高度减去两个集水盆地所对应的较大的势能值，形成落差。落差是对应于分水岭的。




图 2.7 未考虑合并时各集水盆地对应的势能值及分水岭对应的落差值

有了上面的定义,我们大致可以看出落差较大的分水岭对应较明显的边界。于是我们引入一个落差阈值 D ,如果分水岭的落差小于该阈值则相应的集水盆地合并,合并后集水盆地的势能值依照定义 1 改变。针对图 2.7,我们设 $L1 < D < L2$,得到的结果如下图所示:




图 2.8 考虑合并时各集水盆地对应的势能值及分水岭对应的落差值

由于 $L1, L4$ 小于 D ,故集水盆地 2、3 和 4、5 分别合并为 B 和 C。A 为原来的集水盆地 1。合并后 A、B、C 三个集水盆地对应的势能值分别为 $S1, S3, S4$ 。最后我们得到两条分水岭线 $H5$ 和 $H6$,它们的落差为 $L5$ 和 $L6$ 。 $L6$ 与原来的 $L3$ 相同,而 $L5 = H5 - S3 = L1 + (S2 - S3)$,大于原来的 $L1$ 。同理,如果设 $L5 < D1 < L6$ 可以得到仅包含中间一条分水岭的分割。可以看到梯度变化剧烈对应分水岭的落差被保留甚至增强,反映在实际中,明显的边界被保留而不明显的被去除,达到了我们去过分割的目的。

具体实现时,改进算法只是在原有算法基础上加入了一个图像大小的矩阵以记录各点的势能值,然后在确定的分水岭标记上比较两边集水盆地的势能值,并得到落差,继而根据预先设定的落差阈值判断是否合并。

§ 2.4.1.3 改进结果及分析

我们对腹部 CT 图片用形态学强滤波器(取 $n = 2$)滤波后,用形态学多尺度梯度算法生成梯度图(取的 $m = 3$),结合上述改进的 VS 算法得到了最后的分水岭分割结果(落差阈值分别取为 5 和 10)。可以看到过分割被明显抑制,CT 图最后被分割成 1360 块和 976 块(如图 2.9)远小于原 VS 算法的 2161 块(如图 2.5(b))。需要说明的是,该改进算法的速度几乎与原算法相同,对 512×512 灰度范围 $0 \sim 4095$ 的 DICOM 图,都在 0.75s 左右。另外,落差阈值大小的选择并不是越大越好,过大的阈值会出现严重的误分割,通过一系列的实验我们认为合理的取值范围是 $5 \sim 10$ 。




图 2.9 改进 VS 算法的分割结果，共分成 845 块

§ 2.4.2 基于链码的 BM 分水岭算法

BM 算法是 Bieniek 和 Moga 提出的基于连通分支的分水岭算法^[12]。该方法与模拟浸水过程相反，是一个模拟降雨过程，即当雨滴落到山地模型上时，必将沿着山坡流入谷底，雨滴所经过的路线就是一个连通分支，也是雨滴落到谷底的一条最陡峭路径，而通往同一谷底的所有连通分支就形成了一个贮水盆地。与基于浸水模型的方法相比，由于该方法不要进行贮水盆地扩展时的出入队列操作，并且无需像素排序，因此其算法复杂度较低，速度更快。孙涵等^[13]在其基础上提出了基于链码的分水岭分割算法，保持速度较快的同时使得到的结果更利于后续处理。下面简要叙述基于链码 BM 分割算法的原理并给出实验结果。




图 2.10 指出链码和指入链码示意图

首先将传统的链码扩展为指出链码(point-out chain code)和指入链码(point-in chain code)，如图 2.10 所示。

定义 4 指出链码是当前像素指向邻居像素的方向码。指出链码的取值范围为 $\{0, 1, 2, 3, 4, 5, 6, 7, 8\}$ ，其中方向码 8 代表当前像素不指向任何邻居。算法限定每个像素最多只能指向一个邻居像素。

定义 5 指入链码是邻居像素指向当前像素的方向码。由于存在多个邻居同时指向当前像素的情况，所以采用单个字节中的每个比特位分别表示一种指入方向码。这样，指入链码

的取值为 $\{0 \times 00, 0 \times 01, 0 \times 02, 0 \times 04, 0 \times 08, 0 \times 10, 0 \times 20, 0 \times 40, 0 \times 80\}$ 中一个或多个 OR 运算的结果, 其中 0×00 表示没有任何邻居指向当前像素。

由指出链码和指入链码的定义可知, 图像中任意两个像素 A 和 B 间的连通关系可由链码串表示, 即从 A 开始, 可以由一串指出链码到达 B; 同时也可从 B 开始, 通过指入链码回溯到 A。在分水岭变换中, 由于各个贮水盆地内部的像素是连通的, 因此可以用链码来标识和描述贮水盆地。

利用链码实现分水岭变换具有如下性质。

性质 1 图像中任意一个像素到对应的局部极小值点的最陡峭路径都可由该像素开始的一串指出链码表示。

说明: 当前像素 P_i 到对应的局部极小值像素 P_0 的最陡峭路径 L 是由 $\{P_i, P_{i-1}, \dots, P_1, P_0\}$ 这样一串像素组成, 其中各像素的灰度值满足如下关系:

$$f(P_i) \geq \dots \geq f(P_i) \geq f(P_{i-1}) \geq \dots \geq f(P_0) \quad (i = l-1, \dots, 2)$$

并且像素 P_{i-1} 是像素 P_i 邻居中灰度值最小的一个。使用指出链码来描述上述的最陡峭路径如

下: 从当前像素 P_i 开始, 令各像素 $P_i (i = l, \dots, 2, 1)$ 的指出链码指向灰度值小于或等于自己, 且是最小的一个邻居, 则从像素 P_i 开始的与这串指出链码连接的所有像素就是像素 P_i 到

对应的局部极小值点 P_0 的最陡峭路径。由此可见, 只要图像中所有像素都有符合要求的指出链码, 则任意一个像素都能根据指出链码沿最陡峭路径到达对应的局部极小值点。下面给出满足上述要求的指出链码的生成方法。

由链码定义可知, 指出链码的取值由当前像素和其邻居像素的关系决定。设当前像素 P 的灰度值为 $f(P)$, 邻居像素 N_p 中灰度最大值为 $\{f(N_p)\}_{\max}$, 最小值为 $\{f(N_p)\}_{\min}$, 则当前像素与其邻居的灰度值大小关系共有 4 种:

$$(1) \quad \{f(N_p)\}_{\min} < f(P) < \{f(N_p)\}_{\max}$$

$$(2) \quad \{f(N_p)\}_{\min} = f(P) = \{f(N_p)\}_{\max}$$

$$(3) \quad \{f(N_p)\}_{\min} = f(P) < \{f(N_p)\}_{\max}$$

$$(4) \quad \{f(N_p)\}_{\min} < f(P) = \{f(N_p)\}_{\max}$$

显然, 指出链码的取值完全由上述的 4 种关系类型决定。针对这 4 种关系类型, 各像素指出链码的具体生成过程参见文献[13]。

可见, 任意像素通过指出链码串到达对应的局部极小值点的过程就是一个模拟降雨过程。

性质 2 贮水盆地可从对应的局部极小值点开始的指入链码回溯得到。

说明: 由性质 1 可知, 属于同一贮水盆地的所有像素均可通过一串指出链码到达该贮水盆地对应的局部极小值点, 并且在指出链码的形成过程中, 就已生成了相应的指入链码。由于局部极小值点没有灰度值比自己更小的邻居, 它的指出链码值就为 8(不指向任何邻居),

但存在有效的指入链码，因此可从这点开始，根据指入链码回溯，凡是能回溯到的像素，必属于该贮水盆地。

由性质 2 可知，从局部极小值点开始回溯贮水盆地的过程相当于一个模拟浸水过程。

§ 2.4.3 改进 BM 算法与 VS 算法的比较

根据上一小节介绍的两个定义和两条性质，我们可以实现基于链码的改进 BM 分水岭算法，伪代码见文献[13]。给出实验结果的同时，我们比较了改进 BM 算法和传统 VS 算法的性能。从表可以看出前者的速度较快，但分割出的块数也较多，考虑到改进后的 VS 算法能够更好地抑制过分割，这为后续的合并的操作带来了极大的便利，所以我们还是倾向于使用后者的改进算法。实验中的预处理部分我们使用了强滤波器滤波 ($n=2$)，形态学多尺度梯度算法生成梯度图 ($m=3$)。




图 2.11 基于链码的改进 BM 算法分割结果，分割成 3609 块

表 2.6 基于链码的改进 BM 算法与传统 VS 算法的性能比较

$n=2$ $m=3$	区域块数	所用总时间(秒)	预处理时间(秒)	分割算法用时(秒)
基于链码的改进 BM 算法	3609	0.563	0.484	0.079
VS 算法	2161	0.734	0.484	0.25

§ 2.5 基于评价函数的区域合并

虽然我们利用了性能良好的强滤波器滤波，利用形态学多尺度梯度算法生成梯度图，以及在传统 VS 算法中引入了势能和落差两个概念后对其进行了改进，但在保证没有误分割的前提下，这些方法只是在一定程度上抑制了过分割。为了进一步减轻过分割，方便最后的手动合并，我们有如下考虑：前面所述的方法都是在分割前和分割过程中的处理，针对分割后

的结果，我们可以确定若干个评价因子来描述各区域间的相似性，继而做进一步的合并。

我们建立区域邻接图（RAG）来表示区域的相邻关系，通过评价函数计算相邻区域的不相似度，并排序，用数据结构堆来灵活实现。然后合并最小不相似度对应的两个相邻区域，并修改 RAG 和堆。由于这种方法每次只是合并一块区域，合并后还要更新 RAG 和堆，所以效率较低。更简单的方法是设定初始阈值，当评价函数所得值低于该阈值时就合并，不过不能设定过大的阈值（过大很容易误分割），效果也仅是减轻过分割。

