

# 目 录

中文论著摘要.....	3
英文论著摘要.....	6
英文缩略语.....	9
第 1 章 绪 论.....	10
1.1 研究背景和意义.....	10
1.2 国内外研究现状和发展趋势.....	11
1.3 研究内容.....	12
1.4 本文组织结构.....	13
第 2 章 脑磁共振图像获取与多参数图像选择.....	14
2.1 引言.....	14
2.2 脑磁共振图像获取.....	14
2.3 多发性硬化症.....	15
2.4 脑磁共振多参数图像选择.....	16
第 3 章 脑磁共振图像多参数分割算法研究.....	18
3.1 SOM 神经网络.....	18
3.2 硬 C-均值聚类.....	21
3.3 模糊 C-均值聚类.....	21
3.4 聚类有效性函数.....	23
3.5 改进聚类有效性函数.....	23
3.6 自适应模糊 C-均值聚类.....	24
第 4 章 SOM-FCM 二层分割算法的实现.....	26
4.1 SOM-FCM 二层分割算法.....	26
4.2 医学图像分割评价标准.....	27
4.3 基于 SOM-FCM 算法的分割结果.....	27
4.3.1 不同组织类别的图像分割判别结果.....	28
4.3.2 同一层图像不同噪声等级的分割结果.....	28
第 5 章 结 论.....	32

本论文创新性的自我评价 .....	33
参考文献 .....	34
综述 .....	38
在学期间科研成果 .....	52
致谢 .....	53
作者简介 .....	54

## 脑磁共振图像多参数分割算法的研究与实现

### 前言

磁共振成像(MRI)作为目前少有的安全无创性、快速、准确的临床诊断方法,被广泛应用于人体内部精细结构的可视化。其中,磁共振成像对于软组织的高对比度和多参数成像特性使其在脑功能研究方面显示出独特的优势,在很多神经性疾病的诊断中,磁共振成像都发挥着重要作用,如多发性硬化症(MS)和老年痴呆症等。为了检测生理或者病理状态的脑组织容量,准确而稳健的组织分类或图像分割非常关键。随着成像技术的不断发展,磁共振图像的大小和数量不断增加,由神经外科医师进行的手动分割非常费时且不具有可重复性,因而有必要利用计算机实现的分割算法对图像进行自动分割。

计算机实现的图像分割算法一般分为单参数分割算法和多参数分割算法。磁共振图像具有多参数的成像特性,因而通常选用多参数分割算法进行分割。模糊C均值聚类算法(FCM)是应用比较广泛的多参数分割算法。但是,传统的FCM算法仅基于目标函数进行聚类,需要预先设定聚类数目,并且无法确定聚类结果是否最优。另外,当样本量过大时,FCM算法的收敛时间过长,甚至发生不收敛的现象,这就需要利用其他算法,如分水岭算法、SOM神经网络等先对样本进行粗分,以减小FCM算法的输入规模,加快算法的收敛速度。其中,SOM神经网络可以使高维数据映射成低维阵列,并且对噪声不敏感,更适合用于多参数医学图像分割。

基于MRI多参数成像特点和FCM算法的特性,提出了一种SOM-FCM二层分割算法,改进了聚类有效性函数,使得FCM算法在迭代过程中自动产生最优聚类数,使用BrainWeb多发性硬化症模拟数据集对算法进行评估,在不同级别的噪声条件下,比较SOM-FCM算法和传统FCM算法的分割结果。

### 材料与方法

1、使用国际通用的加拿大麦吉尔大学蒙特利尔神经研究所 BrainWeb 数据集中带有多发性硬化症病灶的模拟脑磁共振图像进行多参数分割算法的研究。

2、为证明多参数分割具有理论依据和实际意义，同时减少分割算法的输入样本量，达到降低维度的目的，分别对 BrainWeb 数据集中的 10 层图像计算其  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像之间的相关系数，与经验值进行对比，去除与其他图像相关程度较高的加权像。

3、使用 SOM 自组织映射神经网络对  $T_1$  加权像和  $T_2$  加权像图像信息进行融合的同时，对输入图像进行粗分割，分割结果为最终目标类的若干子类，用以减少模糊 C-均值聚类算法的输入样本量。

4、根据 Xie-Beni 准则改进聚类算法有效性函数，使得模糊 C-均值聚类算法在迭代过程中自动产生最佳聚类数目。

5、采用正确分割率指标对 SOM-FCM 算法的分割结果进行评估，并与传统算法的分割结果进行比较分析。

## 结果

1、经过对 10 层多参数图像间相关系数的计算，得出  $T_1$  加权像和  $T_2$  加权像之间的平均相关系数为 0.3765，属于轻度相关，而  $T_1$  加权像和 Pd 加权像、 $T_2$  加权像和 Pd 加权像之间的平均相关系数分别为 0.8015 和 0.8359，均属于具有很强的相关性。

2、根据输入样本特征空间的分布特性，最终选用  $4 \times 20$  的二维网格结构作为 SOM 自组织映射神经网络竞争层的拓扑结构，训练结果显示这种拓扑结构使得神经元节点对特征空间拟合程度较好。

3、根据医学图像分割的特点，改进 Xie-Beni 指标有效性函数，得到新的聚类算法有效性函数，并将其加入到模糊 C-均值聚类的算法流程中，实验结果显示对于 5 层正常脑组织图像（像素主要类别包括灰质、白质、脑脊液和图像背景），新的聚类算法有效性函数于 4 类处达到最小值，对于 5 层含有多发性硬化症病灶的图像，新的聚类算法有效性函数于 5 类处达到最小值，与图像实际情况相符合。

4、对于同一层图像的加入 1%、3%、5%和 7%四种不同噪声等级，使用 SOM 自组织映射神经网络粗分割图像作为输入数据的改进模糊 C-均值聚类算法相比于传统 FCM 算法显示了更好的稳定性和更高的正确分割率，实验结果有统计学意义 ( $P < 0.05$ )。

## 结论

1、根据各个加权像之间计算的相关系数得出， $T_1$  加权像和  $T_2$  加权像之间的平均相关系数最小，图像信息之间互补性较大，最具有融合意义。

2、改进了 Xie-Beni 指标有效性函数，提出适合本实验数据特性的新的聚类有效性函数。

3、利用新的有效性函数改进的模糊 C-均值聚类能自适应的选择最佳聚类数目。

4、利用 SOM 自组织映射神经网络进行粗分割可以有效的降低噪声对于模糊 C-均值聚类的影响，是得算法对于噪声更具有稳定性。

## 关键字

磁共振成像；SOM 神经网络；FCM 算法；有效性函数；多发性硬化症

## **Research and realization on multiparameter segmentation algorithm of brain MRI**

### **Introduction**

Magnetic resonance imaging (MRI) as noninvasive, fast and accurate clinical diagnosis method, at present, has been widely applied in the visualization of interior structure of human body. Especially, the unique feature of superb soft tissue contrast and multiparameter imaging make magnetic resonance imaging have special advantage in brain function research. Magnetic resonance imaging plays an important role in the diagnosis of many neurological disorders, such as multiple sclerosis and Alzheimer's disease. In order to detect the volume of the physiological or pathological brain issues, accurate and robust issue classification or image segmentation is very important. With the development of imaging technology, the size and amount of MRI become increasingly, it is necessary that using the computer to implement a segmentation algorithm in order to make the image segmentation automatic.

The image segmentation algorithms implemented by computer are usually divided into two types, one-parameter segmentation algorithms and multiparameter segmentation algorithms. MRI has the unique feature of multiparameter imaging, therefore, the multiparameter segmentation algorithms are always chosen in MRI segmentation. Fuzzy C-mean clustering algorithm (FCM) is a kind of multiparameter segmentation algorithm which has been widely applied. But the traditional FCM algorithm is only based on objective function and needs to set the cluster number in advance. In addition, if the data set is too large, the convergence time of FCM algorithm will too long to achieve a clustering result. So it should be combined with another algorithm, such as watershed algorithm or SOM neural networks. Especially,

SOM neural networks can map the high dimensional data into low dimensional array and is insensitive to the image noise, therefore, it is better be used in multiparameter image segmentation.

Based on the multiparameter imaging feature of MRI and feature of FCM algorithm, we propose a SOM-FCM two layer segmentation algorithm. We improve the cluster validity function and use BrainWeb multiple sclerosis simulated database to evaluate this algorithm. In different level of the image noise, we compare the segmentation results of the SOM-FCM algorithm and traditional FCM algorithm.

## **Methods and materials**

1. Using the BrainWeb multiple sclerosis simulated database to research the multiparameter segmentation algorithms of brain MRI.

2. Select 10 slices of images of BrainWeb database, calculate the correlation coefficient between  $T_1$  weighted image,  $T_2$  weighted image and Pd weighted image. Comparing with the empirical value, we remove the images which have higher degree of correlation.

3. Using SOM neural networks to combine the information of  $T_1$  weighted image and  $T_2$  weighted image, meanwhile, we roughly segment the input image into many subclasses.

4. According to Xie-Beni index, we improve the cluster validity function, in order to make the FCM algorithm produce optimal cluster number.

5. Using the percentage of correctly estimated to evaluate the segmentation results of the SOM-FCM algorithm and compare with the segmentation results of the traditional FCM algorithm.

## **Results**

1. The average correlation coefficient between  $T_1$  weighted image and  $T_2$  weighted image is 0.3765, while that between  $T_1$  weighted image and Pd weighted

image is 0.8015, and that between  $T_2$  weighted image and Pd weighted image is 0.8359, which are higher degree of correlation.

2. Choosing  $4 \times 20$  two dimensional grid as the topology structure of the SOM neural networks. The result of training shows that this kind of topology structure fit feature space better.

3. Improving the cluster validity function, it makes the FCM algorithm can produce the optimal cluster number automatically. According to different issue classes, the results show that the new cluster validity function reaches its minimum in 4 classes and 5 classes respectively.

4. According to different noise level of one slice of image, the SOM-FCM algorithm is more robust and has higher percentage of correctly estimated than traditional FCM algorithm. These results have statistical significance ( $P < 0.05$ ).

## Conclusions

1. According to the average correlation coefficient between each weighted images,  $T_1$  weighted image and  $T_2$  weighted image have smallest correlation coefficient. They have the significance to combine.

2. Improving the Xie-Beni index validity function, we propose a new cluster validity function.

3. Using new cluster validity function, new FCM algorithm can choose optimal cluster number automatically.

4. Using SOM neural networks can reduce the effect of image noise and make the algorithm more robust.

## Key words

MRI; SOM neural networks; FCM algorithm; Validity function; Multiple sclerosis

·英文缩略语·

英文缩写	英文全称	中文全称
MRI	Magnetic Resonance Imaging	磁共振成像
MS	Multiple Sclerosis	多发性硬化症
GM	Gray Matter	灰质
WM	White Matter	白质
CSF	Cerebrospinal Fluid	脑脊液
SOM	Self-Organizing Maps	自组织映射
FCM	Fuzzy C-Mean	模糊 C-均值
VF	Validity Function	有效性函数
PCE	Percentage of Correctly Estimated	正确分割率

# 第1章 绪 论

## 1.1 研究背景和意义

随着医学成像技术的不断发展,各种模式的医学影像在现代医疗诊断中发挥着越来越重要的作用,如超声成像(Ultrasound Imaging)、电子计算机X射线断层扫描技术(Computed Tomography, CT)、磁共振成像(Magnetic Resonance Imaging, MRI)、数字减影血管造影技术(Digital Subtraction Angiography, DSA)、正电子发射计算机断层扫描技术(Positron Emission Computed Tomography, PET)和其他形态学成像技术都提供了一种有效的无创性解剖结构映射方法<sup>[1]</sup>,为临床医生提供了丰富的2D/3D/4D人体图像,使得医生对病变部位的观察更加直接准确,极大扩展了医学研究对于生理或病理组织的认识,是医疗诊断和治疗计划的重要组成部分。

相较于其他医学成像技术而言,磁共振成像具有无电离辐射损伤、卓越的软组织对比度、多方向、多参数成像等诸多优良特性,使其在脑组织分类、容量分析和影像诊断等方面发挥着重要的作用。磁共振成像不仅能提供较为清晰的人体解剖结构信息,而且还能提供关于器官功能性和分子水平的诊断信息,使其越来越广泛的应用于神经科学、认知科学和心理学等学科的研究<sup>[2][3]</sup>。

早期的磁共振成像大部分用于定性的临床病理学诊断,随着人们对诊断精确度要求的提高和医学科学的发展,人们越来越关注于对磁共振图像信息进行定量分析。在很多神经性疾病中,如多发性硬化症(MS)和阿兹海默症等<sup>[4]</sup>,脑白质(White Matter, WM)、脑灰质(Gray Matter, GM)以及全脑容积的变化,都提示着神经元和轴突损失的重要信息<sup>[5][6]</sup>。临床上对脑肿瘤或脑损伤部位进行诊断和制定治疗计划时,都需要将目标区域的空间位置、大小、形状和一些重要组织器官的边界从磁共振图像中分割出来。所以,对于检测生理或者病理状态的脑组织容量,准确而稳健的组织分类或图像分割非常重要<sup>[7]</sup>。随着成像技术的不断发

展, 医学图像的数量和图像大小的不断增加, 仅依靠神经外科医师手动进行分割非常费时且不具有可重复性<sup>[8]</sup>。因此, 很有必要利用计算机实现的分割算法来简化医学图像处理和分析过程。

