



Université de REIMS CHAMPAGNE-ARDENNE

UFR Sciences Exactes et Naturelles

Ecole Doctorale Sciences Technologie Santé

THÈSE

Pour obtenir le grade de

Docteur de l'Université de Reims Champagne-Ardenne

Discipline : Traitement d'images

par

Zhibin CHEN

le 21/12/2009

## Segmentation of MRI Images using Non Parametric Deformable Models Integrating Fuzzy Technique

Directeurs de thèse

Su RUAN Professeur; Tianshuang QIU Professeur

### Jury

M. Baisuo WANG	Rapporteur	Dalian Maritime Univ.
M. Yvon VOISIN	Rapporteur	Univ. de Bourgogne
Mme. Mireille GARREAU	Examineur	Univ. de Rennes I
M. Hongyu WANG	Examineur	Dalian Univ. of Technology
Mme. Su RUAN	Directrice	Univ. de Reims
M. Tianshuang QIU	Directeur	Dalian Univ. of Technology

N° attribué par la bibliothèque

||R||E||I||



---

## Remerciements

I would like to gratefully acknowledge my supervisor Prof. Su RUAN, for her guidance, encouragement and constant support throughout the course of the research. Prof. RUAN is always willing and eager to talk about the research problems. She always shares his innovative ideas which have enhanced the overall quality of this thesis.

I would like to thank my advisor Prof. QIU Tianshuang, for introducing me to the medical image processing fields. His enthusiastic guidance of my work and carefully read all words of the thesis were truly invaluable.

I would also like to express my thanks to Dr. Frédéric MORAIN-NICOLIER, Dr. Stéphane LEBONVALLET, Dr. Jérôme Landré and Mrs. Guo Yu of the CReSTIC Lab at IUT de Troyes, Université de Reims Champagne Ardenne, for their helps and taking good care of me when I was there at the beginning of 2008.

I am deeply grateful to my classmates of the BME Lab, Dalian University of Technology, Mrs. Lin Xiangbo, Mr. Li Xiaobing, for discussion about the image processing problems. Many thanks as well as to Dr. Tang Hong, Dr. Liu Rong, and Dr. Liu Hui, Mr. Zhu Yong and Mrs. Li Sen, for their helps in life and in studies.

I would like to take this opportunity to thank my parents for their constant support over the years. I am most grateful to my wife and my daughter, for their understanding and encouragement during these years of my studies.

CHEN Zhibin

Dec. 2009





## Contents

Introduction .....	I
Chapter 1 MRI Image Segmentation and Evaluation Criteria: state of the art .....	IV
Chapter 2 Histogram-Analysis based Non-parametric Deformable Models .....	VIII
2.1 Geometric active contour .....	VIII
2.2 Improvement .....	VIII
2.3 Results and validation .....	IX
2.4 Conclusion.....	XIII
Chapter 3 Regional Non-parametric Deformable Models .....	XV
3.1 An improved Region-based Geodesic Active Contour .....	XV
3.2 Adaptive Level Set Algorithm Integrating the Fuzzy Segmentation .....	XXII
3.3 Conclusion.....	XXV
Chapter 4 Multiclass Algorithm for MRI Image Segmentation.....	XXVII
4.1 The proposed multiclass algorithm .....	XXVII
4.2 Experimentations and validation.....	XXVIII
4.3 Conclusion.....	XXXII
Conclusions and Perspectives .....	XXXIV
References .....	XXXVI
Publications .....	XXXVIII

## ABSTRACT

---

***Introduction***

The rapid development of medical imaging technologies brings about a revolution in medicine. Medical imaging allows researchers and physicians to collect potentially life-saving information of human body by non-invasive approaches. The role of medical imaging has expanded beyond the simple visualization and inspection of anatomic structures. It has become a tool for surgical planning and simulation, surgical navigation, radiotherapy planning, and for tracking the progress of diseases. For example, precisely knowing the detailed shapes and organization of anatomic structures enables surgeons to plan an optimal approach to some target structure in advance. In radiotherapy, medical imaging allows the delivery of a dose of radiation to a tumor with minimal collateral damage to healthy tissues.

With medical imaging playing an increasingly prominent role in the diagnosis and treatment of diseases, the medical image analysis society has to face the challenge of extracting clinically useful information about anatomic structures imaged through US, CT, MR, PET, and other modalities. Advanced imaging devices provide exceptional views of internal anatomy, while the computer-aided analyses these embedded structures further provide quantitative information about them. Accurate, repeatable, quantitative data will efficiently support the biomedical investigations and clinical activities from diagnosis, radiotherapy, to surgery.

Magnetic resonance imaging (MRI) is playing more and more important roles in clinical uses due to its high spatial resolution and its good discrimination of soft tissues. Advanced applications that use the morphological contents of MRI frequently require segmentation of the imaged volume into tissue types, i.e., gray matter (GM), white matter (WM), and cerebrospinal fluid (CSF). There are several major reasons for doing MRI brain tissue segmentation: multimodality image correlation, 3D visualization (neurosurgical planning, brain mapping...), volume quantification, and their clinical uses such as tumor and lesion detection. Manual delineation of the three brain tissues (WM, GM, CSF) in MR images by an expert is too time-consuming for studies involving larger datasets. In addition, the lack of clearly defined edges induces large intra- and inter-observer variability, which deteriorates the significance of the analysis of the resulting segmentation, thus calling for automatic segmentation methods. The research goals in this thesis are to develop an automatic segmentation method to:

- (1) extract the brain volume, and
- (2) segment brain tissues into gray matter, white matter, and cerebrospinal fluid.

Brain volume extraction is a difficult problem in cerebral MRI. Automated and reliable tissues segmentation is complicated by the overlap of MR intensities of different tissue classes (partial volume effects) and by the presence of spatially smoothly varying intensity in-homogeneity. Many automated or semi-automated approaches for tissue segmentation in brain images, using T1-weighted

or multispectral MR data have already been proposed. The trend in the literature has been favoring the use of T1-weighted data which is capable of providing higher resolution data without increasing acquisition time and still maintaining good tissue contrast and low noise.

Quantitative brain measurements have contributed to the study of developmental language disorders and autism, Alzheimer's disease, dyslexia, attention deficit hyperactivity disorder, schizophrenia, multiple sclerosis, Huntington's disease, obsessive compulsive disorder. Precise delineation of cortical parcellation units can be used to locate active brain regions in functional neuroimaging studies, and localization of white matter parcellation units is useful for treatment planning for brain damage such as that caused by stroke.

The characteristics of ambiguity, uncertainty, the complexity and variability of the anatomic shapes in MRI images, together with artifacts, spatial aliasing, and noise introduced during the acquired procedure make it hard to accurately segment these cortical brain tissues. Traditional low-level image processing techniques which consider only local information can generate infeasible object boundaries. Deformable models are capable of accommodating the often significant variability of biological structures over time and across different individuals. The deformable models possess of the ability to segment, match, and track images of anatomic structures by considering both the constraints derived from the image data the a priori knowledge about the location, size, and shape of these structures.

In this dissertation, we employ the non-parametric deformable models integrating statistical information or fuzzy information of images to segment the brain matter into different tissue types, from multi modalities of MRI images: T1-weighted, T2-weighted and PD-weighted. According to the topics mentioned above, the research work discussed in this dissertation mainly focuses on:

1. model based on intensity distribution of the MRI images via the mixture Gaussian model (MGM). Estimation of the parameters of MGM is firstly performed by using the Expectation Maximization (EM) algorithm. Then the estimated parameters are used to guide the evolution of the level set curves to achieve the brain tissues segmentation.
2. an improved algorithm to region-based geometric active contour, which solves the underlying stability problem associated with the original algorithm. The algorithm is extended to segment brain tissues into GM, WM and CSF classes from different modalities of MRI images.
3. an adaptive level set algorithm to segment the brain tissues, which integrates the fuzzy information into the framework of the geometric active contour.
4. a multiclass algorithm based on level set algorithm, which reduces the computational complexity compared to the existing multiphase algorithm, so speeding up the convergence rate. The

algorithm uses a set of ordinary differential Equations (ODEs) allowing to provide accuracy segmentation results with good robustness to against noise.

The dissertation is organized around these methods that I developed:

**Chapter 1 -- MRI Image Segmentation and Evaluation Criteria: state of the art**

- Presentation of recent segmentation methods of MRI images existing in the literatures and some usually used evaluation criteria.

**Chapter 2 -- Histogram Analysis based Non-parametric Deformable Model**

- Proposition of a deformable method based on histogram analysis.

**Chapter 3 -- Regional Non-parametric Deformable Model**

- An improvement of a method based on non-parametric deformable model.

**Chapter 4 -- Multiclass Algorithm for MRI Image Segmentation**

- Proposition of a new multiclass segmentation based on deformable models

**Conclusions and Perspectives**

***Chapter 1 MRI Image Segmentation and Evaluation Criteria: state of the art***

At the beginning of this section, we briefly introduce the magnetic resonance imaging and the modalities of MRI images. Magnetic resonance imaging (MRI) is a noninvasive medical imaging technique providing rich information about the human soft tissue anatomy. It has several advantages over other imaging techniques enabling it to provide data with high contrast between soft tissues [1] [2].

In MRI images, the soft-tissue contrast can be widely manipulated. In a typical image acquisition the basic unit of each sequence (i.e. the  $90^\circ$  -  $180^\circ$  -signal detection) is repeated many times. By altering the echo time (TE) or repetition time (TR) the signal contrast can be altered or weighted. Generally, T1-weighting requires short TE and short TR, while T2-weighting requires long TE and long TR, and PD-weighting requires short TE and long TR.

MRI images have a number of features. First, they are statistically simple: MRI images are theoretically piecewise constant with a small number of classes. Second, they can have relatively high contrast between different tissues. Unlike other medical imaging modalities, the contrast in an MRI image depends strongly on the way the image is acquired. By altering radio-frequency and gradient pulses, and by carefully choosing relaxation timings, it is possible to highlight different components in the object being imaged and produce high-contrast images. These two features facilitate segmentation. However, ideal imaging conditions are never realized in practice. The piecewise constant property is degraded considerably due to the electronic noise, intensity inhomogeneities in the RF field and the partial-volume effect. Moreover, MRI images are not always high-contrast. Many T2-W and PD-W images have low contrast between GM and WM. Therefore, it is important to take advantage of useful data while at the same time overcoming these potential difficulties.

Secondly, we review the segmentation techniques of the MRI images. Image segmentation approaches can be classified based on the features and the type of technique used. Features can be pixel intensities, gradient magnitudes, or measures of texture. In this dissertation, we roughly classify the brain segmentation algorithms into one of the groups: edge-based, region-based, clustering-based, level set based and others.

In edge-based segmentation approaches, the resulting segmented image is described in terms of the edges or boundaries between different regions. Edges can be detected with a large number of different edge operators [3]. The most used ones are the LoG (Laplacian-of Gaussian), Sobel, Prewitt, Canny [4], and Roberts. Due to image noise, some smoothing operation is generally required as pre-processing, and the smoothing effect consequently blurs the edge information. However, the computational cost is relatively lower than other segmentation approaches. Another edge detection

technique which has rapidly gained popularity in recent years is referred to as active contours or snakes. Snakes were introduced by Kass, Terzopoulos et al. [5, 6], and further developed by Cohen [7] and Xu et al [8, 9].

Region-based segmentation techniques divided an image into regions, based on some homogeneity properties. Often used region-based techniques are region-growing [10], split-and merge [11], and hierarchical segmentation methods [12]. Region-based approaches are generally less sensitive to noise, and usually produce more reasonable segmentation results as they rely on global properties rather than local properties, but their implementation complexity and computational cost can be quite large.

Cluster analysis is an important technique in the rapidly growing data-analysis field and is being applied in a variety of engineering and scientific disciplines such as biology, psychology, medicine, marketing, computer vision, and remote sensing. Cluster analysis is a tool for exploring the structure of the data that does not require the assumption common to most statistical method. It is called “unsupervised learning” in the literature of pattern recognition and artificial intelligence [13].

Three commonly used clustering algorithms are the K-means algorithm [14], the fuzzy c-means (FCM) algorithm [15, 16], and the expectation-maximization (EM) algorithm [17-21]. The K-means clustering algorithm clusters data by iteratively computing a mean intensity for each class and segmenting the image by classifying each pixel in the class with the closest mean. The FCM algorithm generalizes the K-means algorithm, allowing for soft segmentation based on fuzzy set theory. The EM algorithm applies the same clustering principles with the underlying assumption that the data following a Gaussian mixture model. It iterates between computing the posterior probabilities and computing maximum likelihood estimations of the means, covariances, and mixing coefficients of the mixture model.

The level set method for capturing moving fronts was introduced by Osher and Sethian [22] in 1987. Over the years, the method has proven to be a robust numerical tool in diverse collection problems. Applications range from capturing multiphase fluid dynamical flows, to graphics, to visualization, image processing, epitaxial growth, computer vision and many others [23-26]. It is not hard to seek an application of the level set method for image segmentation, since boundaries and level contours are fundamental objects in image processing science. In recent years, level set based segmentation methods are widely used in brain MR images. The applications include the segmentation of the brain tissues, the anatomical structures, and the tumor and lesions [27-29].

Thirdly, we introduce the deformable models and detail their advantages and disadvantages. The deformable model that has attracted the most attention to date is popularly known as “snakes”. Snakes

or “deformable contour models” represent a special case of the general multidimensional deformable model theory of Terzopoulos.

Deformable models are object-delineating curves/surfaces that deform within two-dimensional/three-dimensional digital images under influence of both internal and external forces and used defined constraints. Deformable models are classified as either parametric deformable models (classical deformable models) [5] or non-parametric deformable models (geometric deformable models) [30, 31] according to their representation and implementation. In particular, parametric deformable models are represented explicitly as parameterized curves/surfaces in a Lagrangian formulation. Non-parametric deformable models are represented implicitly as level sets of higher-dimensional distance functions, which evolve according to an Eulerian formulation. Non-parametric deformable models are based on the theory of curve evolution implemented via level set techniques.

The classical deformable models are formulated by minimizing an energy functional that takes a minimum when contours are smooth and resided on object boundaries. Solving the energy minimization problem leads to a dynamic equation that has both internal and external forces. The internal forces control the strength of the contour’s elasticity and rigidity. The external force is designed to pull the active contour towards object boundaries or other features of interest.

Parametric deformable models have proven to be effective in segmenting, matching, and tracking anatomic structures by exploiting constraints derived from the image data together with a priori knowledge about the location, size, and shape of these structures. Deformable models are capable of accommodating the significant variability of biological structures over time and across different individuals. Furthermore, they support highly intuitive interaction mechanisms that, when necessary, allow medical scientists and researchers to bring their expertise to bear on the model-based image interpretation task.

Non-parametric deformable models have several important advantages over parametric deformable models. First, they are completely intrinsic and therefore are independent of the parameterization of the evolving contour. Second, the intrinsic geometric properties of the contour such as normal vector and curvature can be easily computed from the level set functions. Third, the propagating contour can automatically change topology in non-parametric models (merging and splitting) without requiring an extra mechanism to handle such changes as in parametric models. Finally, the resulting contours do not contain self-intersections, which are computationally costly to prevent in parametric deformable models. Topological flexibility has long been claimed as a major advantage of non-parametric deformable models over parametric deformable models. Such flexibility is desirable in our applications.



Finally, we discuss the evaluation criteria of segmentation algorithms and performance indexes used in our quantitative analyses on the segmentation results. The objective of the segmentation evaluation is to optimize the segmentation via the researching the segmentation performance of the algorithms. Segmentation algorithms can be evaluated analytically or empirically, so the evaluation methods can be divided into two categories: the analytical methods and the empirical methods [32]. The analytical methods directly examine and assess the segmentation algorithms themselves by analyzing their principles and properties. The empirical methods indirectly judge the segmentation algorithms by applying them to test images and measuring the quality of segmentation results. The empirical methods can still be classified into two types: goodness methods and discrepancy methods. The empirical goodness methods judge the segmented image or output image so as to indirectly assess the performance of algorithms. The empirical discrepancy methods compare the segmented image or output image to the reference image and use their difference to assess the performance of algorithms.

As there is no general segmentation theory currently, the empirical methods are more suitable and useful than the analytical methods for performance evaluation of segmentation algorithms. Among empirical methods, the discrepancy methods are better for objectively assessing segmentation algorithms than the goodness methods. In this dissertation, we adapt the quantitative discrepancy method to evaluate the quantizing segmentation results. The quantizing indexes include the sensitivity, specificity, total performance [33], similarity, false positive rate, and false negative rate [29] etc. These indexes reflect the segmentation performance of the under investigation algorithms in different visual angles.

The MRI images used in this dissertation are mainly downloaded from Internet Brain Segmentation Repository (IBSR) [34] and Brainweb [35]. In these databases the manual segmentation results of experts or the discrete models are provided simultaneously, which is convenient for users to evaluate their algorithms.

## ***Chapter 2 Histogram-Analysis based Non-parametric Deformable Models***

In this chapter, I present a non-parameter deformable model integrating the statistical information derived from the histogram analysis of the image, which is the first method developed for the segmentation of MRI images as part of my thesis.

### **2.1 Geometric active contour**

Caselles and Malladi *et al.* [31, 37] proposed the geometric active contours models, whose partial differential function has the formulation as follow:

$$\frac{\partial \phi}{\partial t} = g(I)(c + K) |\nabla \phi|, \quad (2.1)$$

where  $\phi$  is the signed distance function,  $c$  is a constant, and  $K$  is the mean curvature.

The stopping term  $g(I)$  is defined as

$$g(I) = \frac{1}{1 + |\nabla(G_\sigma * I)|^2}, \quad (2.2)$$

where  $G_\sigma$  is Gaussian function with scale  $\sigma$ ,  $*$  is the convolution operator.

Equation (2.1) can also be rewritten as follow:

$$\frac{\partial \phi}{\partial t} = g(I)F(K) |\nabla \phi|, \quad (2.3)$$

where  $F(K) = 1 - \varepsilon K$  is called as curvature depended speed term,  $\varepsilon$  is an user defined constant, which controls the smoothness of the evolving curve.

### **2.2 Improvement**

In an original geometric active contour, the stopping term is critical. It usually depends on a function of gradient of Gaussian smoothed image. On the one hand, since the gradient values of image within the homogeneous regions tend to zeros, the stopping term tends to unit 1. In this case the curves propagate with the constant speed in the normal directions. While at the boundaries, the gradient values tend to infinite, the stopping term tends to zero, and consequently the curves evolving stops. However, with real images, the stopping term is never truly zero at boundaries. Thus, the propagating curve can't stop at the boundaries and only evolves very slowly, which consequently results in the leakage of boundaries. On the other hand, the Gaussian smoothing used in the classical stopping term will blur the image and shift boundaries, which will reduce the accuracy of boundaries locating.

For solving above problems, statistical information based stopping function is adopted. That allows to remove the depending upon the gradient information of image of the original geometric active contour, and also overcome the limitation of accuracy of boundary locating due to Gaussian smoothing operation. In addition, the curves can propagate in both directions (inward and outward) of the normals, while the classical geometric active contour can evolve only in either inward or outward direction, and also should be predefined. Consequently, the new algorithm can get better robustness

and higher segmentation accuracy than classical ones. The statistical information is derived from the analysis of intensity histogram of image.

The gray-level histogram is a function showing for each gray level the number of pixels in the image that have that gray level. The histogram of image contains considerable information; certain types of image are completely specified by their histogram. Normalizing the gray-level histogram by dividing the area of the image produces the probability density function (PDF)  $h(z)$ .

Generally, the image with complex object and background usually has a multimodal histogram. Using a mixture density function, the histogram can be represented as a mixture parametric density functions. Each tissue type is modeled by a Gaussian distribution with the mean determined by the peak position and the variance determined by the width.

The probability density function of this mixture Gaussian model (MGM) [38] can be described as

$$p(z) = \sum_{i=1}^K A_i \mathcal{N}(z | \mu_i, \sigma_i) \quad (2.4)$$

There are two approaches to estimate the probability density function: parametric and non-parametric methods, that depends on the methods to represent the mixture density function. In the proposed algorithm, we employ the Expectation Maximization (EM) algorithm to estimate the mixture parameters (mixture proportion  $A_i$ , mean  $\mu_i$ , and the standard deviation  $\sigma_i$ ) of each component in MGM.

The new model is formulated as:

$$\frac{\partial u}{\partial t} = \alpha(I)(1 - \varepsilon K) |\nabla u| \quad (2.5)$$

where the constraint function  $\alpha(I)$  is defined as follow:

$$\alpha(I) = \begin{cases} 1 & I \in R_k \\ -1 & I \notin R_k \end{cases}, \quad (2.6)$$

and  $R_k = [\mu_k - \lambda_r \sigma_k, \mu_k + \lambda_r \sigma_k]$  corresponds to the object region in the histogram represented by the  $k^{\text{th}}$  Gaussian component.

**The Histogram analysis-based non-parametric deformable model:**

1. Image preprocessing
2. Approximation the normalized Histogram with mixture Gaussian model to obtain parameters  $\{A_i, \mu_i, \sigma_i\}$ .
3. Generation the constraint function  $\alpha(I)$  using  $\{\mu_i, \sigma_i\}$ .
4. Initialization the level set function  $\phi_t(x, y, 0) = \phi_{t,0}(x, y)$ , evolve the curves until convergence.
5. Extraction the segmented objects, and morphological postprocessing.

The new algorithm is firstly applied to segment a synthetic image. The image contains some shapes of concave, convex, corner and arcs features, etc. Fig. 2.1 shows the effects of the Gaussian smoothing operation on the segmentation results obtained by the classical geometric active contour (GAC) and ours. Our method obtains the accuracy positions of boundaries whatever initialization approaches. A comparison study is carried out through synthetic images to illustrate the performance of our method by statistical indexes shown in Table 2.1.

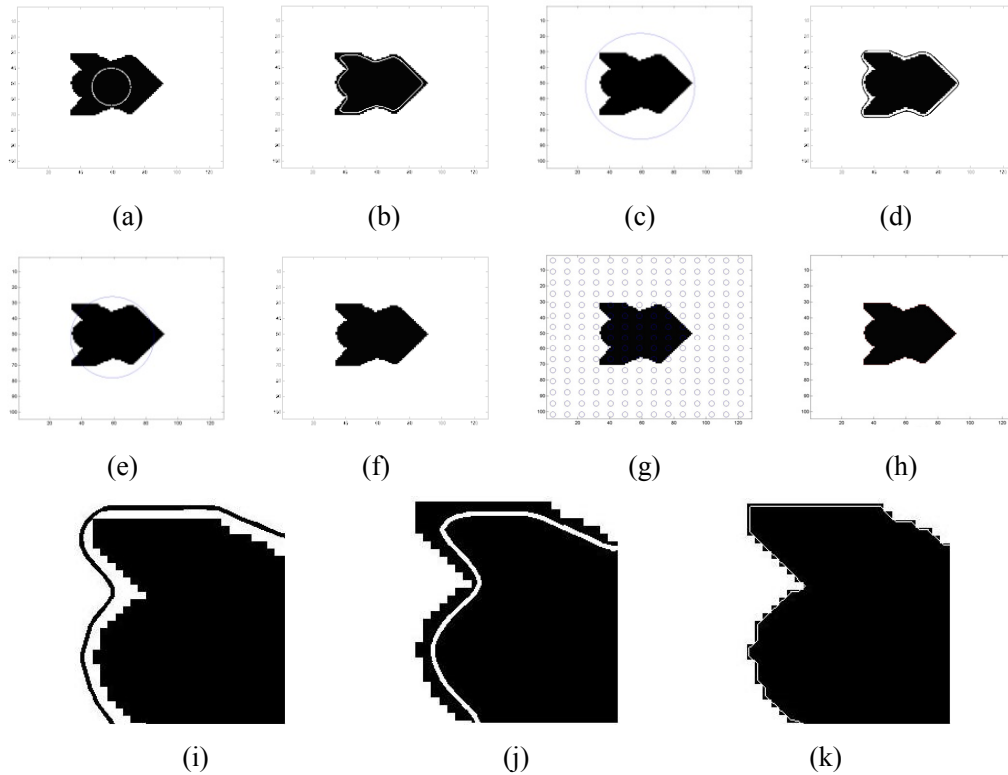


Fig. 2.1 Experiments on the synthetic image. GAC (Geometric Active Contour) segmentation results shown in (b) and (d) with the initial curve inside (a), and outside (c) respectively; segmentation results of our method shown in (f) and (h) with an arbitrary initial curve (e) and multi-initial curves (g), respectively; (i) and (j) are the selective enlargements of (b) and (d) respectively; (g) the selective enlargement of (h)

Table 2.1 Comparison of the segmentation accuracy of two algorithms

initialization approach	internal		external	
	error pixels	error rate (%)	error pixels	error rate (%)
GAC	231	13.48	386	22.64
Our method	0	0	0	0

We secondly evaluate the new algorithm with the simulated MRI image. The test set includes ten simulated MRI images extracted from different data volumes. Multi-seeds initialization approach is used in this experiment. Fig.2.2 shows the segmentation results and corresponding quantitative measures are shown in Table 2.2 and Table 2.3.

It can be seen from Table 2.2 and Table 2.3, in the WM segmentation, all the indexes are superior to 97%. In the CSF segmentation, except the sensitivity index, the specificity and total performance indexes are around 98%. Small standard deviations indicate the good segmentation coherence of our algorithm. Our result (average sensitivity is 91.78%) outperforms the results in reference [39] (average sensitivity is 84.60%). Although the adapted MR image is different in both algorithms, it still demonstrates the good performance of our algorithm in some degree.




Fig. 2.2 Experiment on simulated MRI image. (a) Original image and gold standard (from left to right: T1W, WM, GM and CSF); (b) Segmentation results of the our algorithm (from left to right: WM, GM and CSF)


Table 2.2 Statistical indexes (%) of segmented results of ten images

Image index	1	2	3	4	5	6	7	8	9	10
Sensitivity	97.82	93.76	94.18	94.63	93.6	94.37	93.44	94.25	94.01	97.11
specificity	97.75	96.98	97.85	97.55	97.16	97.43	97.54	97.51	97.51	97.90
Total performance	97.82	96.63	97.47	97.17	96.75	97.11	97.17	97.09	97.06	97.89


Table 2.3 Average performances (mean  $\pm$  sd) of segmentation results of ten images in term of tissues

Indexes (%)	WM	GM	CSF	AVG
Sensitivity	97.02 $\pm$ 1.01	95.35 $\pm$ 1.26	91.78 $\pm$ 2.52	94.72
specificity	97.90 $\pm$ 0.22	96.45 $\pm$ 0.51	98.20 $\pm$ 0.24	97.52
Total performance	97.71 $\pm$ 0.31	96.23 $\pm$ 0.62	97.72 $\pm$ 0.32	97.22


Fig. 2.3 shows the segmentation procedure of a real MRI image. Fig. 2.3 (b) and (c) show the histogram of image and the Gaussian fitting to it. WM and GM segmentation results are shown in Fig. 2.3 (d) and (e) respectively. The parameters estimated via EM algorithm are shown in Table 2.4. The radiologists confirm the segmentation results by visual inspection.



(a)



(b)



(c)




Fig. 2.3 Segmentation results of a real MRI image: (a) MR image; (b) histogram; (c) fitting curve; segmentation results of (d) gray matter and (e) white matter.

Table 2.4 Characteristic parameters of the histogram analysis

Cluster	$\mu_i$	$\sigma_i$	$A_i$
1	0.30268	1.7198	0.72145
2	31.024	7.5439	0.13789
3	59.146	6.3074	0.14066

## 2.4 Conclusion

This chapter presents our first work to segment MRI images. The new algorithm adopts the statistical information derived from the intensity histogram of image instead of the classical gradient-based stopping term. The constraint term based on global statistical information improves the accuracy of the boundary locating and the segmentation quality, while eliminating the overly relying of the classical geometric active contour on the gradient information of the image. The algorithm can adaptive adjust the directions of the curve propagation during the evolution, while in the classical geometric active contour the curve can evolve only in one direction (inflating or deflating) and the evolving direction has to be predefined. This property reduces the manual intervention, and makes the initialization of the algorithm more flexible and convenient for user. It also improves the robustness of the algorithm to the initial condition, avoids the algorithm converging to the local minima.

Experiments on synthetic image and simulated MRI images are carried out to evaluate the algorithm. The quantitative analyses indicate the good segmentation performance of the algorithm. However, the relative low sensitivity index indicates the over segmentation of the CSF. We think the cause of the over-segmentation maybe is that the CSF location at the external of the brain matter or in the lateral ventricles with thin-long and convoluted shape. In our experiments, we dilate the binary

segmentation results with two-pixel structure. That improves the segmentation performance of CSF. Another problem is the Gaussian approximation to intensity histogram. The accuracy of approximation affects the segmentation performance of the algorithm. Ongoing works include the improvement in both problems.

In the next chapter the second method is proposed which is based on the region information; the fuzzy information provided by the fuzzy analysis on the image is integrated into the non-parametric deformable model.



### Chapter 3 Regional Non-parametric Deformable Models

In this part, we present an improved algorithm based on the Region-based Geometric Active Contour (RGAC) of Suri [27].

Suri proposes the algorithm of region-based Geometric Active Contour (RGAC) by replacing the second continuity term of the parameterized curve with the pressure force term in the classical snake model [5].

If  $\phi$  is a signed distance function or level set function, the partial differential equation (PDE) of the RGAC algorithm formulates as follow

$$\frac{\partial \phi}{\partial t} = (\varepsilon k + V_p) |\nabla \phi| - V_{\text{ext}} \cdot \nabla \phi, \quad (3.1)$$

where  $V_p$  is the regional force term,  $k$  is the mean curvature,  $\varepsilon$  is a positive constant, which controls the smoothness of the evolving fronts, and  $V_{\text{ext}}$  is the external force term.

Suri discretizes (3.1) using the forward Euler method given by

$$\phi_{x,y}^{n+1} = \phi_{x,y}^n - \Delta t \{V_{\text{reg}}(x, y) + V_{\text{grad}}(x, y) - V_{\text{cur}}(x, y)\}, \quad (3.2)$$

where  $V_{\text{grad}}(x, y)$  is the gradient-based term,  $V_{\text{cur}}(x, y)$  is the curvature-based velocity term,  $V_{\text{reg}}(x, y) = V_p(x, y) |\nabla \phi|$  is the region-based velocity term,  $V_p$  is a function of the membership set  $u(x, y)$ , and is defined as

$$V_p(x, y) = \frac{\omega_R}{\lambda(1 - 2u(x, y))}, \quad \omega_R, \lambda \in \mathbb{R}^+. \quad (3.3)$$

#### 3.1 An improved Region-based Geodesic Active Contour

##### 3.1.a Principles

The RGAC algorithm includes three velocity terms: i.e., the gradient-based velocity term, the curvature-based velocity term and region-based velocity term. We find severe limitations of the algorithm when it is used to segment brain tissues: the segmenting performance greatly varies with the various tissues to be segmented, even with different slices of the same brain volume, and the algorithm sometimes diverge, which reveals the underlying problems of the robustness and stability.

In the original RGAC algorithm, the velocity term is presented by  $V_p(x, y) = \omega_R / (\lambda(1 - 2u(x, y)))$ , where  $\omega_R = 0.5$ ,  $\lambda = 1$ . A discontinuity point of the second kind occurs at  $u(x, y) = 0.5$ .