§ 2.5.1 区域合并评价函数的构建

观察前几节得到的分割结果图，很容易想到同一组织的各区域间具有灰度相似性。文献[14]正是以区域平均灰度以及面积的差异作为判别两个区域是否相似的依据，具体使用的评价函数为：

$$C(i, j) = \frac{\|R_i\| \times \|R_j\|}{\|R_i\| + \|R_j\|} (\mu_i - \mu_j)^2 \quad (2.7)$$

其中 R_i 和 R_j 是相邻区域， $R_i = \{p_{i,1}, p_{i,2}, \dots, p_{i,\|R_i\|}\} (i = 1, \dots, K)$ 是区域 i 内像素的集合，

$\|R_i\|$ 表示区域 i 的面积大小，即区域内像素的个数。区域的灰度均值为：

$$\mu_i = \frac{1}{\|R_i\|} \sum_{k=1}^{\|R_i\|} Y(p_{i,k}) \quad (2.8)$$

其中 $Y(p_{i,k})$ 表示像素 $p_{i,k}$ 的灰度值。根据此代价函数，灰度均值相近、面积小的区域合并代价小。

另外，考虑到区域不一定是以灰度均值的形式来区别于背景的，因为它很可能是以纹理的方式提供关于区域平滑、稀疏、周期或准周期性的描述。所谓测量一个目标的纹理，就是找出区域中像素灰度级的特殊排列特性，以表示纹理在目标内的有效变化。文献[15]在共生矩阵的基础上，定义了一个基于纹理一致性 A 和对比度 C 的检验准则，用于合并分割结果中满足该准则的相邻区域。其评价函数定义如下：

$$C(i, j) = |W_i - W_j| \quad (2.9)$$

W_i 和 W_j 可表示为：

$$W = \sum_{g_1} \sum_{g_2} |g_1 - g_2| p(g_1, g_2) \sqrt{|g_1 - g| \times |g_2 - g|} \quad (2.10)$$

其中， $p(g_1, g_2)$ 为共生矩阵 P 各元素取值，表示相应位置算子的联合灰度分布，

$\sum_{g_1} \sum_{g_2} |g_1 - g_2| p(g_1, g_2)$ 表示算子相应位置上纹理的对比度。当共生矩阵中大的元素接近

对角线时，对比度较大，等价于近邻图像反差大的情况。对比度描述虽然考虑了位置算子内的纹理特性，但由于不同图像纹理准周期不一样，因此所需位置算子会有差异。如果仅考虑近邻的位置算子，那么只需要对其对比度作一个加权，且加权量与各位位置相对于目标区域均值的偏差有关，就能更好地反映纹理在整个区域内的一致性和对比度。 W 值就是这样的一

一个特性值。

但是考虑到共生矩阵本身计算较慢，而且合并后区域的 W 值需要重新计算（不能通过合并前两个区域的 W 得到），速度就更加难以接受（下一节实验说明）。因此，我们又采用了另一种方式表示纹理特性，用文献[16]中介绍的 Laplace 积分的方法计算每个区域的平均纹理值，其评价函数可表示为：

$$C(i, j) = |T_i - T_j| \quad (2.11)$$

T_i 和 T_j 可表示为：

$$T = (K - |L|) / \|R\| \quad (2.12)$$

其中：

$$K = \sum \sum_R |\Delta I| da \quad (2.13)$$

$$L = \sum \sum_R \Delta I da \quad (2.14)$$

是区域 R 内各点的 Laplace 算子的总和， ΔI 表示点的 Laplace 算子。与式 (2.10) 的纹理评价函数相比，只要分开存储计算各区域的 K 和 L ，合并后区域的相应值可以通过它们的线性运算得到，计算效率大大提高。例如，合并前两个区域对应的参数分别为 K_1 ， L_1 ， $\|R_1\|$

和 K_2 ， L_2 ， $\|R_2\|$ （ $\|R_1\|$ ， $\|R_2\|$ 是两个区域的点数），如果 $|T_1 - T_2|$ 小于预先设定的阈值，则


合并，合并后的 $K_{\#}$ 和 $L_{\#}$ 可表示为：

$$K_{\#} = (K_1 \times \|R_2\| + K_2 \times \|R_1\|) / (\|R_1\| + \|R_2\|) \quad (2.15)$$

$$L_{\#} = (L_1 \times \|R_2\| + L_2 \times \|R_1\|) / (\|R_1\| + \|R_2\|) \quad (2.16)$$


§ 2.5.2 几种评价函数的效果比较

我们对腹部 CT 图片用形态学强滤波器（取 $n = 2$ ）滤波后，用形态学多尺度梯度算法生成梯度图（取的 $m = 3$ ），然后结合改进的 VS 算法得到分水岭分割结果（落差阈值取为 5）。针对分割结果，采用上一小节所述的三种评价函数（由于 2.9 式要用到灰度共生矩阵，我们以各区域包围盒中心为中心， 5×5 大小的窗口范围为纹理特征区域）。在确保没有误分割的前提下，尽量增大三种方法所对应的阈值，得到了下面的结果：



(a) 分水岭分割后的结果

(b) 根据式 (2.7) 得到的合并结果



(c) 根据式 (2.9) 得到的合并结果

(d) 根据式 (2.11) 得到的合并结果

图 2.12 根据 3 种不同评价函数得到的区域合并结果


表 2.7 各评价函数的性能比较

$n = 2$ $m = 3$	区域块数	所用时间 (秒)	阈值(更大的值会产生误分割)
传统 VS 算法	2161	0.734	—
改进 VS 算法 (落差阈值为 5)	1360	0.750	—
基于灰度、面积的合并准则 (2.7) 式	457	0.844	20000
基于纹理的合并准则 (2.9) 式	1206	4.718	0.07
基于纹理的合并准则 (2.11) 式	1252	0.797	0.3

从图 2.12 和表 2.7 可以看出, 基于灰度、面积合并准则的合并方法明显优于其它两种准则。它不仅速度快, 而且可以很好地抑制过分割, 是一种较为理想的方法。我们会在后续的应用中使用这一合并准则。不过也要看到, 每一个准则都有其各自的适用范围, 我们得出的


结论目前只限于通常的 CT 图片。

事实上，如果把合并准则 (2.7) 式的阈值取得更大一些，并把落差阈值调整为 10，仍然可以很好地服务于后续的操作。



(a) 阈值为 30000，分割成 354 块
没有误分割

(b) 阈值为 70000，分割成 254 块
没有误分割




(c) 阈值为 110000，分割成 201 块
没有误分割

(d) 阈值为 300000，分割成 115 块
肝脏左侧 (图) 有误分割


图 2.13 灰度、面积准则，取不同阈值时的结果

§ 2.6 手动提取感兴趣区域


有了上面各节的充分准备，我们已经能够获得较好的分割结果。我们又设计了一些简单的手动区域合并工具，手动合并感兴趣区域中出现的过分割块，并得到出了所要的感兴趣区域 (敏感组织) 的轮廓线。为了确保整个序列图像的分割结果不出现误分割，前面所述的 4 个阈值不宜取得过大，我们用 $n = 2$ 形态学强滤波器滤波， $m = 3$ 的形态学多尺度梯度算法生成梯度图，改进 VS 算法中的落差阈值取为 10，灰度、面积合并准则阈值取为 50000。



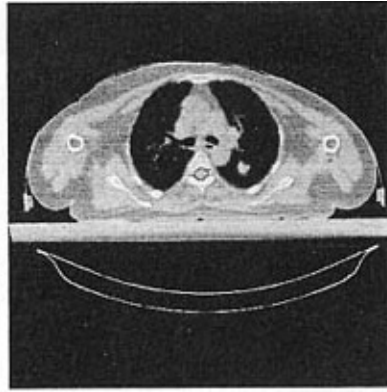
(a) 提取出脊髓、肾和肝



(b) 提取出脊髓




(c) 提取出眼球



(d) 提取出脊髓和肺

图 2.14 在分水岭分割基础上手动合并，得到感兴趣区域轮廓线






图 2.15 手动提取腹部序列图像的感兴趣区域（脊髓、左右肾脏和肝脏）

§ 2.7 本章小结

本章主要介绍了分水岭分割算法在 CT 图片上的应用，在得到分割结果后，通过手动合并区域获得放疗中感兴趣区域（敏感组织）的轮廓。

首先介绍了分割前的预处理方法。针对分水岭算法的特性，选择形态学强滤波器对初始图像滤波，然后用形态学多尺度梯度算法生成分水岭算法所需要的梯度图。所用的预处理方法很好地简化了图像，抑制了分水岭算法中出现的过分割。接下来，实现了两种分水岭算法，一种是基于浸水模型的 VS 算法，我们引入势能和落差两个概念后改进了该算法，进一步抑制了过分割；另一种是基于链码的改进 BM 算法，该算法模拟了降雨过程。比较两种算法的优劣性后，得出了更倾向于使用改进 VS 算法的结论。最后列举并比较了三种针对分割结果的区域合并准则，选定基于灰度、面积的准则完成区域合并。通过以上步骤，我们已经得到了过分割被较好抑制的分割结果，运用简单的手动合并工具就可以得到感兴趣区域的轮廓。