医学图像分割是医学影像在临床当中广泛应用的一个先行条件, 如特征识别、三维重建、可视化操作和虚拟手术等<sup>[9]</sup>。医学图像分割的对象是形状复杂, 形态特征多变的人体解剖结构, 并且依据不同的成像技术, 对应使用不同的分割算法, 目前尚无通用有效的分割方法。一般的, 医学图像分割算法的提出, 以提高分割准确率和尽量减少人工干预为目的, 以期达到自动、准确、可重复性好的分割效果。本课题针对磁共振成像的多参数成像特性, 提出将同一部位不同对比度的图像信息进行融合, 以期望得到更加准确的分割结果。针对现有分割算法的特点, 改进参数估计的形式, 使其能够自适应的进行图像分割, 减少人工干预, 提高算法的可重复性。

## 1.2 国内外研究现状和发展趋势

医学图像分割在整个影像诊断当中处于非常重要的位置, 因此医学图像的分割算法的研究一直受到各国科研人员和学术团队的高度重视, 近年来涌现了一大批各式各样的医学图像分割算法。Clarke 等人<sup>[10]</sup>将医学图像分割算法分为两大类, 既单参数分割算法和多参数分割算法。

单参数分割算法包括阈值法、边缘检测法和区域生长法等。单参数分割算法的主要局限性是不能应用于多通道图像, 并且对图像噪声非常敏感<sup>[11][12]</sup>。因此, 单参数分割算法很少单独应用于医学图像分割, 通常与其他算法组成多层算法体系, 共同完成图像分割任务。

多参数分割算法包括人工神经网络和模糊聚类算法等。由于磁共振成像具有独特的多参数成像特性, 这种特性使 MRI 可以获得不同组织对比度的图像 (如  $T_1$  加权像,  $T_2$  加权像, 质子密度加权像等) <sup>[13][14][15]</sup>,  $T_1$  加权像对正常组织分辨率较高, 而  $T_2$  加权像对损伤组织分辨率较高, 因此利用多参数算法将不同组织对比度的图像信息结合起来可能会使图像分割效果得到改进。人工神经网络方法对噪声的不敏感性使其广泛应用于医学图像分割<sup>[16][17]</sup>, 但是由于大部分神经网络的

学习需要大量的训练样本,这样就需要有期望输出,并且需要预先确定分类数目,使得人工神经网络在医学图像分割中的应用大大受限。模糊 C-均值聚类算法(FCM)是应用比较广泛的多参数分割算法<sup>[18][19]</sup>。但是,传统的 FCM 算法仅基于目标函数进行聚类,需要预先设定聚类数目,并且无法确定聚类结果是否最优。为解决这一问题,Xie, Beni 等人<sup>[20]</sup>提出了 Xie-Beni 指标有效性函数,为聚类数目的确定提供了理论依据。另外,当样本量过大时,FCM 算法的收敛时间过长,甚至发生不收敛的现象,这就需要利用其他算法,如分水岭算法、SOM 神经网络等先对样本进行粗分,以减小 FCM 算法的输入规模,加快算法的收敛速度<sup>[21]</sup>。其中,SOM 神经网络可以使高维数据映射成低维阵列,并且可以降低分割算法对图像噪声的敏感性,更适合用于多参数医学图像分割。

### 1.3 研究内容

综合分析国内外医学图像分割的研究现状,本课题主要针对磁共振图像多参数成像特性和多参数图像分割算法特性进行研究,研究内容如下:

1、计算脑磁共振  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像等多参数图像间的相关系数,研究不同参数图像像素之间的相关程度,使得多参数图像的选择更具有实际意义,为多参数图像分割提供理论依据。

2、利用 SOM 神经网络对  $T_1$  加权像和  $T_2$  加权像图像信息进行融合的同时,将图像像素进行粗分割,分割结果为大于目标类的若干子类,减少算法的输入样本量,并用以降低图像噪声对分割效果的影响程度。

3、使用模糊 C-均值聚类算法对粗分图像进行进一步分割得到最终目标类,并通过改进 Xie-Beni 指标有效性函数,使得模糊 C-均值聚类算法能在迭代过程中自动产生最优聚类数。

4、本课题使用国际公认的 BrainWeb 多发性硬化症模拟数据集对算法进行评估,利用不同组织类别的图像评估聚类算法有效性函数的判别程度。针对不同噪声等级的同一组图像,对比分析 SOM-FCM 算法和传统 FCM 算法的分割效果,最终找到一种新的适用于带有多发性硬化症病灶的脑磁共振多参数图像分割的有效算法。

## 1.4 本文组织结构

第1章 绪论：主要介绍研究背景及意义、研究现状、研究内容以及论文组织结构。

第2章 脑磁共振图像获取和多参数图像选择：主要介绍脑磁共振图像数据来源，图像特征和多参数图像选择标准。

第3章 脑磁共振图像多参数分割算法研究：针对磁共振图像的多参数成像特性，对主要的多参数分割算法进行研究，并对模糊 C-均值聚类算法加以改进，以便提高算法的性能。

第4章 SOM-FCM 二层分割算法的实现：提出 SOM-FCM 二层分割算法的体系结构，并用国际公认的脑磁共振体数据对算法进行评估，并与传统 FCM 算法进行比较。

第5章 结论：总结全文，叙述本文的创新之处和不足之处，展望进一步的工作。

## 第2章 脑磁共振图像获取与多参数图像选择

### 2.1 引言

磁共振图像因具体成像技术和被扫描个体的不同而存在相当大的差异,因此,磁共振图像分割算法研究阶段的数据选取非常重要。本课题主要采用国际公认的脑磁共振图像数据库进行算法研究,以便使得分割结果更有可比性<sup>[22]</sup>。另外,磁共振的多参数成像特性虽然使得图像信息互有补充,但是也存在一定的数据冗余问题,本章通过图像间相关系数的计算,使得磁共振多参数图像的选择更具有理论依据。

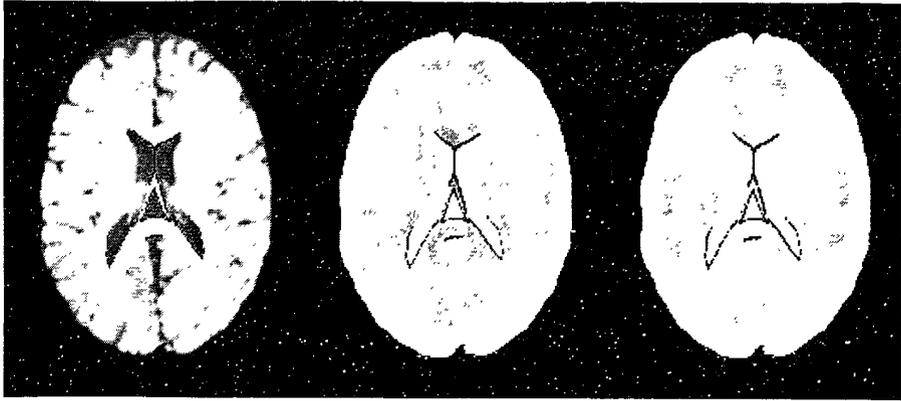
### 2.2 脑磁共振图像获取

加拿大麦吉尔大学蒙特利尔神经病学研究所 (Montreal Neurological Institute) BrainWeb 多发性硬化症模拟图像数据集提供带有多发性硬化症病灶的脑组织磁共振图像<sup>[23]</sup>,其中包括  $T_1$  加权像、 $T_2$  加权像和质子密度 (Pd) 加权像等多参数体数据,每个体数据由  $181 \times 217 \times 181$  个像素组成,4096 灰度级,层厚 1mm,表 2.1 中描述了 BrainWeb 体数据的维度信息。

表 2.1, BrainWeb 体数据维度信息

坐标轴	长度	增量	初始值
Z 轴	181	1	-72
Y 轴	217	1	-126
X 轴	181	1	-90

BrainWeb 数据集可针对同一层图像模拟多种噪声等级,包括 1%、3%、5% 和 7% 等。由于数据集是模拟图像,所以相应层上的  $T_1$  加权像、 $T_2$  加权像、Pd 加权像之间完全配准。本课题的输入图像均先使用开源软件 MIPAV 进行去壳处理<sup>[24]</sup>,去除非脑组织。图 2.1 显示了一层经过去壳处理后的  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像 ( $Z=18$ )。



(a) T<sub>1</sub> 加权像

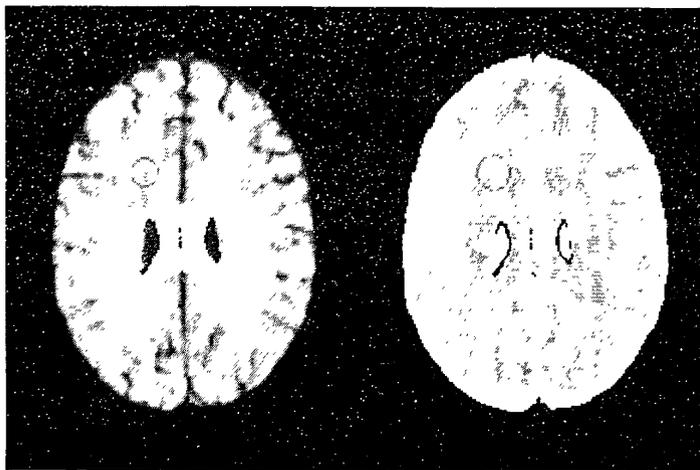
(b) T<sub>2</sub> 加权像

(c) Pd 加权像

图 2.1, 去壳后的脑 MR 图像

### 2.3 多发性硬化症

多发性硬化症是与免疫有关的中枢神经系统疾病，主要是由免疫系统异常引起的神经纤维髓鞘脱落而引起的瘢痕<sup>[25][26]</sup>。在脑组织磁共振图像中，不同参数的图像对于多发性硬化症病灶的对比度不同。图 2.2 显示了 T<sub>1</sub> 加权像和 T<sub>2</sub> 加权像对于同一层带有多发性硬化症病灶脑 MR 图像的不同组织对比度。其中画红色圆圈的部位是一块多发性硬化症病灶。



(a) T<sub>1</sub> 加权像

(b) T<sub>2</sub> 加权像

图 2.2, 带有多发性硬化症病灶的脑 MR 图像

从图 2.2 中可以看出，T<sub>1</sub> 加权像对正常组织的边界显示较为清晰，而对损伤组织，如多发性硬化症病灶的边界显示较为模糊。相比之下，T<sub>2</sub> 加权像对多发性

硬化症病灶等损伤组织的边界显示较为清晰,但是,在  $T_2$  加权像中病灶区域的像素值与脑脊液的像素值具有一定的相似性,所以单纯利用  $T_2$  加权像也不能得出满意的分割结果。

## 2.4 脑磁共振多参数图像选择

磁共振成像具有多参数成像特性,能得出不同组织对比度的图像,因此将多参数图像信息融合起来,可以提高分割的准确度。但是,对于本实验中所采用的图像,每层图像的分辨率为  $181 \times 217$ ,即 39277 个像素点,如果将三种加权像的信息都融合在一起,会导致算法的输入样本量过大,影响算法执行的效率。这就需要输入数据的特征进行分析,采用适当的方法对输入数据进行降维处理,以减少输入样本量,提高算法的执行效率。本课题抽取数据集中的 10 层图像,通过计算 10 层图像的  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像之间的相关系数,来确定多参数分割算法的输入图像。相关系数是衡量两个变量线性相关密切程度的量。其计算公式如下

$$r_{xy} = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (2-1)$$

表 2.2 列出 10 层图像  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像之间的相关系数值。这 10 层图像分别是:  $Z=6$ 、 $Z=14$ 、 $Z=18$ 、 $Z=24$ 、 $Z=26$ 、 $Z=28$ 、 $Z=30$ 、 $Z=32$ 、 $Z=38$ 、 $Z=48$ 。

表 2.2,  $T_1$  加权像、 $T_2$  加权像和 Pd 加权像之间的相关系数

	$T_1$ 与 $T_2$	$T_1$ 与 Pd	$T_2$ 与 Pd
1	0.3643	0.8057	0.8211
2	0.3130	0.7801	0.8151
3	0.3315	0.7900	0.8184
4	0.3313	0.7894	0.8193
5	0.3036	0.7762	0.8163
6	0.3659	0.8020	0.8295

7	0.3986	0.8160	0.8357
8	0.4284	0.8213	0.8495
9	0.4539	0.8193	0.8682
10	0.4741	0.8154	0.8856
$\bar{r}$	0.3765	0.8015	0.8359

一般的，以  $r$  值的大小来看相关的强弱，当相关系数为 0~0.25 之间时，表示两个数据没有或轻微相关；当相关系数为 0.25~0.5 之间是，表示两个数据轻度相关；当相关系数为 0.5~0.75 是，表示两个数据中度相关；当相关系数在 0.75 以上时，表示量数据有很强的相关性<sup>[27]</sup>。从表 2 中可以看出， $T_1$  加权像和  $T_2$  加权像之间的平均相关系数为 0.3765，属于轻度相关，而  $T_1$  加权像和 Pd 加权像、 $T_2$  加权像和 Pd 加权像之间的平均相关系数分别为 0.8015 和 0.8359，均属于具有很强的相关性。因此，可以将 Pd 加权像除去，只使用  $T_1$  加权像和  $T_2$  加权像作为算法的输入图像，这样既不会损失太多的信息，又减少了算法的输入样本量。