Equation (3.2) can be rewritten as

$$\frac{\partial \phi}{\partial t} + (V_{\text{ext}} \cdot \nabla \phi - V_p |\nabla \phi|) = \frac{\partial \phi}{\partial t} + H = \varepsilon k |\nabla \phi|, \quad (3.4)$$

where both  $V_p |\nabla\phi|$  and  $V_{\text{ext}} \cdot \nabla\phi$  are hyperbolic term, while  $\varepsilon k |\nabla\phi|$  is a parabolic term. When the algorithm is implemented by level set methods, the hyperbolic term and the parabolic term need to be discretized using upwind difference and central difference respectively. Forward Euler or Runge-Kutta (RK) time discretization can be used to advance the front forward in time. According to reference [35], the combined Courant-Friedrechs-Lewy (CFL) condition for equations that contain both hyperbolic and parabolic terms is given by:

$$\Delta t \left( \frac{|H_1|}{\Delta x} + \frac{|H_2|}{\Delta y} + \frac{|H_3|}{\Delta z} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} + \frac{2|\varepsilon|}{(\Delta z)^2} \right) < 1, \quad (3.5)$$

where  $H_1$ ,  $H_2$  and  $H_3$  are the partial derivatives of  $H$  with respect to  $\phi_x$ ,  $\phi_y$  and  $\phi_z$  respectively,  $\Delta x$ ,  $\Delta y$  and  $\Delta z$  are the space step in  $x$ ,  $y$  and  $z$  directions of three-dimensional (3-D) image volume.

Combining with (3.4) and (3.5), a two-dimensional (2-D) CFL condition can be written as

$$\Delta t \left( \frac{|V_p \frac{\phi_x}{|\nabla\phi|} - V_{\text{ext}}|}{\Delta x} + \frac{|V_p \frac{\phi_y}{|\nabla\phi|} - V_{\text{ext}}|}{\Delta y} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} \right) < 1. \quad (3.6)$$

Let  $N_x = \frac{\phi_x}{|\nabla\phi|}$  and  $N_y = \frac{\phi_y}{|\nabla\phi|}$ , where  $N_x$  and  $N_y$  are the components of the unit normal vector  $\mathcal{N}$  in  $x$  and  $y$  directions respectively, and with the constraint  $N_x^2 + N_y^2 = 1$ .

So we have the following equation:

$$\Delta t \cdot \max \left( \frac{|V_p N_x - V_{\text{ext}}|}{\Delta x} + \frac{|V_p N_y - V_{\text{ext}}|}{\Delta y} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} \right) = \alpha, \quad 0 < \alpha < 1. \quad (3.7)$$

When  $u \rightarrow 0.5$ ,  $V_p = \omega_R / \lambda R_{\text{ind}}(x, y) \rightarrow +\infty$  or  $-\infty$ , then  $\max(\bullet) \rightarrow \infty$ . If and only if  $\Delta t \rightarrow 0$  the equation (3.7) satisfies the requirement of the CFL condition. If  $\Delta t$  takes a finite small value, such as 0.01 or 0.001, the CFL condition can not be satisfied. So a convergent result will not always be achieved under the condition of the original regional term (3.3).

Considering the underlying stability problem of the original algorithm, we propose to modify the velocity term  $V_p$  as

$$V_p(x, y) = \omega_R \cdot (1 - 2u(x, y)), \quad \omega_R \in \mathbb{R}^+. \quad (3.8)$$

Firstly, from the view point of stability, in (3.8),  $V_p \in [-\omega_R, \omega_R]$ . The stability of the algorithm is ensured by tuning the time-step. Secondly, the sign of  $V_p$  determines the direction of the curve

evolution (expanding or contracting), while the value of  $V_p$ , together with other two terms, determines the speed of the curves propagation.

For the spatial discretization, the hyperbolic term and the parabolic term are discretized by using upwind difference and central difference respectively [40]. For the temporal discretization, we adopt the third-order accurate total variation diminishing (TVD) Runge-Kutta (RK) method to increase the accuracy [35].

### 3.1.b Experiment results




Fig. 3.1 Segmentation results of T1-weighted image: (a) original image; ground truths of the three tissues (b) WM, (c) GM, and (d) CSF; segmentation results of original RGAC algorithm (e) WM, (f) GM, and (g) CSF; segmentation results of the improved algorithm (h) WM, (i) GM and (j) CSF.

We evaluate the improved algorithm with simulated T1-, T2-, and PD-weighted MRI images by comparing to the original RGAC. Fig. 3.1 shows one of the segmentation results. The statistical indexes (similarity index  $\rho$ , false positive ratio  $r_{fp}$  and false negative ratio  $r_{fn}$ ) on the ten successful

segmentation results are shown in Table 3.1. Fig. 3.2 and Fig. 3.3 show the segmentation results of one of PD-W and T2-W MR images. We overlay the contours of the segmented images on the original images, allowing to inspect the results visually. The statistical indexes of the segmentation results are shown in Table 3.2.

Table 3.1. Statistical indexes (%) on ten images segmented by RGAC and our algorithm

Method	Tissue	$\rho$	$r_{fp}$	$r_{fn}$	iterations
Suri algorithm	CSF	60.04	59.80	30.89	85.5
	GM	85.33	18.68	11.47	160.4
	WM	86.35	24.24	5.46	188.1
	average	77.24	34.24	15.94	144.7
Our method	CSF	84.88	24.74	7.76	9.8
	GM	91.23	14.54	3.83	22.0
	WM	94.53	9.29	2.00	14.1
	average	90.21	16.19	4.53	15.3




Fig. 3.2 Segmentation results of PD-weighted image: (a) original image; segmentation results of our method (b) WM and (c) GM; (d) ground truth.




Fig. 3.3 Segmentation results of T2-weighted image: (a) original image; segmentation results of our method (b) WM and (c) GM; (d) ground truth.

Table 3.2 Statistical indexes (%) of the segmentation results in Figure 3.2 and Figure 3.3

	GM			WM		
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$
Fig. 4.2	94.02	7.18	4.91	97.17	3.27	2.41
Fig. 4.3	91.54	4.00	12.23	97.36	4.97	0.43




Fig. 3.4 Total performance vs. parameters ( $\varepsilon$ ,  $\omega_e$  and  $\omega_r$ )

We take different parameter values to test their effect on performance of our proposed algorithm. Fig.3.4 plots the total performance indexes of different tissues with respect to parameters  $\varepsilon$ ,  $\omega_e$  and  $\omega_r$  respectively. It can be seen from Fig. 3.4 that the performances of WM and GM segmentation is less sensitive to parameters  $\varepsilon$  and  $\omega_e$ , and maintain almost unvaried in a certain extent with respect to parameter  $\omega_r$ . The segmentation performance of CSF has a slight change with respect to these parameters. Generally, the algorithm is less sensitive to the parameters of  $\varepsilon$ ,  $\omega_e$  and  $\omega_r$ .

Fig. 3.5 shows the real T1-weighted MR images (20<sup>th</sup> slice) and their segmentation results of our method and the piecewise constant (PC) model [41], which is proposed by Vese and Chan for multiphase segmentation. The corresponding statistical indexes are shown in Table 3.3. Experiments on slices 90 and 100 are also carried out and the statistical indexes are also shown in Table 3.3. It can be seen from the statistical results that the generally the segmentation performances of our method outperform those of the PC algorithm according to the indexes of similarities and total errors ( $r_{fp} + r_{fn}$ ). At the same time, our method needs less iterative numbers and takes shorter time (on notebook PC with T9300 CPU and 2G RAM).




Fig. 3.5 Real MR image segmentation (20<sup>th</sup> slice): (a) original image, (b) ground truth, (c) energy-function convergence curve of PC model, segmentation results of our method (d) gray matter and (e) white matter, (f) segmentation result of the PC model.

Table 3.3 Statistical indexes of the segmentation experiments on MRI images

slice index	GM			WM			iteration	elapse	
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$	number	time (s)	
PC	20	0.9007	0.0090	0.1733	0.7953	0.4997	0.0101	1078	214.50
	90	0.9180	0.0232	0.1320	0.9011	0.2093	0.0083	1524	311.47
	100	0.9548	0.0002	0.0864	0.9178	0.1787	0.0003	1867	378.47
our method	20	0.9502	0.0077	0.0879	0.8933	0.2005	0.0309	26	15.53
	90	0.9489	0.0270	0.0729	0.9476	0.0849	0.0231	22	10.38
	100	0.9748	0.0055	0.0439	0.9601	0.0576	0.0236	23	11.90

Fig. 3.6 shows the segmentation results of a real MR image (93<sup>rd</sup> slice) of our method and PC model. In Fig. 3.6 (b), the result of the PC model, GM at the positions of A and B is segment to WM incorrectly, while the corresponding parts in Fig. 3.6 (f), the result of our results, are segment correctly. Statistical indexes of each segmentation result in Fig. 3.6 are shown in Table 3.4. We also show the statistical indexes of the same experiment on this image of the MFCM algorithm [34].

It can be seen from Table 3.4 that, the total errors ( $r_{fp} + r_{fn}$ ) of our method are 7.65% and 8.45% for GM and WM respectively, which are significantly better than those of the PC model (18.07% and 28.01% for GM and WM respectively) and the MFCM algorithm (15.92% and 11.79% for GM and WM respectively).




Fig.3.6 Real MR image segmentation: (a) original image and initial curves of the PC model, (b) segmentation result of the PC model; (c) the manual segmentation result; original image and initial curves (d) and segmentation results (e) WM and (f) GM. of our method.

Table 3.4 Performance indexes (%) for different methods applied to the real MR image in Fig. 3.6

	GM			WM		
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$
PC model	90.07	0.00	18.07	87.71	28.01	0.00
Wang et al [8]	91.58	2.48	13.44	94.22	7.92	3.87
Our method	96.03	0.23	7.42	95.92	7.78	0.67

We also apply our algorithm to segment the whole data volume (IBSR\_18) [35]. The average similarity indexes of the whole volume are shown in Table 4-5. Our average similarity indexes of WM and GM in this volume are 82.91% and 89.90%. Wang et al reported that their average similarity indexes of this volume are 75.98% and 81.90% for WM and GM segmentations respectively.

In Table 3.5, we also show the segmentation results of other IBSR volumes (IBSR\_14 to IBSR\_17). Generally, the similarity index  $\rho > 70\%$  indicates an excellent segmentation. The similarity indexes in Table 3.5 indicate the good performance of our method. In Fig. 3.7, we show the 3-D reconstruction results for white matter of volume IBSR\_14 using the reconstruction tool.

Table 3.5 Average similarity indexes (%) of experiments on IBSR data volumes

IBSR_No.	14	15	16	17	18
GM	87.24	87.36	88.97	85.83	89.90
WM	81.81	80.62	80.50	78.54	82.91




Fig. 3.7 Reconstruction 3D of the obtained WM of IBSR\_14 data volume

### 3.2 Adaptive Level Set Algorithm Integrating the Fuzzy Segmentation

#### 3.2.a Principle

The fuzzy segmentation could retain more information from the original image than hard segmentation by taking into account the possibility that more than one tissue class may be present in a single pixel (partial volume effect). In the second section of this chapter, we propose an adaptive level set algorithm, where the fuzzy region indicator is used in replace of the stopping term in the classical geometric active contour. Theoretically, the gradient-based stopping term takes the unit value due to the zero gradients in the homogeneous regions, while takes the zero value at edges where gradient is considered infinite. Due to limitations of the imaging system, noises, inhomogeneous magnetic field, partial volume effect and the diversity of the biological tissues make the boundaries between different tissues illegible. Hence the stopping term never takes zero exactly at the real edges, and the evolution will not stop. The front may pass through boundaries and consequently results in leakage. Moreover, the GAC method itself suffers from the limitations of excessively relying on the gradient information of image data, and being sensitive to noise.



We propose the new membership based constraint term as follows:

$$f(u_n) = \omega_R \cdot \text{sign}(1 - 2u_n), n = 1, 2, \dots, C, \quad (3.9)$$

where  $\text{sign}(\cdot)$  is the sign function; and  $\omega_R$  is the user defined constant.

So the improved geometric active contour integrating the fuzzy segmentation can be formulated as:

$$\frac{\partial \phi}{\partial t} = f(u_n)(1 - \varepsilon K) |\nabla \phi|, \quad (3.10)$$

The sign of  $f(u_n)$  determines the evolution directions, while the absolute value determines the speed of the interface propagation in a great extent.

The multi-seed initialization approach is used here because it not only minimizes the sensitivity of the algorithm to the initial condition, but also speeds up the convergence, as well as limiting the risks of convergence of the minimization to local minima.

### 3.2.b. Experiments and validation




Fig. 3.8 Experiment results on simulated MR image. Top row: original image and the ground truth of the three tissues: WM, GM and CSF; Bottom row: initialization and segmentation results WM, GM and CSF of the proposed method.

Fig. 3.8 shows one of the segmentation results of the simulated MRI images with the proposed method. Comparing with ‘ground truth’, the segmentation results in bottom row of Fig.3.8 are visually satisfied, especially the gray matter segmentation, the fine profiles of the lateral ventricular are clear, intact and perfect. Table 3.6 shows the average performances (mean  $\pm$  standard derivative) in terms of WM, GM and CSF. It can be seen from Table 3.6 that the general average performance of the

sensitivity, specificity and total performance reach to 96.42%, 96.96, and 97.00% respectively. Relative equipoise of performances of the three tissues shows that the algorithm is less sensitive to tissues and the areas of the objects to be segmented.

Table 3.6 Statistical indexes of segmentation results of ten MRI images

Indexes	WM	GM	CSF	AVG.
Sensitivity (%)	98.10±1.47	96.70±1.30	94.48±2.12	96.42
Specificity (%)	97.20±0.20	95.79±0.52	97.91±0.18	96.96
Total performance (%)	97.40±0.28	95.97±0.64	97.66±0.27	97.00

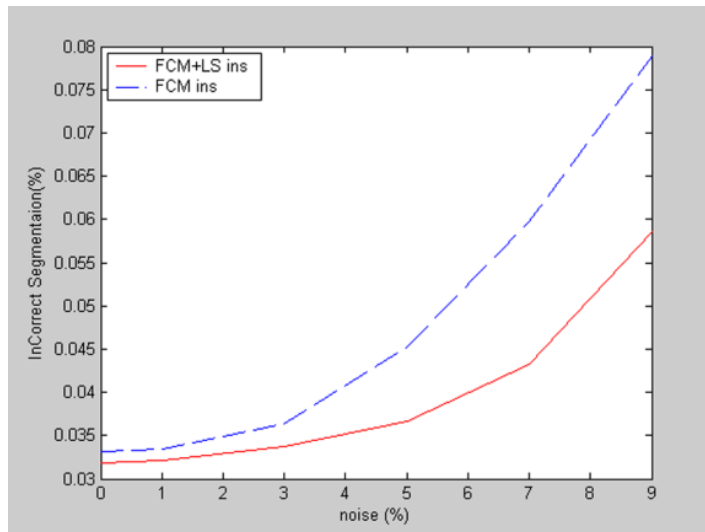


Fig.3.9 Comparison between the proposed method (■) and FCM method (■)



Fig. 3.10 White matter segmentation results (original image, result of our method, and FCM method)



Fig. 3.11 Segmentation results of real T1-W MR image (original image, WM, and GM)

We also compare the proposed method with the fuzzy *c*-means method to validate it is necessary of the level set segmentation in the second step. Fig. 3-9 shows the error rates of the proposed method and the FCM method. Curves in Fig.3-9 demonstrate the performance of the proposed method is better than the FCM method, especially when the images are badly corrupted by noise.

Fig. 3.10 shows the white matter segmentation results under 5% Gaussian additive noise. The result of the fuzzy *c*-means method shows the overall grain (isolated pixels) scattering around the object to be segmented, while the result of the proposed method shows less specking, the resulting object is smooth and intact. That demonstrates the combination of level set method with FCM method can effectively improve the segmentation accuracy and robustness to noise.

Fig. 3.11 shows one of the experimental results of one real MR T1-weighted image. The thin-long structures and the profile of the lateral ventricular are clear and accurate in Fig. 3.11(b). In Fig.3.11(c), the external profile of the gray matter is accurately segmented, and continuously delineated. The results are confirmed by the radiologists.

### 3.3 Conclusion

This chapter presents a new algorithm to segment the brain tissue from MR images in the first part of this chapter. The new algorithm overcomes the problems of stability and sensitivity of the segmentation results to some parameters associated with the original algorithm proposed by Suri. The new algorithm can segment successfully various cerebral tissues (WM, GM and CSF) from the various modality MR images (T1-, T2- and PD-weighted). The new algorithm improves the accuracy of the segmentation significantly. The multi-seed initialization, used in the improved algorithm, enables an automatic segmentation of the cerebral tissues with the lower degree of manual interventions. It also speeds up the convergence of the algorithm, and decreases the sensibility to initial conditions. The algorithm is evaluated using both simulated and real MR images. The quantitative analyses demonstrate the feasibility and the effectiveness of the improvement. The comparisons with other algorithms indicate the better segmentation performance of the proposed method.

The fuzzy region indicator proposed in the above algorithm is extended to use in the second algorithm of this chapter. In the new algorithm, the fuzzy information based stopping term replaces the stopping term of the geometric active contour. Thanks to the new stopping term, the algorithm can adaptively govern the directions of the evolving curves. It also eliminates the relying of the geometric active contour on the gradient information of images. The fuzzy logic framework implicitly takes into account the partial volume effect in the FCM segmentation step. Benefiting from both FCM and level set methods, the combination of the fuzzy information with the level set method can improve the segmentation accuracy and the robustness of the algorithm.

### Chapter 4 Multiclass Algorithm for MRI Image Segmentation

In this part, we present a multiclass algorithm for MR images segmentation. The use of partial differential equations (PDEs) for image processing has become an interesting research topic in the past few years. One of the most successful and pioneering models that adopt this approach is the model of Mumford and Shah functional. Based on the Mumford-Shah functional [42], a variety of segmentation approaches were proposed, such as multiscale algorithm [43], C-V model [44] and C-V multiphase algorithm [41].

#### 4.1 The proposed multiclass algorithm

Chan and Vese [44] proposed to decompose the image into two regions with piecewise constant approximations (i.e.  $I_0$  is a constant in each region). It is a particular case of the minimal partition problem of Mumford and Shah for segmentation of images. The evolving equation of the C-V model is formulated as

$$\frac{\partial \phi}{\partial t} = \delta_\varepsilon(\phi) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi}{|\nabla \phi|} \right) - \lambda_1 (I_0 - c_1)^2 + \lambda_2 (I_0 - c_2)^2 - \nu \right]. \quad (4.1)$$

The C-V model was generalized to multiphase case by Vese and Chan (C-V multiphase algorithm) [41]. The evolving equations can be formulated as

$$\begin{aligned} \frac{\partial \phi_1}{\partial t} &= \delta_\varepsilon(\phi_1) \left\{ \mu \nabla \cdot \left( \frac{\nabla \phi_1}{|\nabla \phi_1|} \right) - \left[ ((I_0 - c_{11})^2 - (I_0 - c_{01})^2) H(\phi_2) + ((I_0 - c_{10})^2 - (I_0 - c_{00})^2) (1 - H(\phi_2)) \right] \right\} \\ \frac{\partial \phi_2}{\partial t} &= \delta_\varepsilon(\phi_2) \left\{ \mu \nabla \cdot \left( \frac{\nabla \phi_2}{|\nabla \phi_2|} \right) - \left[ ((I_0 - c_{11})^2 - (I_0 - c_{10})^2) H(\phi_1) + ((I_0 - c_{01})^2 - (I_0 - c_{00})^2) (1 - H(\phi_1)) \right] \right\}, \end{aligned} \quad (4.2)$$

where  $\mathbf{c} = (c_{11}, c_{10}, c_{01}, c_{00})$  is a constant vector, corresponding to the four regions respectively.

It can be seen the above equations in construct a coupled non-linear PDEs system. The parabolic terms of the equations require a significant stringent time-step restriction of  $\Delta t = O(\Delta x^2)$  [35]. The main drawback of the algorithm is the high computational expense in solving the nonlinear parabolic partial differential equation.

We propose to replace the fitting term in the C-V model with the difference of two-cluster fuzzy memberships, where  $u_1$  and  $u_2$  represent the objects to be detected and the background respectively.

$$\frac{\partial \phi}{\partial t} = \delta_\varepsilon(\phi) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi}{|\nabla \phi|} \right) + \omega_R \cdot (u_1 - u_2) \right], \quad \omega_R \in R^+. \quad (4.3)$$

The evolving equation of the two-class segmentation algorithm is extended to multiclass algorithm. In multiclass segmentation, each class is represented by a separate level set function. Following the strategy in [45], a constraint to discourage overlap and vacuum between classes is enforced. The evolution equation of our multiclass segmentation algorithm is firstly formulated as

$$\frac{\partial \phi_j}{\partial t} = \delta_\varepsilon(\phi_j) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi_j}{|\nabla \phi_j|} \right) + \omega_R (u_j - \max_{i \neq j} (u_i)) \right], \quad \omega_R \in R^+, \quad j = 1, 2, \dots, C. \quad (4.4)$$

In (4.4) the parabolic term requires a significant stringent time-step restriction, which will slow down the convergence rate of the algorithm. As the operation of noise removing is arranged in the

preprocessing step, the regularity term can be removed in our algorithm. In the preprocessing step, we recommend using the anisotropic diffusion filter [46]. The method can preserve the edge properties while reducing the additive noise. We adopt the fast AOS scheme to implement the anisotropic diffusion filter [47]. The diffusion operation also could be used in place of motion by mean curvature to regularize the level set evolution to a certain extent [48]. Furthermore, in order to extend  $\phi$  to all level sets, we take  $\delta_\varepsilon(\phi) = 1$ . So the algorithm can be simplified as

$$\frac{d\phi_j}{dt} = \omega_R(u_j - \max_{i \neq j}(u_i)), \quad \omega_R \in R^+, \quad j = 1, 2, \dots, C. \quad (4.5)$$

**The multiclass segmentation algorithm:**

- (1) Filter the image (anisotropic diffusion filter) if it is necessary;
- (2) Apply FCM method to image to obtain the fuzzy membership set  $\mathbf{u} = \{u_j \mid j = 1, 2, \dots, C\}$ ;
- (3) Initialize  $\phi_j$  as a signed distance function;
- (4) Evolve  $d\phi_j / dt = \omega_R(u_j - \max_{i \neq j}(u_i))$ ;
- (5) Periodically re-initialize  $\phi_j$  to a signed distance function;
- (6) Repeat (4) and (5) until convergence.

**4.2 Experimentations and validation**

The segmentation results of a synthetic image are shown in Fig. 5-1. Fig.5-1 reveals although various initializations are used, they all achieve the corrected result. It demonstrates that the algorithm is not sensitive to the initial conditions.




Fig. 4.1 Segmentation results of the synthetic image. Initial contours (blue circles), middle evolving curves (magenta lines), and the final segmentation results (white lines).

To demonstrate the segmentation performance under different noise conditions, we apply our method to segment a synthetic image with Gaussian noise (mean 0 and variance 0.02) and salt & pepper noise (noise density 0.05) respectively. Fig.4.2 shows the results of our algorithm and C-V model respectively. From Fig. 4.2, under Gaussian noise condition, it can be seen that our algorithm obtains the similar result with that of C-V model. However, under salt & pepper noise condition, our result is superior to that of C-V model.




Fig. 4.2 Segmentation results of a synthetic image with different noises. Original image (a), original image corrupted by Gaussian noise (overlapped with initial curves) (b), corresponding result of C-V model (c) and result of our algorithm (d); original image corrupted by salt & pepper noise (overlapped with initial curves) (e), corresponding result of C-V model (f) and result of our algorithm (g).

Table 4.1 Performance indexes (%) under different noise types

		Kappa	$r_{fp}$	$r_{fn}$
Gaussian	C-V model	99.63	0.42	0.33
	our method	99.20	0.99	0.62
salt & pepper	C-V model	95.87	7.22	1.28
	our method	99.07	1.10	0.76

Table 4.1 shows the average performance indexes over the 100-time experiments on image with different noise types. Statistical results show that, under the Gaussian noise condition, the performance indexes of C-V model are slightly better than those of our algorithm. Under the salt & pepper noise condition, performance of the C-V model degrades; higher false positive ratio (7.22%) of the C-V model reveals its sensitivity to this type of noise, while the performance indexes of our algorithm are evidently better than those of C-V model. Our algorithm can obtain good performance under both Gaussian noise and salt & pepper noise conditions, which demonstrates that our algorithm is robust against noise.

Fig. 4.3 shows the segmentation results of our algorithm and the C-V multiphase algorithm applied to the simulated MRI images under 7% and 9% Rician noise levels. Table 4.2 shows the statistical indexes of the experiments. It can be seen from Fig. 4.3 that the segmentation results of the C-V multiphase model are visually ‘noisy’, while our method obtains the better results observed in both noise levels. Table 4.2 shows that, under both noise conditions, the total errors (false positive rate



+ false negative rate) of our method are better than those of the C-V multiphase model. The indexes confirm the superiority of our method.




Fig. 4.3 Segmentation results of simulated MRI images under noisy conditions. 107<sup>th</sup> slice with 7% Rician noise: initialization conditions (a) and results of GM (b) and WM(c) of our algorithm, initialization conditions (e) and results of GM (f) and WM (g) of the C-V multiphase algorithm; the ground truths of GM(d) and WM (h). 94<sup>th</sup> slice with 9% Rician noise: initial conditions (i) and results of GM (j) and WM (k) of our algorithm, initial conditions (m) and results of GM (n) and WM (o) of the C-V multiphase algorithm; the ground truths of GM(l) and WM(p).



Table 4.2 Performance indexes (%) of experiments in Fig. 4.3

	noise level (%)	GM			WM		
		Kappa	$r_{fp}$	$r_{fn}$	Kappa	$r_{fp}$	$r_{fn}$
C-V	7	89.94	5.96	13.41	93.83	11.70	1.29
Multiphase	9	87.92	8.13	15.18	93.84	11.49	1.46
	7	93.14	3.82	9.51	97.02	2.89	3.07
our method	9	90.39	11.03	8.43	96.24	4.52	3.06

We also apply our method and C-V multiphase model to segment 20 slices (from 84 to 103 slices) of the brain volume with different noise levels for comparison. The curves of average Kappa indexes for tissues of GM and WM under different noise levels are plotted in Fig. 4.4. The curves indicate that the Kappa indexes of our method under different noise levels are clearly superior to those of the C-V multiphase model. Our method also exhibits a good robustness against noise, and high accuracy for tissues segmentation.

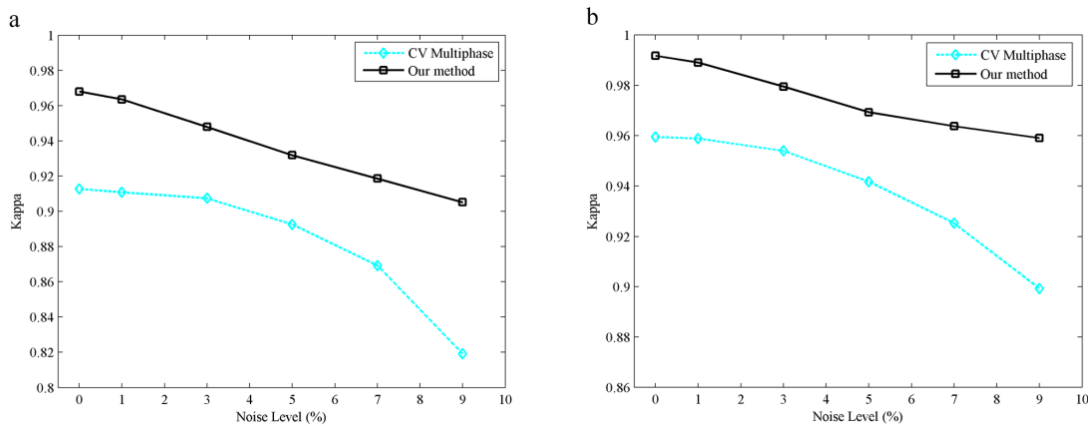


Fig. 4.4 Performance comparison of our method (■) with C-V multiphase algorithm (◆) under different noise level: (a) GM; (b) WM.




Fig. 4.5 Segmentation a real MR image: original image with initial curves (a), segmentation results of our method: WM (b), GM (c); manual segmentation result (d).

Table 4.3 Performance indexes (%) of the experiment in Fig. 4.5

	GM			WM		
	Kappa	$r_{fp}$	$r_{fn}$	Kappa	$r_{fp}$	$r_{fn}$
Wang et al	91.58	2.48	13.44	94.22	7.92	3.87
Our method	96.45	0.18	6.69	95.89	7.51	0.99

Fig.4.5 shows a real T1-weighted MR image (93rd slice) and its segmentation results. Corresponding statistic indexes of each segmentation result are shown in Table 4.3.

From Table 4.3, it can be seen that the Kappa indexes of our method are greater than 95% for both gray matter and white matter tissues. All of our performance indexes shown in Table 4.3 are better than those of the MFCM algorithm of Wang et al.

We also apply our algorithm to segment the whole data volume. The Kappa indexes of GM and WM of each image slice are shown in Fig. 4.6. The average Kappa indexes of WM and GM are 82.48% and 90.42%. Our results are better than those of the MFCM algorithm (average similarity indexes of WM and GM are 75.98% and 81.90%).




Fig. 4.6 Kappa indexes of each image slice in real T1-wighted MRI data volume.

### 4.3 Conclusion

In this chapter, we propose a multiclass algorithm to segment the brain tissues. The algorithm is composed of a set of ordinary differential equations. Each tissue type is represented by a level set function. A constraint is enforced to discourage the overlap and vacuum between classes. The curvature-based regularized term is removed and the anisotropic diffusion filter is used to reduce the noise level, as well as to regularize the level set function evolution. This relaxes the stringent time-step restriction, allowing to the fast convergence of the algorithm. The synthetic image, the simulated and

real MRI images are employed to evaluate the proposed algorithm. The multiclass algorithm is compared quantitatively with C-V multiphase algorithm and MFCM algorithm. The qualitative analyses and the quantitative evaluations on the segmentation results indicate that our multiclass algorithm has the better segmentation accuracy, and less computational complex, as well as the good robustness to noises.

### ***Conclusions and Perspectives***

In this dissertation, we firstly present a histogram analysis-based algorithm to segment the brain MRI images into different tissues. The normalized intensity histogram of image is approximated with the mixture Gaussian model. The parameters of the components in the mixture Gaussian model are estimated via the Expectation Maximization algorithm. The statistical features-based constraint term is integrated into the framework of the geometric active contour by replacing the gradient-based stopping term. The proposed algorithm overcomes the limitations associated with the classical geometric active contour of overly relying on the gradient information of image, and the accuracy reducing in boundaries locating due to the Gaussian smoothing to image. The new algorithm is able to adaptively adjust the evolving directions of the fronts, while in the classical geometric active contour the curves can only propagate in one direction and has to be predefined.

Secondly, we propose an improved algorithm of the region-based geometric active contour (RGAC) of Suri. We mathematically prove the stability problem associated with the original RGAC algorithm. Thanks to the new regional term, the improved algorithm solves the underlying stability problem and the sensitivity of the segmentation results to some parameters of the original algorithm. The new algorithm can segment successfully various cerebral tissues (WM, GM and CSF) from different MR images of modalities (T1-, T2- and PD-weighted) with more quick convergence rate. The algorithm is evaluated using both simulated and real MR images. The quantitative analyses demonstrate the feasibility and the effectiveness of the improvement. The comparisons with other algorithms indicate the better segmentation performance of the proposed method. Then, the proposed fuzzy region indicator is extended to the geometric active contour. The fuzzy information derived from the fuzzy clustering analysis provides the global constraint to the proposed algorithm, and guides the curves propagation in both directions. The framework of fuzzy logic, used in the proposed algorithms, allows for ambiguity and uncertainty in MR images by assigning a voxel to all brain tissues with different absolute memberships. The presented approaches take advantages of both FCM and level set methods: fuzzy clustering methods provide the regional information, while the level set method maintains the smoothness of piecewise continuous nature of the tissue regions. The experiments demonstrate that the combination of the FCM and the level set method can effectively improve the segmentation accuracy.