参考文献

- [1] 胡逸民. 肿瘤放射物理学. 原子能出版社, 1999, 328~341.
- [2] Haas O. Radiotherapy Treatment Planning. New System Approaches. Springer-Verlag, 1998.
- [3] Duncan J, Ayache N. Medical image analysis: Progress over two decades and the challenges ahead. IEEE Tran PAMI, Jan 2000, 22(1):85~106.
- [4] Pal N R, Pal S K. A review on image segmentation techniques. Pattern Recognition, 1993, 26: 1277~1294.
- [5] Vincent L, Soille P. Watershed in digital spaces: An efficient algorithm based immersion simulations. IEEE Trans, PAMI, 1991, 13(6): 583~598.
- [6] Soille P, Ansout M. Automated basin delineation from DEMs using mathematical morphology. Signal Processing, 1990, 20: 171~182.
- [7] Meyer F, Beucher S. Morphological segmentation. Journal of Visual Communication and Image Representation, 1990: 21~46.
- [8] Salembier P, Serra J. Flat zones filtering, connected operator, and filters by reconstruction. IEEE Transactions on Image Processing, 1995, 4(8): 1153~1160.
- [9] Salembier P. Morphological multi-scale segmentation for image coding. Signal Processing, 1994, 38(3): 359~386..
- [10] Crespo J, Majojo V. New result on the theory of morphological filters by reconstruction. Pattern Recognition, 1998, 31(4): 419~429.
- [11] 卢官明. 一种计算图像形态梯度的多尺度算法. 中国图像图形学报, 2001, 6(3): 215~218.
- [12] Bieniek A, Moga A. An efficient watershed algorithm based on connected components. Pattern Recognition, 2000, 33 (3): 907~916.
- [13] 孙涵, 任明武. 基于链码的分水岭变换算法. 中国图象图形学报, 2004, 9 (9): 1025~1031.
- [14] Haris K, Efstratiadis S N, Maglaveras N, et al. Hybrid image segmentation using watersheds and fast region merging. IEEE Transactions on Image Processing, 1998, 7(12): 1684~1699.
- [15] 马丽红, 张宇, 邓健平. 基于形态开闭滤波二值标记和纹理特征合并的分水岭算法. 中国图象图形学报, 2003, 8 (1): 77~83.
- [16] Blafiert T, Dippel S, Stahl M, et al. The Laplace integral for a watershed segmentation. IEEE, 2000.
- [17] 杜啸晓, 杨新, 施鹏飞. 一种新的基于区域和边界的图象分割方法. 中国图象图形学报, 2001; 6 (8): 755~759.

- [18] 崔明, 孙守迁, 潘云鹤. 基于改进快速分水岭变换的图像区域融合. 计算机辅助设计与图形学学报, 2005, 17 (3): 546~552.
- [19] 罗玲, 解梅, 陈杉. 基于多尺度形态滤波的分水岭图像分割方法. 计算机辅助设计与图形学学报, 2004, 16 (2): 168~173.
- [20] 姜晓彤, 罗立民, 汪家旺等. 一种肺部肿瘤 CT 图象序列的自动分割方法. 中国图象图形学报, 2003, 8 (9): 1028~1033.
- [21] Buena G, Fisher M, Burnham K, et al. Automatic segmentation of clinical structures for RTP: Evaluation of a morphological approach. IEEE Acoustics, Speech, and Signal Processing (ICASSP '04), 2004, 5:597~600.

第三章 腹部放疗感兴趣区域的自动分割

§3.1 引言

基于分水岭的半自动分割方法在一定程度上减轻了医师勾画感兴趣区域的劳动强度,但分割过程中依然需要医师大量的介入,分割的结果也会随着主观意识的不同而有所出入。为了进一步提高标识的效率,我们采用了一些先进的分割识别技术,尝试自动识别腹部 CT 图片上的感兴趣区域。

§3.2 基于图像上下文相关神经网络的图像分割

识别腹部器官的第一步是对可能的器官组织区域进行分割,这一步很关键,为此,文献 [1][2][3]提出了一种多模型的图像上下文相关神经网络 (Multimodule Contextual Neural Network) 方法。这种分割方法主要利用图像的灰度信息及其邻域的相关信息将图像像素分成若干类。图 3.1 表示的是多模型的图像上下文相关神经网络结构图。




图 3.1 上下文相关神经网络结构示意图

令 $U = \{U_1, U_2, U_3, \dots, U_i, \dots, U_n\}$, 它包含了每个像素隶属于每个类的概率向量。

其中 $U_i = \{u_{i1}, u_{i2}, \dots, u_{ik}, \dots, u_{im}\}^T$, $1 \leq i \leq n$, U_i 中的每个元素 u_{ik} 表示像素 i 隶属于第 k 类的概率。这里 n 表示图像的尺寸, 而 m 表示图像像素被分成的类数。因此, 概率向量 U_i 必须满足:

$$\sum_{k=1}^m u_{ik} = 1, \forall i, \text{ 且 } 0 \leq u_{ik} \leq 1 \quad (3.1)$$

在本文的神经网络中, 如图 3.1 所示, 模型 k 中的第 i 个神经元的概率值 $u_{ik}(t+1)$ 取决于它的当前值 $u_{ik}(t)$ 及其邻域像素对它的贡献值 $v_{ik}(t)$, 因此, $u_{ik}(t+1)$ 迭代式为:

$$u_{ik}(t+1) = \frac{P(u_{ik}(t) + v_{ik}(t))}{\sum_{k=1}^m P(u_{ik}(t) + v_{ik}(t))} \quad (3.2)$$

式 (3.2) 中 $P(x)$ 定义为:

$$P(x) = \begin{cases} x, & x \geq 0 \\ 0, & \text{其它} \end{cases} \quad (3.3)$$

分母起到归一化作用, 以保证 $u_{ik}(t+1)$ 始终满足式 (3.1)。式 (3.2) 中的 $v_{ik}(t)$ 可以通过下式获得:

$$\begin{bmatrix} v_{i1} \\ v_{i2} \\ \vdots \\ v_{ik} \\ \vdots \\ v_{im} \end{bmatrix} = \frac{1}{p} \begin{bmatrix} \sum_{\delta \in \Delta} W_1 U_{i+\delta} \\ \sum_{\delta \in \Delta} W_2 U_{i+\delta} \\ \vdots \\ \sum_{\delta \in \Delta} W_k U_{i+\delta} \\ \vdots \\ \sum_{\delta \in \Delta} W_m U_{i+\delta} \end{bmatrix} \quad (3.4)$$

式中, Δ 表示当前像素点 i 的邻域, p 则表示像素点 i 邻域像素的个数; $W = \{W_1, W_2, \dots, W_k, \dots, W_m\}^T = [w_{i,j}]$, $1 \leq i, j \leq m$, $w_{i,j}$ 表示如图 3.1 中两个神经元之间的权重。

根据式 (3.4), 如果 W_k ($1 \leq k \leq m$) 表示较大的兼容性(compatibility), 表现为一个正值, 而且概率向量 $U_{i+\delta}$ 中的 $u_{i+\delta,k}$ 比较大, 那么 v_{ik} 的值将是较大的正数; 如果 W_k 表示较小的兼容性, 表现为一个负值, 而且概率向量 $U_{i+\delta}$ 中的 $u_{i+\delta,k}$ 比较大, 那么 v_{ik} 的值将是较小的负数; 相反, 如果 $u_{i+\delta,k}$ 较小, 那么它对 v_{ik} 的贡献也是可以忽略不计的。简单起见, 文献 [4] 是这样定义这个权重矩阵的:

$$w_{i,j} = 1 - \frac{|i-j|}{m-1}, \forall i, j = 1, 2, \dots, m \quad (3.5)$$

从式 (3.2) 可以看出, 第 k 类的神经元 i 通过迭代, 不断的接收来自邻域的响应, 然后产生新的输出 $u_{ik}(t+1)$ 。利用这种方法, 每个像素隶属于每个类的初始概率 (向量) $U_i(0)$ 在迭代开始之前就应该被确定下来。在本文中, 自组织映射 (SOM) 神经网络算法被用来分析图像像素灰度的分布情况并确定每个像素隶属于每个类的初始概率 (向量) $U_i(0)$ 。

§3.3 自组织映射 (SOM) 神经网络

3.3.1 SOM 神经网络原理

自组织特征映射 SOM 是一种无指导训练的神经网络，由芬兰人 Kohonen 于 1981 年开始研究，自组织的过程实际上就是一种无指导的学习。它通过自身训练，自动对输入模式进行聚类。在分类聚类、机器人视觉、机械控制、语音识别、向量量化及组合优化等领域都有着广泛的应用。

自组织特征映射 SOM 模型可以用二维阵列表示。这种结构如图 3.2 所示。




图 3.2 二维阵列 SOM 模型

二维阵列神经网络由输入层和竞争层组成。输入层是一维的神经元。竞争层是二维的神经元。输入层的神经元和二维阵列竞争层的神经元每个都相互连接。二维阵列竞争层也称输出层。在 SOM 模型中，对于输出神经元 j ，它的外部输入信号可以用 I_j 表示：

$$I_j = \sum_i W_{ij} x_i \quad (3.6)$$

其中 x_i 是外部输入信号； W_{ij} 是输入神经元 i 到输出神经元 j 之间的权系数。对输出神经元 j 来说，它输出 Y_j 的活动可以用如下微分方程表示：

$$\frac{dY_j}{dt} = I_j + \sum_{k \in S_j} r_k Y_j - g(Y_j) \quad (3.7)$$

其中 S_j 是和神经元 j 相联系的神经元子集； r_k 是系数，它和权系数都与横向连接结构有关； $g(Y_j)$ 是非线性损失，如神经元饱和、分流和泄漏效应等。神经元的输入情况可以用图 3.3