## 第3章 脑磁共振图像多参数分割算法研究

### 3.1 SOM 神经网络

SOM 神经网络也称自组织映射神经网络,它可以将非线性高维数据项之间的统计学关系转换成简单的低维阵列的几何学关系<sup>[28][29]</sup>。由于 SOM 神经网络不需要期望输出,只依靠输入数据本身的特征进行特征映射,所以,这种神经网络经常用于数据分类。

SOM 神经网络在本课题中用于融合  $T_1$  加权像和  $T_2$  加权像的图像信息,生成大量的参考向量,这些参考向量可视为主要脑组织类(灰质、白质、脑脊液等)的子类。图 3.1 显示了 SOM 神经网络对  $T_1$  加权像和  $T_2$  加权像进行图像信息融合并进行粗分割的过程。

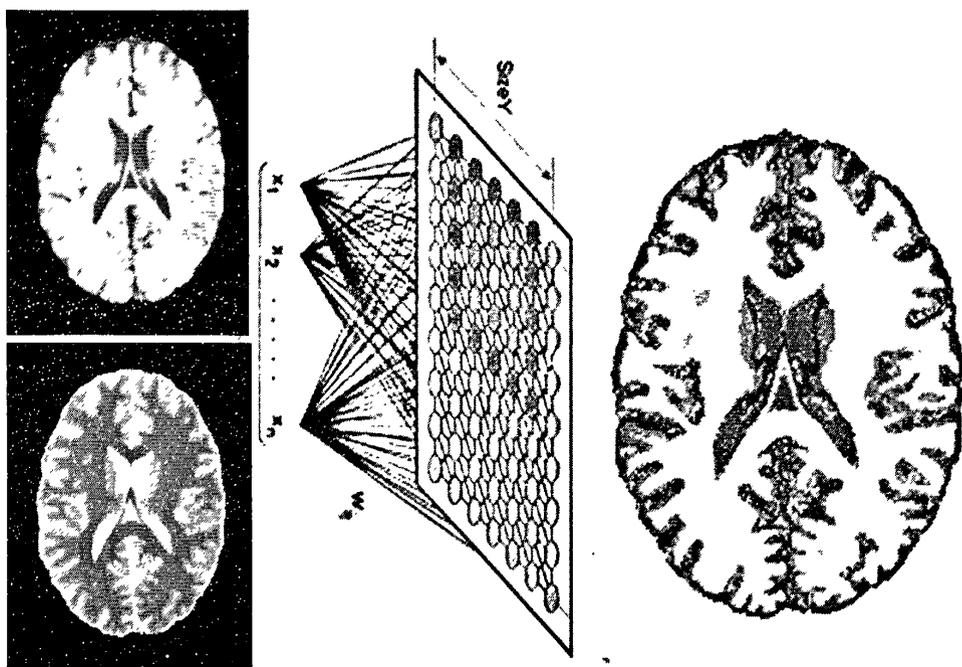


图 3.1, SOM 神经网络图像信息融合示意图

如图 3.1 所示,输入数据被粗分割成许多子类,这些子类作为 FCM 算法的输入向量,可以减少算法的收敛时间。

通常 SOM 神经网络分为两层,既输入层和竞争层<sup>[30]</sup>。SOM 神经网络的竞争层由一个二维节点网格结构组成,本课题应用 Matlab 建立 SOM 神经网络竞争层,

采用4×20的二维网格结构作为SOM网络竞争层的拓扑结构。图3.2中显示了4×20的竞争层拓扑结构。

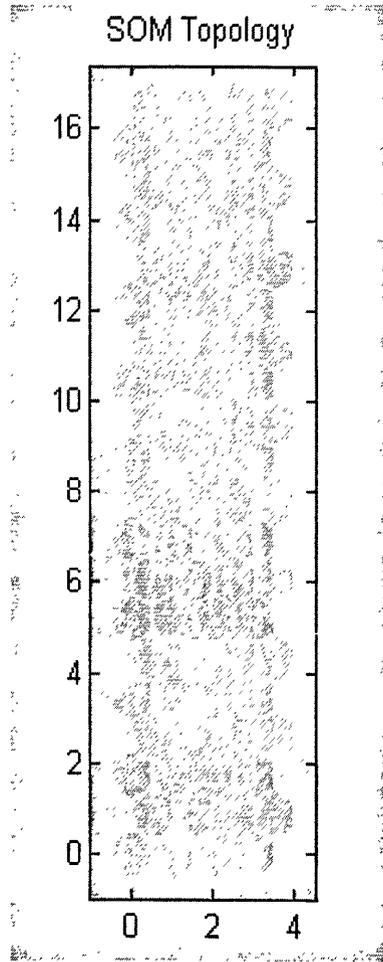


图 3.2, SOM 神经网络竞争层 4×20 拓扑结构

对每一个输入样本  $x_k$ ，计算它与参考向量  $w_j$  的欧式距离。然后，选择与  $x_k$  距离最短的参考向量作为胜利结点。在学习过程中，用相同的  $x_k$  更新参考向量，学习规则为

$$w_j(t+1) = w_j(t) + \alpha(t)\eta_{ci}(t)(x_k(t) - w_j(t)) \quad \forall j, k \quad (3-1)$$

其中， $t$  是时间， $\alpha(t)$  是学习率， $\eta_{ci}(t)$  是邻近中心， $0 < \eta(t) \leq \eta(t-1) \leq 1$ 。 $n$  是迭代次数， $d_{ci} = r_c - r_i$  是映射网格上映射单元  $c$  和  $i$  之间的距离。 $\sigma(t)$  和  $\alpha(t)$  都是时间  $t$  的单调递减函数，初始学习率  $\alpha(0)$  设为 0.1，迭代次数为 50 次。图 3.3 显示

了 SOM 神经网络经一层带有 多发性硬化症病灶的脑组织图像训练后，竞争层节点向特征空间的拟合情况。其中纵轴代表样本在  $T_1$  加权像中对应的像素值，横轴代表样本在  $T_2$  加权像中对应的像素值。

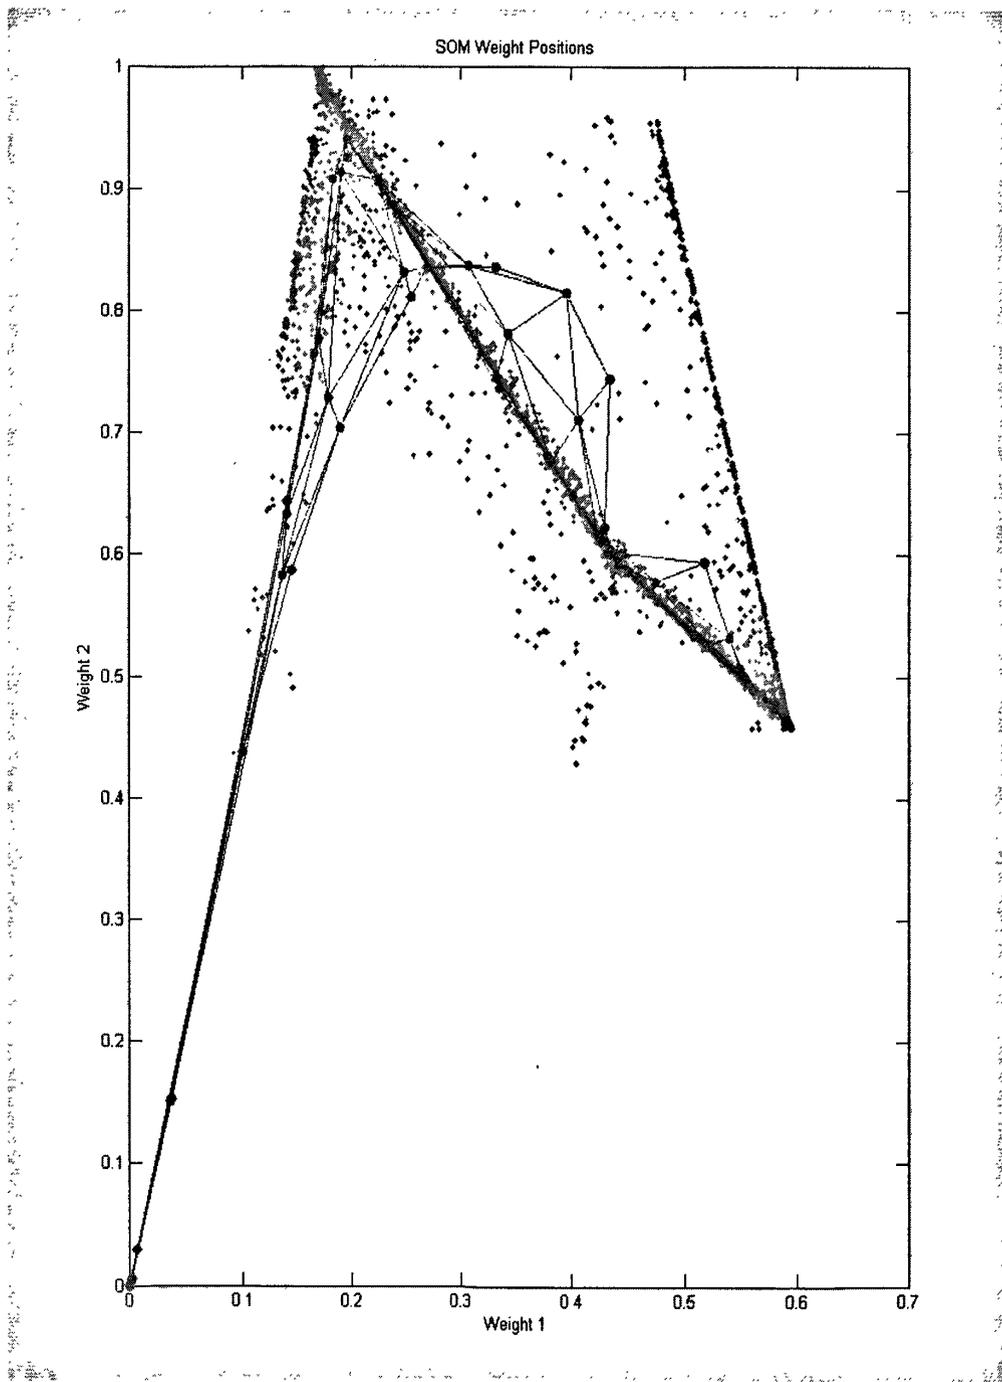


图 3.3，训练后的 SOM 神经网络竞争层节点拟合情况

### 3.2 硬 C-均值聚类

硬 C-均值算法把  $n$  个向量  $x_j(1,2,\dots,n)$  分为  $c$  个组  $G_i(i=1,2,\dots,c)$ ，并求每组的聚类中心，使得非相似性（或距离）指标的价值函数（或目标函数）达到最小<sup>[31]</sup>。当选择欧几里德距离为组  $j$  中向量  $x_k$  与相应聚类中心  $c_i$  间的非相似性指标时，目标函数可定义为：

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left( \sum_{k, x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (3-2)$$

这里  $J_i = \sum_{k, x_k \in G_i} (\|x_k - c_i\|^2)$  是组  $i$  内的目标函数。这样  $J_i$  的值依赖于  $G_i$  的几

何特性和  $c_i$  的位置。

划分过的组一般用一个  $c \times n$  的二维隶属矩阵  $U$  来定义。如果第  $j$  个数据点  $x_j$  属于组  $i$ ，则  $U$  中的元素  $u_{ij}$  为 1；否则，该元素取 0。由于一个给定数据只能属于一个组，所以隶属矩阵  $U$  具有如下性质：

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n \quad (3-3)$$

且

$$\sum_{i=1}^c \sum_{j=1}^n u_{ij} = n \quad (3-4)$$

医学图像的本质是模糊的，特别是在脑组织 MR 图像中，组织的复杂性体现在灰质和白质常有相互重叠的部位，这使得有些像素不只属于一个目标类，可能对每个目标类都有一定的隶属度，这时，采用硬 C-均值聚类算法就不能很好的进行组织分割。

### 3.3 模糊 C-均值聚类

模糊 C-均值聚类是用隶属度确定每个数据点属于某个聚类的程度的一种聚类算法<sup>[32][33]</sup>。1973 年，Bezdek 提出了该算法，作为早期硬 C 均值聚类（HCM）方法的一种改进<sup>[34][35]</sup>。在医学图像处理过程中，通常将图像按列或行转换成一维

向量  $X = [x_1, x_2, \dots, x_n]$ , 其中  $n$  为像素个数, 也称样本数。图像分割相当于将  $n$  个样本分成  $c$  类, 得到  $c$  个类的中心向量  $V$  和样本对于每个类的隶属度矩阵  $U$ 。FCM 算法的基本原理就是找到特定的  $V$  和  $U$  使得算法的目标函数取得最小值, 其中算法的目标函数定义为

$$J(U, V) = \sum_{j=1}^c \sum_{i=1}^n u_{ij}^m d_{ij}^2 \quad (3-5)$$

式中  $u_{ij}$  为第  $i$  个样本关于第  $j$  类的隶属度,  $d_{ij} = \|x_i - v_j\|$  是样本  $x_i$  到聚类中心  $v_j$  的欧氏距离,  $m$  为模糊权重, 经验取值范围为  $[1.1, 2.5]$ , 本文取 1.2 时聚类效果比较理想。目标函数的限制条件是

$$\sum_{i=1}^c u_{ij} = 1, \forall j = 1, \dots, n \quad (3-6)$$

根据拉格朗日乘法可知, 使得目标函数达到最小值的必要条件是:

$$\begin{aligned} \bar{J}(U, V_1, \dots, V_c, \lambda_1, \dots, \lambda_n) &= J(U, V_1, \dots, V_c) + \sum_{j=1}^n \lambda_j (\sum_{i=1}^c u_{ij} - 1) \\ &= \sum_{i=1}^c \sum_j u_{ij}^m d_{ij}^2 + \sum_{j=1}^n \lambda_j (\sum_{i=1}^c u_{ij} - 1) \end{aligned} \quad (3-7)$$