Finally, we present a multiclass segmentation algorithm. The algorithm consists of a set of ODEs, and each one represents one class. A constraint is enforced to discourage the overlap and vacuum between classes. The curvature-based regularized term is removed and the anisotropic diffusion filter is applied to reduce the noise level, as well as to regularize the level set function evolution. This relaxes the stringent time-step restriction imparted by parabolic term, allows to the fast convergence of the algorithm. The algorithm is easy to be implemented. The synthetic image, simulated and real MRI images are applied to evaluate the algorithm. The qualitative analyses, together with the quantitative evaluations on the segmentation results, indicate that the multiclass algorithm has the better segmentation accuracy, and less computational complex, as well as the good robustness to noises.

The used multi-seed initialization enables an automatic segmentation of the cerebral tissues with the lower degree of manual interventions. It facilitates the operation and avoids introducing subjective

factors of the operators. It also speeds up the convergence rate of the algorithm, and decreases the sensibility to initial conditions, avoiding the risk of convergence to local minima.

In conclusion, the contributions of this dissertation include:

1. Propose a histogram-analysis based non-parametric deformable model to segment brain tissues. In the algorithm, the finite mixture model is employed to approximate the normalized intensity histogram of image to be segmented; Expectation Maximization algorithm is applied to estimate the parameters of the Gaussian components. The resulting statistical parameters are used in the level set segmentation phase to generate the constraints function to control the evolution of fronts, whose directions can be adaptively adjusted.
2. Propose an improved region-based geometric active contour algorithm based on the stability analysis of the original algorithm. The proposed algorithm solves the underlying stability problem associated with the original algorithm. The algorithm is extended to segment brain tissues into GM, WM and CSF classes from different MRI images of modalities (T1-, T2-PD-weighted) with high accuracy and less iterative numbers.
3. Present a multiclass segmentation algorithm. The algorithm is formulated as a set of ordinary differential Equations (ODEs). The algorithm may include three steps: anisotropic diffusion filtering, fuzzy cluster analysis to the image, and the level set refine segmentation. The algorithm is easy to be implemented numerically with less computational complexity, and has high segmentation accuracy and good robustness to against noise.
4. Propose a framework of combining FCM method with level set techniques. The fuzzy information provides a global constraint to the curve evolution, guides the directions of the curve evolving. Moreover, the fuzzy logical framework allows for the partial volume effect implicitly, and retains more information than the crisp segmentation algorithm. The level set method makes the segmentation results more smooth and accurate.

The future work includes:

1. Intensity inhomogeneous. The intensity inhomogeneous is introduced by the imperfect radio-frequency coil, which changes the absolute intensities for a given tissue type. The future work should consider the correction of the intensity inhomogeneous while not removing the useful information.
2. Partial volume effect. In our proposed algorithms, we implicitly take into account the partial volume effect by using the FCM method. The future work should explicitly consider the PV problem in case of the MR images with a low spatial resolution.
3. Three-dimensional application. The proposed algorithms are limited to the applications of the two-dimensional intensity images. The insufficient information in the two-dimension image affects the segmentation accuracy in some cases. The next work should extend the current algorithms from two-dimension to three-dimension case.
4. Anatomical structures' segmentation. By segmenting neuron-anatomical structures in digital MRI data, quantitative three-dimensional morphometrics can be used as evidence for diagnosis and for assessing response to treatment. The next work is to segment the anatomical structures, especially the gray matter anatomical structures, which are closely related with some diseases.

## References

- [1] J. P. Hornak. The Basics of MRI. <http://www.cis.rit.edu/htbooks/mri/index.html>
- [2] Haacke, E Mark; Brown, Robert F; Thompson, Michael; Venkatesan, Ramesh (1999). Magnetic resonance imaging: Physical principles and sequence design. New York: J. Wiley & Sons
- [3] M. Kunt. Edge detection: a tutorial review. IEEE ICASSP, 7:1172-1175, 1982.
- [4] J. Canny. A computational approach to edge detection. IEEE Trans. PAMI, 8(6):679-698.
- [5] M. Kass, A. Witkin, and D. Terzopoulos. Snakes: Active contour models. International Journal of Computer Vision, 1(4): 321-331, 1988.
- [6] D. Terzopoulos, K. Fleischer. Deformable models. The Visual Computer, 4(6): 306-331, 1988.
- [7] L. D. Cohen. On active contour models and balloons. CVGIP: Image Understanding, 53(2): 211-218, 1991.
- [8] C. Xu and D. L. Prince. Snakes, Shapes and gradient vector flow. IEEE Trans. On Image Processing, 7(3): 359-369.T.
- [9] T. McInerney, D. Terzopoulos. Deformable models in medical image analysis: a survey. Medical image analysis, 1: 91-108, 1996.
- [10] R. Adams and L. Bischof. Seeded region growing. IEEE Trans. PAMI, 16(6):641-647, 1994.
- [11] S. Horowitz, T. Pavlidis. Picture segmentation by a directed split-and-merge procedure. Proceeding of second international joint conference on pattern recognition, 4:424-433, 1974.
- [12] L. D. Griffin, A. C. F. Colchester, G. P. Robinson, and D. J. Hawkes. Structure sensitive scale and the hierarchical segmentation of grey level images. Proceedings of the SPIE Visualization in Biomedical Computing, 1992:24-32.
- [13] A. K. Jain, R.C. Dubes. Algorithms for clustering data. Prentice Hall, Englewood Cliffs, NJ. 1988.
- [14] J. B. MacQueen. Some Methods for classification and Analysis of Multivariate Observations. Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. 1967: 281-297.
- [15] J. C. Bezdek, L. O. Hall, L. P. Clarke. Review of MR image segmentation techniques using pattern recognition. Med. Phys 20, 1033-1048, 1993.
- [16] A. W. C. Liew, H. Yan. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation. IEEE Tans. On Medical Imaging, 22(9):1063-1075, 2003.
- [17] A. P. Dempster, N. M. Laird, and D. B. Rubin. Maximum likelihood from in-complete data via the EM algorithm. Journal of the Royal Statistical Society: Series B, 39(1):1-38, 1977.
- [18] K. V. Leemput, F. Maes, D. Vandermeulen, P. Suetens. Automated model-based tissue classification of MR images of the brain. IEEE Trans. on Medical Imaging, 18(10): 897-908, 1999.
- [19] W. M. Wells III, W. E. L. Grimson, R. Kikinis, F. A. Jolesz. Adaptive segmentation of MRI data. IEEE Trans. on Medical Imaging, 15(4): 429-442, 1996.
- [20] Y. Zhang, M. Brady, S. M. Smith. Segmentation of brain MR images through a hidden Markov random field model and the expectation maximization algorithm. IEEE Trans. on Medical Imaging, 20(1): 45-57, 2001.
- [21] Z. Liang, J. R. MacFall, D. P. Harrington. Parameter estimation and tissue segmentation from multispectral MR images. IEEE Trans. on Medical Imaging, 13:441-449, 1994.
- [22] S. Osher, J. A. Sethian. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations. Journal of Computational Physics, 79:12-49, 1988.
- [23] F. Gibou, R. Fedkiw. A fast hybrid k-means level set algorithm for segmentation. International Conference on Statistics and Mathematics, pp. 281-291, 2005.
- [24] H. K. Zhao, T. Chan, B. Merriman, S. Osher. A variational level set approach to multiphase motion. Journal of Computational Physics, 22: 179-195, 1996.
- [25] J. A. Sethian. Level set methods and Fast Marching Methods: Evolving interfaces in computational geometry, fluid mechanics, computer vision, and materials science. UK: Cambridge University Press, 1999.

- [26] S. Osher, N. Paragios. Geometric Level Set Methods in Imaging, Vision, and Graphics. Springer, NY, 2003.
- [27] J. S. Suri. White Matter/Gray Matter Boundary Segmentation Using Geometric Snakes: A fuzzy Deformable Model. International Conference on Applicant Pattern Recognition, LNCS2013:331-338, 2001.
- [28] J. S. Suri, K. Liu, S. Singh, S. N. Laxminarayan, et al. Shape Recovery Algorithms Using Level Sets in 2-D/3-D Medical Imagery: A State-of-the-Art Review. IEEE Trans. On Information Technology in Biomedicine, 6(1): 8-28, 2002.
- [29] A. J. Worth, N. Markis, V. S. Caviness, et al. Neuroanatomical segmentation in MRI: technological objectives. International Journal of Pattern Recognition and Artificial Intelligence, 11:1161-1187, 1997.
- [30] V. Caselles, F. Catte, T. Coll, and F. Dibos. A geometric model for active contours. Nemerische Mathematic, 66:1-31, 1993.
- [31] V. Caselles, F. Catte, T. Coll, and G. Sapiro. Geodesic active contours. International Journal of Computer Vision. 22: 61-79, 1997.
- [32] Y. J. Zhang. A survey on evaluation methods for image segmentation. Pattern Recognition Letter. 29:1335-1346, 1996.
- [33] S. Shen, W. Sandham, M. Granat, A. Sterr, MRI fuzzy segmentation of brain tissue using neighborhood attraction with neural-network optimization, IEEE Trans. on Information Technology in Biomedicine, 9(3): 459-467, 2005.
- [34] J. Z. Wang, J. Kong, Y. H. Lu, M. Qi, B. X. Zhang. A modified FCM algorithm for MRI brain image segmentation using both local and non-local spatial constraints, Computerized Medical Imaging and Graphics, 32(8): 685-698, 2008.
- [35] Internet Brain Segmentation Repository: <http://www.cms.mgh.harvard.edu/ibsr/>.
- [36] BrainWeb: Simulated Brain Database, <http://www.bic.mni.mcgill.ca/brainweb/>.
- [37] R. Malladi, J. Sethian, and B. C. Vemuri. Shape modeling with front propagation: A level set approach. IEEE Trans. on Pattern Analysis and Machine Intelligence, 17 (2): 158-175, 1995.
- [38] C. M. Bishop. Pattern Recognition and Machine Learning. Springer, NY, USA, 2006.
- [39] E. Angelini, T. Song, B.D. Mensh, et al. Segmentation and quantitative evaluation of brain MRI data with a multiphase three-dimensional implicit deformable model. SPIE International Symposium on Medical Imaging. San Diego, 2004: 526-537.
- [40] S. Osher, R. Fedkiw. Level set methods and dynamic implicit surfaces. Springer, NY, USA, 2003.
- [41] L. Vese, T. Chan. A multiphase level set framework for image segmentation using the Mumford and Shah model. International Journal of Computer Vision, 50:271-293, 2002.
- [42] D. Mumford, J. Shah. Robust approximation by piecewise smooth functions and associated variational problems. Communication in Pure and Applied Mathematics 42(1):577-685, 1989.
- [43] Koepfler, G., Lopez, C., and Morel, J.-M., 1994. A multiscale algorithm for image segmentation by variational method. SIAM Journal of Numerical Analysis 31(1): 282-299.
- [44] T. Chan, L. Vese. Active contours without edges. IEEE Trans. On Image and Processing, 10(2): 206-277, 2001.
- [45] T. Brox, J. Weickert. Level set segmentation with multiple regions. IEEE Trans. On Image Processing, 15(10): 3213-3218, 2006.
- [46] P. Perona, J. Malik. Scale-space and edge detection using anisotropic diffusion. IEEE Trans. on Pattern Analysis and Machine Intelligence, 12 (1): 629-639, 1990.
- [47] R. Goldenberg, R. Kimmel, M. Rivlin, and M. Rudzsky. Fast Geodesic Active Contour. IEEE Trans. on Image Processing, 10(10):1467-1475, 2001.
- [48] J. Weickert, B. Romeny, and M. Viergever. Efficient and reliable scheme for nonlinear diffusion filtering. IEEE Trans. on Image Processing, 7(3): 398-410, 1998.

**Publications**

- (1) CHEN ZhiBin, QIU TianShuang, Su Ruan. MR Image Segmentation Based on Level Set and Histogram Analysis. Chinese Journal of Biomedical Engineering, 2008 (1).
- (2) CHEN ZhiBin, QIU TianShuang, Su Ruan. FCM and Level Set based Segmentation Method for Brain MR Images. Chinese Journal of Electronics, 2008 (9).
- (3) CHEN ZhiBin, QIU TianShuang, Su Ruan. A brain tissue segmentation approach integrating fuzzy information into level set method. IEEE International Conference on Automation and Logistics 2008, Qingdao, China.
- (4) CHEN ZhiBin, QIU TianShuang, Su Ruan. Fuzzy Adaptive Level Set Algorithm for Brain Tissue Segmentation. IEEE International Conference on Signal Processing 2008, Beijing, China.
- (5) CHEN ZhiBin, QIU TianShuang, Su Ruan. A Multiclass Image Segmentation Using Level Set Method. Submitted to Pattern Recognition Letter.
- (6) CHEN ZhiBin, QIU TianShuang, Su Ruan. A Segmentation Algorithm for Brain MR Images using Fuzzy Model and Level Sets. Submitted to International Journal of Innovative Computing, Information and Control.



---

## 摘 要

本论文的目标是开发自动分割算法，将脑 MRI 图像分割成不同的组织，即脑白质、脑灰质和脑脊液，为脑发育与衰老、有关脑疾病的诊断和治疗、脑外科手术规划和导航等应用提供定量脑测度信息。在本论文中，提出了几个非参数化变形模型和统计信息或模糊信息相结合的算法，从不同模态的 MRI 图像中分割出白质、灰质、脑脊液等脑组织。提出的算法将采用实验的方法进行验证和评估，实验图像包括 T1-加权、T2-加权和 PD-加权仿真和真实的脑 MRI 图像。

论文首先提出了一个基于直方图分析的算法。算法中，用混合高斯模型（mixture Gaussian Model, MGM）来对图像的灰度直方图进行建模，利用期望最大化（Expectation Maximization, EM）算法来估计混合高斯模型中各分量的参数。获得的参数用于产生约束项，以指导水平集曲线的进化，并最终完成脑 MRI 图像的组织分割。用仿真和真实的 MRI 图像对算法进行了评估，论文中提供了 MRI 图像的分割结果，并对分割结果进行了定量评价。

其次，论文提出了一个改进算法，原始算法是由 Suri 提出的基于区域的几何活动轮廓（Region-based Geometric Active Contour, RGAC）模型。基于对 RGAC 算法的稳定性分析，提出了一个新的区域项。新算法解决了原算法存在的稳定性问题。与原算法相比，改进算法的迭代次数明显减少，分割结果对参数的敏感度较低，因而有更好的韧性。算法能够从 T1-加权、T2-加权和 PD-加权等不同模态的 MRI 图像中分割出白质、灰质、脑脊液脑组织。算法用 10 个 MRI 仿真图像和 5 个真实 MRI 数据集进行评估，与其它算法的分割结果进行了比较，验证了算法改进的可行性和有效性。算法中采用的模糊区域指示子函数被推广应用到模糊自适应水平集算法中，它是几何轮廓模型的一个改进算法。在曲线进化过程中，算法能够自适应地调整曲线进化的方向，达到快速收敛的目的。同时也克服了经典活动轮廓模型算法对图像的梯度信息过度依赖，因高斯平滑造成的边界定位精度下降的问题。文中通过仿真 MRI 图像和真实的 MRI 图像对算法进行了评估。

论文最后提出了一个多类算法来分割脑组织。算法由一组常微分方程组成，一个组织类别由一个水平集函数表示。算法包括各向异性扩散滤波、模糊分割以及水平集分割方法等三个主要阶段组成。与现存的多相算法相比，多类算法降低了计算复杂度，能够以更快的速度收敛。算法用人工合成图像、20 幅仿真 MRI 图像和一个真实 MRI 图像集进行了评估。与其它算法相比，多类算法有更好的分割性能和噪声鲁棒性。

---

算法中采用的模糊逻辑，考虑了 MRI 图像中脑组织的模糊性和不确定性，与硬分割算法相比，能够包含更丰富的信息。与水平集方法相结合，有利于提高算法的性能和韧性。

**关键词：**分割；水平集；多类；变形模型；模糊分析；脑 MRI；模糊逻辑

---

# 目 录

摘 要.....	I
1 绪论.....	1
1.1 课题的提出与意义.....	1
1.2 国内外进展.....	3
1.3 研究内容与章节安排.....	4
1.3.1 研究内容.....	4
1.3.2 章节安排.....	4
2 MRI 图像分割与评估准则.....	6
2.1 概述.....	6
2.2 脑部磁共振成像.....	6
2.3 脑 MRI 图像分割方法综述.....	8
2.3.1 基于边缘的分割算法.....	8
2.3.2 基于区域的分割算法.....	9
2.3.3 基于聚类的算法.....	11
2.3.4 基于水平集的算法.....	16
2.3.5 其它分割算法.....	17
2.4 变形模型.....	18
2.4.1 参数化变形模型.....	18
2.4.2 非参数变形模型.....	21
2.5 算法评估准则与分割指标.....	28
2.5.1 算法评估准则.....	28
2.5.2 分割指标.....	29
2.6 本章小结.....	30
3 基于直方图分析的非参数化变形模型.....	31
3.1 概述.....	31
3.2 混合高斯模型及参数估计.....	32
3.2.1 混合高斯模型.....	32
3.2.2 EM 算法.....	33
3.3 基于直方图分析的非参数化变形模型.....	35
3.3.1 直方图分析.....	36

---

3.3.2	高斯分布参数估计 .....	36
3.3.3	几何活动轮廓模型 .....	36
3.3.4	模型的改进 .....	37
3.4	算法实现 .....	38
3.5	实验结果 .....	39
3.6	本章小结 .....	43
4	基于区域的非参数变形模型 .....	45
4.1	概述 .....	45
4.2	基于区域的几何活动轮廓模型 .....	46
4.3	存在问题与算法改进 .....	48
4.3.1	存在问题 .....	48
4.3.2	稳定性分析与改进 .....	48
4.4	算法实现 .....	50
4.4.1	空间离散 .....	50
4.4.2	时间离散 .....	51
4.5	实验结果 .....	52
4.5.1	T1-加权图像分割实验 .....	53
4.5.2	PD-和 T2-加权图像分割实验 .....	55
4.5.3	真实 MRI 图像分割实验 .....	56
4.6	模糊自适应非参数变形模型 .....	63
4.6.1	算法描述 .....	63
4.6.2	实验结果 .....	64
4.7	稳定问题与多初始化 .....	67
4.7.1	算法的稳定性问题 .....	67
4.7.2	模糊分割与水平集结合 .....	67
4.7.3	多种子初始化 .....	68
4.8	本章小结 .....	68
5	多类算法在 MRI 脑组织分割中应用 .....	69
5.1	概述 .....	69
5.2	Mumford-Shah 泛函 .....	70
5.3	Chan-Vese 模型 .....	71
5.4	Chan-Vese 多相模型 .....	73

---

5.5	多类分割算法	76
5.5.1	FCM 算法	76
5.5.2	二类算法	77
5.5.3	多类算法	78
5.5.4	各向异性扩散滤波	79
5.6	实验结果	83
5.6.1	合成图像分割实验	84
5.6.2	仿真 MRI 图像分割实验	86
5.6.3	真实 MRI 图像分割实验	89
5.7	算法比较与问题讨论	92
5.8	本章小结	94
6	结论与展望	95
6.1	结论	95
6.2	未来工作	96
	参考文献	98
	攻读博士学位期间发表学术论文情况	109
	致 谢	110
	Résumé	111

---

# 1 绪论

## 1.1 课题的提出与意义

图像分割就是根据某种均匀性的原则，把图像分割成若干个有意义的区域，使得每一个区域都符合某种一致性的要求，并提取感兴趣目标的技术和过程，是实现从图像处理到分析，进而完成图像理解的关键步骤。这些一致性或均匀性可以是像素的灰度、颜色、纹理等特性，而感兴趣的目标可以是单个区域，也可以对应多个区域。图像分割用数学语言可以描述如下<sup>[1]</sup>：

令 $\Omega$ 代表整个图像区域，对 $\Omega$ 的分割可看作将其分成 $N$ 个满足下列条件的非空子集 $R_1, R_2, \dots, R_N$ 的过程：

(1)  $\bigcup_{i=1}^N R_i = \Omega$ ，即各子区域合集应等于原图像、每个像素都被分配到一个子区域中；

(2)  $R_i \cap R_j = \emptyset, \forall i, j, \text{且} i \neq j$ ，即任意两个子区域互不重叠；

(3)  $P(R_i) = \text{True}, \forall i$ ，即同一个子区域的像素具有相同的特性；

(4)  $P(R_i \cup R_j) = \text{False}, \forall i, j, \text{且} i \neq j$ ，即不同子区域的像素具有不同的特性；

(5)  $R_i$ 是连通区域， $\forall i$ ，即同一个子区域的任意两个像素在本子区域内相互连通。

医学成像技术的快速发展带来了医学的革命性的进步。医学成像技术可以通过非侵入的方式呈现人体内部结构，研究人员和内科医生通过它能够获取挽救生命的潜在的信息。目前的医学成像任务已经超越了简单的可视化和解剖结构的检查，已经成为制定外科手术计划和模拟、手术导航、放射治疗计划以及跟踪疾病发展必不可少的工具。例如，通过术前确切了解解剖结构的详细形状和组成，外科医生可以制定一个最佳的手术方案。在放射治疗中，放疗师通过医学成像技术传递一定量的辐射到肿瘤部位时，能够使辐射对健康组织的损害减小到最低。

随着医学成像在疾病诊断和治疗中发挥越来越突出的作用，医学图像分析的研究人员不得不面对从CT, MR, PET, US等模态图像中提取解剖结构临床信息的巨大挑战。尽管现代成像设备能够提供内部解剖结构的异常视角，但是，利用计算机来量化和分析内部解剖结构的准确性和效率依然是有限的。必须提取有效、准确、可重复、定量的信息，为疾病诊断、放射治疗以及外科手术等广泛的生物医学研究和临床活动提供支持。

---

磁共振成像（MRI）是现代重要的医学成像技术，能够提供丰富的人体软组织解剖信息，具有其它影像设备无法比拟的优势，在临床应用中扮演越来越重要的角色。这些优势主要体现在以下几个方面：

- （1）高的空间分辨率和良好的组织辨别力；
- （2）通过调整成像参数能够提供丰富的诊疗信息；
- （3）通过调整磁场可以获取任意方位断层；
- （4）对人体没有电离辐射损伤。

MRI 在医学诊断中具有广泛应用，特别是对头部的应用最为广泛，如脑肿瘤，多发性硬化症、脑炎，脑损伤、脑出血、阿尔茨莫尔（Alzheimer）和脑水肿（hydrocephalus）等疾病以及脑发育和衰老的研究等。许多文献特别专注于头部 MRI 图像的分割，该领域的研究目标包括：

- （1）提取大脑；
- （2）脑组织分割，包括白质、灰质和脑脊液；
- （3）脑结构分割，如海马体，胼胝体等脑结构。

在 MR 脑片中提取大脑是个难题，对于 T1 加权图像尤其困难。然而，在分割其它结构、组织之前，提取大脑通常又是必须的步骤。提取大脑的难题在于脑组织和非脑组织之间灰度重叠，而且在空间上也经常是相互连接的。一个解决方法是在预分割阶段允许损失一部分脑组织，然后通过形态学滤波器恢复这些组织<sup>[2,3]</sup>。多数方法<sup>[4-6]</sup>最后一个处理步骤选择用变形模型。基于图谱（Atlas）的方法也可用来分割脑组织<sup>[5]</sup>。

脑组织分割中通常使采用 T1 加权图像<sup>[7-9]</sup>或者多谱图像<sup>[10-13]</sup>。T1 加权图像在不增加图像采集时间的情况下，能够提供高的分辨率，且能保持良好的组织对比度和低的噪声，因而被众多的文献优先采用。分割脑组织的方法包括了分类器方法，聚类方法，神经网络方法，和 Markov 随机场等方法。这些方法大多数是基于灰度信息的方法，这类方法考虑的主要是灰度不均匀（Intensity Inhomogeneities）问题。由于灰质结构上细小、且高度缠绕，需要考虑的另一个问题是部分容积效应问题（Partial Volume Effect, PVE）。对部分容积效应进行建模常用的方法有统计方法<sup>[14-17]</sup>，软分割<sup>[18-21]</sup>、线性滤波器<sup>[22]</sup>等方法。

脑结构的分割是形态测度分析研究的重要领域。大脑皮层的分割已经引起了许多关注，提出了许多算法，大多数方法采用了变形模型<sup>[23-26]</sup>。用变形模型方法来分割诸如脑室<sup>[27,28]</sup>、胼胝体<sup>[28,29]</sup>、海马体<sup>[30,31]</sup>等<sup>[32-34]</sup>脑结构。尽管基于图集的方法不常用来分割脑皮层，但是，该方法还是非常适合于分割如脑室<sup>[35, 36]</sup>和海马体<sup>[37]</sup>等皮下脑结构。从 MRI 图像中分割脑肿瘤采用的方法包括了神经网络<sup>[38]</sup>、线性滤波器<sup>[22]</sup>、模糊区域生长<sup>[39]</sup>等。

---

在脑 MRI 图像中普遍存在的组织边界模糊不清晰、不确定特性，以及组织结构形状的复杂性和个体之间的差异和多样性，加之伪影、空间混叠、噪声、部分容积效应、偏置场等因素的影响，要准确分割这些脑组织变得越发困难，现有的分割算法远没有达到理想的效果。因此，医学图像分割算法的研究仍然是当前图像处理和分析的热点。

非参数变形模型能够适应解剖结构随时间和不同个体的易变性，因而能够分割、匹配和追踪解剖结构目标，并能够同时考虑来自图像的约束和关于解剖结构位置、大小以及形状的约束。本文着重研究基于非参数化变形模型的脑部 MRI 图像组织分割算法。在本文呈现的算法中，将模糊聚类算法（Fuzzy c-means, FCM）和期望最大化算法（Expectation Maximization, EM）集成到非参数化变形模型框架中。利用了 FCM 和 EM 分析提供的全局信息，来提高算法的分割准确度和噪声鲁棒性。

在本文的研究中，实验采用的图像包括 T1-, T2-, 和 PD-加权 MRI 图像。

## 1.2 国内外进展

Clark 等人<sup>[40,41]</sup>自从 1993 年以来，一直致力于基于知识的 MRI 图像的自动分割方法的研究。他们首先利用非监督的 FCM 算法对 MRI 图像进行初始分割，然后利用图像匹配技术对初始分割的结果进行再聚类(re-clustering) 和标记(labeling)。算法中采用了临床和解剖学方面的有关知识，利用临床知识获取脑组织在特征空间中的聚类分布，利用解剖学知识选取匹配模板。

加拿大 McGill 大学的 McConnell 脑成像中心，致力借助于计算机，利用 MRI 图像进行解剖脑映射和定量的脑分析研究。为了便于定量地验证算法，他们建立了仿真脑数据库。数据库能够提供 20 个脑仿真数据集，并提供离散脑模型和模糊脑模型<sup>[42]</sup>。该中心在脑 MRI 领域享有很高的声誉，数据集被众多研究者广泛采用。

伦敦学院大学（University college London）的神经医学院开发了一套称之为统计参数映射（Statistical Parameters Mapping, SPM）的软件系统<sup>[43]</sup>，用于对 MRI 图像、fMRI 图像、PET/SPECT 图像以及 M/EEG 信号的分析。该软件系统在概率框架下，将图像配准、组织分类和偏置场校正有机地结合在一起。

谢逢等描述了一种基于知识的三维 MRI 图像的自动分割显示方法，完成脑组织的自动分割及显示。系统包含动态模块及静态模块两部分：静态模块即人脑知识库，存贮脑内各组织形态、生理及图象灰度方面的知识；动态模块包含全局数据区、图象处理算子集和控制规则集。在知识的指导下，运用“智能光线跟踪”方法提取、显示脑内主要解剖结构<sup>[44]</sup>。



---

第一军医大学的陈武凡教授课题组也一直致力于脑部 MRI 图像的分割和三维重建方面的研究，他们利用 Markov/Gibbs 随机场理论等进行建模，实现脑组织和脑肿瘤的分割<sup>[45]</sup>。

### 1.3 研究内容与章节安排

#### 1.3.1 研究内容

本文中采用非参数变形模型对脑组织进行分割，目标图像包括 T1-、T2-和 PD-加权模态的 MRI 图像。本文的研究内容主要包括：

- (1) 对 MRI 图像的灰度分度，利用有限混合高斯模型 (Mixture Gaussian Model, MGM) 进行建模；采用非参数化的方法对混合高斯模型参数进行估计；利用估计获得参数生成约束项，指导水平集曲线的进化，最终完成脑组织的分割。
- (2) 针对基于区域的几何活动轮廓模型 (Region-based geometric active contour, RGAC)，提出一种改进算法。解决原始算法中存在的稳定性问题以及对初始条件敏感的问题等。扩展算法到从多种模态图像中分割不同的脑组织，包括灰质、白质和脑脊液。
- (3) 提出一种自适应水平集算法，来分割脑组织。首先对图像进行模糊聚类分析；将获得的模糊信息融合到非参数变形模型中。
- (4) 提出一种 MRI 图像的多类算法。算法由一组常微分方程构成，每个方程对应一个类别的目标。降低算法的计算复杂度，提高算法收敛速度。算法能够提高分割结果的准确度，同时，具有良好的噪声鲁棒性。

#### 1.3.2 章节安排

根据以上研究内容，本文各章节内容安排如下：

第一章 介绍了医学图像分割的意义，回顾了 MRI 图像分割方面国内外研究的进展情况，然后给出了本文主要的研究目标和研究内容。

第二章 首先介绍了 MRI 成像技术及其在诊疗中的应用，对 MRI 图像的分割算法进行了回顾，将现有算法分为基于边界、基于区域、基于聚类、基于水平集和其它算法等类别分别进行介绍。最后介绍了分割算法的评价方法和本文评价算法性能的定量指标。

第三章 介绍了一种结合直方图分析的非参数化变形模型算法。算法首先对待分割图像的直方图进行分析，通过 EM 算法估计混合高斯模型的参数，获得的参数来指导和控制水平集的进化，以完成 MRI 图像的分割。

---

第四章 提出了一种改进的基于区域的几何活动轮廓模型。通过稳定性分析，证明了原始算法存在的问题。提出了一个新的区域项，解决了原始算法存在的稳定性方面的问题，并将算法扩展到从不同模态的 MRI 模态图像中分割出不同的组织类别。

第五章 提出了一种 MRI 脑部图像的多类分割算法。算法由滤波预处理、模糊分析和水平集分割等阶段构成。将模糊分割与水平集方法相结合，使得算法既保持了 FCM 算法的简单和有效性，又得益于水平集方法的鲁棒性。算法提高了分割的质量，加快了收敛速度。