来表示。




图 3.3 神经元输入情况

神经元的输出 Y_j 的初始分布可能是随机的。但随着时间的变化，由于输出层神经元有侧向交互的作用， Y_j 的分布就会因对环境的组织而形成“气泡”状，这种状态如图 3.4 所示。




图 3.4 侧交互模式

在神经网络中，随着外部信号的输入，神经元的权系数是自适应变化的；这一过程就是神经网络自学习的过程。神经元自适应过程和其输出值、外部输入、权系数都有关系，一般用如下方程表示：

$$\frac{dW_j}{dt} = \alpha Y_j X - \beta Y_j W_j \quad (3.8)$$

其中 W_j 是权系数向量， $W_j = \{W_{1j}, W_{2j}, \dots, W_{nj}\}^T$ ； X 是输入向量， $X = \{X_1, X_2, \dots, X_n\}^T$ ；

α, β 是正的标量常数。

神经元在自适应过程中所形成的“气泡”，在本质上是产生和输入模式对应的表示形态。而这种“气泡”是以特定的神经元 c 为中心的，并且是以一定半径所包围的神经元子集 N_c ，如果令 $Y_j \in (0, 1)$ ， $\beta \in (0, \alpha)$ 并且有

$$Y_j = \begin{cases} 1, j \in N_c \\ 0, \text{其它} \end{cases}$$

$$\beta_j = \begin{cases} \alpha, j \in N_c \\ 0, \text{其它} \end{cases}$$

这在实质上要求神经元在所给定的半径范围之内的 N_c 子集中时，则其输出为 1，而在子集 N_c 之外时，则其输出为 0。同时，系数 β 在神经元处于 N_c 之内时，取值为 α ，否则取值为 0。这时的神经元自适应过程表示如下：

$$\frac{dW_j}{dt} = \alpha X - \beta Y_j W_j = \alpha X - \beta W_j = \alpha X - \alpha W_j = \alpha(X - W_j) \quad (3.9)$$

考虑 $j \in N_c$ 和 $j \notin N_c$ 两种情况，则自组织过程可用两个不同条件的式子表示，并且有

$$\begin{cases} \frac{dW_j}{dt} = \alpha(X - W_j), j \in N_c \\ \frac{dW_j}{dt} = 0, \text{其它} \end{cases} \quad (3.10)$$

上式说明：在自组织过程中，SOM 模型神经元所处的位置对学习结果有影响。当和中心神经元 c 的距离较近，在给定半径之内时，权系数以输入模式和现行权系数 W_j 之差的一定水平进行修改；和神经元 c 的距离较远，则权系数不变。

3.3.2 基于 SOM 神经网络的图像模糊聚类

该算法由学习和回调两个部分构成。在学习步骤中，令 $A = \{I_1, I_2, \dots, I_i, \dots, I_n\}$ 包含了输入图像的灰度值，其中 I_i 表示第 i 个像素的灰度值， n 表示图像的尺寸即学习的样本数量。令 $L_k (1 \leq k \leq m)$ 表示 I_i 与 Kohonen 神经网络第 k 个神经元的权重（模糊聚类中心）。图像聚类时，SOM 神经网络根据下式完成学习过程：

$$\|I_i - L_c\| = \min_{1 \leq k \leq m} \{\|I_i - L_k\|\} \quad (3.11)$$

式中的索引 c 表示获胜神经元。获胜神经元周围的权重根据下式进行更新：

$$L_k(t+1) = \begin{cases} L_k(t) + \alpha(t)(I_i - L_k(t)), & k \in N_c(t) \\ L_k(t) & , \text{其它} \end{cases} \quad (3.12)$$

式中 $N_c(t)$ 表示获胜神经元 c 在 t 时刻的邻域函数, $\alpha(t)$ 表示相应的学习效率。在整个学习过程中, 获胜神经元的邻域函数和学习效率一直在变化。一般说来, 邻域函数和学习效率函数都是非增函数, 而且 $0 < \alpha(t) < 1$ 。只要学习充分, 输出权重 L_k 就会趋于服从从输入数据 (图像的灰度值) 的分布。

在回调步骤, 根据式 (3.11), 对于任意像素 i , 对应的获胜神经元 c 将被确定下来, 然后它隶属于每个类的初始概率 (向量) $U_i(0)$ 可以根据高斯分布 $N(c, \sigma)$ 进行初始化。 $U_i(0)$ 根据下式定义:

$$U_i = \begin{bmatrix} u_{i1} \\ u_{i2} \\ \vdots \\ u_{ik} \\ \vdots \\ u_{im} \end{bmatrix} = \frac{1}{\sum_{k=1}^m \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(k-c)^2}{2\sigma^2}}} \begin{bmatrix} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(1-c)^2}{2\sigma^2}} \\ \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(2-c)^2}{2\sigma^2}} \\ \vdots \\ \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(k-c)^2}{2\sigma^2}} \\ \vdots \\ \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(m-c)^2}{2\sigma^2}} \end{bmatrix} \quad (3.13)$$

式中标准方差 σ 表示控制初始概率的扩散因子。根据式 (3.13), 在 $U_i(0)$ 初始向量中, 元素 u_{ic} 的概率值很大, 而其它元素比较小, 主要取决于变量 σ 和 k 与 c 的距离。分母则起到归一化作用, 以保证 u_{ik} 始终满足式 (3.1)。


经过设置初始概率和网络权重矩阵 W , 式 (3.2) 迭代运算直到 $U_i = \{u_{i1}, u_{i2}, \dots, u_{ik}, \dots, u_{im}\}^T$ 满足如下关系:

$$\sum_{i=1}^n \|U_i(t+1) - U_i(t)\| < \varepsilon \quad (3.14)$$

式中 ε 是很小的一个值。

为了提高 SOM 神经网络的学习效率, 本文首先将每个像素为 16bits 的 CT 图像通过适当的窗宽窗位, 比如窗宽 $W=400$, 窗位 $L=20$ 压缩至每个像素为 8bits 的灰度图 (如图 3.5 所示)。在本试验中, m 取 7, SOM 学习的最大时间 (迭代次数) 为 400, $N_c(t)$ 取半径为 1 的圆, $\alpha(t)$ 初始值为 0.9。当扩散因子 $\sigma=1.0$, 迭代次数等于 3 时, 分割效果如图 3.6 所


示，可以看出分割曲线比较曲折但肝脏的主要轮廓基本上可以勾勒出来；当扩散因子 $\sigma = 1.5$ ，迭代 5 次时，分割效果如图 3.7 所示，虽然有些组织边界变得模糊不清（如肝脏与腹腔内壁的边界），但得到的各部分组织的轮廓比较平滑。



(a) 原始 16 位图

(b) 窗宽 400，窗位 20 时的 8 位图


图 3.5 原始图像及适当窗宽窗位下 256 色灰度图



(a) 分类效果

(b) 各类组织轮廓

图 3.6 $\sigma = 1.0$ ，迭代次数为 3 条件下的分割结果



(a)分类效果

(b) 各类组织轮廓

图 3.7 $\sigma = 1.5$, 迭代次数为 5 条件下的分割结果

§3.4 基于判定准则的感兴趣区域自动识别

3.4.1 判定准则定义

前面几节的内容已经详细介绍了如何利用基于图像上下文相关神经网络方法分割出可能的感兴趣区域, 接下来的任务是如何自动识别这些器官。在这里, 我们定义了一组特征来描述感兴趣区域, 比如相对位置, 相对距离, 面积, 周长, 组织密度 (灰度范围), 紧密度等。

(1)相对位置: 假设集合 $A = \{a_1, a_2, \dots, a_i, \dots, a_m\}$, $B = \{b_1, b_2, \dots, b_i, \dots, b_n\}$ 分别包含了两个区域的点。A 是待定区域, B 是参考位置。文献[5][6]中定义了如下的位置关系判定准则集合(3.15)~(3.18):

$$\mu_{right}(\Theta_{AB}) = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \begin{cases} \cos^2 \theta_{ij}, & -\frac{\pi}{2} \leq \theta_{ij} \leq \frac{\pi}{2} \\ 0, & \text{其它} \end{cases} \quad (3.15)$$

$$\mu_{left}(\Theta_{AB}) = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \begin{cases} \cos^2 \theta_{ij}, & -\pi \leq \theta_{ij} \leq -\frac{\pi}{2} \text{ 或 } \frac{\pi}{2} \leq \theta_{ij} \leq \pi \\ 0, & \text{其它} \end{cases} \quad (3.16)$$

$$\mu_{below}(\Theta_{AB}) = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \begin{cases} \sin^2 \theta_{ij}, & 0 \leq \theta_{ij} \leq \pi \\ 0, & \text{其它} \end{cases} \quad (3.17)$$

$$\mu_{above}(\Theta_{AB}) = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \begin{cases} \sin^2 \theta_{ij}, & -\pi \leq \theta_{ij} \leq 0 \\ 0, & \text{其它} \end{cases} \quad (3.18)$$

其中 $\theta_{ij} = \angle(a_i \times b_j)$ 。

(2) 相对距离：相对距离定义为两个区域中心的欧氏距离，即：

$$dis = \|Center_A - Center_B\| \quad (3.19)$$

其中 $Center_A, Center_B$ 分别表示组织区域 A 和 B 的中心。

(3) 面积：假设组织 A 的外轮廓 C 由有序二维点集组成 $C = \{(x_1, y_1), \dots, (x_k, y_k), \dots, (x_n, y_n)\}$ ，则轮廓 C 包围面积 S 为：

$$S = \frac{\left| \sum_{k=1}^n (x_k y_{k+1} - x_{k+1} y_k) \right|}{2} \quad (3.20)$$