这里  $\lambda_j$  是  $n$  个约束式的拉格朗日乘子。对所有输入参量求导, 使目标函数达到最小的必要条件为:

$$V_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (3-8)$$

和

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left( \frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (3-9)$$

传统 FCM 算法需要预先确定聚类数目  $c$ ，然后根据上述聚类中心和模糊隶属度公式迭代优化使目标函数取得极小值，最终得到聚类结果。

### 3.4 聚类有效性函数

传统 FCM 算法不但需要预先确定聚类数，而且无法判别聚类结果是否最优。Xie 等人<sup>[20]</sup>根据聚类算法的目标函数和数据集本身的结构特点提出了称为 Xie-Beni 指标的聚类有效性函数

$$V_{xb} = \frac{\sum_{j=1}^c \sum_{i=1}^n u_{ij}^m d_{ij}^2}{n \left( \min_{i \neq k} \|v_i - v_k\|^2 \right)} \quad (3-10)$$

式中分子为聚类的目标函数，分母是聚类中心的分离性测度， $V_{xb}$  值越小，表明聚类的效果越好。因此，Xie-Beni 指标有效性函数为聚类数目的确定提供了理论依据。

### 3.5 改进聚类有效性函数

较好的聚类效果应满足类内的相似性尽可能高而类间的相似性尽可能低<sup>[36]</sup>。在图像处理中，像素间的相似性用其在特征空间中的欧氏距离表示，则对于一次特定的分类结果，各类内部的平均距离应为

$$D_{internal} = \frac{\sum_{j=1}^c \sum_{i=1}^n u_{ij}^m \|x_i - v_j\|^2}{cn} \quad (3-11)$$

各类间的平均距离为

$$D_{interval} = \frac{\sum_{j=1}^c \|v_j - \bar{x}\|^2}{c} \quad (3-12)$$

式中  $\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j$  是所有像素在特征空间中的中心向量。改进后的聚类有效性

函数为

$$VF = \frac{D_{internal}}{D_{interval}} \cdot b \quad (3-13)$$

式中  $b = c^{2.5}$ ，是本文根据医学图像的特征和实验经验确定的收敛因子。VF 值越小，说明类间距离越大且类内距离越小，聚类的效果也越好。因此，改进后的聚类有效性函数能够有效的判断聚类结果是否最优。

### 3.6 自适应模糊 C-均值聚类

本文提出的自适应模糊 C-均值聚类是指在传统 FCM 的基础上，加入改进的聚类有效性函数作为确定聚类数目的判别依据，使得算法能够自适应的确定最佳聚类数目。图 3.4 显示加入改进聚类有效性函数后的自适应模糊 C-均值聚类算法流程图。

如图 3.4 所示，自适应模糊 C-均值算法的步骤是：

步骤 1：用取值范围在 0, 1 间的随机数初始化算法的隶属矩阵 U，使其满足式 (3-6) 所示的隶属度矩阵的约束条件，初始化聚类中心和有效性函数，并设置初始聚类数目为 2，并根据先验的解剖学知识，设置最大分类数为 7；

步骤 2：计算每个输入数据对于 c 个聚类中心  $V_i, i=1, \dots, c$  的隶属度矩阵 U；

步骤 3：根据式 (3-8) 所示聚类中心的计算公式计算新的聚类中心 V；

步骤 4：比较新的聚类中心和原有聚类中心，如果变化值小于某一常量  $\epsilon$  则算法进入下一步，否则返回第二步继续迭代；

步骤 5：比较当前聚类结果下的有效性函数值，如果有效性函数值达到最小值，则算法终止，输出最佳分类数目和隶属度矩阵，否则返回步骤 2 继续下一次迭代。

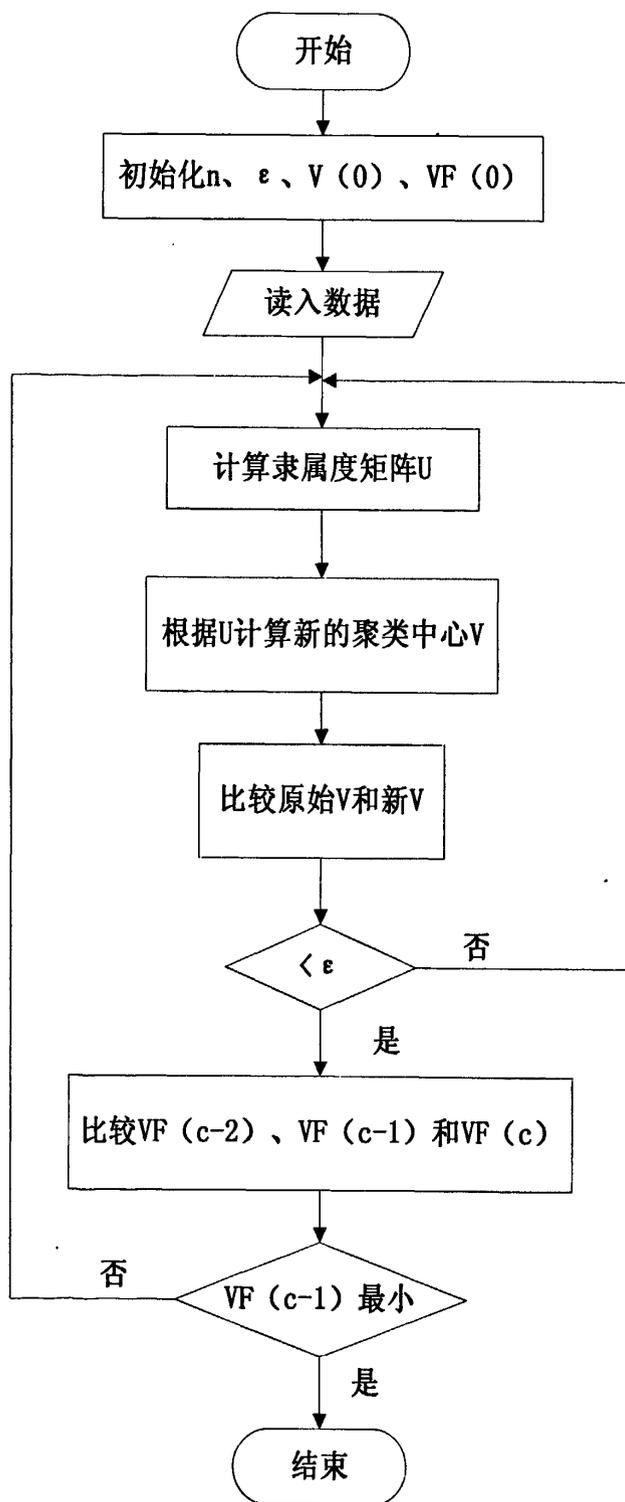


图 3.4, 自适应模糊 C-均值聚类算法流程图

## 第4章 SOM-FCM 二层分割算法的实现

### 4.1 SOM-FCM 二层分割算法

本文使用 SOM 神经网络对输入的  $T_1$  加权像和  $T_2$  加权像图像信息进行融合的同时进行粗分割, 再将粗分割的结果用于模糊 C-均值算法的输入, 并加入改进的有效性函数使得模糊 C-均值聚类能够自适应的确定最佳聚类数目。图 4.1 给出这种 SOM-FCM 二层分割算法的流程图。

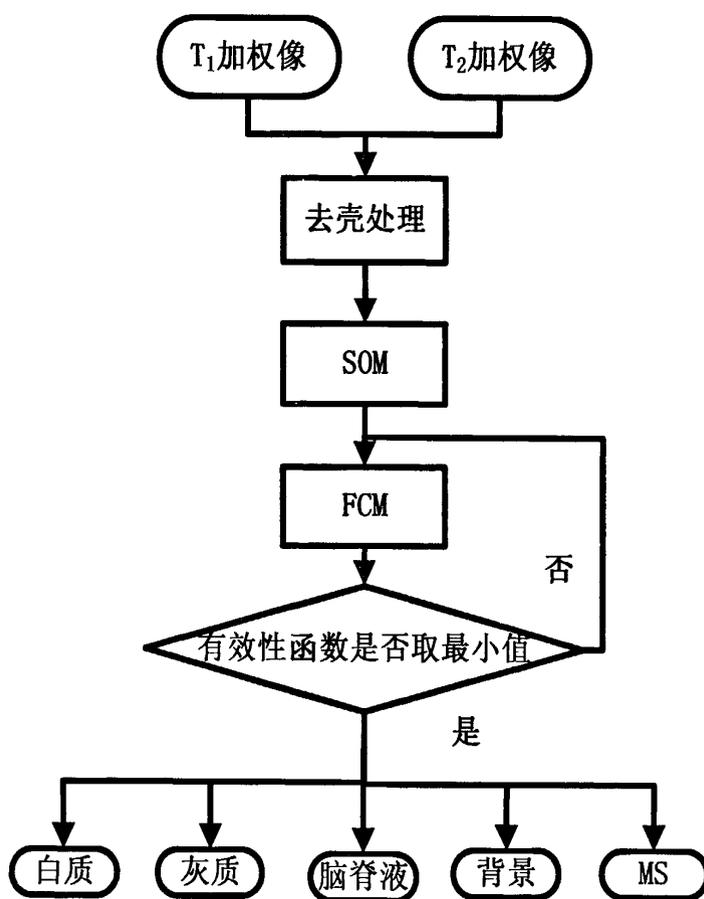


图 4.1, SOM-FCM 二层分割算法流程图

磁共振图像具有多参数成像的特性,  $T_1$  加权像对正常组织的边界显示较为清晰, 而对损伤组织, 如多发性硬化症病灶的边界显示较为模糊。相比之下,  $T_2$  加权像对多发性硬化症病灶等损伤组织的边界显示较为清晰。针对这一特征, 本课程首先利用 SOM 神经网络对去壳后  $T_1$  加权像和  $T_2$  加权像的图像信息进行融合,

并对融合信息进行粗分割，粗分割的结果是大于最终目标类（灰质、白质、脑脊液、多发性硬化症病灶和图像背景）的若干子类。将这些子类作为模糊 C-均值聚类算法的输入参考向量。由于传统模糊 C-均值聚类需要人工确定分类数目，没有去除人工干预，本课题通过改进 Xie-Beni 准则有效性函数，作为算法迭代的标准，使得改进后的模糊 C-均值聚类可以自适应的确定最佳分类数目，分割结果为最终 5 个目标类，既灰质、白质、脑脊液、多发性硬化症病灶和图像背景。

## 4.2 医学图像分割评价标准

目前，对于医学图像分割结果的评价并没有所谓的“金标准”，较常使用的评价标准主要分为主观评价和客观评价两种<sup>[37][38]</sup>。主观评价主要是由有多年临床诊断经验的影像科医师对图像分割结果进行目测，判断图像分割结果是否达到所要求的目标，属于定性的评价方法，评价结果因人而异，不具有可重复性，在图像数量和图像大小达到一定数量级时，此种评价方法非常费时且不具有可行性。客观评价方法通常只适用于带有 Ground Truth 正确分割结果的模拟 MR 图像，通过公式计算分割结果的正确分割率，得到对分割结果的定量评估。其中计算正确分割率的公式为：

$$PCE = \frac{\text{Ref} \cap \text{Seg}}{\text{Ref}} \times 100\% \quad (4-1)$$

其中，Seg 代表分割结果的组织容积，Ref 代表由 Ground Truth 正确分割结果生成的参考容积。

## 4.3 基于 SOM-FCM 算法的分割结果

本课题通过 MATLAB 编程实现 SOM-FCM 算法后，采用国际公认的 BrainWeb 多发性硬化症数据集中的脑组织图像体数据对 SOM-FCM 二层算法体系执行的效果进行评估，首先使用带有不同组织类别数的多层图像对聚类算法有效性函数进行测试，检测其是否能对图像的不同组织类别数进行判别，最终给出最佳聚类数目。其次使用带有不同噪声等级的同一层图像对 SOM-FCM 算法的稳定性和准确性进行评估，并与传统 FCM 算法分割效果进行对比。

### 4.3.1 不同组织类别的图像分割判别结果

利用 SOM-FCM 算法对 BrainWeb 多发性硬化症数据集中的 2 层无噪声脑 MR 图像 ( $Z=30$  和  $Z=48$ ) 进行自动分割, 其中  $Z=30$  层图像中存在多发性硬化症病灶,  $Z=48$  层图像中无病灶。由于灰质和脑脊液的相似性, 尤其在皮层两个组织常有显著的重叠, 本文将脑组织分成 5 类, 包括白质 (WM)、灰质 (GM)、脑脊液 (CSF)、多发性硬化症病灶 (MS) 和背景。表 4.1 和表 4.2 分别给出了 SOM-FCM 算法针对 10 层组织分类数不同的图像分割结果的有效性函数值, 表 4.1 中  $Z=48$ 、 $Z=50$ 、 $Z=52$ 、 $Z=54$  和  $Z=56$  这 5 层是不带有多发性硬化症病灶的图像, 表 4.2 中  $Z=14$ 、 $Z=24$ 、 $Z=26$ 、 $Z=28$  和  $Z=32$  这 5 层是带有多发性硬化症病灶的图像。