第六章 对本文进行了总结，对未来的工作进行了展望。

---

## 2 MRI 图像分割与评估准则

### 2.1 概述

由于大脑结构是由组织的边界定义的，对脑组织进行分割、对颅脑进行定量形态学的分析是至关重要的。精确的脑组织分割有利于以下几个方面应用的研究：（1）探测影响脑实质的不同病理条件；（2）放疗计划的制定；（3）外科手术计划的制定和仿真；（4）脑结构的 3D 可视化和定量测量；（5）研究人脑的发育和老化机理；6）对大脑进行功能性研究<sup>[46]</sup>。另外，在对诸如老年性痴呆、多发性硬化症以及精神分裂症等退化脑疾病的研究中，除了研究灰质、白质、白质损伤和脑脊液的空间分布以及临时改变意外，对这些组织的精确测量也是必不可少的。许多神经性疾病改变了人脑组织（白质、灰质）、脑脊液的正常体积及其区域的分布<sup>[47]</sup>，这些即便通常与脑水肿的病情、脑萎缩以及肿瘤的生长有关。要对这些疾病做出准确的诊断，也必须对人脑的有关组织进行定量测量和分析。

本章首先简单回顾磁共振成像技术，以及脑成像中常用的三种模态图像（T1-、T2-和 PD-加权 MRI 图像）。然后简单回顾脑部 MRI 图像的分割算法，这些算法大致可以划分为基于边界、基于区域、基于聚类、基于水平集和其它类别。最后简单介绍了图像分割算法评价方法和本论文中用到的定量指标。

### 2.2 脑部磁共振成像

磁共振成像是一种安全、无损的医学成像技术，可以提供人体内部组织的高对比度和高分辨率的医学图像，是基于核磁共振（Nuclear Magnetic Resonance, NMR）原理的一种灵活的成像技术，能够提供详细的解剖结构信息。采用不同的成像序列可以提供组织间不同的对比度，以突出显示被成像的不同组织，产生不同模态的二维和三维图像。不同的成像序列包含不同的射频、不同梯度脉冲和不同的弛豫时间（Relaxation timings）。

由于能够区分不同的软组织，因此磁共振成像技术非常适合脑组织的成像，如灰质，白质和脑脊液等。临床上常用的脑 MRI 图像有 T1-加权、T2-加权和 PD-加权成像模态。在一个典型的图像采集过程中，每个成像序列（90 度脉冲，180 度脉冲，图像检测）重复多次。通过调整回波时间（Echo Time, ET）和/或重复时间（Repetition Time, TR，也即连续的 90 度脉冲之间的时间间隔），可以改变或加权被成像组织的对比度。在固定磁场强度下，不同的组织有不同的 T1 时间常数（纵向弛豫时间），但是 T1 时间常数与磁场强度有关；不同的组织也有不同的 T2 时间常数（横向弛豫时间），但是 T2 时间常数与磁场强度无关。因此相同的组织在不同的成像模态下具有不同的灰度值，从而产

---

生不同对比度的 MRI 图像。例如，用长的 TE，组织 T2 时间的固有差别将变得明显。T2 时间常数长的组织（比如水）需要长的衰减时间，因而它在图像中比 T2 时间常数短的组织（如脂肪）明亮。TR 以相同的方式调整 T1 对比度。拥有长 TR 的组织需要长的时间恢复到平衡磁场状态，因而短 TR 的组织与时间常数 T1 短的组织相比显得较灰暗。当 TR 和 TE 时间都选择减小 T1 和 T2 权值，则信号对比度由组织的质子数或质子密度确定，这就是所说的 PD-加权。

概括来说：

取 TR 时间远大于被成像组织的 T1 值，TE 约等于组织的 T2 值时，获得 T2-加权图像。T2-加权图像主要受组织的 T2 时间常数影响，有利于显示病变本身的情况，但其信噪比较低，图像质量略差。

取 TR 时间约等于成像组织的 T1 值，TE 远小于组织的 T2 值时，获得 T1-加权图像。T1-加权图像除了与质子密度有关外，主要与组织的 T1 值有关，有利于显示组织的解剖结构，而且信噪比较高，图像质量较好。

取 TR 值远大于 T1 值，TE 远小于组织的 T2 值时，获得 PD-加权图像。质子密度加权图像信噪比较高，图像质量较好。但由于各器官组织水含量相差较小，故图像对比度较差。

图 2.1 中给出了 T1-，T2-和 PD-加权 MR 示例图像。从图中可以看出同一组织在不同的模式下呈现出不同的灰度值，以及不同组织间对比度的变化。

临床上根据应用的不同，选择不同的成像模态，或者多个模态结合使用。




图 2.1 不同模态 MRI 示例图像（从左到右：T1-，T2-和 PD-加权 MRI 图像）

Fig. 2.1 Examples of different modalities MRI images (From left to right: T1-, T2-, and PD-weighted)

---

## 2.3 脑 MRI 图像分割方法综述

从 MRI 成像技术出现并且被用于临床实践中开始，便不断有 MRI 图像分割算法涌现出来。这些算法或者利用不同的图像特征，或者采用不同的技术方法。本文根据采用的技术特点，将脑部 MRI 图像分割方法大致划分为基于边界，基于区域，基于聚类和基于水平集和其它等几个类别，然后分别进行介绍。

### 2.3.1 基于边缘的分割算法

基于边缘检测的图像分割方法通过检测相邻像素特征值的突变来获得不同区域之间的边缘。图像中的边缘可以分为阶跃式边缘和屋脊式边缘两种。阶跃式边缘是由图像中局部区域灰度值变化最剧烈的点构成的，而屋脊式边缘是图像中灰度的极值点构成的。一般而言，阶跃式边缘反映的是图像中不同区域的边界，而屋脊式边缘则反映的是图像中的点状结构。

通常通过各种边缘算子对边缘进行检测，这些边缘算子大致可以划分为一阶微分边缘算子和二阶微分边缘算子<sup>[48]</sup>。一阶微分算子利用的是图像的一阶导数在边缘处取得极大值而在屋脊式边缘处为零的特性，二阶微分算子利用的是二阶导数在阶跃式边缘处是零，而在屋脊式边缘处取得极大值的特性。常用的算子中，Robert 算子、Sobel 算子等属于一阶微分算子，而 Laplacian 算子、LOG 算子、Canny<sup>[49]</sup>算子属于二阶微分算子。

边界拟合的方法是另外一种基于边缘的分割方法。在边缘模型已经建立的情况下，可以设计相应的理想边缘曲线对实际边缘进行拟合，以确定边缘的位置。这种方法的优点是算法得到的是连续的边缘曲线。常用的拟合函数有  $n$  阶多项式、分段线性函数等。曲面拟合方法的精度可以达到亚像素级，但是用于拟合的曲面函数的选择非常关键。Staib 和 Duncan<sup>[50]</sup>采用傅立叶参数模型来描述曲线，作者用该方法来从 MRI 图像中分割胼胝体。

近年来兴起的活动轮廓模型或者称 Snake 模型<sup>[51]</sup>，也属于一种基于边缘的分割模型。活动轮廓模型又通常划分为参数化模型和非参数化模型。非参数化模型又称几何活动轮廓模型或几何变形模型，本文将其归为基于水平集的算法之中，以突出其能够灵活应对拓扑结构变化的特点。Snake 模型在肿瘤等分割中得到较多的应用。Luo 等<sup>[52]</sup>提出了一个具有两个外作用力的算法，来分割脑部肿瘤。Xu 等<sup>[53]</sup>在经典 Snake 模型基础上，提出了梯度矢量流模型，使得进化曲线能够深入到深度凹陷的结构之中。算法需要人工放置初始化曲线。上述两个算法中都加入了气球力，以调提高算法的捕获范围，同时加快算法的收敛速度。Jiang 等<sup>[54]</sup>提出了分割和量化肿瘤的算法，但是算法初始化需要人工干预，初始化曲线/表面需要放置在肿瘤内部或者外部。

---

基于边缘检测的方法定位精度比较高，但是易受噪声因素的影响。对于医学图像而言，仅仅利用边缘检测的分割技术是难以达到要求的目标。

### 2.3.2 基于区域的分割算法

基于区域的图像分割方法是利用隶属于同一区域内部的均匀性，依照共同的图像属性来划分图像区域。分割的目的就是把图像中的每个像素都赋予一个类别的属性，使得具有预先定义属性的像素都聚集在同一个类别之中。

在医学图像中，属于同种组织的图像区域通常具有相似的灰度值和纹理等特性。基于区域的分割方法就是通过识别具有相同特性的组织区域来分割图像的。基于区域的分割方法利用了图像空间的邻域像素相互关系。常用的基于区域的分割方法有门限法、区域生长法、分裂和合并法、分水岭法、和基于 Markov 随机场的方法等。

灰度门限法是最常见的直观检测区域的分割方法。它是基于模型的方法：假设图像由具有单峰灰度分布的目标和背景组成，在目标和背景内部的相邻像素间的灰度值是高度相关的，但在目标和背景交界处两边的像素在灰度值上有很大的差别。这类图像用阈值法可以获得较好的分割。Ganser 等<sup>[55]</sup>提出了一个门限法来分割皮下结构。Shan 等人<sup>[56]</sup>通过直方图来选择门限，结合形态学算子后处理的方法来分割全脑。Jack 等人<sup>[57]</sup>提出了基于直方图的门限法来分割 FLAIR 图像。灰度门限法中的阈值选择非常关键。近年来，许多方法借用了神经网络、模糊数学、遗传算法、信息论等工具<sup>[58]</sup>，来提高分割的准确度。

区域生长法是另一种常用的基于区域的分割算法，其基本思路是利用生长规则，将具有相似性质的像素集合起来构成区域<sup>[59,60]</sup>。该方法首先要选取一个种子像素，然后依次将种子周围的相似像素依据生长规则合并到种子像素所在的区域中。将这些像素当作新的种子点继续进行上面的分割过程，直到没有满足条件的像素被包括进来。分割过程中，生长规则控制着区域的生长过程。因而，如何确定一个合适的相似性准则在区域生长算法中是非常重要的。Heinonen 等<sup>[61]</sup>提出了一种半自动的区域生长技术来分割 MRI 图像中的病理组织。Tamez-Pena 等<sup>[62]</sup>提出了一种统计区域生长算法，算法先估计每个像素所在区域的统计均值和标准差，最后的生长参数通过最小化目标函数来确定，并利用分离和合并算法来提高 MRI 图像的分割质量。Pohle 等<sup>[63]</sup>提出了一种自适应的区域生长算法，相似性是通过自学习的方法获得的。基于区域生长的图像分割技术虽然受噪声影响较小，但容易产生过分割，而且边缘定位也不准确。

分裂和合并算法是将整个图像作为原始分割结果，只要当前的分割保证足够的均匀性，就将其继续分裂，而将具有足够相似性的小区域进行合并。Manousakas 等人将分裂和合并方法用于 MRI 图像的分割<sup>[64]</sup>。

---

分水岭算法是居于数学形态学的一种区域分割算法。在分水岭算法中，图像的灰度被看成高度，这样一幅图像就变成了地形地貌图，高度显著变化的地方对应要提取的边界点。算法首先去确定地形中的局部极小值点，并假设在每个局部最小值点刺穿一个小孔，然后把地形图匀速侵入一个湖中，湖水开始从局部极小值的小孔注入，形成水库。为了防止两个不同的局部极小值点对应的水汇聚到一起，在它们的连接处建起一个水坝。当地形完全被侵入湖面一下时，那些水坝就构成了分水岭。结果就是产生了有水坝分割的许多汇水盆，这些水坝，也即分水岭，就是所要的分割结果<sup>[65]</sup>。分水岭算法的缺点是图像的过分割问题，也即产生过多的小区域，而感兴趣的区域难以分辨<sup>[66]</sup>。减少过分割的方法就是在图像分割之前，用各项异性滤波器对图像进行处理。在获得分水岭分割的初始结果后，利用合并的方法将这些汇水盆依据某种规则进行合并处理，得到最后的分割结果。Sijber 等人<sup>[67]</sup>、Bueno 等人<sup>[68]</sup>、Grau 等人<sup>[69]</sup>分别将分水岭算法应用于 MRI 图像的分割。

Markov 随机场 (Markov Random Field, MRF) 模型本身不是一种分割算法，而是一个统计模型，可以用在分割方法之中。Markov 随机场模拟一个像素的邻域和附近像素的相互关系。它能够模拟图像的不同属性和特点，为局部的约束关系提供了机制。在医学图像中，Markov 随机场通常被用来考虑这样一个事实，即大多数像素和它的邻域像素一样属于同一个类别。这预示仅仅包含一个像素的解剖结构在 MRF 假设下发生的概率非常的小。MRF 用于图像分割的中心思想是从 Markov 随机场的角度对图像进行建模，把图像的像素点看作符合某种联合概率密度分布的随机变量，并估计出具有最大后验概率的分布。D. Geman 和 S. Geman 提出了图像和统计力学系统之间的相似性<sup>[70]</sup>。物理系统的能量函数给定之后，Gibbs 分布便确定了。Hammerilei-Clifford 定理<sup>[71]</sup>指出了 Markov 场和 Gibbs 场之间的等价性，所以给定了能量函数也就确定了图像的 Markov 模型。MRF 模型用概率描述图像像素之间的相互关系，任意一个像素属于某一特定状态的概率完全取决于其相邻像素的概率。

基于 MRF 的处理方法广泛应用于 MRI 图像的分割之中<sup>[72-77]</sup>。Wells 等人<sup>[72]</sup>将图像分割和偏置场估计嵌入到贝叶斯估计框架中，利用期望最大化 (Expectation Maximization, EM) 算法进行图像分割和偏置场估计，用递归的方法来分割脑组织，同时对偏置场进行估计和校正。该方法没有考虑像素间的空域关系，对噪声的抑制能力有限。Held 等<sup>[73]</sup>改进了 Wells 的算法，利用 MRF 模型来引入邻域像素的约束。利用非参数估计方法 Parzen 窗方法估计灰度值的概率分布，用 MRF 模拟偏置场。Leemput 等人<sup>[74]</sup>利用数字脑图谱 (Atlas) 的先验概率信息来构建不同组织的概率密度模型，用有限混合高斯模型结合 MRF 模型来描绘图像，用四阶多项式参数模型表示偏置场，用最小二乘法来估计多项

---

式的参数。整个算法由图像分割、偏置场估计和脑组织概率密度估计三个步骤组成。Rajapakse<sup>[8]</sup>也采用了高斯混合模型来表示脑组织的灰度值分布，将组织概率模型的均值看成是在空间缓慢变化的函数，来表达同种组织内有生理原因导致的灰度值变化；由偏置场导致的灰度值变化，以相同的方式改变组织概率模型的均值和噪声的方差。算法中用 3D MRF 做为先验，模拟组织区域内灰度值光滑分段连续的特点。类似的方案也在 Desco 等人<sup>[75]</sup>的工作中可以看到。Zhang 等提出用隐含马尔可夫随机场（Hidden MRF, HMRF）模型来代替有限混合模型，将 HMRF 模型和 EM 算法结合起来分割脑组织<sup>[76]</sup>。最近，Solomon 等也提出了一个类似的方法来分割全增强的肿瘤<sup>[77]</sup>，隐含马尔可夫随机场模型嵌入到 EM 算法之中，来改善分割质量。

基于 MRF 的方法通过随机场模型引入了空域约束，但它存在边缘定位不准确，优化处理复杂，计算量大的缺点。

### 2.3.3 基于聚类的算法

聚类(Clustering)是按照某种相似性准则，将待处理的数据集或分为若干个类或簇(Cluster)的过程。划分到同一类中的数据应具有尽可能大的相似性，而分到不同类别中的数据相异性也尽可能大。也即把属于同一类的数据对象尽可能地聚集在一起，而属于不同类的数据尽可能地分离。

为了将数据空间中数据点进行分类，就要确定数据点之间关系，相似性测度用来度量它们之间的关系。常用的两类相似性测度：（1）距离，即计算任意两个数据点之间的距离，距离越小说明这两点越相似。把距离较近的点归为一类，距离较远的数据点归为不同的类。常用的距离测度有明氏（Minkowski）距离和马氏（Mahalanobis）距离。

（2）相似系数，利用相似系数度量数据之间的相似程度，越相似的数据点，它们的相似系数越接近于 1；而差别较大的数据点，它们的相似系数越接近于零。把较相似的数据点归为一类，把差别较大的数据点归为不同的类。数据点之间的相似系数通常包括夹角余弦和相关系数。

常用的聚类方法有 K-均值（K-Means）、模糊 C-均值（Fuzzy C-Means, FCM）、期望最大值（Expectation Maximization, EM）算法和分层聚类技术。

#### （1）K-均值算法

K-均值算法以 K 为参数，把 n 个样本对象划分为 K 个聚类，使类内具有较高的相似度，而类间相似度较低。相似度是根据一个簇中样本对象的平均值即聚类的质心来进行计算的。算法的处理过程如下：首先，随机选取 K 个对象作为初始的聚类质心；然后，将其余对象根据与各个聚类中心的距离分配到最近的聚类中；最后，重新计算各个聚类



的质心。这个过程不断重复，直到目标函数最小化为止。通常采用的目标函数形式为误差平方和准则函数：

$$J_e = \sum_{i=1}^K \sum_{x \in C_i} \|x - m_i\|^2 \quad (2.1)$$

其中  $x$  为样本对象， $m_i$  是聚类  $C_i$  的质心，聚类  $C_i$  中的样本数为  $N_i$ ，即：

$$m_i = \frac{1}{N_i} \sum_{x \in C_i} x \quad (2.2)$$

$J_e$  度量了用  $K$  个聚类中心  $m_1, m_2, \dots, m_K$  代表  $K$  个样本子集  $C_1, C_2, \dots, C_K$  时所产生的总的误差平方。

对于不同的聚类， $J_e$  的值当然是不同的，使  $J_e$  极小的聚类是误差平方和准则下的最优结果。当结果聚类是密集的，而聚类和聚类之间区别明显时，它的效果较好。面对大规模数据集时，该算法是相对可扩展的，并且具有较高的效率。通常情况下，算法可以终止于局部最优解。

但是， $K$ -均值算法只是在聚类的平均值被定义的情况下才能使用。其次，算法要求聚类数  $K$  是预先知道的。显然，这在某些应用中是不合实际的。另外， $K$ -均值算法不适应于非凸形状的聚类，或者大小差别很大的聚类。最后，它对于噪声和孤立样本点比较敏感<sup>[78]</sup>。

## (2) FCM 算法

实际中应用最为广泛的是模糊  $C$ -均值算法 (Fuzzy C-Means, FCM)。FCM 算法最先由 Dunn<sup>[79]</sup> 提出，后经 Bezdek 改进，并证明了它的收敛性<sup>[80,81]</sup>。

### ① 算法原理

定义  $\{x_i, i=1, 2, \dots, n\}$  是  $n$  个样本组成的样本集， $C$  为预定的分类数目， $m_j$  为每个聚类的中心， $\mu_j(x_i)$  是第  $i$  个样本对于第  $j$  类的隶属度函数。用隶属度函数定义的目标函数可以写为：

$$J_{FCM} = \sum_{j=1}^K \sum_{i=1}^n [\mu_j(x_i)]^p \|x_i - m_j\|^2 \quad (2.3)$$

其中常数  $p > 1$ ，控制聚类结果的模糊程度。

隶属度函数要求满足：

A. 对于任意的  $j$  和  $i$ ， $\mu_j(x_i) \in [0, 1]$

B. 对于任意的  $i$  ,  $\sum_{j=1}^C \mu_j(x_i) = 1$

C. 对于任意的  $j$  ,  $0 < \sum_{i=1}^n \mu_j(x_i) < n$

在上述条件的约束下, 求目标函数的极小值, 令  $J_{FCM}$  对聚类中心  $m_j$  和隶属度函数  $\mu_j$  的偏导数分别为零, 可得如下计算公式:

$$m_j = \frac{\sum_{i=1}^n [u_j(x_i)]^p x_i}{\sum_{i=1}^n [u_j(x_i)]^p}, \quad j = 1, 2, \dots, C, \quad (2.4)$$

$$\mu_j(x_i) = \frac{1 / (\|x_i - m_j\|^2)^{1/(p-1)}}{\sum_{l=1}^C 1 / (\|x_i - m_l\|^2)^{1/(p-1)}}, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, C. \quad (2.5)$$

用迭代方法求解式 (2.4) 和 (2.5), 算法步骤如下:

- A. 设定聚类数目  $C$  和参数  $p$ ;
- B. 初始化各个聚类中  $m_j$ ;
- C. 重复下面的运算, 直到各个样本的聚类中心稳定:
  - a. 用当前的聚类中心计算隶属度函数;
  - b. 用当前的隶属度函数更新计算各聚类中心。

当算法收敛时, 就得到了各类的聚类中心和各样本分属于不同类别的隶属度值, 从而完成了模糊聚类划分。

## ② 存在的问题

采用模糊  $C$ -均值聚类的方法进行图像分割的优点是避免了设定阈值的问题, 并且能解决阈值化分割难以解决的多个分支的分割问题; FCM 适合于图像中存在不确定性和模糊性的特点; 同时 FCM 算法是属于无监督的分类方法, 聚类过程中不需要任何人工的干预, 很适合于自动分割的应用领域。

然而, FCM 算法进行图像分割存在着以下多个方面的问题:

### A. 聚类类别数的确定

在进行聚类之前必须确定聚类的数目, 否则聚类无法进行。为了确定聚类的类别数, Rosenberger 等人<sup>[82]</sup>提出了一种试探性的、逐步优化的方法来确定类的数目, 最后达到自动分割的目的。

### B. 初始类中心的确定

---

模糊聚类分割方法必须给出初始聚类中心。数学分析理论表明，一个迭代并且收敛的序列，如果迭代的初始值比较接近于最后的收敛结果，则收敛的速度会明显提高，且迭代次数也会大幅度减小；如果聚类迭代的初始值接近于某个局部极值，聚类结果就很大可能最终陷入局部极值，从而得不到全局最优值。所以初始参数的确定对于计算量的降低显得尤其重要。

在一般的自动系统中，都采用随机的初始聚类中心，这使得最终的结果可能不是最优结果。王培珍和陈维南<sup>[83]</sup>采用二维阈值分割算法对图像进行粗分割，并求得初始聚类中心。丁震等人<sup>[84]</sup>以直方图中相邻的谷之间的均值作为初始类中心进行模糊聚类。用C-均值方法对数据进行初始分类，将得到各类的质心作为初始的类中心，也是个不错的选择。

#### C. 局部极值的问题

由于聚类中的迭代优化本质上属于局部搜索方法，很容易陷入局部极值点。Hui等人<sup>[85]</sup>和 Selim 等人<sup>[86]</sup>都选择采用基于全局优化的模拟退火技术，Chaudhuri 和 Chaudhuri<sup>[87]</sup>选择采用密度函数估计法，Postaire 等<sup>[88]</sup>采用形态学方法以及模糊测度方法等方法，以试图获得好的初始值，尽量避免局部极值。

#### D. 计算量问题

由于聚类是一个非线性优化过程，而图像分割又是大样本分类问题，迭代算法中计算量大，耗时很多，使得 FCM 算法的实际应用具有一定的局限性。解决问题的方法可以从如下三个方面来考虑：选择接近最后结果的初始值，尽可能地减少迭代的次数；改进算法，减少每一轮迭代的计算量；设计快速的实现算法。

#### E. 空间信息的使用

模糊均值聚类方法分割的另一个问题是它只考虑到了灰度特征或彩色图像的颜色特征，忽略了图像中固有的丰富的空间信息，使得分割出的区域往往不连续。有效地利用空间信息能够提高分割质量，但附带的问题是计算量的增加。

#### F. 后处理的问题

由于模糊聚类法分割是一般都没有有效地利用图像像素之间的空间关系信息，容易导致分割出来的区域可能不连续；另外，分割时类别数未必是正确的，往往有过分割的可能。一般在聚类完成后，对分割出的结果需要进行一些合并类的后处理，使得最后分割出的区域都是有意义的。

### ③ 应用于 MRI 分割

FCM 聚类方法是一种无监督的分类方法，在图像分割和模式分类中有着广泛的应用。与 K-均值算法不同，FCM 算法赋予被分割像素以不同的隶属度值分别对应于不同

---

的类别，即软分割的方法。该特征使得 FCM 算法可以模拟 MRI 图像中的部分容积效应（Partial Volume Effect, PVE），因而常被用在 MRI 图像分割之中。但是，FCM 算法本身对噪声较为敏感性，因而在应用中提出要考虑空域约束来提高其抗噪声性能。Pham 提出了一种鲁棒的 FCM 算法<sup>[89]</sup>，作者在标准 FCM 算法的目标函数中加入了平滑隶属度函数项，并用一个参数来控制平滑项的强度。Ahmed 等<sup>[90]</sup>提出了相似的方案，他们同样在目标函数中引入了一空域约束项，使得像素的分类受到其直接邻域像素类别的影响。Shen 等<sup>[91]</sup>提出了一个改进的 FCM 算法，基于邻域位置和特特征的邻域吸引入到算法中，吸引力用神经网络进行优化。Boskovitz 和 Guterman<sup>[92]</sup>开发了一个神经模糊系统来自动分割图像和边缘检测。模糊聚类技术对图像进行预先标注，多层感知神经网络通过自适应门限来完成图像分割。Masulli 等<sup>[93]</sup>提出了一个交互式的可能性神经 FCM 算法（Possibilistic Neuro Fuzzy C-means algorithm）来分割多模态图像。

基于核的方法在最近获得的广发的应用，该方法也被融合到 FCM 算法之中并应用于图像分割<sup>[94-96]</sup>。Chen 和 Zhang<sup>[95]</sup>引入核的方法到 FCM 算法中。通过核方法，在原始数据空间中引入非欧氏距离测度，得到新的目标函数并进行聚类。算法增强了 FCM 算法对噪声和野点的鲁棒性，同时又保持算法的计算简单性，对 MRI 图像的分割结果表明了空域约束的有效性。

Wang 等<sup>[97]</sup>提出了一种修改的 FCM 算法来分割脑组织。他们将非局部均值滤波器算法<sup>[98]</sup>集成到 FCM 框架中，并加入局部约束来提高抗噪声性能，同时减小对图像细节的滤除。算法获得来良好的分割效果，但是计算量巨大限制了它的应用。Hou 等<sup>[99]</sup>提出了规则化的 FCM 算法（regularized FCM），用滑动平均滤波器作为调整子，将邻域模糊隶属度的平均值引入到目标函数中。Xue 等<sup>[100]</sup>提出了集成的无监督的 MRI 图像分割算法。在算法中，先用基于小波的技术滤除噪声，然后对像素进行分类。Cai 等<sup>[101]</sup>提出了一个快速的 FCM 算法，图像先经过局部相似性测度算子滤除噪声，然后用快速 FCM 算法对降噪后的图像进行分割。

Karmakar 提出了一种基于模糊尺度的聚类方法<sup>[102]</sup>，该方法独立于具体的应用，结合空间关系信息，引入了与众不同的隶属度函数，再在此基础上进行聚类。Udupa 等人提出了一个模糊连接度的概念，利用点之间的模糊连接度进而定义点到对象（区域）之间的模糊连接度。然后将利用这些个连接度来计算类中心和隶属度矩阵，再进行模糊聚类，分割各连通的区域<sup>[103-105]</sup>。这种方法利用了图像的空间信息，但其计算复杂度太高。

最近提出的算法在进行组织分割的同时，对偏置场进行校正。Pham 提出了一个同时实现图像分割和偏置场校正的 FCM 算法<sup>[21]</sup>。作者在目标函数中引入一阶和二阶调整项以保证图像的空域平滑和缓慢变化。为了引入空域约束信息，Liew 等人<sup>[106]</sup>提出了

---

一种利用  $3 \times 3$  小窗口内的像素之间的关系, 结合 8-邻域内的连续性, 修改了 FCM 中基于最小二乘法原理的目标函数, 提出了区域之间重叠度的类合并策略, 优化类别的数目。Liew 和 Yan<sup>[107]</sup>在目标函数中引入目标像素邻域约束项, 在分割的同时对偏执场进行校正。此后, Liew 和 Yan 又对该算法扩展到 3D MRI 图像分割<sup>[108]</sup>, 作者在目标函数中引入了两个调整项来考虑像素的空域连续性约束, 减少噪声的影响和分割的模糊度, 同时对偏置场进行估计和校正。

本文中, 将 FCM 方法和水平集方法相结合, 来分割脑组织。提出的算法受益于 FCM 和水平集方法, 既保持了 FCM 的简洁和高效, 又保持了水平集方法的鲁棒性。

### (3) EM 算法

期望最大化(EM)算法是由不同的研究者独立发现并使用的算法, 后经过 Dempster 将其思想进行融合, 证明了算法的收敛性, 并命名为 EM 算法<sup>[109]</sup>。由于这些开创性的工作, 数以百计的文献涌现出来, 并广泛应用于经济、临床、和社会学研究领域。EM 算法的一个典型应用领域是遗传学。在遗传学中, 被观察的数据(显型)是隐含的未被观察的基因模式(基因型)的函数<sup>[110]</sup>。另一个应用领域是混合分布的参数估计<sup>[111]</sup>。文献<sup>[112]</sup>还介绍了一些 EM 算法在统计方法中的应用。

EM 算法在脑部 MRI 图像分割中能够也得到了应用。Wells 等<sup>[72]</sup>提出了一个 EM 方法来分割脑组织, 同时来估计偏置场。此后, Kapur 等将形态学、活动轮廓方法与 EM 算法结合来分割大脑<sup>[4]</sup>, 并在此后的工作中再次将 Gibbs 随机场和几何先验知识与 EM 算法结合<sup>[113]</sup>。Shattuck 和 Leahy<sup>[114]</sup>提出了利用贝叶斯分析通过 EM 算法实现对脑组织的自动分割。Hashimoto 和 Kudo<sup>[115]</sup>中, 作者用 EM 算法来对有序子集数据进行估计, 以完成脑组织的分割。

## 2.3.4 基于水平集的算法

1988 年 Osher 和 Sethian 首次提出了水平集算法<sup>[116]</sup>, 算法中借鉴了流体力学中的重要思想。这是一种有效解决曲线演化问题的数值解法, 并且计算稳定, 适宜处理任意维数空间的应用。随后, Osher 等人对水平集算法作出了总结和扩展<sup>[117-121]</sup>。随着水平集技术的不断丰富和发展, 近年来被广泛地应用于图像处理领域, 包括滤波、分割、图像修复等诸多方面。水平集方法是将  $n$  维曲线/曲面的演化问题转化为更高 1 维空间的水平集曲面/超曲面演化的隐含方式来求解。基于水平集的分割算法主要是利用了其在求解偏微分方程方面的优势。在基于 PDF 的分割模型建立之后, 用水平集方法实现, 使算法在处理拓扑结构变化问题上更加的便利和灵活。Casseles 和 Malladi 等提出的几何活动轮廓模型<sup>[121, 122]</sup>和测地线轮廓<sup>[123]</sup>模型则是采用了水平集的方法。Chan 和 Vese 等在

---

Mumford-Shah 泛函<sup>[124]</sup>的基础上, 提出了无边界的 C-V 模型<sup>[125]</sup>, 并在随后将其推广为多相算法<sup>[126]</sup>, 相似的工作也可以在文献<sup>[127]</sup>中看到。