其中 $(x_{n+1}, y_{n+1}) = (x_1, y_1)$ 。

(4) 周长：假设组织 A 的外轮廓 C 由有序点集组成 $C = \{p_1, \dots, p_k, \dots, p_n\}$ ，其中 $p_k = (x_k, y_k)$ ，则轮廓 C 的周长 P 为：

$$P = \sum_{k=1}^n \|p_{k+1} - p_k\| \quad (3.21)$$

其中 $(x_{n+1}, y_{n+1}) = (x_1, y_1)$ 。

(5) 组织密度：组织密度不同，则对应的 CT 值也将不同。所以根据图像灰度值可以区分组织密度较为明显的组织，比如脊椎。

(6) 紧密度：紧密度 ξ 可以定义为：

$$\xi = \frac{4\pi S}{P^2} \quad (3.22)$$

其中 S 为组织面积，P 为组织外轮廓周长。

3.4.2 相关组织的解剖结构特征

上述判定准则用来识别基于图像上下文相关神经网络方法分割后的组织轮廓，如图 3.6, 3.7 所示。当从分割后的图像中搜索一个指定器官时，我们利用组织区域的空间判定特性和器官区域的相关特征做比较，这些器官区域的特征是根据解剖结构的先验知识和专家的意见确定的^[7, 8]。这些特征概括如下：

- (1) 脊椎：脊椎位于图像的中底部，它和图像中心点的距离并不远。还有，脊椎属于骨头——高密度组织，因此，在图像中，其组织区域的灰度值最大。
- (2) 肾脏：两个肾脏正好位于脊椎两侧，一个在其左侧，另一个在其右侧。而且它们形状较为规则，组织区域的紧密度比较大。
- (3) 肝脏：肝脏位于右肾或者脊椎（如果该切片没有右肾）的右上方，它离脊椎的距

离比较远；它的面积和紧密度都比较大，而且在有的切片中肝脏还可能分为好几个区域。

- (4) 脊髓：脊髓在脊椎内，它属于软组织——密度比较小，在图像中，其组织区域的灰度值相对脊椎小得多，比较容易区分；但是在有些切片当中，脊椎被分成上下两块——上面一块较圆，下面一块是倒三角状，而脊髓真好这个条缝里。这时脊髓的分割和识别都比较困难。
- (5) 肺部：肺部位于脊椎的上方，确切的说一半在左上方，另一半在右上方。肺部属于软组织，密度比较小，在图像中对应的灰度很小。而且它们面积都很大，紧密度较大。

这些解剖结构及其在图像中的灰度分布将被转变为识别器官的空间判定准则。具体的识别过程见下一节。

3.4.3 感兴趣区域自动识别过程

为了定义感兴趣器官的相对位置，固定标记点（Landmark）必须首先被确定下来。

- 1) 固定标记点：固定标记点是在每层切片中用来描述感兴趣区域的相对位置的参考点。因而它必须存在于每一层切片当中而且比较容易被检测出来。根据前一节的内容，对于腹部和胸部 CT 系列图像，可以知道脊椎满足了这些条件。根据脊椎的解剖结构特征，脊椎很容易被识别出来，有了这个参考位置之后，肾脏、脊髓、肝脏或者肺部等感兴趣器官都可以一一被识别出来。
- 2) 组织区域重叠信息：通常在连续的 CT 系列图像中，同一器官组织在相邻的切片具有很大的相似性，我们可以充分利用这个重要特征进行下一切片的感兴趣组织区域识别。为了利用组织区域重叠信息，本文定义了两个重要参数：当前重叠率（COR）和下一层重叠率（NOR）：

$$\text{COR} = \frac{S_C \cap S_N}{S_C} \quad (3.23)$$

$$\text{NOR} = \frac{S_C \cap S_N}{S_N} \quad (3.24)$$

式中， S_C 表示当前已经识别的某一组织 R_C 的面积， S_N 表示下层切片中待识别的可能同一组织 R_N 的面积。 $S_C \cap S_N$ 表示上述两个区域 R_C 和 R_N 重叠部分的面积。


根据这两个参数及试验观察，我们可以获得以下重要特征：

- a) 如果 COR 和 NOR 都比较大，那么区域 R_C 和 R_N 属于同一个组织。
- b) 如果 COR 较大，而 NOR 较小，则区域 R_C 和 R_N 同属于一个组织，但 R_N 存在突起或与其它组织连在一起，如图 3.5 中的肝脏。
- c) 如果 COR 较小，而 NOR 较大，则区域 R_C 和 R_N 同属于一个组织，但 R_N 只是该组织的一部分，比如肾脏组织中的肾管，它的灰度与周围的肾脏组织的灰度值仍有一定差异。

- d) 如果 COR 和 NOR 都比较小, 那么区域 R_C 和 R_N 同属于不同的组织。
- 3) 系列图像识别过程: 首先确定每一切片的固定标记点脊椎, 然后各切片中的每个区域与脊椎的相对位置可以被计算出来。在系列图像中找一感兴趣组织对比度较好的切片, 然后根据各个组织的解剖结构特征和在图像中的位置关系, 可以将它们一一识别。再以这切片为起始点, 沿切片位置方向依次搜索, 并结合区域的重叠信息校正一些可能因为分割错误而导致的组织区域。考虑到相邻的切片相似性, 使用 SOM 神经网络对图像进行学习的时候, 可以间隔若干层进行样本学习, 这样可以提高系列图像分割的效率, 特别是切片数较多且层距较小的情况。
 - 4) 组织轮廓曲线修正: 从图 3.4 可以看出, 由于各种原因, 比如噪声干扰, 由图像分割中得到的轮廓曲线比较曲折。这时需要利用一些平滑的方法对轮廓曲线进行修正。首先可以利用数学形态学的方法, 将指定轮廓填充成一副二值图像 (轮廓内部为 1, 背景为 0), 然后进行闭操作 (先膨胀后腐蚀操作), 再提取像素值为 1 的区域的外轮廓, 这样得到的轮廓会比较光滑。对于由于边界模糊导致组织边界产生突起, 与其它组织合并在一起的情况, 可以利用组织区域上下层之间的相似关系对错误曲线进行裁剪校正。


§3.5 实验结果及讨论

首先对单切片图进行识别。和前面的例子一样, 将每个像素为 16bits 的 CT 图像通过适当的窗宽窗位, 压缩至每个像素为 8bits 的灰度图, 然后将这灰度图作为 SOM 神经网络的输入, 通过充分学习, 灰度图被分为 7 类。再根据这 7 类灰度分别提取每一类的连通域的外轮廓, 得到如图 3.8 (a) 的结果。然后根据腹部 CT 图 (人体检查部位信息可以在 DICOM 图像信息头获得) 中的感兴趣器官的空间判定准则对前面所提取的轮廓线进行识别, 识别的顺序依次为脊椎, 脊髓, 肾脏 (分为左肾和右肾), 肝脏等。在识别成功之后, 可以针对某些组织进行轮廓线修正, 比如肾脏和肝脏。识别结果如图 3.8 (a) 所示。




(a) 图像分割结果及组织轮廓 (b) 肝脏、肾脏, 脊髓等器官识别结果

图 3.8 $\sigma=1.5$, 迭代次数为 3 条件下的图像分割及感兴趣器官识别结果



(a)系列图分割结果



(b)系列图识别效果

图 3.9 系列图分割及识别效果

对于序列图，考虑到相邻切片的相似性，对任意连续的若干切片中我们可以只需通过学习中间某一切片的灰度值信息，得到 7 类的灰度值中心，并将这些中心值应用于周围切片。这样可以大大减少学习样本的时间。如图 3.9 所示，这是 4 张连续的腹部切片，我们选用第三张切片作为学习样本进行学习，然后将学习结果应用于其它三张，分割结果如 3.9 (a) 所示，再分别对每层切片中的所提取轮廓线进行识别，结果如 3.9 (b) 所示。虽然肝脏轮廓线有些粗糙，但总体识别效果还是令人满意的。

基于判定准则的识别方法也有它的局限性。它极为依赖前面的分割结果，如果分割结果不理想或者错误，识别就无能为力。如图 3.10 所示，由于肾管的灰度和肾脏的灰度很接近，两个肾脏都和肾管连在一起，在进行图像分割的时候无法使它们分开，因此我们的方法受到了限制。再者，位于脊椎上方的大动脉对脊椎的分割及识别也有较大的干扰，因为它们很靠近，而且灰度值也很接近。正是由于这些原因，用该方法识别有些组织识别率不是很高。



图 3.10 识别失败的例子

本文也对大量的腹部 CT 序列图做了识别实验。首先选择图像系列中间一切片，和上文的方法一样，识别出感兴趣器官，比如脊椎，脊髓及左右肾脏。然后朝上下两个方向依次搜索其余切片，在识别的过程中，不断的利用已识别的器官位置信息及特征参数来指导待识别的相邻切片中的同类器官识别。图 3.11 显示的是图像分割后的所有可能组织的轮廓图，图 3.12 则是利用上述方法识别的结果。有些图像中的组织比如肾脏没能识别出来，主要是因为两个肾脏都和肾管连在一起，很难将它们区分开来。




图 3.11 腹部 CT 序列的分割结果




图 3.12 腹部 CT 序列图的识别结果

和其它基于神经网络分割方法一样，学习样本是比较耗时的过程。就 $512 \times 512 \times 8\text{bits}$ 的灰度图像，学习过程需要耗费 25s 左右的时间。尽管如此，在进行序列图像分割时，采用相邻若干切片进行一次学习，这样每切片平均分割时间将大大减少。

针对以上的图像分割及识别方法的局限，将是我们继续研究和改进的方向。

§3.6 本章小节

本章主要介绍了腹部 CT 图像的自动识别。首先，我们运用自组织映射神经网络对图像进行初始分割，该过程相当于模糊聚类中初始隶属度的确定。继而利用基于图像上下文相关神经网络优化分割结果，使各组织分离的更为完全。在此基础上，结合专家知识，建立了若干个判定准则，判别分割结果中是否存在感兴趣区域，并标示出来，最终得到了较为满意的结果。