表 4.1, 无 MS 病灶图像分割结果有效性函数值

分类数	$Z=48$	$Z=50$	$Z=52$	$Z=54$	$Z=56$
2	0.2469	0.2448	0.2464	0.2426	0.2385
3	0.1333	0.1121	0.1040	0.0983	0.0933
4	0.0450	0.0434	0.0453	0.0452	0.0403
5	0.0572	0.0596	0.0480	0.0595	0.0536

表 4.2, 有 MS 病灶图像分割结果有效性函数值

分类数	$Z=14$	$Z=24$	$Z=26$	$Z=28$	$Z=32$
2	0.3308	0.3269	0.3190	0.2916	0.2715
3	0.1955	0.1778	0.1332	0.1230	0.1158
4	0.0780	0.0649	0.0724	0.0688	0.0694
5	0.0614	0.0595	0.0700	0.0635	0.0646
6	0.0833	0.0693	0.0913	0.0760	0.0840

从表 4.1 和表 4.2 中可以看出, 对于 5 层无 MS 病灶图像和 5 层有 MS 病灶图像, 本课题改进的聚类算法有效性函数值分别与 4 类和 5 类处达到最小值, 可以根据图像中组织类别的不同有效的判别出最佳的聚类数目。

### 4.3.2 同一层图像不同噪声等级的分割结果

在  $Z=30$  这一层图像中分别加入 1%、3%、5% 和 7% 的随机噪声，用于对本文提出的 SOM-FCM 算法和传统 FCM 算法的分割结果进行比较评估。图 4.2 给出了对于加入 7% 的随机噪声的  $T_1$  加权像和  $T_2$  加权像，本文提出的 SOM-FCM 算法和传统 FCM 算法的分割结果比较。

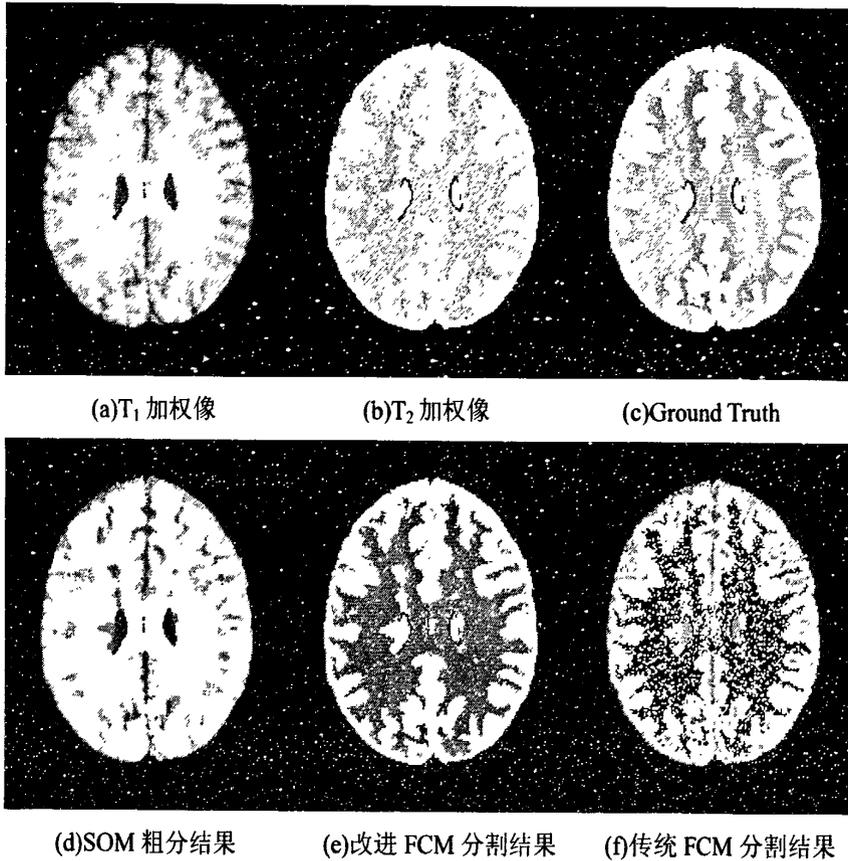


图 4.2, 噪声等级 7% 的脑 MR 图像分割结果

图 4.4(a)、(b) 分别为加入 7% 随机噪声的  $T_1$  加权像和  $T_2$  加权像，可以看到脑组织中伴有大量的噪声点，使得组织内部相似性减弱，组织类别之间的边界变得模糊。图 4.4(c) 是 BrainWeb 网站上提供的此层图像对应的正确分类结果，主要分为 5 类，包括灰质、白质、脑脊液、多发性硬化症病灶和图像背景。图 4.4(d) 是利用 SOM 神经网络对上述  $T_1$  加权像和  $T_2$  加权像的图像信息融合后进行粗分割的结果，从图中可以看到，由于融合了  $T_1$  加权像和  $T_2$  加权像的图像信息，粗分割后的若干子类对于原始图像的噪声敏感度大大降低。图 4.4(e)、(f) 分别为利用 SOM 神经网络粗分结果作为输入的改进 FCM 算法分割结果和直接利用原始  $T_1$  加权像

和  $T_2$  加权像作为输入的传统 FCM 算法分割结果。可以看出，由于使用 SOM 神经网络对两种互补图像信息的融合，改进后的 FCM 算法最终的分割结果对噪声具有较好的稳定性，但仍不可避免的在多发性硬化症分割中存在一定的过分割现象，将噪声点错误的分割成多发性硬化症病灶。

表 4.3 给出 SOM-FCM 算法和传统算法分别在四种噪声等级下对于四种组织类别（脑脊液、灰质、白质和多发性硬化症病灶）的正确分割率。

表 4.3, 两种算法在四种噪声等级下对四种组织正确分割率对比

		1%噪声	3%噪声	5%噪声	7%噪声
SOM-FCM 算法	CSF	0.9543	0.9210	0.9063	0.8846
	GM	0.7661	0.7196	0.7192	0.7373
	WM	0.9795	0.9699	0.9589	0.9322
	MS	0.9955	0.9420	0.8616	0.7768
传统 FCM 算法	CSF	0.8808	0.8545	0.8437	0.8826
	GM	0.2307	0.5303	0.6492	0.6937
	WM	0.9303	0.9479	0.8605	0.6771
	MS	0.7991	0.8080	0.7500	0.6384

从表中数据可以看出，在四种噪声等级下，本课题提出的 SOM-FCM 算法相比传统 FCM 算法在脑脊液和白质的分割中，拥有较好的正确分割率和良好的稳定性，但由于组织的重叠和组织间差异的模糊，灰质和白质有一定的重叠，造成灰质的正确分割率普遍不高。

使用 SOM 神经网络粗分后，改进的 FCM 算法的平均收敛时间在 1min 左右，而传统 FCM 算法则在 2min 左右。图 4.3 给出了两种算法对 4 种噪声等级图像的分割结果的平均正确分割率。

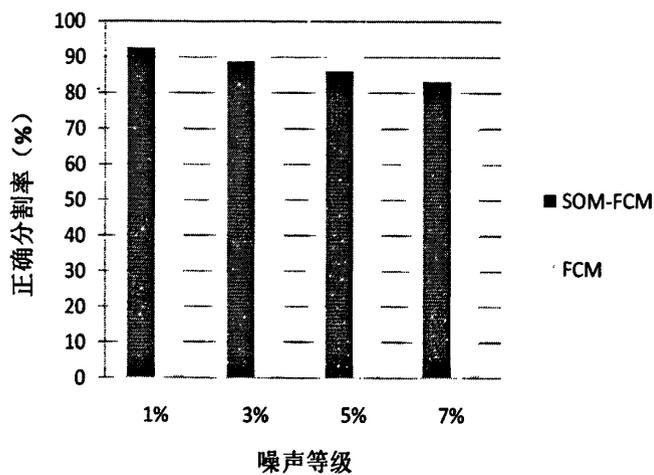


图 4.3, 平均正确分割率比较

随着噪声等级的不断增大, SOM-FCM 算法和传统 FCM 算法的平均正确分割率差异具有统计学意义 ( $P < 0.05$ )。

## 第5章 结论

脑磁共振多参数图像对于不同组织的对比度不同，为图像分割提供了互补信息，本文根据不同对比度图像间的相关系数，选择  $T_1$  加权像和  $T_2$  加权像作为算法的输入，利用 SOM 神经网络对输入图像信息融合的同时进行粗分割，分割结果为最终目标类的若干子类，即达到了融合图像信息的目的，又减少了模糊 C-均值聚类算法的输入样本量。使得改进后的 FCM 算法的运行时间小于传统 FCM 的运行时间。对于不同组织类别的不同层图像，本文提出的算法能够得出正确的聚类数目，并与实际情况相符合。对于不同噪声等级的同一层图像，由于使用 SOM 神经网络融合输入图像进行粗分割，使得模糊 C-均值聚类算法对于噪声更具稳定性，分割结果的平均正确分割率高于传统 FCM 算法，结果具有统计学意义

( $P < 0.05$ )。通过对传统算法的研究与改进算法的实现，本课题得出如下结论：

1、MRI 所独有的多参数成像性质为多参数分割算法提供了可能，根据不同对比度图像间的相关系数，舍去  $P_d$  加权像，使用  $T_1$  加权像和  $T_2$  加权像作为算法的输入图像，其中  $T_1$  加权像适于正常组织分割， $T_2$  加权像适于损伤组织分割。

2、SOM 神经网络采用  $4 \times 20$  二维网格结构作为竞争层的拓扑结构，经训练后能够更好的拟合输入样本的特征空间。

3、加入改进的有效性函数的模糊 C-均值矩阵能够自适应的确定最佳聚类数目，并由于使用 SOM 神经网络融合图像信息后粗分割的图像作为输入图像，因而对图像噪声具有更好的稳定性，平均正确分割率高于传统 FCM 算法。

但是，由于医学图像本身的模糊性、复杂性、个体差异性和噪声的随机性较大，导致本文提出的算法有一定的局限性，在对多发性硬化症病灶的分割结果中存在一定的过分割现象，既将部分噪声点错误分割成多发性硬化症病灶。由于脑磁共振图像中，相邻两层之间的图像信息较为接近，可以考虑以相邻层的图像信息作为参考，增强算法分割的准确性。另外，本课题使用 SOM 神经网络进行粗分时迭代时间过长，影响了整体算法效率，有必要继续改进 SOM 神经网络的结构和参数设置，以加快收敛速度和分割精度。

## ·本论文创新性的自我评价·

首先，本文使用相关系数舍去相关度较高的 Pd 加权像，为多参数分割提供理论依据；其次，本文提出了 SOM-FCM 二层分割算法对传统 FCM 进行改进，最后，利用改进的有效性函数使得模糊 C-均值算法能够自适应的选择最佳聚类数目。

## ·参考文献·

- [1] Deloire MS, Ruet A, Hamel D, et al. MRI predictors of cognitive outcome in early multiple sclerosis [J]. *Neurology*, 2011, 76(13):1161-1167.
- [2] Kim MJ, Hong JH, Ang SH.. The cortical effect of clapping in the human brain: A functional MRI study[J]. *NeuroRehabilitation*, 2011, 28(2):75-79.
- [3] Modinos G, Renken R, Ormel J, et al. Self-reflection and the psychosis-prone brain: An fMRI study[J]. *Neuropsychology*, 2011, 25(3):295-305.
- [4] Deloire MS, Ruet A, Hamel D, et al. MRI predictors of cognitive outcome in early multiple sclerosis[J]. *Neurology*, 2011, 76(13):1161-1167.
- [5] Harrison DM, Caffo BS, Shiee N, et al. Longitudinal changes in diffusion tensor-based quantitative MRI in multiple sclerosis[J]. *Neurology*, 2011, 76(2): 179–186.
- [6] He R, Datta S, Sajja BR, et al. Generalized fuzzy clustering for segmentation of multi-spectral magnetic resonance images[J], *Computerized Medical Imaging and Graphics*, 2008, 32:353–366.
- [7] de Boer R, Vrooman HA, van der Lijn F, et al. White matter lesion extension to automatic brain tissue segmentation on MRI[J]. *Neuroimage*, 2009, 45(4):1151-1161.
- [8] Rafael C. Gonzalez, Richard E. Woods, *Digital Image Processing*[M]. Prentice Hall, 2002, 567-568.
- [9] Kim D, Trzasko JD, Smelyanskiy M, et al. High-performance 3D compressive sensing MRI reconstruction[J], *Engineering in Medicine and Biology Society*, 2010, 2010:3321-3324.
- [10] Clarke LP, Velthuizen RP, Camacho MA , et al. MRI Segmentation: Methods and Applications[J], *Magnetic Resonance Imaging*, 1995, 13(3): 343-368.
- [11] Agrawal A, Mittal A, Jain R, et al. Fuzzy-adaptive-thresholding-based exon prediction[J], *International Journal of Computational Biology and Drug Design*, 2011, 3(4):311-333.
- [12] Khademi A, Venetsanopoulos A, Moody AR. Edge-based partial volume averaging estimation for FLAIR MRI with white matter lesions[J]. *IEEE*, 2010:6114-6117.
- [13] Ozer S, Langer DL, Liu X, et al. Supervised and unsupervised methods for prostate cancer