随着水平集方法的理论不断完善, 其应用领域也在不断的扩展, 这里当然包括医学图像处理领域。Baillard 等人<sup>[128]</sup>通过估计灰度分布的概率密度函数, 在水平集框架下分割脑组织。算法自适应地估计进化所需要的时间步长, 实现自适应分割。Zeng 等<sup>[129]</sup>基于皮层厚度是常数的假设, 用两个耦合的水平集表面来分割皮层。Yang 等<sup>[130]</sup>提出了先验形状表观模型结合几何变形模型的方法, 来分割皮下结构。算法基于脑组织结构的形状和灰度级变化有的关联性, 通过构建形状表观先验模型提供结构和纹理信息以辅助分割。算法中用最大后验估计 MAP 的方法, 通过水平集进化来估计皮下结构的形状。Goldenerg 等<sup>[131]</sup>提出了一个几何变分模型来进化两个相互耦合的表面来分割皮层, 作者提出了一个有效的数字方案来实现几何表面模型, 还提出了基于图像梯度的力、图像灰度的力、脑组织概率密度函数的驱动力。该方法与 Zeng 的方法类似。Ballester 等<sup>[132]</sup>提出了一个将分类和变形模型结合的方法。在算法中, 贝叶斯分析和活动表面方法相结合来分割脑结构。Shen 等<sup>[144]</sup>将几何轮廓模型和脑结构形状的统计信息相结合以辅助脑结构的分割。Suri 将模糊分割与水平集方法结合来分割白质和灰质的边界<sup>[134]</sup>。Chan 和 Vese 基于提出了一个 Mumford-Shah 函数的无边界分割模型<sup>[124]</sup>, 该算法随后被推广到多相算法<sup>[126]</sup>, 两个算法都利用了图像的灰度统计信息。

### 2.3.5 其它分割算法

基于图谱和基于神经网络的分割方法等算法也用来对脑 MRI 图像进行分割。

基于图谱的方法是利用图像的图谱来指导图像的分割。该方法将组织的图谱作为先验的知识引入到解剖结构的分割算法中, 以帮助实现对感兴趣目标的自动分割。该方法的前提是假设在正常的组织结构中, 不同的组织拓扑关系是不同的, 分割过程实际上是执行一个空间变化, 实现图谱数据到目标图像的映射。Shattuck 和 Leahy<sup>[114]</sup>中利用图谱的方法实现脑组织的分割。Christensen 等<sup>[135]</sup>提出了一种基于图谱的分割方法, 利用微分同胚变换实现脑结构的分割。

神经网络是一种大规模的并行处理系统, 具有强大的自学能力和非线性表达能力。基于神经网络的分割方法的基本思想是将图像影射为某种网络, 然后把边缘已知的图像及其边缘作为先验知识对网络进行训练, 直到训练过程收敛为止。神经网络分割方法由特征提取和神经网络分割两个步骤组成。Reddick 等人<sup>[13]</sup>利用 Hopfield 神经网络实现了对多谱 MR 图像的非监督分割。Amatur 等人<sup>[136]</sup>提出了一个混合的 Kohonen 自组织多层 BP 神经网络用于对 MRI 大脑图像进行分割。

还有一些算法用来对脑部 MRI 图像进行分割, 这里不再赘述。

---

## 2.4 变形模型

自 Kass 等提出蛇模型 (Snake) 即参数变形模型<sup>[51]</sup>以来, 对变形模型的研究一直在进行之中。变形模型已经由最初的 Snake 模型衍生出具有各种不同特点的变形模型, 如 Cohen 的气球模型<sup>[137]</sup>, McInerney 和 Terzopoulos 的 T-Snake 模型<sup>[138]</sup>、Xu 等的梯度矢量流 (Gradient Vector Flow, GVF) 模型<sup>[139]</sup>, Caselles 等的测地线模型<sup>[140]</sup>等。

虽然传统的参数变形模型已经受到了广泛研究和应用, 但是这些模型仍然存在一些缺陷: 不能处理复杂的几何形体; 需要额外的机制处理拓扑结构的变化。针对这些问题, Osher 和 Sethian 等提出了基于水平集 (Level Set) 理论的几何变形模型<sup>[141]</sup>, 又称非参数化变形模型, 近年来得到了广泛的研究和应用, 并成为图像分割研究的另一个重要方向。非参数化变形模型是基于曲线演化理论的, 它的发展由最初的曲线曲率运动, 到测地线几何变形模型, 再到 Siddiqi 引入区域最小化项<sup>[142]</sup>等, 经历了不同的发展阶段。在采用水平集的数值方法后, 变形模型能自然地处理拓扑结构的变化, 这是水平集方法的最大优点。

如前文所述, 变形模型分为参数化和非参数化变形模型两种, 本节中以下内容将分别就其原理进行介绍。

### 2.4.1 参数化变形模型

参数型变形模型<sup>[51]</sup>是由 Kass 在 1988 年提出的。由于该模型在轮廓搜索时, 运动轨迹很像蛇的运动, 因而得名 Snake 模型。此模型的基本原理为: 当图像局部能量取最小值时, 轮廓线的位置即为图像边界位置。也就是当图像的内、外力大小相等、方向相反时, 轮廓线将停止运动。

#### (1) 算法原理

对于一个 2D 的参数变形模型, 假设轮廓线用  $X(s)=[x(s), y(s)]$  表示, 其中:  $s \in [0, 1]$ , 其运动方向为使得如下能量函数沿最小方向运动:

$$E = \int_0^1 \frac{1}{2} (\alpha |X'(s)|^2 + \beta |X''(s)|^2) + E_{ext}(X(s)) ds \quad (2.6)$$

其中,  $\alpha$  和  $\beta$  为加权系数, 用于控制变形轮廓线的张力 (Tension) 和刚性力 (Rigidity);  $X'(s)$  和  $X''(s)$  分别表示参数化曲线  $X(s)$  的一阶和二阶导数;  $E_{ext}$  为外部势函数, 通常用灰度图像梯度模的负值来表示:

$$E_{ext}^{(1)}(x, y) = -|\nabla I(x, y)|^2 \quad (2.7)$$

$$E_{ext}^{(2)}(x, y) = -|\nabla G_{\sigma}(x, y) * I(x, y)|^2 \quad (2.8)$$

其中， $I(x, y)$ 为像素灰度值， $G_{\sigma}(x, y)$ 是以标准差为 $\sigma$ 的二维高斯函数， $\nabla$ 为而为梯度算子， $*$ 为卷积运算符。

从式(2.7)和(2.8)可见在边界处梯度取最大值，而势函数却达到最小。因此。如果轮廓线沿着能量最小方向运动，则可以通过轮廓线的收敛获得合理的边界位置。因而，Snake的外力定义为外部势函数梯度的反方向，如式(2.9)所示：

$$F_{ext} = -\nabla E_{ext} \quad (2.9)$$

最小化(2.6)式得到的变形模型将满足如下欧拉(Euler)方程<sup>[51]</sup>：

$$\alpha X''(s) + \beta X'''(s) - \nabla E_{ext} = 0. \quad (2.10)$$

如果用 $F_{int} = \alpha X''(s) + \beta X'''(s)$ 表示模型的内力，起阻碍轮廓线伸展(Stretching)和弯曲(Bending)作用，那么由(2.10)式就可以得到如下的内力、外力平衡方程：

$$F_{int} + F_{ext} = 0 \quad (2.11)$$

在实际的Snake分割中，图像的每一个像素点均被视为一个有质量的角点，当它们受到内力和外力的作用时，将开始向真正的边界方向运动。角点 $i$ 所受合力为<sup>[143]</sup>：

$$F_i = \omega_{ex} F_{ex,i} + \omega_{in} F_{in,i} \quad (2.12)$$

其中， $\omega_{ex}$ 和 $\omega_{in}$ 分别为外力和内力的加权系数，它们可以控制外力和内力在搜索中所起作用的大小。当加大外力加权系数 $\omega_{ex}$ 时，轮廓线将更快接近最大梯度位置，即边界位置，但轮廓线的平滑程度将降低；相反，当加大内力加权系数 $\omega_{in}$ 时，效果正好相反。因此，对这些不同加权系数的调整将依赖于图像的特点和分割的目的。

假设角点 $i$ 的位置矢量、速度矢量和加速度矢量分别为 $s_i$ ， $v_i$ 和 $a_i$ ，根据牛顿定律，则有下面式子：

$$s_i(t + \Delta t) = s_i(t) + v_i(t)\Delta t \quad (2.13)$$

$$v_i(t + \Delta t) = v_i(t) + a_i(t)\Delta t \quad (2.14)$$

$$a_i(t + \Delta t) = \frac{1}{m_i} F_i(t + \Delta t) \quad (2.15)$$



其中， $m_i$  是角点的质量，并假设它们的质量相等，则此系数相当于加权系数； $\Delta t$  为运动时间间隔。则搜索收敛条件为：

$$v_i = a_i = 0 \quad (2.16)$$

考虑到搜索后期，角点可能在收敛条件附近做较长时间振荡。因此需要引入一个阻尼力，以阻止长时间的振荡，使角点能尽快在边界线处停止运动。而所加阻尼力应该与速度矢量方向相反，所以可定义

$$F_{damp,i} = \omega_{damp} v_i \quad (2.17)$$

其中， $\omega_{damp}$  为负值。则式 (2.12) 的合理可以改写为

$$F_i = \omega_{ex} F_{ex,i} + \omega_{in} F_{in,i} + F_{damp,i} \quad (2.18)$$

因此，一个传统的 Snake 动态轮廓算法可以简单描述为：首先通过手工标记点标记得到初始轮廓线，接着，利用 (2.18) 提供的合力及收敛条件 (2.16)，动态地搜索目标或感兴趣区，最后完成对图像的分割。

## (2) 参数变形模型的优点与不足

### ① 参数变形模型的主要优点：

- A. 模型将边界看作一个整体，因而可以利用目标形状的先验知识来约束分割问题。
- B. 模型内在的连续性和平滑性可以补偿噪声、缝隙和其它目标边界的不规则性。
- C. 模型参数化表示提供了一个目标形状的紧凑、解析描述。

上述特性产生了一个鲁棒、优雅的技术，将稀疏或者噪声污染的局部图像特征与连贯一致的目标模型链接在一起。

### ② 存在的问题

参数型变形模型是一种基于能量最小样条的局部方法，它通过外力与内力相互作用来产生推拉效果，共同促使样条朝着图像的边界方向运动，使轮廓线达到边界位置时能量最小。在参数变形模型中，由于边界轮廓线的搜索是通过内外力的共同作用来推动的，没有考虑到图像像素间的邻域相关关系，因此对于退化图像的分割，无论是在精度上，还是在鲁棒性上都无法得到保障。解决这类问题的主要思路是引入区域约束信息，如与区域分割算法或统计概率算法相融合。同时由于它没有考虑到临床组织间拓扑改变，使得其对复杂结构(如脑部沟、回)的分割精度进一步降低。对于组织分裂或消失等拓扑关系变化，算法存在致命性的缺陷。解决的主要方法是通过引入几何模型，使模型本身能更好地描述这种几何特性，从而解决拓扑关系改变给分割带来的难题。对于初始轮廓线

---

的放置和内外力加权系数权重的分配与调整，主要还是依靠先验知识，如统计意义上的先验知识和经验等。

概括来说，参数型变形模型在医学图像分割中存在以下方面的问题和不足<sup>[144,145]</sup>：

- A. 要求初始轮廓线的设定在形状和距离上应与目标边界相近；
- B. 要求图像的拓扑关系不发生改变；
- C. 要求针对不同图像设置不同的内、外力加权系数；
- D. 对含有边界重叠的复杂分割问题存在缺陷；
- E. 对退化图像分割的精度和鲁棒性不够等。

由于要求初始标记轮廓必须比较接近真正轮廓，否则，不仅所获得的目标边界可能仅是局部结果，而且将极大地影响分割的速度。因而参数化变形模型方法对操作人员要求较高。这种通过手工放置初始轮廓线的方法重复性较差，且只能适合于半自动化分割。针对上述存在的问题，已经提出了一些改进方法，如梯度矢量流 (Gradient Vector Flow, GVF) 变形模型<sup>[139, 146]</sup>、几何变形模型<sup>[129]</sup>以及不同约束的变形模型<sup>[147,148]</sup>，从不同的角度对参数化变形模型作出了改进。

#### 2.4.2 非参数变形模型

非参数变形模型即几何变形模型，又称水平集 (Level Sets) 方法，最初由 Osher 和 Sethian 于 1988 年在其论文中首次出现<sup>[116]</sup>。该方法利用偏微分方程 (Partial Differential Equations, PDE) 作为数值分析 (Numerical Analysis) 方法与技术手段被广泛运用于轮廓线或面的运动跟踪。作为变形模型的另一种形式，水平集方法能较好地解决参数型变形模型所暴露的两大缺陷<sup>[149]</sup>：(1) 参数型算法一般要求初始轮廓必须与目标相近，否则一旦发生初始轮廓与目标轮廓在边界或形状上差别较大时，往往需要动态地修改模型的相关参数才能满足其分割要求；(2) 当图像发生拓扑关系改变，如分裂 (Splitting) 或融合 (Merging) 时，参数型算法将出现分割困难。而水平集方法<sup>[121]</sup>通过将闭合运动轮廓线作为零水平集而引入到高一维的  $\phi$  函数中，从而很好地解决了参数化变形模型所遇到的分割缺陷。

##### (1) 水平集方法

假设用  $\Gamma$  表示一个闭合界面 (Interface, 又称 Front)，它可以是二维中的一条闭合曲线 (Curve)，也可以是三维中的一个闭合曲面 (Surface)。水平集的主要思想就是将界面  $\Gamma$  作为零水平集 (Zero Level Set, ZLS) 嵌入到高一维的函数中，用一个关于函数  $\phi$  的水平集  $\{\phi = 0\}$  来描述界面  $\Gamma(t)$  的运动状态。

这里假设 $\Gamma$ 是一条平面封闭曲线，采用隐式表示，将它定义为一个二维函数 $\phi(x, y)$ 的水平集：

$$\Gamma = \{(x, y) | \phi(x, y) = c\}, \quad c \text{ 是任意常数} \quad (2.19)$$

这样，如果 $\Gamma$ 有某种变化，可以将它归结为是由函数 $\phi(x, y) = c$ 发生了某种相应的变化所引起的。具体来说，随着时间变化的封闭曲线 $\Gamma(t)$ ，可表达为随着时间变化的二维函数 $\phi(x, y)$ 的零水平集，即

$$\phi(\Gamma(x, y, t), t) = 0 \quad (2.20)$$

式(2.20)对 $\phi$ 求全导数，由复合函数求导的链式规则可得：

$$\phi_t + F |\nabla \phi| = 0 \quad (2.21)$$

其中 $F$ 是 $\frac{\partial \Gamma}{\partial t} = \bar{V}$ 的法向分量。




图 2.2 内嵌函数与区域划分

Fig. 2.2 Embedded Function and the Partitioned Regions

这里假定函数 $\phi(x, y)$ ：

$\phi(x, y) < 0$ ， $(x, y)$ 在封闭曲线 $\Gamma$ 内部；

$\phi(x, y) > 0$ ， $(x, y)$ 在封闭曲线 $\Gamma$ 外部；

$\phi(x, y) = 0$ ， $(x, y)$ 在封闭曲线 $\Gamma$ 上。

函数 $\phi(x, y)$ 对区域的划分如图 2.2 所以。

函数  $\phi(x, y)$  的选择不是唯一的，通常取  $\phi(x, y)$  表示平面上的点  $(x, y)$  到曲线  $\Gamma$  的有符号距离，即

$$\phi(x, y) = \begin{cases} d[(x, y), \Gamma], & (x, y) \in \text{inside}(\Gamma) \\ -d[(x, y), \Gamma], & (x, y) \in \text{outside}(\Gamma) \end{cases} \quad (2.22)$$

式中， $d[(x, y), \Gamma]$  表示点  $(x, y)$  与曲线  $\Gamma$  之间的欧氏距离。这一选择的优点是距离函数具有如下的基本性质：

$$|\nabla \phi| = 1 \quad (2.23)$$

这意味着  $\phi(x, y)$  的变化率处处是均匀的，没有太陡峭的“坡地”，也没有“平原”。这将有利于算法的稳定性。




图 2.3 曲线进化示意图

Fig.2.3 Example of Curves Evolving

这样，给定任意水平集函数  $\phi_0(x, y) = \phi(x, y, t = 0)$ ，方程 (2.21) 可以保证水平集函数  $\phi(x, y, t)$  随时间的演化满足  $\{\phi(x, y, t) = 0\}$  的条件，即  $\phi$  的零水平集始终是封闭曲线  $\Gamma$ 。式 (2.21) 对应的边界  $\Gamma(t)$  在常数速度下的进化过程如图 2.3 所示。

从式 (2.19) - (2.21) 可以看出，在给定某中速度场  $F$  下，式 (2.21) 就成了一个标准的 Hamilton-Jacobi 方程。将边界的运动规律用 Hamilton-Jacobi 方程表示，具有如下优点<sup>[150]</sup>：

- A. 不管边界  $\Gamma$  是否发生拓扑关系改变，如中断、融合或者出现拐角，函数  $\phi(x, y, t)$  在拓扑关系发生改变时总能保持完整，无需改变函数的形式，只要速度场是平滑的；

B. 可结合离散网格与有限差分法 (Finite Difference) 来形成数值逼近 (Numerical Approximation) 方法, 以解决时间与空间的微分方程求解问题, 如式 (2. 21) 可进一步用数值方式改写为:

$$\frac{\phi_{ij}^{n+1} - \phi_{ij}^n}{\Delta t} + (F)(\nabla_{ij} \phi_{ij}^n) = 0$$

或

$$\phi_{ij}^{n+1} = \phi_{ij}^n + \Delta t [\max(F_{ij}, 0) \nabla^+ + \min(F_{ij}, 0) \nabla^-] \quad (2.24)$$

其中,  $\phi_{ij}^n$  和  $\phi_{ij}^{n+1}$  分别表示像素点  $(i, j)$  在当前与下一步的水平集函数; 而

$$\begin{aligned} \nabla^+ &= [\max(D_{ij}^{-x}, 0)^2 + \min(D_{ij}^{+x}, 0)^2 + \max(D_{ij}^{-y}, 0)^2 + \min(D_{ij}^{+y}, 0)^2]^{1/2} \\ \nabla^- &= [\max(D_{ij}^{+x}, 0)^2 + \min(D_{ij}^{-x}, 0)^2 + \max(D_{ij}^{+y}, 0)^2 + \min(D_{ij}^{-y}, 0)^2]^{1/2} \end{aligned} \quad (2.25)$$

而  $D_{ij}^{-x}$ ,  $D_{ij}^{+x}$ ,  $D_{ij}^{-y}$  和  $D_{ij}^{+y}$  分别表示后向和前向差分:

$$\begin{aligned} D_{ij}^{-x} &= \frac{\phi_{i,j} - \phi_{i-1,j}}{\Delta x}, & D_{ij}^{+x} &= \frac{\phi_{i+1,j} - \phi_{i,j}}{\Delta x} \\ D_{ij}^{-y} &= \frac{\phi_{i,j} - \phi_{i,j-1}}{\Delta y}, & D_{ij}^{+y} &= \frac{\phi_{i,j+1} - \phi_{i,j}}{\Delta y} \end{aligned} \quad (2.26)$$

C. 通过水平集函数  $\phi$  可以容易地确定边界所固有的几何特性, 如:

$$\bar{n} = \frac{\nabla \phi}{|\nabla \phi|} \quad (2.27)$$

表示单位法线向量;

$$k = \nabla \cdot \frac{\nabla \phi}{|\nabla \phi|} \quad (2.28)$$

表示平均曲率;

$$Length(\Gamma) = \int_{\Omega} \delta(\phi) |\nabla \phi| d\Omega \quad (2.29)$$

表示曲线长度;

$$Area(\Gamma) = \int_{\Omega} H(-\phi) |\nabla \phi| d\Omega \quad (2.30)$$

表述曲线内包含的面积。

其中,  $H(\phi)$  是 Heviside 函数, 通常用平滑函数  $H_\varepsilon(\phi)$  逼近(  $\varepsilon$  是一个小的常数):

$$H_\varepsilon(\phi) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan\left(\frac{\phi}{\varepsilon}\right) \right] \quad (2.31)$$

$\delta(\phi)$  是 Direc 函数, 通常用平滑的 Heviside 函数  $H_\varepsilon(\phi)$  的导数表示:

$$\delta_\varepsilon(\phi) = H'_\varepsilon(\phi) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + \phi^2} \quad (2.32)$$

D. 这种水平集函数方法可以很容易地推广到三维或更高维空间。

## (2) 速度场设计

水平集方法之所以能广泛应用于流体力学、机械制造、图像处理等领域, 与其灵活的速度场设计密不可分。Suri 等按照速度场在计算时有无利用区域信息, 将水平集分割方法划分为正则化 (Regularizers) 和非正则化 (Without Regularizers) 两种类型<sup>[151]</sup>。

正则化水平集方法是指在设计速度场时考虑了基于统计的区域信息。这类方法根据所使用正则化器的不同划分为: 聚类型<sup>[26]</sup>, 基于贝叶斯统计分类型<sup>[152]</sup>, 基于形状特性<sup>[153]</sup>, 耦合水平集约束型<sup>[122]</sup>等。在医学图像分割领域, 正则化水平集方法表现出良好的分割特性。其主要原因是在通过正则化后, 可以让分割系统充分利用图像的局部或全局的形状信息, 使水平集框架更好地获得图像的拓扑关系, 从而使分割结果更为精确有效。

最原始的水平集方法就属于非正则化水平集方法, 主要特点是利用边缘为图像性质发生突变的原理来设计水平集方法的速度场。从快速匹配法的短时距方程可以看出, 到达边界的时间梯度与轮廓线的速度场成反比。如果希望运动轮廓线在目标边界处停止, 最好的方式就是让运动轮廓线在边界处的速度场为零, 而在远离边界时的速度场应较大, 从该意义上讲, 速度场也称使轮廓线停止的“停止力”。因此, 速度场应设计成一个与图像梯度相关的函数。包括: 基于图像梯度<sup>[122]</sup>, 基于边界强度<sup>[154]</sup>, 基于面积最小<sup>[155]</sup>, 基于平均曲率<sup>[156]</sup>等。

## (3) 速度场的延拓与重初始化问题

式 (2.21) 中的速度场  $F$  只是  $\frac{\partial \Gamma}{\partial t} = \bar{\mathbf{V}}$  的一个分量, 它只是在  $(x, y) \in \Gamma$  上的点集 (即  $\phi = 0$  的水平集) 上才是已知的。但是嵌入函数  $\phi$  是定义在图像平面  $\Omega$  域内, 因而, 为了求解式 (2.21), 就要求在  $\Omega$  域内每一点  $(x, y) \in \Omega$  的速度都是已知的, 而不仅仅在  $\phi$  的零水平集上的  $F$  是已知的。因此, 严格来说, 式 (2.21) 本应该写成为:

$$\phi_t + F_{ext} |\nabla \phi| = 0 \quad (2.33)$$

其中， $F_{ext}$  称为延拓速度，原则上它是满足一下条件的任意函数：

$$F_{ext} = F, \quad \forall \phi(x, y, t) = 0 \quad (2.34)$$

于是为了对式 (2.21) 做数值计算，必须有一种具体的方法来满足式 (2.34) 要求的延拓速度  $F_{ext}$ ，这就是所谓速度场的延拓问题。

Sethian 提出了一种交替运行的两层系统来实现速度的延拓<sup>[157]</sup>。该方法的优点是：只要初始是有符号的距离函数，那么在它演化的全部过程中，都一定保持为有符号的距离函数。其缺点是计算效率太低。

本文讨论的曲线/曲面的演化问题，其演化速度仅仅取决于曲线/曲面的几何性质，不涉及更一般的物理界面的演化问题。在这种情况下，常常采用所谓“速度场自然延拓”方法，即鉴定给定的曲线/曲面运动方程不仅对于嵌入式函数的零水平集成立，而且对于嵌入式函数的所有水平集都成立。如曲率依赖的运动：

$$\frac{\partial \Gamma}{\partial t} = k \cdot \vec{n} \quad (2.35)$$

上式称为平均曲率运动方程，其中  $k$  是平均曲率。其对应的水平集方程式：

$$\frac{\partial \phi}{\partial t} = k |\nabla \phi| \quad (2.36)$$

这实际上已经隐含包含了自然延拓，即式 (2.35) 中平均曲率  $k$  的本意是  $\phi$  的零水平集的曲率，而式 (2.36) 中平均曲率  $k$  则被理解为  $\phi$  的所有水平集上的曲率。

然而，自然延拓不能保证  $\phi$  在演化过程中始终保持为有符号距离函数。当它逐渐偏离距离函数的性质后，某些局部就有可能由于  $|\nabla \phi|$  远大于 1 而出现尖峰或深谷，也可能因为  $|\nabla \phi|$  远小于 1 而出现平坦区域。这将导致数据计算的迭代过程趋向不稳定。所以，有必要进行若干次的  $\phi$  的更新迭代后，做一次重新初始化 (Re-initialization)，以使  $\phi$  保持为对于当前零水平集而言是有符号距离函数，也即使  $|\nabla \phi| = 1$ 。

这种重初始化过程可以通过求解以下的偏微分方程来完成<sup>[158]</sup>：

$$\frac{\partial \phi}{\partial t} = \text{sign}(\phi^n)(1 - |\nabla \phi|) \quad (2.37)$$

式中  $\phi^n$  表示需要重初始化的嵌入函数。当式 (2.37) 达到稳态后，其解  $\phi$  显然满足  $|\nabla \phi| = 1$ 。然后就可以将其作为新的嵌入函数初值  $\phi_0$  继续演化过程。由于重新初始化不

必在每次  $\phi$  更新后都进行一次，因而有较高的效率。但是，每隔多少次迭代后做一次重新初始化一次，往往只能根据实验来确定。

#### (4) 稳定性问题

在水平集方法中，稳定性是由 Courant-Friedrichs-Lewy (CFL) 条件来保证的。CFL 条件要求数字波的速度至少和物理波一样快。这意味着数字波速度  $\Delta x / \Delta t$  至少和物理波的速度  $|u|$  一样的快，即  $\Delta x / \Delta t > |u|$ 。这样得到 CFL 时间步长约束

$$\Delta t < \frac{\Delta x}{\max(|u|)} \quad (2.38)$$

$\Delta x$  表示网格间隔， $\max(|u|)$  表示整个平面上所有网格点的最大速度值。

式 (2.38) 可以进一步强化为

$$\Delta t \left( \frac{\max(|u|)}{\Delta x} \right) < \alpha \quad (2.39)$$

式中  $0 < \alpha < 1$ ，常用的接近最优的选择  $\alpha = 0.9$ ，保守的选择是  $\alpha = 0.5$ 。

三维 CFL 条件可以表示为如下形式：

$$\Delta t \cdot \max \left( \frac{|u|}{\Delta x} + \frac{|v|}{\Delta x} + \frac{|w|}{\Delta x} \right) = \alpha \quad (2.40)$$

其中  $u$ ， $v$  和  $w$  是  $\vec{V}$  在三个坐标轴上的分量。

实际计算时，可以扫描速度场，按照上式动态设定时间步长。

#### (5) 非参数化变形模型的优点与不足

##### ① 非参数化变形模型的主要优点是：

- A. 能自然地处理拓扑结构的变化，这是水平集方法的最大优点；
- B. 初始轮廓线不要求非常接近于目标轮廓线，也不要求初始轮廓线的拓扑结构与目标轮廓线的拓扑结构相似；
- C. 变形曲线的内在几何性质可以很容易地由水平集函数来确定；
- D. 易于向高维推广。

##### ② 非参数化模型不足表现在以下方面：

- A. 水平集的分割速度较慢；
- B. 对水平集速度场的合理设计存有困难；
- C. 水平集分割结果易产生边界泄漏现象；
- D. 初始轮廓线的放置问题等。



---

在非参数化变形模型中, 由于在每一步轮廓线运动都将涉及到对所有点进行水平集函数求解, 因此计算量非常之大, 从而降低了分割的效率, 目前解决的方法是引入窄带 (Narrow Band, NB) 方法和快速步进方法 (Fast Marching Method, FMM) [150]。对于速度场的设计应根据具体的问题选择是否需要正则化约束。边界泄漏问题是水平集分割遇到的最大的难题。关于泄漏问题的成因多种多样, 其中一个主要因素是将图像的梯度信息作为轮廓线停止运动的停止力。因为在离散空间无法保证轮廓线在到达图像边界时, 停止力达到无穷大, 且速度场完全降为零。因此, 不可避免将在某些区域产生泄漏现象。目前, 解决泄漏的主要方案有两类, 一类是引入空间约束信息或统计信息来对速度场进行正则化约束, 另一种则是引入不同停止力, 确保轮廓线在运动到边界时产生足够的停止力, 避免轮廓线进一步越过边界, 继续运动下去, 从而产生不必要的边界泄漏现象。对于零水平集初始化的放置问题, 虽然没有参数型模型那样严格, 但如果初始化离目标较远时, 将花费更多的时间。可以结合图像的先验知识, 通过结合一些统计特征, 做到较好地初始化零水平集是可能的。

## 2.5 算法评估准则与分割指标

### 2.5.1 算法评估准则

对分割算法评价的目标是通过对算法的研究来优化算法。对分割算法的评价可以通过分析的方法和实验的方法来进行, 因而评价方法可划分为分析法和实验法两种[159]。分析方法通过分析分割算法本身的原理和性能直接作出评价, 而实验的方法是通过测试图像的分割结果间接来评价算法。实验方法又可以分为优度法和偏差法两类。优度法是以建立在视觉基础上的某些图像特征为依据, 通过对图像的分割结果的判断间接来评价分割效果。偏差法则是通过分割结果和参考图的比较, 用二者的差别来评价算法。这种差别可以是基于错误分割的像素数, 也可以是基于错误分割的像素点的位置, 或是基于分割结果区域数的差别等等。优度法评价中不需要参考图像, 而偏差法是需要使用参考图像。

每类测试方法中都有多种不同的测度, 可以根据其特点归入不同的分组, 其中应用最多的是定量实验方法的测度。常用的定量实验的优度法的测度包括: 区域间对比度 (inter-region contrast)、区域内一致性 (intra-region uniformity) 和区间形状测度 (region shape)。常用的用于定量实验的偏差方法的测度包括: 目标计数一致性 (object count agreement)、像素距离误差 (pixel distance error)、像素数量误差 (pixel number error), 最终测量精度 (ultimate measurement accuracy, UMA) [160] 和重叠测度 (overlap measures) [91] 等。

尽管利用分析方法对分割算法的评估可以免除一些实验因素的影响，但是，并非所有的算法性能都能够通过分析而得到。迄今为止还缺乏有关图像分割的一般理论作为分析算法的理论依据。考虑到定量评估的客观性，将本文中所提算法的分割结果与参考图像（人工手动分割，或者计算机产生的、能作为“金标准”的结果）进行比较、分析，从而定量或定性地评估对应算法的分割质量和精度。

### 2.5.2 分割指标

本文中主要采用重叠测度对算法结果进行评价，所用的量化指标主要有灵敏度（Sensitivity），特异性（Specificity），总体性能（Total performance），误分割(Incorrect Segmentation, InS)，相似度 (Similarity,或 Kappa index)，假阳性率(False Positive rate,  $r_{fp}$ ) 和假阴性(False Negative rate,  $r_{fn}$ )率等<sup>[128,91]</sup>。

$$\text{灵敏度} = TP / (TP + FN)$$

$$\text{特异性} = TN / (FP + TN)$$

$$\text{总体性能} = (TP + TN) / (TP + FP + TN + FN)$$

$$\text{误分割} = (FP + FN) / (TP + FP + TN + FN)$$

$$\text{相似度} = 2TP / (2TP + FP + FN)$$

$$\text{假阳性率} = FP / (TP + FN)$$

$$\text{假阴性率} = FN / (TP + FN)$$

其中，TP、TN、FP 和 FN 分别是真阳性、真阴性、假阳性和假阴性像素数。




图 2.3 重叠度表示  
Fig.2.3 Overlap measure

---

## 2.6 本章小结

本章首先简单回顾了脑 MRI 成像技术，介绍本文实验中即将用到的 T1-加权、T2-加权和 PD-加权 MRI 图像及其特点。然后对脑 MRI 分割方法进行了回顾。文中将分割算法分为基于边缘、区域、聚类、水平集和其它算法，并分别就其技术特点进行了介绍和说明，介绍了各类算法的优点和不足等。需要指出的是这种分类不是严格的，可能存在交叉。本章最后就分割算法的评价标准作了简单的介绍，并给出了本文中对提出的算法进行评估用到的定量指标。