参考文献

- [1] Rosenfeld A, Hummel R A, and Zucker S W. Scene labeling by relaxation operations. IEEE Trans. Syst., Man, Cybern., 1976, 6: 420~433.
- [2] Lin W C, Tsao E C K, Chen C T. Constraint satisfaction neuralnetworks for image segmentation. Pattern Recognit., 1992, 25(7): 679~693.
- [3] Haring S, Viergever M A, Kok J N. Kohonen networks for multiscale image segmentation. Image Vision Comput., 1994, 12(6): 339~344.
- [4] Chen C T, Eric Tsao C K, Lint W C. Medical Image Segmentation by a Constraint Satisfaction Neural Network. IEEE Transactions on nuclear science, 1991, 38(2): 683~683.
- [5] Krishnapuram R, Keller J M, Ma Y. Quantitative analysis of properties and spatial relations of Fuzzy image regions. IEEE Trans.Fuzzy Syst., 1993, 1(3): 222~233.
- [6] Miyajima K, Ralescu A. Spatial organization in 2D segmentedimages: Representation and recognition of primitive spatial relations. Fuzzy Sets Syst., 1994, 65: 225~236.
- [7] Weir J. An Imaging Atlas of Human Anatomy. Wolfe, 1992.
- [8] Wegener O H. Whole Body Computerized Tomography Schering. West Germany, 1983.

第四章 放疗感兴趣区域可视化

§ 4.1 引言

近年来,随着医学影像技术的日益成熟以及各种医学影像设备在医院中的广泛使用,医生可以通过这些设备无损地获取人体内部组织的断层图像。从一组二维断层图像上理解病人身体内部器官的三维结构是非常困难的,即使对于经验丰富的医生也很难准确地描述器官的立体结构和确定病变体的方位,所以三维重建是对病变体进行定量分析(如计算体积,表面积和空间定位等),提高诊断准确率的重要保证。

三维重建技术包括两种方法:表面重建和体重建。本章首先介绍了轮廓线表面重建方法,重建出了放疗感兴趣区域的表面;继而运用体重建中的光线跟踪算法,实现了放疗中CT模拟的DRR,并结合感兴趣区域的三维表面,得到了具有立体感的BEV。

§ 4.2 放疗感兴趣区域表面重建

表面重建的任务就是恢复出蕴藏在体数据中的组织结构的几何信息,以便更加方便地对组织进行定量分析、处理和显示。Kepl, Fuch 和 Ekoule^[1, 2]采用轮廓拼接方法重建三维物体,根据体数据由很多张平行切片组成的特点,先求出每张切片中物体的闭合轮廓,然后将相邻切片之间的轮廓连接生成物体表面。由于本文前两章已经得到了感兴趣区域的轮廓线,因此可以方便地获得感兴趣区域的三维表面。

§ 4.2.1 轮廓线表面重建的基本原理与难点问题

在医学上轮廓线表面重建是以断层图像作为处理的对象,首先在每个切片图像上抽取物体的轮廓,然后用这些轮廓拼接出物体表面。从一组平行的平面轮廓重建三维表面必须解决四个基本问题^[3]:

- (1) 轮廓对应问题(Correspondence problem): 确定相邻切片上轮廓的对应关系。由于约束不足,轮廓对应存在很大的任意性。特别是当切片间距很大时,轮廓之间的错位也会很大,对应问题就变得愈发难以解决。目前还没有完全可靠地解决轮廓对应问题的全自动方法,人工干预在某些场合还是必不可少的。目前常用的手段有轮廓覆盖检查和基于全局的广义柱体方法(Generalized cylinder)。
- (2) 轮廓拼接问题(Tiling problem): 用多边形或者三角形连接不同层上的对应轮廓以“最佳地”表示物体表面,“最佳”的含义是使某种准则最优。关键是确定对应轮廓上点的相互对应关系,并用多边形构造轮廓间的表面。通过一组平面轮廓的曲面有无穷多个。为了使重建问题有解,人们引入新的约束,如体积最大、表面积最小、对应方向一致、跨度最小或者使轮廓点匹配方向最大程度地与质心匹配方向一致等^[1]。轮廓拼接就变成了基于这些优化目标的优化问题。
- (3) 分叉问题(Branching problem): 当一个物体在一对相邻断层上的轮廓个数不相等时就发生了分叉情况。分叉发生时的轮廓对应关系一般无法由分叉发生的局部信息来确定,分叉处理必须依赖于形体全局的拓扑和几何结构。
- (4) 曲面拟合(Surface-fitting problem): 根据以上步骤确定的点之间的连接关系和表面拓扑结

构, 确定最佳的拟合曲面。一般选用参数曲面拟合拼接得到多边形网格, 产生光滑的表面。在拟合过程中, 网格点作为控制点, 网格点之间的连接关系决定曲面的拓扑结构。

从理论上来说, 虽然引入新的约束去除了原始重建问题的多义性, 但却不能保证重建出的曲面很准确地表示真实物体的表面。另一个更加棘手的问题是对分叉情况的处理都没有可靠的方法。当三维物体自身出现分叉状态, 在断层图像上表现为相邻断层上的轮廓存在一对多关系, 这时由于约束不足, 轮廓对应的随意性很大。再者, 切片级重建方法是把各切片上抽取的物体轮廓作为输入, 但是至今仍没有鲁棒的分割方法保证边缘轮廓抽取的正确性, 人机交互仍是不可缺少的。尽管切片级重建方法目前存在一些尚未解决的问题, 但是在物体几何结构不是十分复杂的情况下还是能够自动地重建出物体的表面^[3]。

§ 4.2.2 实验结果

前两章已经得到了序列图像中感兴趣区域的轮廓线, 如图 2.15 和 3.12。

针对轮廓对应和分叉这两个难点问题, 由于尚无完善的解决方法, 我们考虑可以把分叉的轮廓线组分拆为多组单轮廓线序列, 并分别存储和计算。这样的做法一定程度上解决了问题, 不足之处是分叉部位无法正确连接, 并且需要人工交互来分开原有轮廓线组 (如果使用轮廓跟踪, 由于每次每层只能得到一条轮廓线, 所以没有这个问题)。

常用的轮廓线拼接方法有: 最短对角线法, 最大体积法和相邻轮廓线同步前进法三种^[1]。它们在处理非凸轮廓线间重构时会遇到不同的问题而造成错误。可行的方法是先把非凸轮廓线映射为凸轮廓线^[2], 然后再运用同步前进法重建。得到正确的三角顶点位置和顺序后, 加上各点的法向量, 就可以应用 OpenGL 库实现三维表面的显示。

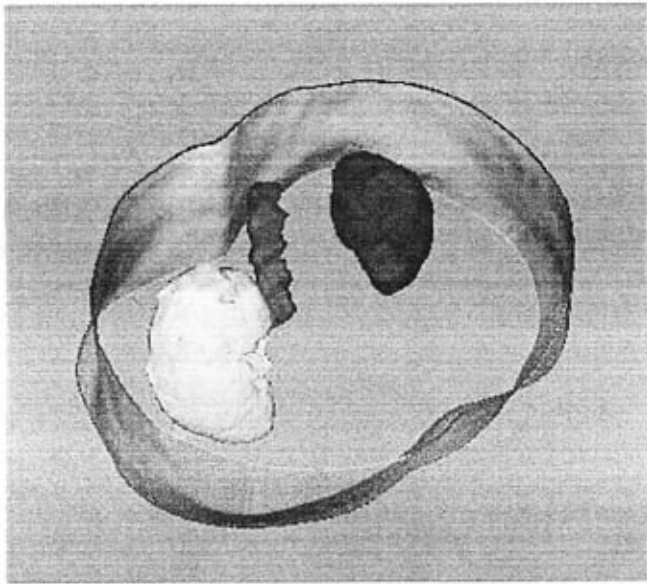


图4.1 感兴趣区域 (包括左右肾、脊髓和体表) 表面重建
左右肾和脊髓的轮廓线来自图2.15, 体表轮廓线由轮廓跟踪得到

§ 4.3 三维感兴趣区域在 CT 模拟中的应用

CT 的发明克服了常规诊断型 X 线机和模拟定位机^[8]拍摄平片的缺点, 提供了更多的横断面内的解剖结构细节, 在放射治疗计划设计中得到了广泛的应用。在 CT 和 MRI 等断层扫描重建技术出现后, 由于断层图像的卓越分辨率和三维信息, 不仅为放射界提供了强大的诊断工具, 也为治疗界开辟了新的领域, 提供了新的方法。首先是在传统模拟机上加上 CT 功能, 在透视的同时, 还可重建若干幅关键部位的断层图像, 为确定靶区和射野边界提供了一些三维信息, 但主要问题在于此种 CT 扫描时间太慢。随着数字计算影像重建和显示技术的发展, 以及超薄 CT 扫描和螺旋 CT 扫描的出现, 极大的改变了放射治疗计划设计的定位和治疗模式的面貌。Galvin 和 Erdo 最早提出了 CT 模拟机 (CT simulator) 概念, Nishidai^[9] 和 Nagata^[10] 提出 CT 模拟机系统 (CT simulation)。于是 CT 模拟定位系统开始用于放射治疗的临床。