- segmentation with multispectral MRI[J]. *Medical Physics*, 2010, 37(4):1873-1883.
- [14] Ding Z, Preiningerova J, Cannistraci CJ, et al. Quantification of multiple sclerosis lesion load and brain tissue volumetry using multiparameter MRI: methodology and reproducibility[J]. *Magnetic Resonance Imaging*, 2005, 23(3):445-452.
- [15] Zhou Xiaodong, Bao Shanglian, Li Dejun. The Research on Tissue Segmentation for Brain Multi-spectral MR Image[J]. *Chinese Journal of Medical Physics*, 2003, 20(2): 89-91.
- [16] 孙炜, 王耀南, 徐航. 基于自组织小波神经网络的磁共振图像分割方法[J]. *电子测量与仪器学报*, 2008, 22(4): 26-29.
- [17] 孙炜, 王耀南. 基于模糊小波神经网络的磁共振图像分割方法[J]. *中国生物医学工程学报*, 2006, 25(3): 267-270.
- [18] Shi J, Sahiner B, Chan HP, et al. Treatment response assessment of breast masses on dynamic contrast-enhanced magnetic resonance scans using fuzzy c-means clustering and level set segmentation[J]. *Medical physics*, 2009, 36(11):5052-5063.
- [19] Emblem KE, Nedregaard B, Hald JK, et al. Automatic glioma characterization from dynamic susceptibility contrast imaging: brain tumor segmentation using knowledge-based fuzzy clustering[J]. *Journal of Magnetic Resonance Imaging*, 2009, 30(1):1-10.
- [20] Xie X.L., Beni G. A Validity Measure for Fuzzy Clustering[J]. *IEEE PAMI*, 1991, 13(8):841-847.
- [21] Tasdemir K, Milenov P, Tapsall B. Topology-based hierarchical clustering of self-organizing maps[J]. *IEEE transactions on neural networks*, 2011, 22(3):474-485.
- [22] 康晓东等. 医学影像图像处理[M]. 人民卫生出版社, 2009, 187-198.
- [23] Shattuck DW, Prasad G, Mirza M, et al. Online resource for validation of brain segmentation methods[J]. *Neuroimage*, 2009, 45(2):431-439.
- [24] 周振环, 伍云智, 赵明. 医学图像编程技术[M]. 电子工业出版社, 2010, 212-216.
- [25] Elliott C, Francis SJ, Arnold DL, et al. Bayesian classification of multiple sclerosis lesions in longitudinal MRI using subtraction images[J]. *Medical Image Computing and Computer-Assisted Intervention*, 2010, 13(2):290-297.

- [26] Sicotte NL. Magnetic resonance imaging in multiple sclerosis: the role of conventional imaging[J]. *Neurology clinics*, 2011, 29(2):343-356.
- [27] Carrasco JL, Jover L, King TS, et al. Comparison of concordance correlation coefficient estimating approaches with skewed data[J]. *Journal of Biopharmaceutical Statistics*, 2007, 17(4):673-684.
- [28] Song T, Jamshidi M, Lee R, et al. A Modified Probabilistic Neural Network for Partial Volume Segmentation in Brain MR Image[J]. *IEEE Neural Networks*, 2007, 18(5):1424-1432.
- [29] Liao W, Chen H, Yang Q, et al. Analysis of fMRI data using improved self-organizing mapping and spatio-temporal metric hierarchical clustering[J]. *IEEE transactions on medical imaging*, 2008, 27(10):1472-1483.
- [30] Fredric M. Ham, Ivica Kostanic, *Principles of Neurocomputing for Science and Engineering*[M], McGraw-Hill, 2003, 18-19.
- [31] Sikka K, Sinha N, Singh PK, et al. A fully automated algorithm under modified FCM framework for improved brain MR image segmentation[J], *Magnetic Resonance Imaging*, 2009, 27(7):994-1004.
- [32] Lin M, Chan S, Chen JH, et al. A new bias field correction method combining N3 and FCM for improved segmentation of breast density on MRI[J]. *Medical Physics*, 2011, 38(1):5-14.
- [33] Wang J, Kong J, Lu Y, et al. A modified FCM algorithm for MRI brain image segmentation using both local and non-local spatial constraints[J], *Computerized Medical Imaging and Graphics*, 2008, 32(8):685-698.
- [34] Folkesson J, Carballido-Gamio J, Eckstein F, et al. Local bone enhancement fuzzy clustering for segmentation of MR trabecular bone images[J]. *Medical Physics*, 2010, 37(1):295-302.
- [35] Dao-Qiang Zhang, Song-Can Chen. A novel kernelized fuzzy C-means algorithm with application in medical image segmentation[J]. *Artificial Intelligence in Medicine*, 2004, 32: 37-50.
- [36] Li Yang, Yu Fusheng. A New Validity Function for Fuzzy Clustering[J]. *IEEE CINC*, 2009, 1:462-465.
- [37] Donahue MJ, Blakeley JO, Zhou J, et al. Evaluation of Human Brain Tumor Heterogeneity

using Multiple T1-based MRI Signal Weighting Approaches[J], *Magnetic Resonance in Medicine*, 2008, 59(2):336-344.

- [38] Klauschen F, Goldman A, Barra V, et al. Evaluation of Automated Brain MR Image Segmentation and Volumetry Methods[J], *Human Brain Mapping*, 2009, 30(4): 1310-1327.

## 脑磁共振图像分割方法及应用

**摘要：**磁共振成像具有软组织成像清晰、无创性和多参数成像的特点，在脑功能的研究方面显示出独特的魅力。随之而来，脑磁共振图像的三维重建、定量分析和图像可视化的需求越来越多，而这些都需要更加精确的分割结果。然而，脑组织之间互相混迭在一起，没有清晰的边界，不同个体之间的差异性较大，再加上在成像过程中磁场的非均匀性、部分容积效应以及噪声的影响，都会造成磁共振图像内在的不确定性。因此，脑磁共振图像分割成为当前医学图像研究领域的一个热点。本文从单参数和多参数图像两个方面对医学应用领域中一些有代表性的图像分割方法做了一个概括性的综述，重点分析了多参数图像分割中的人工神经网络和聚类算法，阐述了各类方法的特点和局限性以及目前在脑磁共振图像分割中的应用。

**关键词：**磁共振成像，图像分割，多参数成像，聚类算法，人工神经网络

### 一、 引言

磁共振成像 (Magnetic Resonance Imaging, MRI) 技术，是根据核磁共振原理，利用射频脉冲激发感兴趣区域中的质子，质子吸收了射频场能量之后，通过弛豫将所吸收的能量释放出来，产生磁共振信号，计算机利用这些信号重建图像的过程。MRI 与其它形式的医学成像技术相比具有无损伤、无痛苦、多参数、高分辨率和适合软组织诊断等特点，在医学诊断中发挥着越来越大的作用。同时，MRI 技术的发展产生了大量具有更多细节的图像，这就需要将图像中感兴趣的区域提取出来，并使它尽可能的接近解剖结果，为临床诊疗和病理学研究提供可靠的依据。所以，图像分割是提取医学图像中特殊组织定量信息的不可缺少的手段，同时也是成功进行医学图像分析、理解与描述的关键技术，因为图像分割结果的质量直接影响以后进行的分析、识别和解释的质量<sup>[1]</sup>。但是，完全依赖有经验的医生进行手动分割是一项非常耗时和枯燥的工作，其结果也不具备精确性和可重复性。因此，近年来人们致力于研究交互式或自动式的分割方法，用以产生快速

且准确的分割结果。

## 二、 图像分割定义

所谓图像分割是指将图像中具有特殊涵义的不同区域区分开来，这些区域是互不交叉的，每一个区域都满足特定区域的一致性。从处理对象角度来讲分割是在图像矩阵中确定所关心的目标的定位。图像分割可用的特征包括图像灰度、颜色、纹理、局部统计特征或频谱特征等，利用这些特征的差别可以区分图像中不同目标物体。借助集合概念对图像分割可给出如下比较正式的定义。

定义：令集合  $R$  代表整个待分割的图像区域，对  $R$  的分割可以看作是将  $R$  分成  $N$  个满足以下五个条件的非空子集（子区域）， $R_1, R_2, \dots, R_N$ ：

$$(1) \bigcup_{i=1}^n R_i = R;$$

$$(2) \text{对所有的 } i \text{ 和 } j, \text{ 如果 } i \neq j \text{ 时, } R_i \cap R_j = \emptyset;$$

$$(3) \text{对所有 } i=1,2,\dots,n, \text{ 有 } P(R_i)=TRUE;$$

$$(4) \text{对所有的 } i \neq j, \text{ 有 } P(R_i \cup R_j)=FALSE;$$

$$(5) \text{对所有 } i=1,2,\dots,n, R_i \text{ 是连通区域。}$$

其中  $P$  是给定均匀测度度量，它是一个二值逻辑函数，如果某个区域满足某种均匀性，则它的值为  $TRUE$ ，否则为  $FALSE$ ； $\emptyset$  代表空集<sup>[2]</sup>。

条件(1)指出在对一幅图像的分割结果中全部子区域的总和(并集)应能包括图像中所有像素(即原图像)。

条件(2)指出在分割结果中各个子区域是互不重叠的，或者说在分割结果中一个像素不能同时属于两个区域。

条件(3)指出在分割结果中每个子区域都有独特的特性。

条件(4)指出在分割结果中，不同的子区域具有不同的特性，没有公共元素，或者说属于不同区域的像素应该具有一些不同的特性。

条件(5)要求分割结果中同一个子区域内的像素应当是连通的，即同一个子区域内的任意两个像素在该子区域内互相连通。

医学图像分割的一般过程如图 2.1 所示：

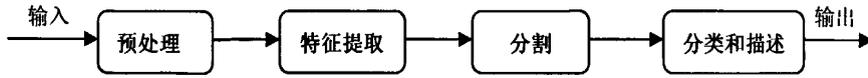


图 2.1, 医学图像分割过程

其中，预处理可减少图像中的伪影，用以增强图像质量；特征提取和选择为图像分割提供必要的度量向量；分割则是将像素分成不同的区域，并以此定义不同组织的边界；伴随着分割进行的是分类和组织类型的标记。

### 三、 脑 MRI 图像分割方法

医学图像分割是医学影像处理中的经典难题，其中很多关键问题还没有得到圆满解决，如何提高图像分割的精度和速度是目前公认的瓶颈，所以大部分图像分割方法的研究也都集中在提高算法的精度和运算速度上。目前针对脑 MRI 图像分割的方法层出不穷，分类标准也多种多样。在没有权威分类标准的情况下，本文考虑到 MRI 多参数，多特征的成像特点，将脑 MRI 图像分割方法分为单参数图像分割方法和多参数图像分割方法两大类<sup>[3]</sup>，并对每种方法进行简要的介绍。

#### (一) 单参数图像分割方法

磁共振图像与其它形式的医学图像相比具有成像方式多参数、多样性的特点。为了得到人体不同部位、不同组织的高清晰度 MR 图像，在利用磁共振进行临床检查时，需要使用不同频率的射频脉冲和梯度磁场，这就要求计算机组织各种脉冲程序工作。通过选择不同的重复脉冲时间(Time to Repeat, TR)和回波延迟时间(Time to Echo, TE)，就可以获取不同的  $T_1$ 、 $T_2$  及 Pd(proton density)的加权图像<sup>[4]</sup>。由某一层面得到的三幅图像  $T_1$  像、 $T_2$  像和 Pd 像构成了多参数 MRI 图像，如果只对得到的某一层面的一幅图像(如  $T_1$ 、 $T_2$  或 Pd)进行图像分割，则称其为单参数图像分割。单参数图像分割方法大体上可分为基于区域的分割方法和基于边界的分割方法。

##### 1. 基于区域的分割方法

在数字图像中，属于一个物体的区域通常拥有相似的特性，也就是说，它们在亮度或者纹理方面是相似的。基于区域的医学图像分割方法试图通过识别图像

中不同物体的不同均匀区域对图像进行分割。常见的基于区域的分割方法有阈值法和区域生长法等。

## 2. 阈值法

阈值分割技术是一种并行分割方法，是最简单且常用分割技术<sup>[5]</sup>。它是通过阈值化操作直接把图像分割成不同的区域，常用于分割对象区域与周围对象或背景区域具有显著不同灰度级的图像。阈值分割技术的关键在于阈值的选择，不同的阈值可能会引起完全不同的分割结果。阈值化方法可以分为单阈值方法和多阈值方法，单阈值方法通过单一阈值将图像分割为目标和背景两个区域；多阈值方法需要选取多个阈值，通过多个阈值将图像分割为多个目标区域和背景。阈值的个数和取值往往要根据实际的要求，由一些先验知识和实验统计数据来确定<sup>[6]</sup>。

阈值化分割方法的优点是实现简单，对于目标灰度值相差很大的图像很有效，但对于目标与背景或目标之间灰度差异不明显的情况，或者目标与背景的灰度值范围有较大重叠的图像，阈值分割则难以得到准确的结果。另外由于阈值方法孤立地考虑每个像素，没有考虑像素之间的空间关系，所以对噪声非常敏感。因此不适合单独应用于脑 MRI 图像分割。