---

## 3 基于直方图分析的非参数化变形模型

### 3.1 概述

图像分割是将图像划分为具备各自特征的、互不重叠的区域、并提取出感兴趣目标的技术和过程<sup>[161]</sup>。图像分割质量的优劣、区域界线定位的精度直接影响后续的区域描述以及图像的分析 and 理解。精确地对医学图像进行分割，有利于对医学解剖结构的分析和理解，在临床诊断、病理分析以及治疗等多方面具有重要意义。

测地活动轮廓线 Geodesic Active Contour (GAC)<sup>[140]</sup>是基于曲线进化理论和 Level Set 技术<sup>[116, 121]</sup>的图像分割方法，具有自由处理曲线拓扑结构变化，能够同时提取多个目标轮廓的优点，因此在边缘提取、运动跟踪、图像分割和分类等方面得到广泛应用。但传统 GAC 方法也存在不足和缺陷。首先，模型中采用了基于图像梯度信息的停止项。理论上，停止项在边缘附近趋于零，曲线进化停止，从而完成边缘的检测和定位。然而，在实际 MRI 图像中，不同组织之间往往没有清晰的边界，使得停止项在真正的图像边缘位置并不为零，使曲线进化不能停止，导致进化曲线越过边界，需要额外的停止项辅助解决。其次，在图像存在噪声时，通常需要对图像进行大尺度高斯平滑和滤波处理。这种处理模糊了图像的边缘，使边缘点的位置发生移动，造成边界定位的精确性下降。针对 GAC 方法存在的问题，文献中提出了一些改进方法。包括：Chan 和 Vese 提出了无边界的轮廓模型<sup>[124]</sup>，采用基于 Mumford-Shah 函数的停止项代替基于图像梯度的停止项，以消除分割过程中对图像梯度的依赖。Yezzi 等<sup>[162]</sup>采用图像的统计信息代替图像的梯度信息，实现多模态图像的分割。Leventon<sup>[153]</sup>则将图像形状的先验信息引入到图像的分割中，以提高分割的准确度。

本研究在对图像进行直方图分析的基础上，用混合高斯模型对直方图进行拟合，以获得的图像统计特征参数作为约束条件，替代传统 GAC 方法中基于图像梯度信息的停止项，指导和控制曲线的进化，完成图像的分割。这种基于图像统计特征的自适应 Level Set 分割方法，去除了对图像梯度信息的依赖，能够克服 GAC 方法中由于对图像的平滑造成的轮廓提取和边缘定位准确度下降的缺陷，有效提高图像分割的准确性。同时也解决了传统 GAC 方法中曲线进化只能在一个方向（向内或者向外）进行的问题，提高了分割结果对初始化位置的鲁棒性。

本章余下的内容安排如下：3.2 节介绍混合高斯模型和 EM 算法；3.3 节给出本章的算法，即基于直方图分析的非参数变形模型算法；3.4 介绍算法实现；3.5 节对算法进行评估实验，给出实验结果；最后，3.6 对本章内容给出简单总结。

---

## 3.2 混合高斯模型及参数估计

### 3.2.1 混合高斯模型

混合高斯模型 (Mixture Gaussian Model, MGM) 是一个常用的描述混合密度分布的模型，即多个高斯分布的混合分布。混合高斯模型的一个重要特性是，如果模型中的分量足够多，它能够以任意精度逼近任意的连续分布。混合高斯模型是一种统计模型，它能够很好地刻画参数空间中数据的分布及其特性。

混合高斯模型定义为  $K$  个高斯密度函数的线性组合：

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x} | \mu_k, \Sigma_k) \quad (3.1)$$

其中  $\mathcal{N}(\mathbf{x} | \mu_k, \Sigma_k)$  是均值为  $\mu_k$  协方差为  $\Sigma_k$  的高斯分布， $\pi_k$  是混合系数，且  $\pi_k$  应满足：

$$\sum_{k=1}^K \pi_k = 1, \text{ 且 } 0 \leq \pi_k \leq 1 \quad (3.2)$$

可以看出，混合系数满足概率的要求。

图 3.1 给出了一个有三个高斯分量构成的混和模型的示例。




图 3.1 混合高斯模型示例

Fig. 3.1 Example of mixture Gaussian Model

从和、积的观点，边缘密度由下式给出：

$$p(\mathbf{x}) = \sum_{k=1}^K p(k)p(\mathbf{x}|k) \quad (3.3)$$

将  $\pi_k = p(k)$  看作是数据样本产生第  $k$  个高斯分量的先验概率，把  $\mathcal{N}(\mathbf{x}|\mu_k, \Sigma_k) = p(\mathbf{x}|k)$  看作给定条件  $k$  下  $\mathbf{x}$  的概率。

### 3.3.2 EM 算法

对于给定的混合高斯模型，要利用该模型对数据进行分类或聚类，还必须要确定模型中各个高斯分量所包含的未知数，即均值  $\mu_k$ ，协方差  $\Sigma_k$ ，和混合系数  $\pi_k$ 。可以有多种方法对这些参数进行估计，其中最常用的是以最大似然估计为基础的期望最大算法 (Expectation Maximization, EM) [109, 111, 163]。EM 算法通过有效的迭代过程来计算不完整数据的最大似然估计。在似然估计中，通过观察数据来估计模型参数。

#### (1) 数据不完整问题与最大似然估计

所谓“不完全数据”一般有两种情况：一种是观察过程本身的限制或者错误，造成观察数据成为错漏的不完全数据；另一种是对参数的似然函数直接优化十分困难，而引入额外的参数(隐含的或丢失的)后就比较容易优化，于是定义原始数据加上额外数据构成“完全数据”，而原始观察数据自然就成为“不完全数据”。不能直接观察的数据称为隐含变量，任何隐含变量的模型都可以归结为数据不完整问题。

令  $X = \{x_1, x_2, \dots, x_n\}$  为  $n$  个观察到的样本集合， $H = \{z_1, z_2, \dots, z_n\}$  表示隐含变量  $Z$  的  $n$  个值，与观察到的样本一一对应，即  $z_i$  与数据样本  $x_i$  对应， $z_i$  是数据样本  $x_i$  的不可见聚类标签。

将观察到的数据样本集的对数似然函数写成如下形式：

$$L(\theta) = \log p(X|\theta) = \sum_H p(X, H|\theta) \quad (3.4)$$

上式表明，观察到的数据样本似然可以表示为观察到的数据样本和隐含数据的似然对隐藏数据的和，它代表了一个以未知参数  $\theta$  为参量的概率模型  $p(X, H|\theta)$ 。在高斯混合模型中，参数  $\theta$  是指  $\{\pi_k, \mu_k, \Sigma_k | k=1, 2, \dots, K\}$ 。通过最大化对数似然函数，可以求得参数  $\theta$  的最大似然解。

#### (2) EM 算法原理

EM 算法是一种求解似然估计的迭代优化算法。它的每一次迭代都能够保证似然函数是非递减的。其迭代过程可以分为 E 步骤和 M 步骤。E 步骤：根据参数初始值或上一次迭代值来计算似然函数的期望。M 步骤：最大化似然函数来获得新的参数值。

(1) E 步骤：在参数  $\theta$  取当前值  $\theta^{(n)}$  的条件下，计算数据样本的对数似然函数

$L(\theta) = \log p(X | \theta) = \sum_H p(X, H | \theta)$  关于条件概率分布  $p(H | X, \theta^{(n)})$  的期望：

$$Q(\theta | \theta^{(n)}) = E \left( \sum_H p(X, H | \theta) | p(H | X, \theta^{(n)}) \right) \quad (3.5)$$

(2) M 步骤：更新  $\theta^{(n)}$  为  $\theta^{(n+1)}$ ，使得期望  $Q(\theta | \theta^{(n)})$  最大化：

$$\theta^{(n+1)} = \max_{\theta} Q(\theta | \theta^{(n)}) \quad (3.6)$$

EM 算法提供了一个简单的、通过迭代计算后延概率函数的方法，其最大优点是简单和稳定。但是，它的结果只能保证收敛到后延概率的局部极大值，不能保证收敛到全局最大值。一个可行的解决该问题办法是选取不同的初始值进行迭代，然后在得到的结果中选择最佳结果，这样可以减轻初始值选取对结果的影响。

(3) EM 算法估计混合高斯模型参数

对于含有  $K$  个高斯分量的混合高斯模型来说，如果确切知道每个数据样本来自哪个高斯分量，则很容易确定参数  $\{\pi_k, \mu_k, \Sigma_k | k=1, 2, \dots, K\}$ ；反过来，如果知道混合模型中各高斯分量的参数，也容易确定数据样本最有可能是有哪个分量产生的。然而，当二者都未知时，就涉及到不完整数据的估计。EM 算法是解决不完整数据的一个最佳选择。

当混合高斯模型的高斯分量数为  $K$ ，样本数为  $N$  时，EM 算法的 E 步骤中期望通过下式计算

$$Q(\theta | \theta^{(n)}) = \sum_{k=1}^K \sum_{i=1}^N p(k | x_i, \theta^{(n)}) \log \pi_k + \sum_{k=1}^K \sum_{i=1}^N p(k | x_i, \theta^{(n)}) \log p_k(x_i | \theta_k) \quad (3.7)$$

$p_k(x_i | \theta_k)$  对应于第  $k$  个高斯分量， $x_i$  的概率分布服从高斯分布； $p(k | x_i, \theta^{(n)})$  为第  $k$  个高斯分量的后验概率：

$$p(k | x_i, \theta^{(n)}) = \frac{\pi_k p_k(x_i | \theta_k)}{\sum_{k=1}^K \pi_k p_k(x_i | \theta_k)} \quad (3.8)$$

在得到期望  $Q(\theta | \theta^{(n)})$  后，在 M 步骤中就可以利用式 (3.9) - (3.11) 重新估计混合高斯模型的各个参数：

$$\pi_k^{(n+1)} = \frac{1}{N} \sum_{i=1}^N p_k(k | x_i, \theta_k^{(n)}) \quad (3.9)$$

$$\mu_k^{(n+1)} = \frac{\sum_{i=1}^N x_i p_k(k | x_i, \theta_k^{(n)})}{\sum_{i=1}^N p_k(k | x_i, \theta_k^{(n)})} \quad (3.10)$$

$$\Sigma_k^{(n+1)} = \frac{\sum_{i=1}^N (x_i - \mu_k^{(n+1)})^2 p_k(k | x_i, \theta_k^{(n)})}{\sum_{i=1}^N p_k(k | x_i, \theta_k^{(n)})} \quad (3.11)$$

E 步骤和 M 迭代，直到得到的各参数值收敛为止。

### 3.3 基于直方图分析的非参数化变形模型

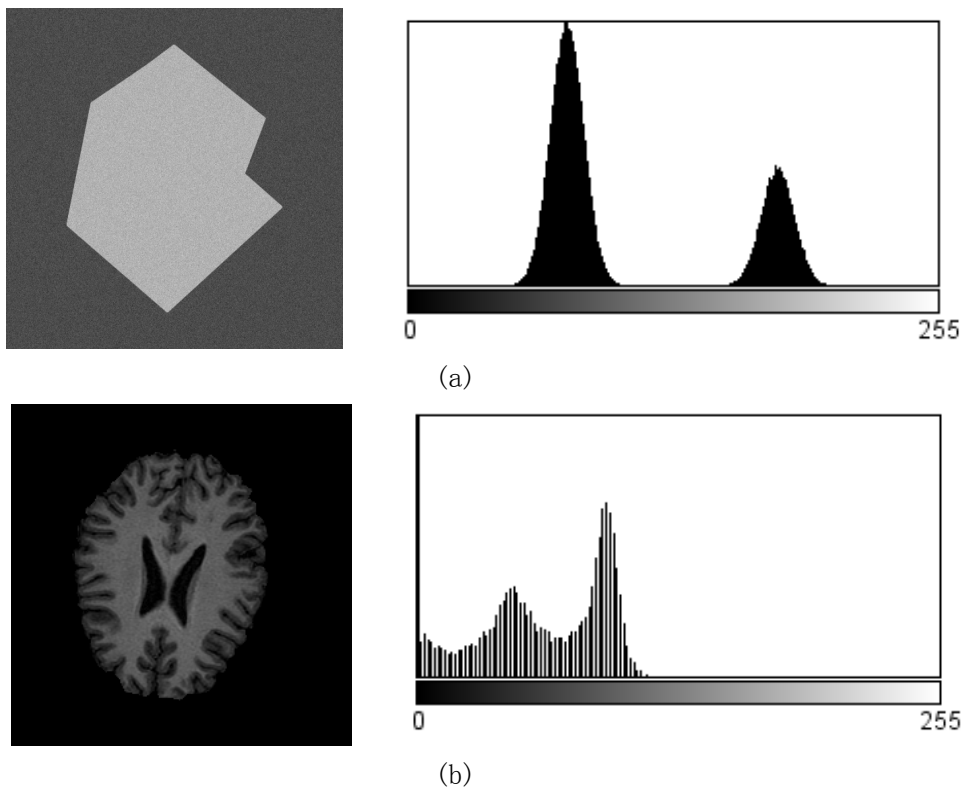


图 3.2 直方图示例

Fig.3.2 Examples of Intensity Histogram

图像灰度直方图反映的是图像中某个灰度值出现的频次，也可以认为是图像灰度概率密度。如果图像所包含的目标区域与背景区域相比比较大，且背景区域和目标区域在



灰度上有一定的差异，那么该图像的灰度直方图呈现双峰一谷形状，其中一个峰对应于目标，另一个峰对应于背景的中心灰度。对于复杂的图像，尤其是医学图像，一般是多峰的。图 3.2 中示出了两个直方图的例子。图 3.2(a) 中的图像直方图呈现出明显的双峰特性，其中一个对应背景区域，另一个对应目标。而在图 3.2(b) 中，直方图呈现出多峰特性。

通过将直方图的多峰特性看作是多个高斯分布的叠加，可以解决图像的分割问题。并且，高斯拟合优化获得的特征参数可以作为后续 Level Set 分割的约束条件来使用。

### 3.3.1 直方图分析

设具有复杂目标和/或背景的图像灰度归一化直方图为  $p(z)$ ，其中  $0 \leq z \leq L-1$ ， $L$  为图像的灰度等级数。归一化的直方图  $p(z)$  可以看作是一组高斯分布的加权和，即用用户那和高斯模型来逼近归一化的直方图：

$$p(z) = \sum_{i=1}^k \pi_i \mathcal{N}_i(z | \mu_i, \sigma_i) + r(z) \quad (3.12)$$

其中， $\mathcal{N}_i(z | \mu_i, \sigma_i)$  是均值为  $\mu_i$ 、方差为  $\sigma_i^2$  的高斯信号， $\pi_i$  是权值； $r(z)$  是残差， $k$  为高斯分量的个数。混合高斯模型的参数可以通过最小平方误差准则<sup>[164]</sup>或者 EM 算法进行估计。本文中采用 EM 算法估计混合高斯模型的参数。

### 3.3.2 高斯分布参数估计

对直方图进行高斯分解就是确定每个高斯分布的特征参数，即  $\mu_i$ 、 $\sigma_i^2$  和  $\pi_i$ 。对于式 (3.12)，共有  $3k$  个参数需要求解。本文采用 EM 算法进行参数估计。具体步骤如下：

① 采用 Savitzky-Golay 方法<sup>[165]</sup>对直方图进行平滑处理，以消除直方图中的毛刺噪声；

② 初始化参数，应用 EM 算法对图像灰度直方图进行高斯拟合，估计高斯分布参数以及混合系数；

③ 剔除虚假聚类中心。对可能存在的虚假聚类中心，依据文献<sup>[166]</sup>提出的方法予以剔除，并重新估计高斯分布参数和权系数。

直方图拟合获得一组特征参数  $(\mu_i, \sigma_i)$ ， $i = 1, \dots, k$  用来生成约束函数，指导曲线的进化，完成图像的分割。

### 3.3.3 几何活动轮廓模型

Caselles 和 Malladi 等人提出了进行边缘检测的几何活动轮廓模型<sup>[140,121]</sup>。

$$\frac{\partial u}{\partial t} = g(I)(c + K)|\nabla u| \quad (3.13)$$

其中  $u$  是水平集函数； $c$  是常数； $K$  是平均曲率。其中停止项  $g(I)$  定义为：

$$g(I) = \frac{1}{1 + |\nabla G_\sigma * I|^2} \quad (3.14)$$

式中， $G_\sigma$  是尺度为  $\sigma$  的高斯函数； $*$  是卷积运算符。在均匀区域，由于图像的梯度为零， $g(I)$  值趋于 1，曲线沿法线方向进化；在边缘附近，图像的梯度值趋于无穷大， $g(I)$  趋近于 0，导致  $\partial u / \partial t = 0$ ，曲线进化停止，从而完成边缘的检测和定位，达到分割目的。式 (3.13) 可以写成更一般形式：

$$\frac{\partial u}{\partial t} = g(I)F(K)|\nabla u| \quad (3.15)$$

式中  $F(K) = 1 - \varepsilon K$ ，称为曲率依赖的速度项，控制曲线的进化。

### 3.3.4 模型的改进

从理论角度，在图像的均匀区域，由于图像的梯度值为 0，因而停止项  $g(I)$  值趋于 1，曲线以常数速度进化；而在目标边缘附近，由于图像梯度值趋于无穷大，从而  $g(I)$  值趋于 0，使得进化停止。然而在 MRI 图像成像过程中，由于噪声、磁场的均匀性、部分容积效应以及生物组织的多样性等因素，使图像的不同组织之间没有清晰的边界，也使得停止项  $g(I)$  在真正的图像边缘位置并不为零。因此，曲线的进化也并不会停止。另外，在图像分割之前，通常需要采用大尺度对图像进行高斯平滑和滤波处理，一方面可以滤除噪声（当噪声存在时），另一方面，也是为了扩大边缘吸引力场的作用范围。这种平滑处理将在一定程度上解决初始化位置必须靠近真实边缘的缺陷。对于成像质量较好的 CT、MRI 图像而言，扩大边缘吸引力场的作用范围是其主要目的。但是，这种处理也模糊了图像的边缘和图像的细节，使边缘点的位置发生移动，造成边界定位的精确性下降。因此，需要对几何活动轮廓模型进行改进。

根据文献<sup>[167]</sup>，采用约束函数  $\alpha$  代替式 (3.15) 中的停止项  $g(I)$ ，得到以下的进化模型：

$$\frac{\partial u}{\partial t} = \alpha \cdot (1 - \varepsilon K)|\nabla u| \quad (3.16)$$

约束函数  $\alpha$  的定义式为：

$$\alpha(i, j) = \begin{cases} 1 & I(i, j) \in R_k \\ -1 & I(i, j) \notin R_k \end{cases} \quad (3.17)$$

其中  $R_k$  是图像直方图拟合中第  $k$  个高斯分量对应的目标区域。

约束函数的生成，关系到图像分割的准确程度。将图像依据直方图高斯拟合中获得的特征参数  $(\mu_i, \sigma_i)$ ，按照  $(u_i - \lambda_L \sigma_i, u_i + \lambda_R \sigma_i)$  的灰度置信区间进行拆分。参数  $\lambda_L$  和  $\lambda_R$  决定了置信区间的大小，选择 2 时可以获得好的分割结果。对目标和背景复杂的图像，则可以按照 Abd-Elmaged 和 Smith<sup>[168]</sup> 给出的方法进行选择。

### 3.4 算法实现

用前向和后向有限差分逼近一阶导数，用 upwind 格式逼近水平集的绝对梯度值。

$$u_{i,j}^{n+1} = u_{i,j}^n + \Delta t \{ (1 - \varepsilon K_{i,j}) [\max(\alpha(i, j), 0) |\nabla_{i,j} u_{i,j}^n|_- + \min(\alpha(i, j), 0) |\nabla_{i,j} u_{i,j}^n|_+] \} \quad (3.18)$$

其中，

$$\begin{aligned} |\nabla u|_+ &= \{ [\max^2(du_x^-, 0) + \min^2(du_x^+, 0)] + [\max^2(du_y^-, 0) + \min^2(du_y^+, 0)] \}^{1/2} \\ |\nabla u|_- &= \{ [\max^2(du_x^+, 0) + \min^2(du_x^-, 0)] + [\max^2(du_y^+, 0) + \min^2(du_y^-, 0)] \}^{1/2} \end{aligned} \quad (3.19)$$

式中， $|\cdot|$  表示 2 范数； $\Delta t$  是时间步距； $du_x^+$  和  $du_x^-$  分别表示沿  $x$  方向的前项和后向差分；

$$\begin{aligned} du_x^- &= \frac{u_{i,j} - u_{i-1,j}}{\Delta x}, & du_x^+ &= \frac{u_{i+1,j} - u_{i,j}}{\Delta x}, \\ du_y^- &= \frac{u_{i,j} - u_{i,j-1}}{\Delta y}, & du_y^+ &= \frac{u_{i,j+1} - u_{i,j}}{\Delta y}. \end{aligned}$$

分割算法可以归结为以下步骤：

- (1) 将具有多峰态的直方图进行高斯拟合，提取特征参数  $(\mu_i, \sigma_i)$ 。
- (2) 根据获得的特征参数  $(\mu_i, \sigma_i)$ ，按照式 (3.17) 生成约束函数  $\alpha(i, j)$ 。
- (3) 设置进化参数，按照式 (3.18) 的算法完成图像分割。
- (4) 形态学后处理。

### 3.5 实验结果

图 3.3 为本文得到的图像分割结果，实验图像为 $128 \times 104$ 人工合成图像。图像中包含凹、凸、角点和圆弧等形状，用于测试算法的分割性能。图 3.3(a) 和 3.3(b) 采用 GAC 方法进行分割。其中左图为初始化情况，右图为分割结果。图 3.3(c) 和 3.3(d) 采用本分割方法，分别采用了半内半外和多零水平集的初始化。初始化在内部和外部试验结果和图 3.3(c) 和 3.3(d) 的结果相同，文中未提供分割结果图。图 3.3 中(e)、(f)、(g) 分别是图中(a)、(b)、(c) 分割结果的左上部分的局部放大图。




图 3.3 合成图像分割结果：(a)初始化位置在图像内部的 GAC 分割；(b)初始化位置在图像外部的 GAC 分割；(c)本文的方法分割(半内半外)；(d)本文的方法分割(多种子初始化)；(e)图(a)中分割结果的左上部分局部图；(f)图(b)中分割结果的左上部分局部图；(g)图(c)中分割结果的左上部分局部图。

Fig. 3.3 Segmentation results of the synthetic image: (a) GAC segmentation with the initial curve inside the image; (b) GAC segmentation with the initial curve outside the image; (c) the improved method segmentation with the arbitrary initial curve; (d) the improved method segmentation with the multiple ZLS initial curves;(e) selective enlargement of result (a); (f) selective enlargement of result (b); (g) selective enlargement of result (c).

从局部放大图可以看出，不管是初始位置完全包围图像，还是在图像内部，分割结果都不令人满意，边界的定位都存在明显的偏差。而本文采用的方法可以准确对目标进行分割，边界定位准确。对图 3.3 中的合成图像将两种算法的分割结果进行了统计，表 1 给出了统计结果（按照分割面积计算）。从分割结果图和统计结果看，GAC 方法的初始化对分割结果有较大影响，初始位置在外部的分割误差大于初始位置在内部初始化；进化曲线不能够深入图像的凹和凸部分（见图 3.3(e)、3.3(f)）；而本文采用的算法都能够准确对边界进行定位，包括凹点和角点（见图 3.3(g)）；另外，不管采用何种初始化形式，本算法分割结果一致，初始化形式对分割结果不产生影响，表明本算法具有较好的韧性。

表 3.1 分割准确度比较

Tab. 3.1 Comparison of the segmentation accuracy of two algorithms

分割算法	初始化（内）		初始化（外）	
	错分点数	错误率/%	错分点数	错误率/%
GAC	231	13.48	386	22.64
本算法	0	0	0	0

为了进一步测试算法的分割性能，采用仿真 MRI 图像进行分割实验。实验图像从 Brainweb<sup>[42]</sup>下载，在 10 个不同的图像集上分别提取第 96 切片，去除非脑组织，图像尺寸为 181 像素×217 像素。参数设置：聚类数  $k=4$ ，拆分区间倍数  $\lambda_L = \lambda_R = 2$ ，进化参数  $\varepsilon = 0.025$ ， $\Delta t = 0.5$  s。初始化方式采用的是多零水平集初始化，256 个种子均匀分布在图像域中，以加快分割速度。迭代终止条件：新分入像素比率分别小于  $10^{-5}$ 、 $5 \times 10^{-4}$ 、 $10^{-4}$  和  $10^{-4}$ （分别对应背景、CSF、GM 和 WM），或者迭代次数超过 100 次。图 3.4 为其中一幅图像及其离散解剖结构模型和三种脑组织的分割结果。

图 3.4 (a) 为原始图像和白质、灰质、脑脊液的离散解剖模型；图 3.4 (b) 为本算法的分割结果（其中背景分割结果没有列出）。从图 3.4 (a)、(b) 的对比来看，除了灰质图像中侧脑室的边沿分割稍微欠缺以外，灰质图像中的其它部分以及白质和脑脊液的分割结果是令人满意的。为了更直观地定量反应分割性能，对 10 幅分割图像的敏感性、专一性和总体性能<sup>[91]</sup>指标进行了统计，表 3.2 为统计结果，表中数据是三个脑组织分割指标的平均值；为了反映算法的总体性能，还对 10 幅图像按照组织进行了统计，表 3.3 为统计结果，表中 WM、GM、CSF 栏目数据是 10 图像分割指标按组织的平均值和标准差，而平均一栏则是三个脑组织平均分割指标的平均值。




图 3.4 T1 加权图像分割实验。（a）原始图像与离散解剖模型；（b）WM、GM 和 CSF 分割结果

Fig. 3.4 Segmentation result. (a) Original image and discrete anatomical model (form left to right: T1W, WM, GM and CSF); (b) Segmentation result of the algorithm (form left to right: WM, GM and CSF)

表 3.2 10 幅图像分割性能按指标平均值

Tab. 3.2 Average performances of 10 segmented results in term of indexes

指标	图像序号									
	1	2	3	4	5	6	7	8	9	10
灵敏度/%	97.82	93.76	94.18	94.63	93.60	94.37	93.44	94.25	94.01	97.11
专一性/%	97.75	96.98	97.85	97.55	97.16	97.43	97.54	97.51	97.51	97.90
总体性能/%	97.82	96.63	97.47	97.17	96.75	97.11	97.17	97.09	97.06	97.89

表 3.3 分割性能按组织平均值

Tab. 3.3 Average performances of segmentation results in term of tissues

指标	WM	GM	CSF	平均
灵敏度/%	97.02 ± 1.01	95.35 ± 1.26	91.78 ± 2.52	94.72
专一性/%	97.90 ± 0.22	96.45 ± 0.51	98.20 ± 0.24	97.52
总体性能/%	97.71 ± 0.31	96.23 ± 0.62	97.72 ± 0.32	97.22

从表 3.2、表 3.3 的统计结果可以看出，按组织统计，白质的分割性能最高，敏感性、专一性、和总体性能三个指标超过了 97 %；灰质的分割结果稍微比白质低，三个指标值均在 95 %以上；脑脊液分割中，除了敏感性指标为 91.78 %，稍低以外，专一性和总体性能指标都在 98 %附近。小的标准差表明本算法有良好的分割一致性。总体分割性能方面，10 幅图像平均敏感度指标达到 94.72 %，而平均专一性指标和平均总体性能指标都超过了 97 %，表明本算法具有较高的分割性能和准确度。

图 3.5 和图 3.6 所示是采用脑部轴向 MRI 切片进行分割的实验情况。图 3.5(a) 是待分割 MRI 真实图像，图像尺寸为 256 像素×256 像素；图 3.5(b) 是待分割图像的直方图(上图)和直方图轮廓及高斯拟合结果(下图)。由于图像亮度较低，图像直方图偏向于直方图的低端。在直方图高斯拟合分析中，设置聚类数为 3。聚类分析结果和优化后的特征参数见表 3.4。




图 3.5 MRI 图像及直方图拟合：(a) 待分割图像；(b) 图像直方图及高斯拟合结果  
Fig.3.5 MRI image and histogram fitting: (a) MR image; (b) histogram and fitting curve.