利用 CT 模拟进行治疗方案的模拟与验证, 是在患者治疗部位的“3D 假体”上进行, “3D 假体”是由 CT 扫描层片经 3D 重建后得到的。DRR 就是从射野方向或从类似模拟定位机的 X 线靶方向观视 (BEV) “3D 假体”的结果, 此过程称为 CT 模拟 (CT simulation) 或虚拟模拟 (virtual simulation), DRR 相当于模拟定位机的射野定位片或证实片。一旦治疗计划被模拟和确认后, 有关治疗参数如射野大小、形状、方向等的数字数据送入计算机控制的激光射野模拟器, 在患者皮肤上作好射野的相关标记。

§ 4.3.1 数字重建射线图像 (DRR) 的构造

§ 4.3.1.1 构造原理

DRR 是实现 CT 模拟的重要构成部分, 它是代替常规模拟机对虚拟“患者”进行 X 射线透视和照相, 类似于 X 射线的平片。DRR 是利用治疗部位的 CT 图像用数学方程重建得出来的, 它的发展始于 1983 年 Goitein 发表的重建数字 X 线影像的方法。

产生 DRR 图像的基本方法如图 4.2 所示, 包括四个步骤: 光线跟踪、插值、灰度累积和映射。在三维的 CT 数据集 (由 CT 断层产生) 中, 虚拟的射线源是可以选择的。X 射线从虚拟的照射源向垂直于射线中轴的平面进行投射。通过将该平面沿射线中轴进行前后移动, 可以得到不同的源到像平面的距离和放大倍数。当射线向数据集投射时, 通过插值方法可以得到所经过的每一点的 CT 值。当投射过程结束后, 可以得到一个相应的衰减累积值。射线和平面的交点定义了 DRR 中点的位置, 该点的灰度值通过将灰度累积值进行映射得到。图像的大小和所选择的 CT 投影体积有关。另外对 CT 数据集的要求是在 Z 方向可以是非均匀的 (例如不同的层厚), 但在 X 和 Y 方向必须均匀采样。




图 4.2 DRR 图像产生示意图

光线跟踪是 DRR 的核心部分。射线的数量可以超过像平面上的点的数量，但一般选取和像平面上点相同的个数。通常采用两种方法来进行射线跟踪。第一种方法是平行投影，将每条射线都平行放在像平面上，射线和图像的交点决定平面的位置。第二种方法是透视投影，射线通过连接虚拟照射源和像平面上点的位置来得到。这两种不同的射线通过三维 CT 数据集，真实的重现了射线从虚拟照射源发出的情景。像平面上的投影点值由射线所碰到的体元的衰减系数 μ 表示， μ 由 CT 值相对于 X 射线的平均能量得到：

$$CT = 1000 \left(\frac{\mu - \mu_w}{\mu_w} \right) \quad (4.1)$$

这里 CT 是在 Hounsfield Unit 中的 CT 值， μ 和 μ_w 是介质和水对应于 X 射线的线性衰减系数。公式 (4.1) 用来决定 μ 值，然后这个 μ 值可以用来计算虚拟射线的衰减系数^[11]

$$A = \exp \left(- \sum_i \mu_i dl_i \right) \quad (4.2)$$

长度 dl_i 是射线前进的步长， μ_i 是计算出的在 dl_i 内的衰减系数。通常步长是一个 CT 体元大小。步长大小的选择决定了采样率，与 DRR 的计算时间直接相关。公式 (4.2) 类似于介质生成 X 射线图像的过程。

在公式 (4.2) 中的 μ_i 的值可以根据不同的插值方法计算得到。所采用的插值方法依赖于 DRR 的速度和准确性。步长是由所需要的采样率所决定的。有两种常用方法可用来计算近邻体元对它的衰减贡献：①最近邻法：取最靠近的像素点 CT 值；②三线性法：即采用最近邻 8 个像素点进行三线性插值。三线性的计算时间是最近邻法的 6-8 倍，但更为精确。Sherouse^[11]详细地讨论了这些插值方法（还包括直接均值法和双线性插值法）。三线性插值方法是最经常使用的，因为可以得到较高的准确度和分辨率^[11]。

§ 4.3.1.2 算法改进

通常情况下，DRR 图像是一个正方形，大小在 80×80 到 512×512 之间。DRR 图像的空间分辨率由 DRR 图像平面上像素单元大小和其本身物理尺寸这两个因素决定。设 DRR 图像大小为 $25.6\text{cm} \times 25.6\text{cm}$ ，当像素单元数为 512×512 时，其像素单元大小为 $0.5\text{mm} \times 0.5\text{mm}$ ；当像素单元数为 128×128 时，其大小为 $2\text{mm} \times 2\text{mm}$ 。当图像大小改为 $51.2\text{cm} \times$

51.2cm 时, 相应的像素单元大小变成 $1\text{mm} \times 1\text{mm}$ 和 $4\text{mm} \times 4\text{mm}$ 。根据图像大小, DRR 图像平面像素单元数可在 80×80 到 512×512 之间选择。

我们发现, 这样的投影平面会造成两方面的不良结果: ①投影正方形边长大于等于下述最小囊括矩形的较长边, 面积显然大于等于该矩形, 光线跟踪时将有更多不与体数据相交的点要处理, 计算效率较低; ②大小差别很大的投影映射到仅有几种大小的矩形中, 可能造成投影分辨率不稳定: 小投影被放大而模糊, 大投影被限制在矩形中而忽略了细节。为了克服上述缺点, 实际构建 DRR 时, 我们采用了动态可变矩形作为投影平面, 以追求更高的分辨率和更好的效果。投影矩形的动态变化是由于:

- ① 设定 DRR 投影平面的分辨率与 CT 平面数据的分辨率相同;
- ② CT 数据长方体在不同的 (由于虚拟视点变化) 透射投影变换下, 向 z' 等于 0 的观察坐标系时, 需要不同大小的最小矩形来囊括。如图 4.3 所示:

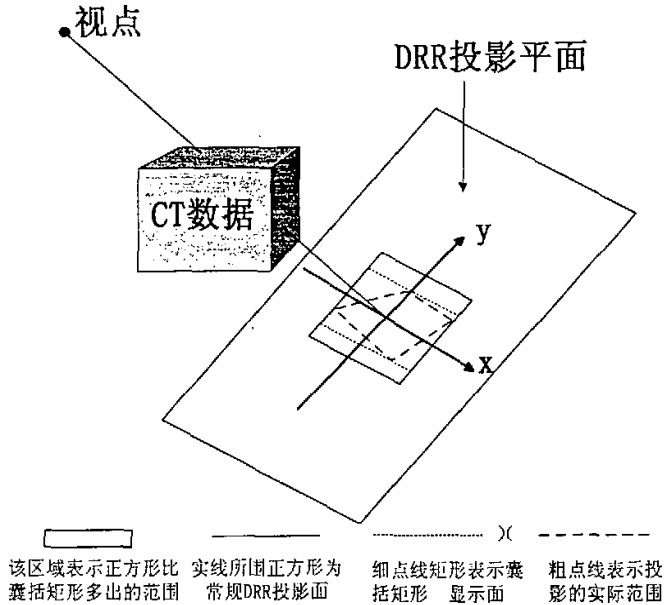


图 4.3 投影平面的确定

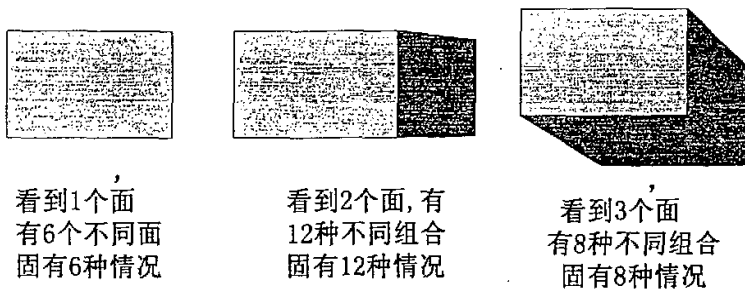


图 4.4 不同位置观察长方体时, 可以看到的面的情况

为了求得动态变化矩形的的大小, 我们先要根据视点位置判断可以看到 CT 数据长方体的哪些平面。一共有 3 大类共 26 种情况 (视点在长方体内时无法投影, 这也是一种情况), 3 大类分别是: 看到 1 个、2 个和 3 个面, 如图 4.4 所示。然后求得投影范围 (要通过透视

投影坐标变换), 最后确定包围矩形的大小, 除以固定分辨率 (即原 CT 平面数据的分辨率) 后得到 DRR 平面大小。

§ 4.3.1.3 实验结果

在三维放射治疗计划系统中, 我们以 CT 数据立方体的物理中心为场景中心, 以 CT 平面分辨率为步长, 求交运算中使用三线性插值法, 结合任意设定的视点和 4.3.1.2 中方法确定的 DRR 投影面作透视投影。我们使用两组 CT 序列图 (分别是头部和腹部) 作为实验数据, 图片是大小为 512×512 (16bit) 的医用 DICOM 图。得到的 DRR 结果图像如图 4.5 所示。需要说明的是, 为了使投影图包含尽可能多的信息, 我们把它设置成灰度范围为 0—4095 的 DICOM 图, 通过调节窗宽窗位, 可以得到更多的组织信息, 图 4.6 给出了相关的例子。