## 3. 区域生长法

区域生长法是一种提取通过预先定义的规则连接起来的图像区域的技术，这里的规则可以是基于灰度信息也可以是图像的边缘<sup>[7]</sup>。这种技术的基本思想是在各个区域里寻找一些种子点，通过预先定义的规则将其周围邻近的像素点归并进来以使得区域逐渐生长扩大。在区域生长的过程中可根据有关区域的先验知识例如区域的灰度均匀性要求、纹理或形状等要求来调整归并准则以期获得较好的区域生长和区域分割结果。文献中很少见到利用区域生长法分割 MR 图像。在 MR 图像的分割中，一般是利用区域生长法获取大脑的边界。区域生长法具有明显的缺点，图像分割前需要由操作者选择区域生长的种子点和阈值。图像分割的结果极大地依赖于种子点和阈值的选择，而操作者的解剖学知识和经验是选择“好”的种子点和阈值的基础。区域生长技术对分割如脑实质这样区域连续的、简单较大的结构效果比较理想，但对于脑白质、脑灰质或脑肿瘤这样复杂的区域不连续结构，区域生长技术往往难以得到理想的结果。

#### 4. 基于边界的分割方法

与基于区域的分割方法不同的是，基于边界的分割方法关注图像区域之间的不一致性和不均匀性，常用的基于边界的分割方法有边缘检测和边缘连接等。

#### 5. 边缘检测

边缘检测方法可以说是人们研究得最多的方法之一，它认为边界点是图像一阶导数的极大值点或二阶导数过零点，边缘检测算子可以检测出这些边界点<sup>[8]</sup>。其具体操作是通过图像滤波来完成的。而图像滤波的方法则基于卷积运算的如下性质：

$$\frac{d}{dx}(f(x)*g(x)) = \frac{d}{dx}f(x)*g(x) = f(x)*\frac{d}{dx}g(x)$$

对图像进行滤波就是用某个滤波算子与图像作卷积运算。根据上式，对滤波算子与图像卷积的结果求一阶导数，相当于用算子的一阶导数与图像做卷积。高阶导数有同样结果。这样，只要事先给出算子的一阶或二阶导数，就可以把对图像进行平滑滤波和对平滑后的图像求一阶或二阶导数组合在一步完成。

从上面的分析我们可以看出，边缘检测方法的核心问题是滤波器，也就是边缘检测算子的设计问题。常用的边缘检测算子有 Robert 算子、Sobel 算子、Prewitt 算子、Kirsh 算子、LOG(Laplacian of Gaussian)算子、Canny 算子等。但是由于受到噪声的影响，边缘检测技术通常不能得到正确的边界。对脑部 MR 图像这样复杂的医学图像，单纯利用边缘检测技术，不可能得到脑组织的正确边界。实际应用中，一般是与其它技术如数学形态滤波技术结合在一起，完成边缘检测。

#### 6. 边缘连接

边缘连接是一个将检测出的边缘点连接起来从而产生一条闭合的连通边界的过程，这个过程填补了因为噪声和阴影的影响所产生的间隙。启发式搜索、曲线拟合和 Hough 变换是常用的边缘连接方法<sup>[9]</sup>。经过边缘连接的处理以后，我们检测出的边缘不再是离散的、不相关的点，而是有着紧凑数学表达形式的曲线或曲面，这对诸如物体识别等后续处理有很大的帮助。

##### (二) 多参数图像分割方法

以上讨论了基于区域的分割方法和基于边界的分割方法。文献<sup>[2]</sup>把这些方法

称为灰度级单参数图像分割方法，因为利用这些方法分割 MR 图像时，算法中用到的图像数据一般是单幅图像的灰度值。这些方法只能用于分割图像中的一些相对简单的结构，而对于一些相对复杂的结构如脑白质、脑灰质或脑肿瘤，它们却显得无能为力。多参数图像由于综合了多幅单参数图像的信息，所以能提供更多的组织解剖结构信息，利用多参数图像分割得到的组织结构比较接近于临床解剖结果<sup>[10]</sup>。

## 1. 图像融合

实现多参数图像分割的有效方法之一就是进行图像融合。MRI 所独有的特性是其可以获得不同组织对比度的图像，即多参数成像，如  $T_1$  加权像， $T_2$  加权像，质子密度加权像等<sup>[11]</sup>。 $T_1$  加权像可清楚分辨表皮与颅骨，脑灰、白质与脑脊液，以及脑损伤的边界，但是损伤内部的灰度特征与周围组织无本质区别。 $T_2$  加权像显示颅骨和损伤边缘清晰，易于提取，损伤周围水肿区较亮，算上图像灰度有层次性变化，脑灰白质和脑脊液之间的灰度差别比  $T_1$  加权像更明显，将多参数的图像信息结合起来可能会使分割质量得到改进<sup>[12]</sup>。

目前常用的图像融合方法可分为简单方法、塔式分解、小波方法等<sup>[13]</sup>。简单方法包括最大选择、最小选择、平均选择、熵选择等方法，基于简单选择的方法具有较低的算法复杂度，缺点是减少了图像熵值和降低了图像的对比度。塔式分解与重构方法在图像融合中具有简单、包含更多信息的优点，塔式分解图像融合方法是多尺度、多分辨率的方法，其融合过程是在图像的各个分解层上分别进行的，并在多尺度、多分辨率上突出图像的重要特征和细节信息，因而有更好的融合效果。融合后的图像也有利于做进一步的分析、理解和识别。小波变换方法也是多尺度、多分辨率的分解重构方法，其处理过程是在各个分解层上分别进行，分解时非冗余、有方向性的，且具有良好的时域和频域局部化分布特性。由于其对图像高频部分采取逐级精细的时域或频域步长，从而可聚焦到分析对象的任意细节，保留更多的图像高频信息，从而可获得更好的融合效果。

## 2. 基于人工神经网络的分割方法

人工神经网络 (Artificial Neural Networks, ANN) 是一种由许多处理单元 (节点) 组成的、能够模拟生物，尤其是人脑的学习过程的大规模并行网络。它的每

个节点都能执行基本的运算，通过调整节点之间的连接关系和权值达到学习的目的。ANN 按连通性可分为前馈网络和递归网络两类；按训练样本是否被作标记可分为有监督学习和无监督学习两类<sup>[14]</sup>。由于具有如下的一些优点：能够学习例子与归纳知识、能抑制噪声、具有容错能力和最优搜索能力，ANN 方法被广泛的用于医学图像分割。

ANN 方法经过训练后能既可直接基于像素（体素）(Pixel-based/ Voxel-based) 分割医学图像，也可以基于图像特征进行分割。具体算法如前馈网络、Hopfield 网络、自组织映射（SOMs）、概率神经网络（PNNs）、脉冲耦合神经网络等。

在脑部的磁共振图像分割问题中，多层前向神经网络方法对训练集的选取比较敏感，选取的训练集越好，图像分割的结果越准确<sup>[15]</sup>。Akmal Younis 等人<sup>[16]</sup> 试图寻找适用于不同磁共振图像的通用训练集，但是由于不同组织的磁共振图像表现不稳定，某部位标记的训练集训练的神经网络，用于其他部位的分割，分割效果并不好。现阶段，还需要人工参与训练集的标记。

Hopfield 网络是一种无监督分割方法，训练时可以减少的人工参与。但是，Hopfield 分割方法对初始值的选择十分敏感，对受到容积效应污染的磁共振图像的分割效果较差。实践中，可以通过预处理降低图像容积效应的影响。另外尝试不同的初始解，有助于找到 Hopfield 网络的全局最优解，设计适用于磁共振图像分割的能量函数，这样，Hopfield 网络在磁共振图像分割中的应用可以得到进一步推广<sup>[17]</sup>。

概率神经网络(PNN)实际上是一种数学插值手段，它的实现引用了神经网络的结构。但它通过研究数学规则，可以比多层前馈神经网络更好地实现插值功能，因而具有潜在的优势。Tao Song, Mo M. Jamshid 等人<sup>[18]</sup>提出了一种改进的 PNN 用于 MRI 图像的分割。在此方法中，用协方差矩阵代替概率神经网络核心函数中的简单平滑因子，并且在概括层模式中增加了权重因子。这种加权概率神经网络分类方法可以解决不仅在最后结果阶段而且在建模过程中普遍存在于 MRI 中的局部容积效应。它采用自组织映射(SOM)神经网络过分割输入的 MR 图像，并且产生概率密度函数估计所必要的参考向量。开发了一种基于贝叶斯定理的监督式“软”标记机制，使得权重因子可以与相应 SOM 参考向量一起产生。Tao Song

等人还比较了不同算法对组织分类的结果，并且证明了其所提出方法的有效性和鲁棒性。

脉冲耦合神经网络是一种不同于传统人工神经网络的新型的网络,图像中的像素点对应的神经元的输入不仅与其本身的亮度信息有关,还与其周围像素点对应的神经元的输出有关。在脉冲耦合神经网络中,具有相似输入的神经元同时发生脉冲,能够弥补输入数据的空间不连贯和幅度上的微小变化,从而较完整地保留图像的区域信息。由于图像内容、性质以及外部环境等因素影响的多样性,图像可能具有各种各样的属性。与图像的多样性相对应,脉冲耦合神经网络模型中所涉及的参数对于分割结果会产生非常重要的影响。Henrik Berg 等人<sup>[19]</sup>采用两种进化算法优化模型中的参数,根据直方图形状、聚类和信息融合,设计一种目标函数,选择最适合的一组参数与每一幅图像对应,以实现最优的分割效果。

采用 ANN 分割需要面临三个主要问题:如何合并上下文信息,如何包含(全局的)先验知识及分割方法的评价。上下文信息可以通过在 ANN 中引入空间相干性或从多尺度小波变换及线性尺度空间获得<sup>[20]</sup>。先验知识可以是所感兴趣物体的形状、空间组织或对最优化问题的好的近似解,如模糊神经网络(fuzzy ANNs)<sup>[21][22]</sup>就可以用专家提出的准则来初始化,这样即可引入先验知识。

### 3. 基于聚类的分割方法

聚类分割方法是一种非监督(unsupervised)分割技术,它能自动地找出数据中的结构。因为没有训练样本集,聚类算法迭代的执行对图像分类和提取各类的特征值。从某种意义上说,聚类是一种自我训练的分类。其中,K 均值、模糊 C 均值(Fuzzy C-Means)、EM(Expectation-Maximization)算法是常用的聚类算法。

K 均值算法先对当前的每一类求均值,然后按新生成的均值对像素进行重新分类(将像素归入均值最近的类),对新生成的类再迭代执行前面的步骤。

模糊 C 均值算法(FCM)从模糊集合理论的角度对 K 均值进行了推广<sup>[23]</sup>。FCM 用于图像分割时是一种非监督模糊聚类后的标定过程,非常适合于 MR 图像中存在不确定性和模糊性的特点<sup>[24]</sup>。

Renjie He 等人<sup>[25]</sup>在众多的分割技术中选择 FCM 作为分割 MR 脑图像的工具,主要原因在于:(1) FCM 是一种非监督的分割方法,它无需人的干预,分割过程

是以完全自动的方式进行；（2）FCM 能很好地处理由噪声、部分容积效应以及 MR 松弛时间的内在易变性等造成的图像模糊；（3）FCM 已经在许多领域得到成功应用；（4）FCM 在 MR 图像分割中的应用已显示出令人鼓舞的结果。然而，FCM 算法本质上是一种局部搜索寻优技术，它的迭代过程采用了一种所谓的爬山 (Hill-Climbing) 技术来寻找最优解。因此该算法对初始化极为敏感，容易陷入局部极小值，而得不到全局最优解<sup>[26]</sup>。

为了解决 FCM 算法对初始值敏感的问题，通常将其与神经网络算法或遗传算法相结合使用，Lia Morra 等人<sup>[27]</sup>提出了一种新的针对多参数脑 MI 图像分割的模糊神经聚类方法，使用 Kohonen 自组织映射对输入空间进行线性变换从而增强聚类功能，此方法是完全无监督的，其结果完全独立于初始网络状况，在模拟和真实脑 MR 图像上都有很好的稳定性。曾翎等人<sup>[28]</sup>通过分析经典模糊 C-均值聚类算法(FCMA)发现其依赖于初始聚类中心的选择，通常得到的是局部最优解而非全局最优解，而遗传算法能搜索到全局最优解，因此将遗传算法(GA)与 FCMA 相结合，对 MRI 直接进行聚类，利用遗传算法搜索全局最优解，从而有效地避免了模糊 C-均值聚类算法收敛到局部最优的问题，并在此基础上实现了对 MRI 的分割，得到了比较满意的效果。金慧珍等人<sup>[29]</sup>针对传统模糊核聚类算法当数据类差别很大时，小数据类被误分或被大数据类吞并的缺陷，提出了一种新的加权模糊核 C 均值聚类算法(Weighted Fuzzy Kernel C-Means)，为每一个类分配了一个动态权值；同时将该算法引入到多参数聚类中，设计了一个以图像灰度特征作为分类样本的改进的多参数聚类算法，解决了多参数聚类应用于图像分割时权矩阵的参数难以计算的实际问题。实验结果表该算法具有较好的分割效果。Shan Shen, William Sandham 等人<sup>[22]</sup>在扩展传统的模糊聚类方法的基础上提出了一种鲁棒的图像分割方法，引进了依赖于邻近像素相关区域和特征的近邻吸引法，并且由神经网络算法产生最佳的吸引度，使得图像分割得到令人满意的效果。