表 3.4 高斯分量特征参数

Tab. 3.4 Characteristic parameters of the Gaussian componets

聚类	$\mu_i$	$\sigma_i$	$A_i$
1	0.303	1.7198	0.72145
2	31.024	7.5439	0.13789
3	59.146	6.3074	0.14066




图 3.6 MRI 图像分割结果: (a) 灰质; (b) 白质

Fig.3.6 Segmentation result of MRI images: (a) gray matter; (b) white matter

图 3.6 为白质和灰质的分割结果。图 3.6(a)中, 右侧上部(坐标约(150, 60)处)和中部(坐标约(180, 100)和(180, 160)处)的脑沟能够准确的分割出来; 图像灰质部分的外边缘定位准确。图 3.6(b)左侧上部(坐标约(70, 80)处)和中部(坐标约(80, 120)处)的细长部分都能够进行准确的分割。专家目测认为具有较高的分割准确度。

### 3.6 本章小结

由于脑皮质图像广泛存在的边缘模糊区域, 边界不清晰的问题, 以及由于成像过程中的噪声、磁场的均匀性、部分容积效应等因素导致的图像质量退化, 使得图像中不同组织之间的界线更加不清晰, 仅利用图像局部边缘信息的 GAC 方法很难得到理想的分割效果。融合图像的区域信息、先验知识, 是提高分割质量的一条有效的途径。根据文献<sup>[166]</sup>的思路, 本文采用的分割方法去除了基于图像梯度信息的停止项, 代之以基于图像统计特征的约束函数。约束函数在曲线进化过程中, 能够自适应地确定曲线进化的方向(收缩或膨胀), 而不必像传统 GAC 方法在初始化时必须指定曲线进化的方向, 也减少了人工干预, 使算法具有更好的鲁棒性。本算法可以方便地推广到多个目标的并行分割, 分别采用对应类的约束函数即可, 而且多个进化曲线之间具有独立性, 互不耦合。

脑脊液的过分割一直是各种分割算法致力解决的问题。由于脑脊液结构上处于灰质边沿部分和侧脑室中, 大体上是一种细长且缠绕的结构, 这决定了脑脊液的分割是最具有挑战性的工作。本研究中, 采用形态学的后处理办法, 对分割后的二值图像进行 2 个像素的膨胀处理, 有效地提高了脑脊液的分割指标。



---

用基于图像全局统计特征的约束项代替传统算法中的基于图形梯度的停止项，提高了边界定位的准确性和图像的分割质量；将直方图分析和自适应水平集分割方法相结合，消除了传统 GAC 分割方法对图像梯度信息的依赖；基于图像统计信息的约束函数的引入，也解决了 GAC 方法中曲线进化只能在一个方向进行且必须在分割开始之前设定好的缺陷，使得初始化的位置和形式对分割结果不产生影响，因而算法具有更好的鲁棒性；随机多种子初始化方式也减少了人工干预，使图像的自动分割成为可能。文中对人工合成图像和 MRI 图像进行了分割实验，并进行了定量和定性分析，MRI 仿真实验的分割灵敏度、专一性和总体性能指标分别达到了 94.72 %、97.52 %和 97.22 %，分析结果表明算法的有效性以及较高的分割准确度。

---

## 4 基于区域的非参数变形模型

### 4.1 概述

磁共振成像由于其高的分辨率和良好的软组织辨别能力在临床应用中发挥着越来越重要的作用。高级应用中的形态测度学需要将脑实质分割成不同的组织，如灰质、白质和脑脊液。这些应用包括多模态图像的校准、可视化、肿瘤和脑损伤检测<sup>[169]</sup>，脑发育和人的衰老<sup>[170]</sup>，诊断和治疗以及认知一些脑的疾病，如 Alzheimer 和脑水肿<sup>[171]</sup>等。研究人员已经提出了一些脑 MRI 图像的分割算法，在这些算法中聚类算法是最流行的一类算法，其中最典型的是模糊 C-均值和期望最大化（EM）算法。

在最近的数十年间，相对于硬分割方法，许多文献更倾向于使用软分割技术。Shen 等<sup>[91]</sup>在传统的 FCM 算法中引入了邻域吸引来分割脑组织，使得像素的分类受到邻域像素位置和特征的影响。算法极大地提高了分割性能。Liew 和 Yan<sup>[108]</sup>在 FCM 算法中考虑了空域连续性的约束。他们在目标函数中介入了像素的直接邻域像素的加权平均约束项，像素的分类受到其直接邻域像素的所属类别的约束。Pham 和 Prince<sup>[172]</sup>提出了自适应的 MRI 图像分割算法。因为算法在分割过程中能同时对偏置场进行校正，因而分割结果能够适应灰度不均匀问题。Awate 等人在<sup>[173]</sup>中应用模糊非参数模型来分割 DT 图像和 MRI 图像。算法中通过 Markov 随机场引入空域约束，通过最小化基于信息理论的能量函数实现在 DT 图像中提取带状物，在 MRI 图像中分割不同的组织。Wang 等<sup>[98]</sup>提出了一个修改的 FCM 算法，算法中能够考虑了局部和非局部的空域约束，来提高分割性能和对噪声的抗干扰能力，缺点是计算代价大。

期望最大化算法的在脑分割中的应用在文献<sup>[72,174,175]</sup>中有报道。Wells 等<sup>[72]</sup>提出了同时进行组织分割和灰度不均匀校正的算法，算法中用 EM 算法进行参数估计并完成分割任务。Leemput 等<sup>[174]</sup>将该算法进行了扩展，算法中通过 Markov 随机场模型也引入上下文信息。在此后的工作中，又在 EM 算法中又隐含地考虑了部分容积效应<sup>[175]</sup>。EM 算法的缺点是关于灰度正态分布的假设问题，这个假设在某些情况下不能够得到满足，如噪声污染的图像。

水平集方法在近年广泛应用于图像处理领域，当然也包括 MRI 图像的脑分割。Xu 等<sup>[26]</sup>应用模糊分割，等值面算法（isosurface algorithm）和变形表面模型来重建完整的皮层，皮层经过拓扑校正，包含深度缠绕的脑沟和回。Cho 等作者<sup>[176]</sup>在确定性模拟退火期望最大算法（Deterministic Annealing Expectation Maximization, DAEM）中引入水平集技术。算法中用混合高斯模型（mixture Gaussian model, MGM）和确定性退火期望最大算法 DAEM 来计算各个类别的后验概率，每个像素依据最大后验概率进行分类，水

平集方法完成最后的分割。Poon 等人<sup>[177]</sup>定义了类内和类间灰度变化测度，然后构建区域能量项来分割左心室。Suri<sup>[134, 178]</sup>将 FCM 算法和水平集方法融合到几何活动轮廓模型（Geometric Active Contour, GAC）框架<sup>[140]</sup>之中，来分割白质/灰质边界。算法中结合了区域信息和梯度信息，被称之为基于区域的 GAC（region-based GAC, RGAC）。算法容易实现，边界定位准确。该文作者声称该算法可以用来分割脑组织，但是并没有提供实验结果。在本文用该算法进行的脑组织分割实验中，反映出了一些问题，如稳定性问题。算法并不能总是得到收敛的结果，同时算法表现出对初始化条件较为敏感。该算法也没有提供分割结果的定量分析。这些促使我们进一步对其进行研究和分析。

我们对 RGAC 算法进行了认真细致的研究，特别关注了它的稳定性问题。基于对其稳定性的分析，我们认为问题主要是由稳定性造成的，而稳定性问题则是由区域项引起的。为此，本文对算法进行了改进，提出了一个新的区域项，来解决原始算法存在的稳定性方面的问题。成功的实验和定性定量分析表明这种修改是有效的，同时算法迭代次数大大降低，收敛速度以更快。另外，算法对迭代终止条件等参数设置的敏感性也得以降低。算法还被扩展到从不同模态的 MRI 图像中有效地分割脑组织，这些图像包括 T1-、T2-和 PD-加权图像。

本章余下的内容安排如下：在 4.2 节简单回顾 Suri 的 RGAC 算法；在 4.3 节对其稳定性进行分析，并提出改进算法；4.4 介绍算法的实现问题；4.5 节给出试验结果；4.6 节给出另外一个算法，即自适应水平集算法和其实验结果；4.7 节对本章内容作出小结。

## 4.2 基于区域的几何活动轮廓模型

Suri<sup>[178]</sup>提出了称之为基于区域的几何活动轮廓模型算法。算法中用压力项代替了经典 Snake 模型<sup>[51]</sup>中参数化曲线的第二个导数项。

Kass 给出的标准动态经典能量模型如下所示：

$$\gamma \frac{\partial X}{\partial t} = \underbrace{\frac{\partial}{\partial s} \left( \alpha \frac{\partial X}{\partial s} \right) - \frac{\partial^2}{\partial s^2} \left( \beta \frac{\partial^2 X}{\partial s^2} \right)}_{\text{internal-energy}} + \underbrace{F_{\text{ext}}(X)}_{\text{external-energy}} \quad (4.1)$$

式中  $X(s)$  是参数化曲线，且  $s \in [0,1]$ ； $\gamma$  是阻尼系数。能量函数由内部能量和外部能量两部分组成。从式（4.1）可以看出，经典能连函数模型构成了一个能量函数最小化的样条，样条由外部力和内部力共同控制，将参数化曲线拉向图像中如线和边缘的特征点。内部能量由两部分组成：第一个导数项作用如同一个薄膜；第二个导数项作用如同薄板，又称为压力。这两项由弹性常数  $\alpha$  和  $\beta$  控制。经典能量模型的第二部分是外部力项  $F_{\text{ext}}(X)$ ，外部力依赖于图像的力，是图像梯度的函数。参数化 Snakes 模型能够灵活地

动态控制参数化曲线的运动，而其在处理高度缠绕的结构、尖角、或有噪声图像时也有其自身的缺陷：如初始化曲线要尽量靠近分割目标，否则可能陷入局部极小值；在处理拓扑结构变化方面有一定的困难，需要特殊的处理等。因而 Suri 试图在保留参数化 Snake 模型的经典属性情况下，引入几何属性来捕获脑中缠绕结构的拓扑变化。

由于式 (4.1) 中的第二个导数项对蛇的性能影响不大，因而 Suri 提出用新的压力项  $F_p(X)$  代替第二个导数项。压力项  $F_p(X)$  是向外的力，是变形曲线的单位法向量  $\mathcal{N}$  的函数。因而定义  $F_p(X) = \omega_p(X)\mathcal{N}(X)$ ，因而新的参数化活动轮廓模型可以用下式描述：

$$\gamma \frac{\partial X}{\partial t} = \frac{\partial}{\partial s} \left( \alpha \frac{\partial X}{\partial s} \right) - \omega_p(X)\mathcal{N}(X) + F_{\text{ext}}(X) \quad (4.2)$$

定义  $\frac{\partial}{\partial s} \left( \alpha \frac{\partial X}{\partial s} \right) = k$  是变形曲线的曲率，并重新定义常数  $\varepsilon = \frac{\alpha}{\gamma}$ ， $V_p = \frac{\omega_p}{\gamma} \mathcal{N}(X)$ ，和  $V_{\text{ext}} = \frac{F_{\text{ext}}}{\gamma}$ ，式 (4.2) 可以改写成如下形式：

$$\frac{\partial X}{\partial t} = (\varepsilon k + V_p + V_{\text{ext}} \cdot \mathcal{N})\mathcal{N} \quad (4.3)$$

式 (4.3) 与水平集方法的进化方程  $\frac{\partial \phi}{\partial t} = V(k)\mathcal{N}$  非常相似，这里  $\mathcal{N} = -\nabla \phi / |\nabla \phi|$  是单位法向量， $\phi$  是水平集函数， $V(k)$  是曲率依赖的速度项。

如果仅考虑沿法向量方向的内部和外部力，则有：

$$\frac{\partial}{\partial s} \left( \alpha \frac{\partial X}{\partial s} \right) \cdot \mathcal{N} = \alpha k \quad (4.4)$$

因而得到偏微分方程：

$$\frac{\partial \phi}{\partial t} = (\varepsilon k + V_p) |\nabla \phi| - V_{\text{ext}} \cdot \nabla \phi. \quad (4.5)$$

式中  $V_p$  作为区域力项，可以在数学上表示为曲线内-外面及的组合，定义为

$$V_p = \frac{\omega_R}{\lambda R_{\text{ind}}} \quad (4.6)$$

其中  $R_{\text{ind}}$  是区域指示项，且  $R_{\text{ind}} \in [0, 1]$ 。区域项是水平集框架下控制几何蛇进化的一个分量。

式 (4.5) 用前向欧拉时间离散成如下形式:

$$\phi_{x,y}^{n+1} = \phi_{x,y}^n - \Delta t \{V_{\text{reg}}(x,y) + V_{\text{grad}}(x,y) - V_{\text{cur}}(x,y)\}, \quad (4.7)$$

其中  $V_{\text{grad}}(x,y)$  是基于图像梯度的速度项,  $V_{\text{cur}}(x,y)$  基于曲率的速度项,  $V_{\text{reg}}(x,y) = V_p(x,y) |\nabla \phi|$  是基于区域的速度项。

Suri 定义  $V_p(x,y)$  为<sup>[178]</sup>

$$V_p(x,y) = \frac{\omega_R}{\lambda R_{\text{ind}}} = \frac{\omega_R}{\lambda(1-2u(x,y))}, \quad \omega_R, \lambda \in \mathbb{R}^+, \quad (4.8)$$

其中  $u$  是隶属度函数, 可以通过 FCM 算法对图像进行模糊分析得到。

### 4.3 存在问题与算法改进

#### 4.3.1 存在问题

Suri 提出的算法用来分割白质和灰质的边界, 其初始轮廓线需要手工放置在待分割目标内部。然后算法在窄带 (Narrow Band, NB) 内运行快速推进算法 (Fast Marching Method, FMM)。Suri 等<sup>[134, 178]</sup>在其工作中仅提供了白质和灰质边界的分割结果, 但是没有定量的分析。本文实现了该算法, 并采用了多种子点初始化方式。在用算法分割脑组织时, 我们发现存在稳定性的问题, 有时得到发散的分割结果; 分割质量随着分割组织的不同而发生剧烈变化, 甚至于在同一个数据集内, 切片变化也会引起分割质量的巨大差别。另外, 算法还表现出对迭代终止条件和设置参数的敏感性。这些表明算法存在稳定性方面的问题。在下一小节中, 我们将对其稳定性进行分析, 并提出改进方法。

#### 4.3.2 稳定性分析与改进

##### (1) 稳定性分析

Suri<sup>[178]</sup>建议区域项取  $V_p(x,y) = \omega_R / \lambda R_{\text{ind}}(x,y)$ , 式中  $R_{\text{ind}}(x,y) = 1 - 2u(x,y)$  是区域指示函数, 作者建议设置  $\omega_R = 0.5$ ,  $\lambda = 1$ 。由于隶属度值  $u(x,y) \in [0,1]$ , 因而区域指示子  $R_{\text{ind}} \in [-1,1]$ , 所以  $V_p \in (-\infty, -0.5] \cup [0.5, +\infty)$ 。很显然在  $u(x,y) = 0.5$  出现了一个二类的间断点。

换一个方式来表示式 (4.5):

$$\frac{\partial \phi}{\partial t} + (V_{\text{ext}} \cdot \nabla \phi - V_p |\nabla \phi|) = \frac{\partial \phi}{\partial t} + H = \varepsilon k |\nabla \phi|, \quad (4.9)$$

式中  $V_p |\nabla\phi|$  和  $V_{\text{ext}} \cdot \nabla\phi$  两项是双曲项,  $\varepsilon k |\nabla\phi|$  是抛物项。用水平集方法实现式(4.9)时, 式中的双曲项需要用迎风差分 (upwinding difference) 格式进行离散, 而抛物项需要用中心差分进行离散。Runge-Kutta (RK) 时间离散可以用来提高时域的离散精度。根据稳定性的要求, 包含抛物项和双曲项方程的 Courant-Friedrichs -Lewy (CFL) 稳定条件有下式给出<sup>[118]</sup>:

$$\Delta t \left( \frac{|H_1|}{\Delta x} + \frac{|H_2|}{\Delta y} + \frac{|H_3|}{\Delta z} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} + \frac{2|\varepsilon|}{(\Delta z)^2} \right) < 1, \quad (4.10)$$

式中  $H_1$ ,  $H_2$  和  $H_3$  是  $H$  分别对  $\phi_x$ ,  $\phi_y$  和  $\phi_z$  的偏微分,  $\Delta x$ ,  $\Delta y$  和  $\Delta z$  是分别是三维空间中在  $x$ ,  $y$  和  $z$  三个方向上的空间步距。

结合式 (4.5) 和 (4.10), 二维下的稳定条件 CFL 可以写成如下形式:

$$\Delta t \left( \frac{|V_p \frac{\phi_x}{|\nabla\phi|} - V_{\text{ext}}|}{\Delta x} + \frac{|V_p \frac{\phi_y}{|\nabla\phi|} - V_{\text{ext}}|}{\Delta y} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} \right) < 1. \quad (4.11)$$

令  $N_x = \frac{\phi_x}{|\nabla\phi|}$  和  $N_y = \frac{\phi_y}{|\nabla\phi|}$ , 分别是单位法向量  $\mathcal{N}$  在  $x$  和  $y$  方向上的分量, 且  $N_x^2 + N_y^2 = 1$ 。

所以有下式:

$$\Delta t \cdot \max \left( \frac{|V_p N_x - V_{\text{ext}}|}{\Delta x} + \frac{|V_p N_y - V_{\text{ext}}|}{\Delta y} + \frac{2|\varepsilon|}{(\Delta x)^2} + \frac{2|\varepsilon|}{(\Delta y)^2} \right) = \alpha, \quad 0 < \alpha < 1. \quad (4.12)$$

当隶属度函数  $u$  趋近于间断点 0.5 即  $u \rightarrow 0.5$  时,  $V_p = \omega_R / \lambda R_{\text{ind}}(x, y) \rightarrow +\infty$  或  $-\infty$ , 这时  $\max(\bullet) \rightarrow \infty$ 。因而只有在时间步长趋近于零, 即  $\Delta t \rightarrow 0$  时, 式 (4.12) 表示的 CFL 条件才能得到满足。而在其取得有限小的值时, 都会违背稳定所需要的 CFL 条件。这样, 式(4.8)不能够总是保证获得一个收敛的结果。

## (2) 算法改进

前一小节的稳定性分析已经证明了该算法潜在的稳定性问题, 而且稳定问题主要是由区域项引起的。因而, 对区域项作出如下的修改:

$$V_p^{\text{new}}(x, y) = \omega_R \cdot (1 - 2u(x, y)), \quad \omega_R \in \mathbb{R}^+. \quad (4.13)$$

对式 (4.13) 做稳定性分析：首先，从稳定性方面考虑，式 (4.13) 消除了二类间断点，由于  $V_p(x, y) = \omega_R \cdot (1 - 2u(x, y))$ ，因而  $V_p^{\text{new}} \in [-\omega_R, \omega_R]$ 。二类间断点的去除，使得稳定条件 CFL 可以通过调整时间步长得到满足。第二，在进化过程中，区域项  $V_p^{\text{new}}$  的符号决定了曲线进化的方向（扩张还是收缩），其绝对值在一定程度上决定了曲线的进化速度，通过调节  $\omega_R$  可以控制进化的速度。后续的实验表明了改进解决了算法的稳定性问题，并能够提高分割的质量。

## 4.4 算法实现

4.3 节中描述的改进算法可以很容易地用水平集方法实现，4.4.1 和 4.4.2 小节分别从空间和时间离散两个方面进行描述。

### 4.4.1 空间离散

(1) 区域项：

由于区域项是双曲项，需要用迎风（upwind differencing）格式进行离散和逼近：

$$V_{\text{reg}}(x, y) = \max(V_p^{\text{new}}(x, y), 0)\nabla^+(x, y) + \min(V_p^{\text{new}}(x, y), 0)\nabla^-(x, y) \quad (4.14)$$

这里  $V_p^{\text{new}}(x, y) = \omega_R \cdot (1 - 2u(x, y))$ ，

$$\begin{cases} \nabla^+(x, y) = \left[ \max(D^{-x}(x, y), 0)^2 + \min(D^{+x}(x, y), 0)^2 + \max(D^{-y}(x, y), 0)^2 + \min(D^{+y}(x, y), 0)^2 \right]^{1/2} \\ \nabla^-(x, y) = \left[ \max(D^{+x}(x, y), 0)^2 + \min(D^{-x}(x, y), 0)^2 + \max(D^{+y}(x, y), 0)^2 + \min(D^{-y}(x, y), 0)^2 \right]^{1/2} \end{cases} \quad (4.15)$$

$D^{-x}(x, y)$ ,  $D^{+x}(x, y)$  and  $D^{-y}(x, y)$ ,  $D^{+y}(x, y)$  分别是用水平集函数  $\phi$  表示的在  $x$  和  $y$  反向的后向和前向差分：

$$\begin{aligned} D^{-x}(x, y) &= \frac{\phi(x, y) - \phi(x-1, y)}{\Delta x}, & D^{+x}(x, y) &= \frac{\phi(x+1, y) - \phi(x, y)}{\Delta x}. \\ D^{-y}(x, y) &= \frac{\phi(x, y) - \phi(x, y-1)}{\Delta y}, & D^{+y}(x, y) &= \frac{\phi(x, y+1) - \phi(x, y)}{\Delta y}. \end{aligned}$$

(2) 梯度项，与区域项类似，

$$\begin{aligned}
V_{\text{grad}}(x, y) &= V_{\text{grad}_x}(x, y) + V_{\text{grad}_y}(x, y) \\
&= \left[ \max(I_x(x, y), 0)D^{-x}(x, y) + \min(I_x(x, y), 0)D^{+x}(x, y) \right], \\
&\quad + \left[ \max(I_y(x, y), 0)D^{-y}(x, y) + \min(I_y(x, y), 0)D^{+y}(x, y) \right]
\end{aligned} \tag{4.16}$$

这里  $I_x(x, y) = \nabla_x(\omega_\epsilon \nabla(G_\sigma * I))$ ,  $I_y(x, y) = \nabla_y(\omega_\epsilon \nabla(G_\sigma * I))$  是平滑版的图像梯度信息,  $\omega_\epsilon$  是正的常数。

曲率项

(3) 曲率项在模型中是抛物项, 需要用中心差分来逼近:

$$V_{\text{cur}}(x, y) = \epsilon k^n(x, y) [(D^{0x}(x, y))^2 + (D^{0y}(x, y))^2]^{1/2}, \tag{4.17}$$

其中,  $k^n(x, y) = (\phi_{xx}^2 \phi_y^2 - \phi_x^2 \phi_y^2 \phi_{xy}^2 + \phi_{yy}^2 \phi_x^2) / (\phi_x^2 + \phi_y^2)^{3/2}$  是平均曲率,  $D^{0x}(x, y)$  和  $D^{0y}(x, y)$  是二阶准确度的  $x$  和  $y$  向中心差分, 用水平集函数  $\phi$  表示为:

$$D^{0x}(x, y) = \frac{\phi(x+1, y) - \phi(x-1, y)}{2\Delta x}, \quad D^{0y}(x, y) = \frac{\phi(x, y+1) - \phi(x, y-1)}{2\Delta y}.$$

#### 4.4.2 时间离散

Shu 和 Osher<sup>[187]</sup>提出了总变差减小 (Total Variations Decreasing, TVD) Runge-Kutta (RK) 法, 来提高直线法方法对时间离散的准确度。直线法方法假设空间离散和时间离散在半离散方式是可分离的, 它允许偏微分方程的时间离散当作常微分方程来处理。有许多的 Runge-Kutta 方案, 只要前向欧拉组成部分不产生寄生振荡, 这些 TVD RK 方案能够保证作为高阶准确度时间离散的结果不会产生寄生震荡。

(1) 一阶准确度的 TVD RK 方案就是前向欧拉方法。

(2) 二阶准确度的 TVD RK 方法与标准的二阶 RK 法是等同的。

设进化方程有如下形式:

$$\phi_t + \vec{V} \cdot \nabla \phi = 0 \tag{4.18}$$

第一步, 将进化方程做一次欧拉步骤,

$$\frac{\phi^{n+1} - \phi^n}{\Delta t} + \vec{V}^n \cdot \nabla \phi^n = 0 \tag{4.19}$$

第二步, 将进化方程再做一次欧拉步骤,

$$\frac{\phi^{n+2} - \phi^{n+1}}{\Delta t} + \vec{V}^{n+1} \cdot \nabla \phi^{n+1} = 0 \tag{4.20}$$



第三步，求二者的平均值

$$\phi^{n+1} = \frac{1}{2}\phi^n + \frac{1}{2}\phi^{n+2} \quad (4.21)$$

最后的平均获得了  $\phi$  在  $t^n + \Delta t$  时刻的二阶准确度的 TVD 逼近。

(3) 三阶准确度的 TVD RK 方案如下：

第一步，求得  $t^n + \Delta t$  时刻的解

$$\frac{\phi^{n+1} - \phi^n}{\Delta t} + \bar{V}^n \cdot \nabla \phi^n = 0 \quad (4.22)$$

第二步，求得  $t^n + 2\Delta t$  时刻的解，

$$\frac{\phi^{n+2} - \phi^{n+1}}{\Delta t} + \bar{V}^{n+1} \cdot \nabla \phi^{n+1} = 0 \quad (4.23)$$

第三步，求二者的加权平均值，得到  $t^n + \frac{1}{2}\Delta t$  时刻的解

$$\phi^{n+\frac{1}{2}} = \frac{3}{4}\phi^n + \frac{1}{4}\phi^{n+2} \quad (4.24)$$

第四步，求得  $t^n + \frac{3}{2}\Delta t$  时刻的解

$$\frac{\phi^{n+\frac{3}{2}} - \phi^{n+\frac{1}{2}}}{\Delta t} + \bar{V}^{n+\frac{1}{2}} \cdot \nabla \phi^{n+\frac{1}{2}} = 0 \quad (4.25)$$

最后，求加权平均，获得  $t^n + \Delta t$  时刻的解：

$$\phi^{n+1} = \frac{1}{3}\phi^n + \frac{2}{3}\phi^{n+\frac{3}{2}} \quad (4.26)$$

结果即为  $\phi$  在  $t^n + \Delta t$  时刻的三阶准确度的逼近<sup>[118]</sup>。

## 4.5 实验结果

本小节通过实验来验证改进的算法，实验图像包括 T1、T2 和 PD-加权 MRI 图像，分割结果将于其它算法进行比较。

需要说明的是，改进算法能够自适应地确定曲线进化的方向，也即曲线能够在两个方向上设置，因而可以采用多种子点的初始化方式。该种初始化方式可以加快算法的收

---

敛速度，以及提高算法对初始化的鲁棒性。在改进算法中，初始化曲线定义为  $16 \times 16$  圆圈种子，均匀地分布在图像区域内。为了方便算法的对比，原始算法也采用这种多初始化方式。

#### 4.5.1 T1-加权图像分割实验

算法首先分割 T1-加权图像。图像从 Brainweb<sup>[42]</sup>网站下载，该网站同时提供了图像的离散组织模型，可以作为‘金标准’对分割结果进行评估。仿真图像轴向尺寸  $256 \times 256$  像素，平面内分辨率 1 mm，切片厚度 1 mm。从不同的数据集中提取 15 个切片，去除非脑组织。为方便显示和图像处理，图像被剪切成  $181 \times 217$  像素大小。

改进算法参数设置： $\omega_e = 0.5$ ， $\varepsilon = 0.025$ ， $\Delta t = 0.1$ ， $\omega_R = 7$

原始算法参数设置： $\omega_e = 0.5$ ， $\varepsilon = 0.025$ ， $\Delta t = 0.1$ ， $\omega_R = 0.5$ ， $\lambda = 1$

FCM 阶段设置： $C = 4$ ，分别对应 WM, GM, CSF 和背景

迭代终止条件：CSF 分割：新分入像素比例小于  $10^{-2}$

GM 和 WM 分割：新分入像素比例小于  $10^{-4}$   
或迭代次数超过 500 次

图 4.1 显示了测试图像集中一幅图像的分割结果。图 4.1(e)中，在图中圈示位置的图像细节没有准确地分割出来。总体来说，图 4.1(e)中的原始算法 (RGAC) 的分割结果不如图 4.1(h)改进算法 (RGAC\_M) 的分割结果。在 4.1(f)中，在顶部圆示位置的 CSF 被误分入 GM 组织中，在左、右以及下部的圈示位置，灰质被错误地分入白质类别中。在改进算法的分割结果图 4.1(i)中的对应部分分割结果好于 4.1(f)；4.1(g)中断断续续的 CSF 轮廓表明原始算法在分割 CSF 时，整体上而言是不成功的；在 4.1(j)中，改进算法准确地分割出了 CSF。很明显，改进算法获得了比原始算法更好的分割结果。定性分析的结果在表 4.1 所示的统计指标中得到了验证。

为了定量地评价分割性能，本文采用三个测度：相似度指标  $\rho$ ，假阳性率  $r_p$  和假阴性率  $r_n$ （具体定义见文献[98]）来评价分割结果。分割 15 幅图像的实验中，原始算法有 5 幅分割失败，其中 2 幅图像在分割 GM 组织时失败，3 幅在分割 CSF 时失败，而改进算法全部成功分割该 15 幅图像。表 4.1 给出了这 10 幅图像的分割结果的统计指标。




图 4.1 T1-加权图像分割结果：(a) 原始图像；金标准 (b) WM, (c) GM 和 (d) CSF；原始算法的分割结果(e) WM, (f) GM 和(g) CSF；改进算法的分割结果(h) WM, (i) GM 和 (j) CSF.

Fig 4.1 Segmentation results of T1-weighted image: (a) original image; discrete anatomical models of (b) WM, (c) GM, and (d) CSF; segmentation results of primary algorithm (e) WM, (f) GM and (g) CSF; segmentation results of the improved algorithm (h) WM, (i) GM and (j) CSF.

表 4.1 RGAC 和 RGAC\_M 算法针对十幅图像分割结果的统计指标 (%)

Tab. 4.1 Statistical indexes (%) on ten images segmented by RGAC algorithm and RGAC\_M algorithm

Method	Tissue	$\rho$	$r_{fp}$	$r_{fn}$	iterations
Suri algorithm	CSF	60.04	59.80	30.89	85.5
	GM	85.33	18.68	11.47	160.4
	WM	86.35	24.24	5.46	188.1
	average	77.24	34.24	15.94	144.7
Our method	CSF	84.88	24.74	7.76	9.8
	GM	91.23	14.54	3.83	22.0
	WM	94.53	9.29	2.00	14.1
	average	90.21	16.19	4.53	15.3

从表 4.1 可以看出，改进算法的性能指标明显优于原始算法。改进算法的平均假阳性率和假阴性率相对于原始算法分别下降了 42.78% 和 28.42%，而平均相似度指标则提高了 16.79%。表中还统计了三个组织分割的迭代次数。改进算法三个组织的平均迭代次数从原始算法的 144.7 次下降到 15.3，表明其收敛速度明显增快。

#### 4.5.2 PD-和 T2-加权图像分割实验

本小节用改进算法分割 PD-加权和 T2-加权 MRI 图像，T2-加权 PD-加权图像与 T1-加权图像在灰度分布、组织对比度和图像清晰度方面均不形同。数据集从 BrainWeb<sup>[42]</sup> 网站下载。数据集尺寸 181×217×181 像素，切片厚度 1mm，平面内分辨率 1mm。

参数设置同 4.5.1 节。

算法在满足下面两个条件中的任一条件时将终止迭代过程：

条件 1：对于 CSF 和 GM 新分入像素比例小于  $10^{-2}$ ，

对 WM 新分入像素比例小于  $10^{-4}$ ；

条件 2：迭代次数超过 500 次。

图 4.2 为 PD-加权 MRI 图像和其分割结果，图 4.3 为 T2-加权 MRI 图像及其分割结果。图中将分割结果的轮廓叠加在原始图像上。表 4.2 为两个实验分割结果的统计指标。定量的评估结果显示，两个实验中白质的分割结果均优于灰质。相似度指标均超过了 90%。对整个 PD 加权数据集的平均相似度指标为：WM 为 84.70%，GM 为 90.06% 以及 CSF 为 81.54%。





图 4.2 PD-加权图像的分割结果：

(a) PD-加权图像，改进算法的分割结果(b) WM 和(c) GM，(d)是金标准。

Fig. 4.2 Segmentation results of PD-weighted image:

(a) Original image; segmentation results of our method (b) WM and (c) GM; (d) ground truth.



(a) (b) (c) (d)

图 4.3 T2-加权图像的分割结果:

(a) T2-加权图像, 改进算法的分割结果(b) WM 和(c) GM, (d)金标准

Fig. 4.3 Segmentation results of T2-weighted image:

(a) Original image; segmentation results of our method (b) WM and (c) GM; (d) ground truth.