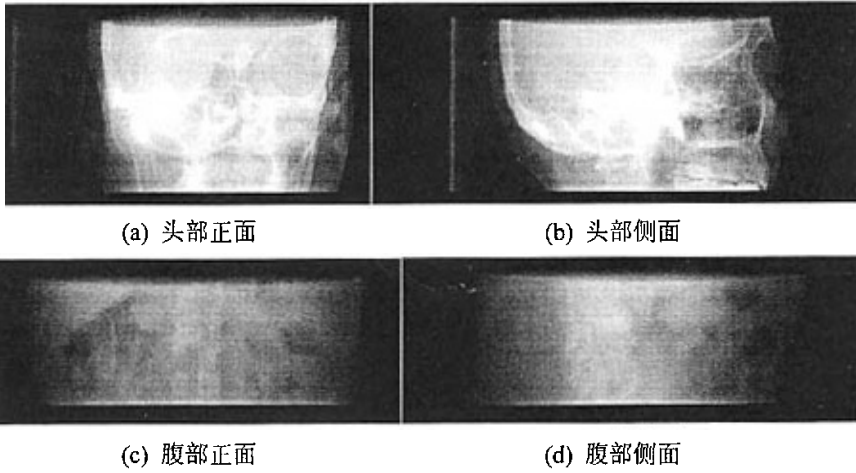



图 4.5 两组 CT 序列图像的 DRR 投影






图 4.7 BEV 效果图, (b) (d) (f)在原 DRR 图像(a) (c) (e)上叠加了具有三维效果的感兴趣区域
头外表作为感兴趣区域




图 4.8 BEV 效果图, DRR 如图 4.6(c), 感兴趣区域如图 4.1

§ 4.4 本章小结

本章主要包含两个部分。

1. 利用轮廓线表面重建算法重建出放疗感兴趣区域，感兴趣区域的轮廓线由前两章的分割算法获得。

2. 实现了CT模拟技术中两个重要的可视化应用 DRR 和 BEV。DRR 由光线跟踪生成。具体开发中，虽然采用了加速算法，但 DRR 的速度还是比较慢（5s~20s），其计算量集中于获取穿过CT数据的X线衰减，实际上是求交运算。有待通过选择合理的步长、分辨率及插值类型，研究加速算法，以继续加快速度到实用级别。BEV 是三维放射治疗计划系统中重要的射野设计工具。为了增强其效果，我们通过图像融合，把表面重建的感兴趣区域图像融入到 DRR 中。结果显示，射野方向观视中的感兴趣区域被有效突出。

参考文献

- [1] 唐泽圣. 三维数据场可视化. 清华大学出版社, 1999.
- [2] Ekoule A B, Peyrin F C, Odet C L. A Triangulation Algorithm from Arbitrary Shaped Multiple Planar Contours. *ACM Transactions on Graphics*, 1991, 10(2): 182~199.
- [3] Grevera G J, Udupa J K. Shape-based interpolation of multidimensional grey-level images. *IEEE Trans[J], Med Imaging*, 1996, 15(6): 881~892.
- [4] Schroeder W J, Zarge J A, Lorensen W E. Decimation of Triangle Meshes. *Computer Graphics*, 1992, 26(2): 65~70.
- [5] 张惠. 医学图象中的虚拟现实技术: 三维医学图象数据处理和显示框架. 东南大学硕士学位论文, 2000.6.
- [6] 杨奎. 计算机辅助手术导航系统的研究与开发. 东南大学硕士学位论文, 2005.3.
- [7] 鲍旭东, 张惠, 罗立民. 仿真影像学综述. *东南大学学报*, 2002, 32(5): 355~361.
- [8] 胡逸民. 肿瘤放射物理学. 原子能出版社, 1999.
- [9] Nishidai T, Nagata Y, Takahashi M, et al. CT simulator: A new 3-D planning and simulating system for radiotherapy. Part 1, Prescription of system. *Int J Radiat Oncol Biol Phys* 1990, 18: 499~504.
- [10] Nagata Y, Nishidai T, Abe M, et al. CT Simulation: A new 3-D planning and simulating system for radiotherapy. Part 2, Clinical application. *Int J Radiat Oncol Biol Phys* 1990, 18: 505~513.
- [11] Sherouse G W, Novins K, Chancy E. Computation of digitally reconstructed radiography for use in radiotherapy treatment design. *Int J Radiat Oncol Biol Phys* 1990, 18: 651~658.
- [12] Goitein M, Abrams M, Rowell D, et al. Multidimensional treatment planning: II. Beams's eye-view, backprojection, and projection through CT sections. *Int J Radiat Oncol Biol Phys*, 1993, 9:789~797.
- [13] Chaney E L, Thorn J S, Tracton G, et al. A portable tool for computing digitally reconstructed radiographs. *Int J Radiat Oncol Biol Phys*, 1995, 32(2): 491~497.
- [14] Giraud J, Killoran J, Svensson G. Quality control, and optimization of DRR. A phantom study (Abstr.). *Med Phys*, 1998. 25(7): A163.
- [15] Joseph H, Killoran, Elizabeth H, et al. A Technique for optimization of digitally reconstructed radiographs of the chest in virtual simulation. *Int J Radiat Oncol Biol Phys*, 2001, 49(1): 231~239.
- [16] 崔智, 张良震, 朱淼良. 基于光线跟踪的数字影像重建技术. 小型微型计算机系统, 2001, 22(10): 1258~1260.

第五章 总结与展望

为了得到放射治疗计划中的感兴趣区域,本文着重研究了图像处理中的分割和识别技术,半自动或自动地实现了放疗感兴趣区域的提取。同时,我们把可视化技术应用于放疗计划系统中,通过建立三维模型,有效地增强了感兴趣区域的显示效果。我们主要做了以下几方面的工作:

1. 重点讨论了分水岭分割算法在 CT 图片上的应用,得到分割结果后,通过手动合并区域获得放疗中感兴趣区域的轮廓。分割前的预处理部分,针对分水岭算法的特性,选择了形态学强滤波器对初始图像滤波,然后用形态学多尺度梯度算法生成分水岭算法所要的梯度图。这两种方法的应用很好地简化了图像,初步抑制了分水岭算法中出现的过分割。接下来,实现了两种分水岭算法,一种是基于浸水模型的 VS 算法,我们引入势能和落差两个概念后改进了该算法,进一步抑制了过分割;另一种是基于链码的改进 BM 算法,该算法具有复杂度低,计算迅速的优点。最后我们列举并比较了三种针对分割结果的区域合并准则,选定基于灰度、面积的准则完成区域合并。通过上面一系列的处理,得到了过分割被较好抑制的分割结果,运用简单的手动合并工具去除少量残余过分割从而得到感兴趣区域,并求得相应的轮廓。

2. 介绍了腹部 CT 图像的自动识别。首先,运用自组织映射神经网络对图像进行初始分割,该过程相当于模糊聚类中初始隶属度的确定。继而利用基于图像上下文相关神经网络优化分割结果,使各组织分离的更为完全。在此基础上,结合专家知识,建立了若干个判定准则,判别分割结果中是否存在感兴趣区域,并标示出来,最终得到了较为满意的结果。

3. 实现了可视化技术中轮廓线表面重建算法。利用已经获得的放疗感兴趣区域轮廓线重建出三维感兴趣区域的同时,也为后面生成具有立体感感兴趣区域的 BEV 图作好了准备。

4. 介绍了 CT 模拟技术中两个重要应用 DRR 和 BEV 的构造。DRR 由光线跟踪生成, BEV 模拟则通过 DRR 来显示。为了增强 BEV 效果,我们通过图像融合,把表面重建的感兴趣区域图像融入到 DRR 中。结果显示,射野方向观视中的感兴趣区域被有效突出。

但是,要使图像分割和可视化技术更好地服务于放疗计划系统,我们还有很多方面值得改进:

1. 自动识别过程有两个问题困扰着我们。一方面该方法的组织识别率不高,究其原因,主要是因为识别过程极为依赖前面的分割结果,如果分割结果不理想或者错误,识别就无能为力。而造成分割不理想的原因之一是我们仅仅利用了像素的灰度和位置信息。以后的工作可以尝试引入纹理并充分利用相邻图片中同一组织变化不大的特性。另一方面,和其它基于神经网络分割方法一样,识别速度很慢,时间的消耗主要集中在识别过程。为了加速识别,在进行序列图像分割时,如果相邻层距不大,可以采用每隔若干切片进行一次学习,这样每层切片平均分割时间将大大减少。

2. 做完自动识别这一章后,可以很自然地想到,把其中的分类过程用于合并分水岭分割结果中的过分割块。由于块数远小于像素数目,效率将远高于直接对图像分类。但限于时

间的限制，有待以后实现。

3. 生成 DRR 时，虽然采用了加速算法，但速度还是比较慢（5s~15s）。其计算量集中于获取穿过 CT 数据的 X 线衰减，实际上是求交运算。有待通过选择合理的步长、分辨率及插值类型，研究加速算法，以继续加快速度使其更为实用。

致 谢

本论文是在我的两位导师罗立民教授、於文雪副教授的精心指导下完成的。从论文的选题到各个研究阶段，一直得到他们的热情关怀和悉心指导，为本文的完成倾注了大量的心血，在此，我向他们表示最衷心的感谢。在我的研究生阶段的学习生活中，正是由于两位老师的引导，才使我得以初窥图像处理的门径，引领我进入了图像处理这个富有挑战性的领域。在这两年多的生活和学习中，罗老师和於老师创造的和谐、民主、自由的学术气氛极大地激发了我的创新意识和开拓进取地精神，使我真正的学会了如何去面对问题；他们严谨求实的治学作风帮助我树立了认真求实的科学态度。

同时，实验室的其它老师也给予了无私的帮助，特别感谢舒华忠、鲍旭东、李松毅、周卫平老师对我的指导和帮助。

感谢我的大学及研究生同学：郑国春、胡轶宁、刘彦鹏、郑启元、荣成城、朱杨兴和梁俊。和你们一起度过的日日夜夜是我一身最好的回忆！

感谢我的父母，他们给予了我生活和精神上支持，使我能够顺利完成学业。他们为了我的成长倾注了大量的心血，我的感激之情是无法用语言表达的。谨以此文作为我对他们的献礼！

周健

2005年8月12日