EM 算法把图像中每一个像素的灰度值看作是几个概率分布（一般用高斯分布）按一定比例的混合，通过优化基于最大后验概率的目标函数来估计这几个概率分布的参数和它们之间的混合比例。分层聚类方法通过一系列类别的连续合并和分裂完成，聚类过程可以用一个类似树的结构来表示<sup>[30]</sup>。聚类分析不需要训练

集,但是需要有一个初始分割提供初始参数,初始参数对最终分类结果影响较大。另一方面,聚类也没有考虑空间关联信息,因此也对噪声和灰度不均匀敏感<sup>[31]</sup>。

#### 四、 分割评估

为了掌握某种分割方法在不同情况下的表现,以寻找合适的参数来适应不同的图像;或者比较多个算法对给定图像的分割效果,都需要对图象分割算法进行评价,从而达到优化分割的目的。

为此,评价方法应满足以下几点基本要求<sup>[32]</sup>:

(1)应具有通用性,即它要适于评价不同类型的分割算法并适合各种应用领域情况。

(2)应采用定量的和客观的性能评价准则,这里定量是指可以精确的描述算法的性能,客观是指评判摆脱了人为的因素。

(3)应选取通用的图像进行测试以使评价结果具有可比性,同时这些图像应尽可能反映客观世界的真实情况和实际应用共同特点。

现有的评价方法一般分为两类:第一类是直接研究分割算法本身的原理、条件、复杂性等,通过分析推理得到算法性能的分析法(analytical method);第二类是根据待评价算法所分割出来的图象质量来间接评判的实验法(empirical method)。其中实验法又可分为优度实验法(EGM)和差异实验法(EDM);EGM通过测量某种优度来评定已分割图像的质量(通常根据人的直觉);EDM通过已分割图像与参考图像之间的对比来评价算法。

分析法只考察算法本身,不涉及分割流程,因此实验法通常比分析法更有效。不过每种方法都有特定的用途和局限性。Frederick Klaushen 等人<sup>[33]</sup>将 EDM 用于 MR 图像的分割评价,首先他们定义一个决定不同分割之间距离的度量空间,然后考察两个衡量标准,一是误分割体素的百分比,另一个是定义在该度量空间上的马氏距离。

实验法的参考图像主要分为模拟图像和真实图像<sup>[34]</sup>。模拟图像一般提供分割的正确结果(Ground Truth)用于对所用算法分割结果的评估,真实图像则由多个有经验的神经外科医生对真实图像进行分割,其结果用于分割结果的评估。

#### 五、 总结

本文从单参数和多参数图像两个方面对医学应用领域中一些有代表性的图像分割方法做了一个概括性的综述，并分析了几类方法的特点和局限性。近几年来虽然仍然有很多研究人员致力于医学图像分割的研究，发表了很多的研究成果，但由于问题本身的困难性，目前的方法多是针对某个具体任务而言的，还没有一个通用的解决办法。

本文通过对部分医学图像分割研究文献的整理，得出以下结论：

(1) 脑 MR 图像结构复杂，各组织之间无明显边界，加之场偏移、部分容积效应和噪声的影响，使得仅用单参数图像分割方法很难得到准确的分割结果，适合使用比较复杂的多参数图像分割方法来提高分割结果的准确性；

(2) 人们逐渐认识到现有的任何一种单独的图像分割算法都难以对一般图像取得令人满意的分割结果，因而人们在继续致力于将新的概念，新的方法引入图像分割领域的同时，更加重视多种分割算法的有效结合。

(3) 在多参数图像分割方法中聚类方法可以对图像进行自动分割，而人工神经网络方法具有很强的鲁棒性，因此，将两类方法相结合用于脑 MR 图像分割，是目前医学图像处理研究的一个重要方向。

## 参考文献

- [1] Zhen Ma, João Manuel R. S. Tavares, R. M. Natal Jorge, A Review of Algorithms for Medical Image Segmentation and Their Applications to the Female Pelvic Cavity[J], Computer Methods in Biomechanics and Biomedical Engineering, 2009, 11(5).
- [2] Rafael C. Gonzalez, Richard E. Woods, Digital Image Processing[M], Prentice Hall, 2002, 567-568.
- [3] Clarke LP, Velthuisen RP, Camacho MA, Heine JJ, Vaidyanathan M, Hall LO, Thatcher RW, Silbiger ML, MRI Segmentation: Methods and Applications[J], Magnetic Resonance Imaging, 1995, 13(3): 343-368.
- [4] John Wiley, Current Awareness in NMR in Biomedicine[J], NMR IN BIOMEDICINE, 2005, 18(1):56-63.
- [5] P.K.Sahoo, S.Soltani, A.K.C.Wang, and Y.C.Chen, A Survey of Thresholding Techniques, Computer Vision[J], Graphics and Image Processing, 1988, 41:233-260.

- [6] Mehmet Sezgin, Survey over Image Thresholding Techniques and Quantitative Performance Evaluation[J], *Journal of Electronic Imaging*, 2004, 13(1): 146-165.
- [7] Dzung L. Pham, Chenyang Xu, and Jerry L. Prince, Current Methods in Image Segmentation[J], *Annual Review of Biomedical Engineering*, 2000, 02: 315-337.
- [8] N.Senthilkumaran and R.Rajesh, Edge Detection Techniques for Image Segmentation-A Survey of Soft Computing Approaches[J], *International Journal of Recent Trends in Engineering*, 2009, 1(2): 250-254.
- [9] K.R.Castleman, *Digital Image Processing*[M], Prentice Hall, 2002, 402-406.
- [10] Zhou Xiaodong, Bao Shanglian, Li Dejun, The Research on Tissue Segmentation for Brain Multi-spectral MR Image[J], *Chinese Journal of Medical Physics*, 2003, 20(2): 89-91.
- [11] Armen R Kherlopian, Ting Song, Qi Duan, Mathew A Neimark, Ming J Po, John K Gohagan, Andrew F Laine, A review of imaging techniques for systems biology[J], *BMC Systems Biology*, 2008, 74(2):1-18.
- [12] Rajeev Ratan, Sanjay Sharma, S. K. Sharma, Multiparameter segmentation and quantization of brain tumor from MRI images[J], *Indian Journal of Science and Technology*, 2009, 2(2):11-15.
- [13] 康晓东 等, *医学影像图像处理*[M], 人民卫生出版社, 2009, 187-198.
- [14] Fredric M.Ham, Ivica Kostanic, *Principles of Neurocomputing for Science and Engineering*[M], McGraw-Hill, 2003, 18-19.
- [15] S.D.Olabarriaga, A.W.M.Smeulders, Interaction in the segmentation of medical images: A survey[J], *Medical Image Analysis*, 2001, 5: 127-142.
- [16] Akmal Younis, Mohamed Ibrahim, Mansur Kabuka, and Nigel John, An Artificial Immune-Activated Neural Network Applied to Brain 3D MRI Segmentation[J], *Journal of Digital Imaging*, 2008, 21(1):69-88.
- [17] Zhang Hongmei, Yuan Zejian, Cai Zhongmin, et al, Segmentation of MRI Using Hierarchical Markov Random Field[J], *Journal of Software*, 2002, 13(9):1779-1808.
- [18] Tao Song, Mo M. Jamshidi, Roland R. Lee, and Mingxiong Huang, A Modified Probabilistic Neural Network for Partial Volume Segmentation in Brain MR Image[J], *IEEE Transactions on Neural Networks*, 2007, 18(5): 1424-1432.

- [19] Henrik Berg, Roland Olsson, Thomas Lindblad, Jose Chilo, Automatic design of pulse coupled neurons for image segmentation[J], *Neurocomputing*, 2008, 71: 1980-1993.
- [20] 孙炜, 王耀南, 徐航, 基于自组织小波神经网络的磁共振图像分割方法[J], *电子测量与仪器学报*, 2008, 22(4): 26-29.
- [21] 孙炜, 王耀南, 基于模糊小波神经网络的磁共振图像分割方法[J], *中国生物医学工程学报*, 2006, 25(3): 267-270.
- [22] Shan Shen, William Sandham, Malcolm Granat, Annette Sterr, MRI Fuzzy Segmentation of Brain Tissue Using Neighborhood Attraction With Neural-Network Optimization[J], *IEEE Transactions on Information Technology in Biomedicine*, 2005, 9(3): 459-467.
- [23] Dao-Qiang Zhang, Song-Can Chen, A novel kernelized fuzzy C-means algorithm with application in medical image segmentation[J], *Artificial Intelligence in Medicine*, 2004, 32: 37-50.
- [24] Renske de Boer, Henri A.Vrooman, Fedde van der Lijn, Meike W. Vernooij, M. Arfan Ikram, Aad van der Lugt, Monique M.B.Breteler, Wiro J. Niessen, White matter lesion extension to automatic brain tissue segmentation on MRI[J], *NeuroImage*, 2009, 45:1151-1161.
- [25] Renjie He, Sushmita Datta, Balasrinivasa Rao Sajja, Ponnada A. Narayana, Generalized fuzzy clustering for segmentation of multi-spectral magnetic resonance images, *Computerized Medical Imaging and Graphics*[J], 2008, 32:353-366.
- [26] Manish Kakara, Dag Rune Olsen, Automatic segmentation and recognition of lungs and lesion from CT scans of thorax[J], *Computerized Medical Imaging and Graphics*, 2009,33: 72-82.
- [27] Lia Morra, Silvia Delsanto, Leonardo Reyneri, Enhanced unsupervised segmentation of multispectral Magnetic Resonance images[J], *European Symposium on Artificial Neural Networks Bruges*, 2004, 8:257-262.
- [28] 曾翎, 王美玲, 陈华富, 遗传模糊 C-均值聚类算法应用于 MRI 分割[J], *电子科技大学学报*, 2008, 37(4):627-629.
- [29] 金慧珍, 赵辽英, 刘 博, 一种基于谱聚类的灰度图像分割法[J], *计算机系统应用*, 2009, 4:74-77.
- [30] 武杰, 聂生东, 汪红志, 张学龙, 周滢, 许建荣, 基于期望值最大化方法的磁共振图像人

- 脑组织分割[J], 中国医学影像技术, 2007, 23(10):1558-1561.
- [31] 林瑶, 田捷, 医学图像分割方法综述[J], 模式识别与人工智能, 2002, 15(2): 192-204.
- [32] Manus J.Donahue, Jaishri O.Blakeley, Jinyuan Zhou, Martin G. Pomper, John Laterra, and Peter C.M. van Zijl, Evaluation of Human Brain Tumor Heterogeneity using Multiple T1-based MRI Signal Weighting Approaches[J], Magnetic Resonance in Medicine,2008, 59:336-344.
- [33] Frederick Klauschen, Aaron Goldman, Vincent Barra, Andreas Meyer-Lindenberg, Arvid Lundervold, Evaluation of Automated Brain MR Image Segmentation and Volumetry Methods[J], Human Brain Mapping, 2009, 30: 1310-1327.
- [34] David W.Shattuck, Gautam Prasad, Mubeena Mirza, Katherine L.Narr, Arthur W.Toga, Online Resource for Validation of Brain Segmentation Methods[J], NeuroImage, 2009, 45:431-439.

·在学期间科研成果·

发表第一作者期刊论文：李杨，洪洋. 基于 SOM-FCM 算法的脑 MR 多参数图像分割. 中国医学物理学杂志. 已录用

## ·致谢·

三年的硕士研究生学习生活即将结束,在此向曾经给予我关怀和帮助的老师、同学们表示深深的感谢。

首先,感谢我的导师洪洋教授,是她搭建了我从计算机科学跨越到生命科学的桥梁,完善了的知识体系,使我的人生规划更加丰富多彩。洪老师对学科发展的远见卓识和独特的个人魅力无时无刻不在感染我的心灵,影响我的言行。在医大学习期间,洪老师为我提供了良好的学习、交流和实验环境,最大力度的保障我的求学质量。在日常生活中,洪老师在繁忙的工作之余经常给予我支持和鼓励,她对人生观的独到见解使我受益终生,在此向洪老师表示由衷的敬意和衷心的感谢

其次,感谢俞航老师、李莉老师、张福利老师、温良老师和张勇德老师在课题研究过程中提供的帮助和建议,老师们渊博的理论知识、活跃的科学思维、严谨的治学态度和深邃的见解都使我受益匪浅。感谢何叶松老师在论文发表过程中给予我的无私帮助,感谢何宁老师用他幽默风趣的处世哲学教导我做人为学的道理。感谢中国医科大学生物物理教研室的全体老师,您们善良、豁达的心胸和真挚、友爱的笑容将使我终生难忘。

此外,感谢我的研究生同学们,是你们一直陪伴着我的成长,与你们的交流与相处是我求学生涯中一笔珍贵的财富。

最后,我要感谢我的父母,20年的求学生涯中,每一点进步与提升都有你们的默默支持、关心和理解的身影,你们的关爱成为我迎接挑战的勇气和源源不断的动力。

祝愿所有在我求学生涯中留下身影的老师、同学和家人们幸福安康!

## ·作者简介·

李杨，男，汉族，1986年5月22日出生，辽宁抚顺人。2008年毕业于东北大学软件工程专业，获工学学士学位，2011年毕业于中国医科大学生物医学工程专业，获工学硕士学位，研究方向为医学图像处理。