表 4.2 图 4.2 和图 4.3 中实验结果的统计指标 (%)

Tab. 4.2 Statistical indexes (%) of the segmentation results in Fig. 4.2 and Fig. 4.3

	GM			WM		
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$
Fig. 4.2	94.02	7.18	4.91	97.17	3.27	2.41
Fig. 4.3	91.54	4.00	12.23	97.36	4.97	0.43

为了评估参数变化对算法分割结果的影响, 改进算法在不同参数设置下对20幅图像进行了分割实验。图4.4中给出了分割结果的统计指标。实验中采用总体性能指标对参数  $\varepsilon$ ,  $\omega_e$  和  $\omega_r$  按照一定步长变化时的分割结果进行评价。从统计曲线图可以看出, WM 和 GM的分割对参数  $\varepsilon$  和  $\omega_e$  不敏感, 性能指标曲线基本保持不变; CSF的性能曲线显示出了对这些参数的一定敏感性, 但是这种变化微乎其微。总体而言, 算法对参数  $\varepsilon$ ,  $\omega_e$  和  $\omega_r$  的变化不敏感, 具有较好的韧性。

#### 4.5.3 真实 MRI 图像分割实验

在本小节, 用真实的 MRI 图像来测试本文提出的改进算法。数据集从 IBSR<sup>[180]</sup>下载, 数据集 IBSR\_18 尺寸  $256 \times 256 \times 128$  像素。在该数据中, 同时给出了手工分割的结果, 可以作为“金标准”对用户提出的算法进行能够评估。

参数设置:

FCM 阶段:  $C = 3$

水平集阶段:  $\omega_R = 7, \omega_e = 0.5, \varepsilon = 0.025, \Delta t = 0.1$






图 4.4 总体性能对参数  $\varepsilon$ ,  $\omega_e$  和  $\omega_r$  变化曲线

Fig. 4.4 Total performance vs. parameters ( $\varepsilon$ ,  $\omega_e$  and  $\omega_r$ )



迭代终止条件：GM、WM 类新分入像素比例小于 $10^{-4}$ ，或  
算法迭代次数超过 500 次

图 4.5 为该数据集中第 93 切片的图像和改进算法的分割结果以及 PC 模型<sup>[126]</sup>的分割结果。从 PC 模型的分割结果图 4.5 (b)来看，图中 A 和 B 所示位置的 GM 错误地分割为 WM；而本文提出的改进算法的分割结果图 4.5 (f)中，对应部分分割正确。图 4.5 中的实验的统计指标在表 4.3 中可以看到。该图像也被 Wang 等人<sup>[98]</sup>采用，他们提供的分割定量结果在该文献的图 10 和表 3 中有所反映。

从表 4.3 可以看出，本文提出的算法的灰质和白质相似性指标超过 95%，总体误差分别是 7.65%和 8.45%，均远远好于 PC 模型的性能指标：灰质和白质的总体误差分别为 12.92%和 19.80%，也好于 MFCM 算法的分割指标：灰质和白质的总体误差分别为 15.92%和 11.79%。




图 4.5 真实 MRI 图像的分割：(a) 原始图像叠加初始化曲线（PC 模型），(b) PC 模型的分割结果（ $\mu = 0.00255 \cdot 255^2$ ）；(c) 手工分割结果；(d) 原始图像叠初始化曲线；本文提出的改进算法的分割结果：(e) WM 和 (f) GM。

Fig 4.5 Real MR image segmentation: (a) original image and initial curves of the PC model, (b) segmentation result of the PC model ( $\mu = 0.00255 \cdot 255^2$ ); (c) the manual segmentation result; (d) original image and initial curves of our method and segmentation results (e) WM and (f) GM.

表 4.3 图 4.5 中所示分割结果的统计指标 (%)

Tab. 4.3 Performance indexes (%) for different methods applied to the real MR image in Fig. 4.5

	GM			WM		
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$
PC model	93.09	0.00	12.92	90.99	19.80	0.00
MFCM <sup>[98]</sup>	91.58	2.48	13.44	94.22	7.92	3.87
Our method	96.03	0.23	7.42	95.92	7.78	0.67

算法还对该数据集进行了分割，分割指标见表 4.4。白质和灰质的平均相似度指标分别为 82.91 和 89.90%，优于 MFCM 的对应分割指标 75.98% 和 81.90%（见[98]中图 11 和有关解释）。表 4.4 中还显示了其余 4 个数据集分割结果的统计指标。通常认为相似度指标大于 70% 时表明算法有杰出的分割结果<sup>[181]</sup>。表中的统计指标显示本文提出的改进算法有良好的分割性能。为了直观显示分割结果，本文利用工具 BrainSuite<sup>[182]</sup>对分割进行了三维重建。图 4.6 显示了数据集 IBSR\_14 白质分割结果的 3D 重建结果。

表 4.4 IBSR 数据集分割实验的平均相似度指标 (%)

Tab. 4.4 Average similarity indexes (%) of segmentation experiments on IBSR data volumes

IBSR_No.	14	15	16	17	18
GM	87.24	87.36	88.97	85.83	89.90
WM	81.81	80.62	80.50	78.54	82.91




图 4.6 数据集 IBSR\_14 白质的重建结果

Fig. 4.6 Reconstruction results for white matter of IBSR\_14 data volume



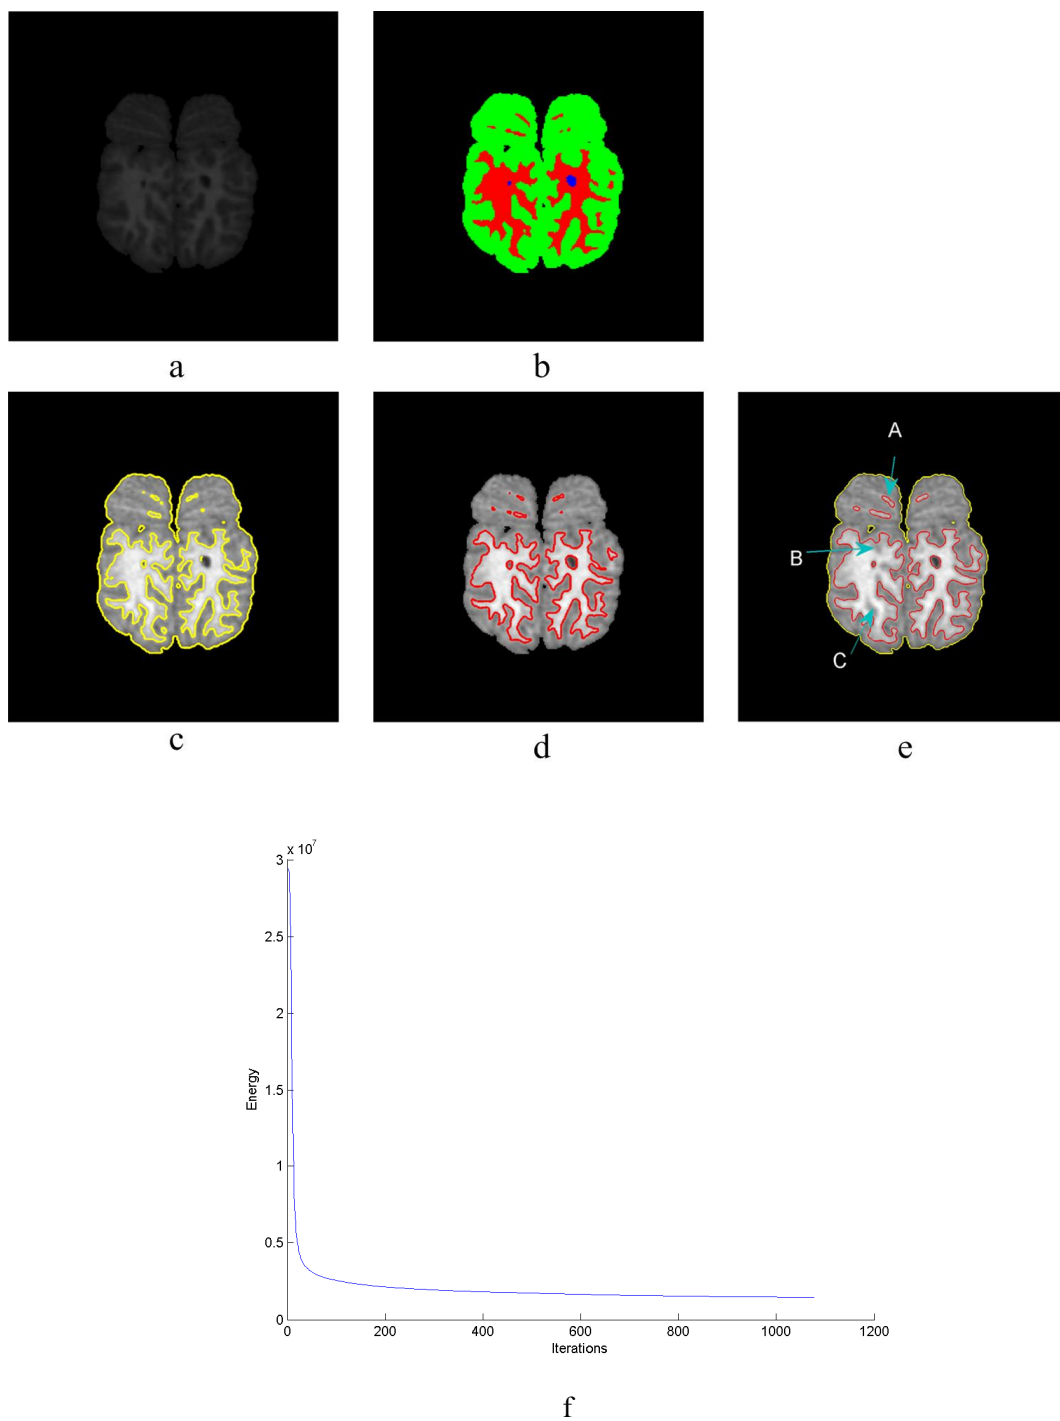




图 4.7 真实 MRI 图像 (IBSR\_18, 第 20 切片) 分割结果: (a) 原始图像, (b) 金标准; 本文算法分割结果 (c) 灰质 (d) 白质; (e) PC 模型分割结果, (f) PC 模型的能量函数收敛曲线

Fig.4.7 Real MR image segmentation (20<sup>th</sup> slice): (a) original image, (b) ground truth, segmentation results of our method (c) gray matter and (d) white matter, (e) segmentation result of the PC model, (f) convergence curve of PC model's energy-function



f

图 4.8 真实 MRI 图像 (IBSR\_18, 第 90 切片) 分割结果: (a) 原始图像, (b) 金标准; 本文算法分割结果(c) 灰质 (d) 白质; (e) PC 模型分割结果, (f) PC 模型的能量函数收敛曲线

Fig. 4.8 Real MR image segmentation (90<sup>th</sup> slice): (a) original image, (b) ground truth, segmentation results of our method (c) gray matter and (d) white matter, (e) segmentation result of the PC model, (f) convergence curve of PC model's energy-function.

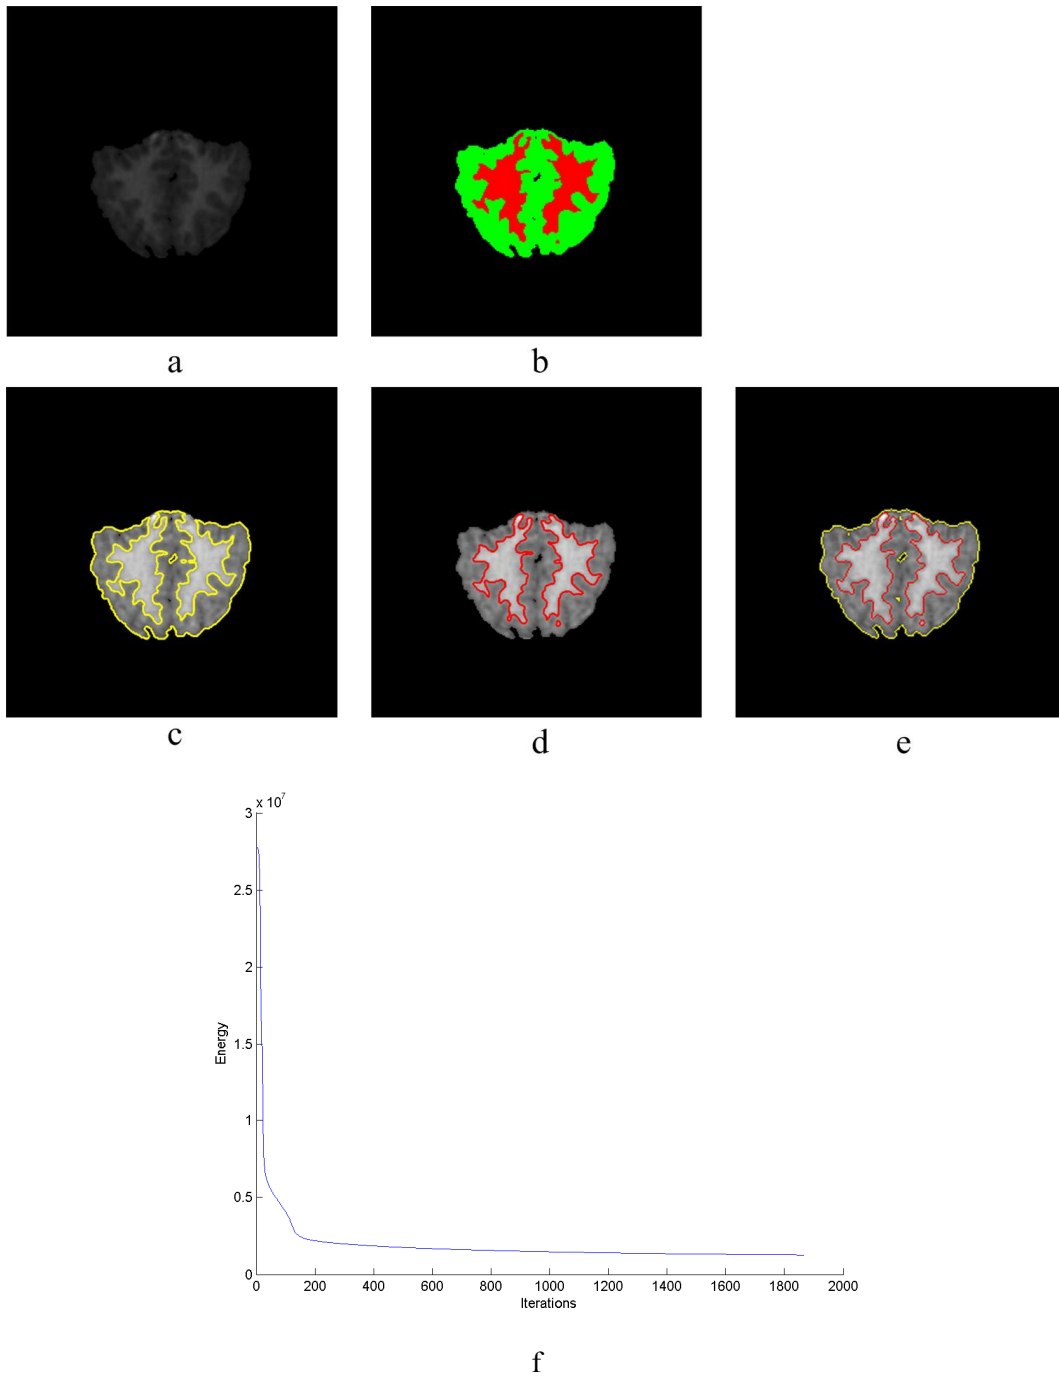


图 4.9 真实 MRI 图像 (IBSR\_18, 第 100 切片) 分割结果: (a) 原始图像, (b) 金标准; 本文算法分割结果(c) 灰质 (d) 白质; (e) PC 模型分割结果, (f) PC 模型的能量函数收敛曲线

Fig. 4.9 Real MR image segmentation (100<sup>th</sup> slice): (a) original image, (b) ground truth, segmentation results of our method (c) gray matter and (d) white matter, (e) segmentation result of the PC model, (f) convergence curve of PC model's energy-function.

表 4.5 真实 MRI 图像分割的统计指标 (图 4.7-图 4.9)

Tab. 4.5 Statistical indexes of the segmentation experiments on real MRI images

	slice index	GM			WM			iteration	elapse
		$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$	number	time (s)
	20	0.9007	0.0090	0.1733	0.7953	0.4997	0.0101	1078	214.50
PC model	90	0.9180	0.0232	0.1320	0.9011	0.2093	0.0083	1524	311.47
	100	0.9548	0.0002	0.0864	0.9178	0.1787	0.0003	1867	378.47
	20	0.9502	0.0077	0.0879	0.8933	0.2005	0.0309	26	15.53
our method	90	0.9489	0.0270	0.0729	0.9476	0.0849	0.0231	22	10.38
	100	0.9748	0.0055	0.0439	0.9601	0.0576	0.0236	23	11.90

为了进一步对本文提出的改进算法进行评估, 改进算法和 PC 模型还对数据集中的第 20、90 和 100 切片进行了分割, 分割结果见图 4.7-图 4.9。图中还给出了 PC 模型能量函数的收敛曲线, 算法在能量函数变化率小于  $10^{-4}$  时终止迭代过程。表 4.5 为该组实验的统计结果, 统计指标还包括了两个算法的迭代次数以及分割耗费的 CPU 时间。从表中总体误差的统计 ( $r_{fp} + r_{fn}$ ) 可以看出, 本文提出的改进算法总体上优于 PC 算法, 同时, 改进算法需要较少的迭代次数以及耗费较少的 CPU 时间 (在同一台计算机上进行实验, 环境 Matlab6.5, T9300 CPU 和 2G RAM)。

## 4.6 模糊自适应非参数变形模型

### 4.6.1 算法描述

模糊分割与硬分割算法相比, 因为考虑了一个像素中 (因部分容积效应) 可能包含多个组织而能够保留更多原始图像中的信息。在本节中, 提出了一个自适应的水平集算法。算法中采用了模糊区域指示子函数来代替非参数变形模型中的停止项。经典几何活动轮廓模型中的停止项是基于图像梯度信息的。理论上, 该停止项在均匀区域, 优于图像梯度为零, 停止项取值 1, 曲线缓慢进化; 在边缘附件, 因图像梯度为无穷大而取值零, 曲线进化停止。然而在实际应用中, 优于成像系统的缺陷按, 噪声, 灰度不均匀以及生物组织的多样性等因素的影响, 使得组织之间的界限变得模糊不清。因而, 停止项在边缘处不会真正取零值, 曲线的进化不会停止, 造成最后越过边界, 形成泄漏。另外, 经典的几何活动轮廓模型过度地依赖图像的梯度信息, 使得模型对噪声比较敏感。

在本章前一个算法中, 采用了模糊区域指示子函数  $R_{ind}(x, y) = \omega_R \cdot (1 - 2u(x, y))$ , 在基于区域的几何活动轮廓模型为算法提供了基于全局的信息。在本节, 将其做简单的变化后, 替代经典几何活动轮廓模型中的停止项。新的约束项具有如下形式:

$$f(u_n) = \omega_r \cdot \text{sign}(1 - 2u_n), n = 1, 2, \dots, C, \quad (4.27)$$

其中  $\text{sign}(\cdot)$  是符号函数， $\omega_r$  是用户指定的常数。

因而改进的几何活动轮廓模型具有如下形式：

$$\frac{\partial \phi}{\partial t} = f(u_n)(1 - \varepsilon K) |\nabla \phi|, \quad (4.28)$$

算法中  $f(u_n)$  的符号决定了曲线进化的方向，无论初始化曲线的位置如何，在进化过程中可以自适应地改变生长方向，因而称其为自适应的水平集算法。

#### 4.6.2 实验结果

本小节中通过仿真实验对算法进行评估。

实验中采用多种子的初始化方式，以加快算法的收敛，降低用户的手动干预，同时也能够避免算法收敛到局部最小。




图 4.10 仿真图像分割结果：第一行从左至右：原始图像，： WM，GM 和 CSF “金标准”；第二行从左至右：原始图像叠加初始化曲线，本文算法分割结果：WM，GM 和 CSF。

Fig. 4.10 Experiment results on simulated MR image.

Top row: original image and the ground truth of the three tissues: WM, GM and CSF;  
Bottom row: initialization and segmentation results WM, GM and CSF of the proposed method.

实验采用仿真 MRI 图像，图 4.10 为自适应水平集算法的分割结果。与“金标准”相比较，图 4.8 中的结果在视觉上是令人满意的，尤其是灰质的分割结果，侧脑室的外轮廓分割清晰，完整。表 4.6 为分割结果的统计指标，数据格式为(均值  $\pm$  标准差)，按照组织类别进行统计。从表中数据可以看到，分割的灵敏度、特异性和总体性能指标分别达到了 96.42%，96.96 和 97.00%。各个组织间的分割指标均衡，除了灵敏度指标外，均有较小的标准差。表明算法对组织类别以及待分割区域的面积大小敏感度较低。

实验还对 FCM 算法和本文提出的自适应算法进行了比较。实验采用了 10 幅图像，分别添加了 1%、3%、5%、7%和 9%的高斯噪声。对其分割结果的误分割进行统计。图 4.11 显示了 FCM 算法的本文提出的算法实验中误分割指标随噪声水平的变化曲线。从图中的误差曲线可以看出，水平集分割使得误差有所下降，在噪声水平较高时性能提升比较明显。

表 4.6 图 4.10 中分割实验的统计指标 (%)

Tab. 4.6 Statistical indexes (%) of segmentation results of ten MRI images

Indexes	WM	GM	CSF	AVG.
Sensitivity (%)	98.10 $\pm$ 1.47	96.70 $\pm$ 1.30	94.48 $\pm$ 2.12	96.42
Specificity (%)	97.20 $\pm$ 0.20	95.79 $\pm$ 0.52	97.91 $\pm$ 0.18	96.96
Total performance (%)	97.40 $\pm$ 0.28	95.97 $\pm$ 0.64	97.66 $\pm$ 0.27	97.00




图 4.11 本文算法与 FCM 算法的误分割曲线

Fig.4.11 Comparison between the proposed method (■) and FCM method (■)




图 4.12 噪声 MRI 图像（5%高斯加性噪声）白质分割  
（从左至右：原始图像，本文算法分割结果，FCM 分割结果）

Fig. 4.12 White matter segmentation from noisy MRI image (5% Gaussian noise level)  
(Original image, result of our method, and FCM method)

图 4.12 中显示了本文算法和 FCM 算法在 5% 高斯噪声条件下的白质分割结果。FCM 算法分割结果中可以明显看到分割目标附近散落的孤立像素呈现出的“斑点”，而本文提出的算法结果则无明显的“斑点”出现，分割结果平滑完整，表现出良好的分割性能。实验表明 FCM 和水平集结合的算法能够有效地提高分割准确度和噪声抗干扰能力。



图 4.13 本文算法的真实 T1-加权 MRI 图像分割结果  
（从左至右：原始图像，白质和灰质分割结果）

Fig. 4.13 Segmentation results of real T1-W MR image  
(From left to right: original image, WM, and GM)

图 4.13 中为自适应水平集算法对一幅真实 MRI 图像进行分割，获得的脑白质和灰质的分割结果。白质分割结果显示，细长的结构和侧脑室的轮廓分割准确，灰质分割外轮廓完整、连续、准确。分割结果得到放射专家的确认。

---

## 4.7 稳定问题与多初始化

### 4.7.1 算法的稳定性问题

当用水平集方法来求解空-时偏微分方程时，需要特别注意数值稳定性问题。稳定性问题是由 Courant-Friedrichs-Lewy (CFL) 条件来保证的。CFL 条件设置了一个时间步长的上限。因而，当时间步长  $\Delta t \sim (\Delta x)$  不能够保证稳定的时候，可以施加一个更加严厉的 CFL 条件  $\Delta t \sim (\Delta x)^2$  来实现数值稳定。稳定性也可以通过不同时间离散方案来实现，如三阶准确度的 Runge-Kutta 法。在双曲方程中加入人工粘性<sup>[118]</sup>也是实现稳定的一个办法。Balliard 等<sup>[128]</sup>提出了一个确定最优时间步长的方法，在避免数值不稳定的前提下，保持曲线进化尽可能的快速。相似的方案在 Zeng 等人<sup>[128]</sup>的工作中也可以看到。

在 4.5 节的 T1-加权仿真 MRI 图像实验中，Suri 的算法有 5 幅图像的分割实验失败，其中 2 幅是在分割灰质时失败，三幅是在分割脑脊液时失败的。而改进算法对十五幅图像的分割全部成功。4.3 节中的稳定性分析表明，Suri 的算法存在潜在的稳定性问题。当速度函数的绝对值趋近于无穷大时，时间步长只能取得无穷小值，才能满足 CFL 条件中二者乘积是有限值的约束<sup>[128]</sup>。然而，时间步长取得无穷小值对曲线进化是没有意义的。很显然，Suri 的算法不能简单地通过调整时间步长的方法实现数值稳定。本文提出的修改算法采用了新的区域项，消除了二阶断点，因而使得算法的稳定性能得以保证。相对大的区域项绝对值使得改进算法的收敛速度加快。实验结果验证了改进是合理的、有效的，也是成功的。

### 4.7.2 模糊分割与水平集结合

最年来，许多文献在定义解剖结构时，而逐渐摒弃了硬分割算法而采用软分割方法。与硬的分割算法相比，软分割方法考虑了在一个像素中可能存在多个组织物质的可能，因而能够比硬分割方法保留更多原始图像的信息。图像采集以及图像分割过程中可能会引入小的误差，在软分割方法中，这些小误差仅仅对分割结果产生部分影响；而硬分割算法中，小的误差可能完全颠覆整个分割结果<sup>[26]</sup>。在本文的算法中，模糊分割作为算法的一个阶段对图像进行模糊分析，获得的模糊隶属度函数作为下一阶段的水平集分割的约束。在水平集分割阶段，基于模糊信息的区域项能够在两个方向上来控制曲线的进化。水平集方法使得分割结果更加的准确和平滑<sup>[176]</sup>。

4.3 节的实验中，对改进算法和 PC 模型<sup>[126]</sup>的分割结果进行了比较。PC 模型对均匀区域有较好的分割效果。然而分段常数的假设在一些应用中难以得到满足，如脑组织分割。MRI 图像在采集过程中引入的噪声和图像不均匀，使得图像的质量退化，也使得



---

PC 模型的分割结果退化。迭代次数多和缓慢的收敛速度是该算法的主要问题。而本文的算法将区域和边缘信息结合在一起，算法从二者中受益。实验结果的定量分析表明本文提出的算法有更好的分割性能。

#### 4.7.3 多种子初始化

在 Suri 提出的算法中，初始轮廓线放置在待分割目标内部，在界面附近的窄带内运行快速步进算法（Fast Marching Method, FMM）。当曲线只能在一个方向进化时，初始化对最后的分割结果非常重要，需要操作者具有有关解剖结构的先验知识。准确放置的初始轮廓线需要准确的初始位置预测。通常，预测位置和真实位置之间是重叠的，因而有必要让曲线能够在两个方向进化<sup>[128]</sup>。为此，研究人员已经提出了一些解决方案<sup>[184,185]</sup>。本文采用了自适应区域项，曲线可以在两个方向生长。

另外，当一些目标内嵌在一个目标内部时，单个水平集不能捕获所有目标。在这种情况下，需要多初始化方式。脑灰质和脑脊液的分割就是这种情况<sup>[121,186]</sup>。本文也采用了多初始化方式。这种初始化方式不需要组织和解剖结构位置的先验信息。多种子初始化不仅可以使算法对初始位置的敏感性最小，而且也能使算法的收敛速度加快，同时，能够避免算法收敛到局部最小<sup>[126]</sup>。

### 4.8 本章小结

本章首先提出了一个从 MRI 图像中分割脑组织的新算法，它是基于区域的几何活动轮廓模型的改进算法。基于对原始算法的稳定性分析，提出了一个新的区域项。新算法克服了原始算法的稳定性问题，降低了分割结果对一些参数的敏感度。新算法可以从 T1-加权、T2-加权和 PD-加权 MRI 图像中分割出白质、灰质和脑脊液等脑组织。与原始算法以及 PC 模型相比，算法的分割准确度大大提高。采用的多种子初始化方式减少了人工干预，也加快了算法的收敛速度，减小了算法对初始条件的敏感度。用仿真和真实的 MRI 图像对算法进行了评估，定量分析结果表明改进的有效性和可行性。同其它算法的比较也表明算法具有良好的分割性能。

本章的第二部分提出了一个自适应的分割算法。算法中采用了前一算法中提出的模糊区域指示子，用其代替了经典几何活动轮廓模型中的停止项。新的停止项可以自适应地控制曲线的进化方向，也消除了经典几何活动轮廓模型算法对图像梯度信息的过度依赖。模糊逻辑框架允许考虑部分容积效应，与硬分割算法变比，能保留图像中的更多信息。算法得益于 FCM 算法和水平集方法，实验结果表明了二者的结合有利于提高分割的准确度以及算法的韧性。

---

## 5 多类算法在 MRI 脑组织分割中应用

### 5.1 概述

分割是一个将图像数据拆分成若干个有意义区域的技术过程，在图像分析和计算机视觉如模式识别、机器视觉、生物医学图像处理等应用中是至关重要的环节。在医学应用中，对解剖结构边界和特征组织定量信息的需求在临床上日益重要，这类应用包括在放射治疗中提取和描绘肿瘤和损伤<sup>[187,169]</sup>，在脑发育与人类衰老的研究中对白质、灰质以及内部结构的容积测量等<sup>[188,189]</sup>。

近几年，用偏微分方程来处理图像引起广泛的研究兴趣。采用偏微分方程获得成功的典范是Mumford and Shah模型<sup>[124]</sup>。基于Mumford-Shah泛函数，涌现出了一批分割算法，如多尺度算法<sup>[190,191]</sup>，Chan-Vese模型<sup>[125]</sup>和Chan-Vese多相分割算法<sup>[192,126]</sup>。Koepfler等基于区域生长和合并分段常数算法，提出了多尺度算法，算法中将简化的Mumford-Shah泛函作为能量函数<sup>[190]</sup>。Chan和Vese提出了一个基于水平集方法的活动轮廓模型来检测目标，目标的边界不必用梯度来定义，该模型称为无边缘活动轮廓模型，即众所周知的Chan-Vese模型<sup>[124]</sup>。由于Chan-Vese模型采用一个水平集函数，只能将带分割图像分割成目标区域和背景两个区域，其应用受到极大的限制。因而在随后的工作中，Chan和Vese将该模型推广到多相算法<sup>[190,126]</sup>。在多相算法中， $n$ 个水平集函数可以分割多达 $2^n$ 个区域。该算法的主要缺点是在求解非线性偏微分方程组时计算代价太高。

针对Chan-Vese多相算法存在的计算代价巨大的问题，研究人员最近提出了一些算法，以实现快速最小化Mumford-Shah函数。这些算法试图避免直接解非线性偏微分方程。Gibou和Fedkiw提出了一个基于Mumford-Shah泛函数的算法<sup>[193]</sup>。算法有三个步骤：用非线性扩散方案<sup>[194]</sup>对图像进行平滑预处理；用K-均值算法将处理的图像分成两相；通过平均曲率运动进化相的边界。Song和Chan<sup>[195]</sup>提出了一个快速分割算法，作者试图找到非偏微分方程技术来最小化目标函数。算法首先将图像拆分成两个区域，然后逐个像素进行检测，并将像素划分到使能量函数下降的区域中。该算法严格说是一个基于像素的方法，而非水平集方法。分割噪声图像是该算法的一个难点<sup>[191]</sup>。另外，算法还很可能陷入局部最小或初始状态<sup>[193]</sup>。Song和Chan的算法<sup>[195]</sup>被Chan和Esedoglu推广到多尺度情形，与原算法相比，有更快的收敛速度<sup>[191]</sup>。

在最近的文献中，二值化的水平集函数被用来指示分割中的区域<sup>[196,197]</sup>。Shi和Karl<sup>[198]</sup>提出了一个具有多个整数数值的水平集函数，每个独立的区域用一个整数值表示。在该算法中，代表边界的水平集进化是在边界点的最优化条件下，通过更新两个边界点列表实现的，算法避免了求解偏微分方程。该算法的缺点在于难以找到合适的方式

表述曲线的几何特征，如单位法向量，平均曲率等<sup>[199]</sup>，另一个缺点是算法对初始条件比较敏感<sup>[196,197]</sup>。

本章提出了一个新的分割算法，算法将FCM方法和基于曲线进化技术的水平集方法结合起来。算法的提出部分是受到Gibou和Fedkiw的工作<sup>[193]</sup>启发，部分是基于对Chan-Vese模型<sup>[124]</sup>中拆分项的观察，即拆分项是像素灰度和聚类中心的一个距离测度。算法中，用代表目标和背景的两个隶属度函数之差替代Chan-Vese模型中的拆分项，提出了二类分割算法，随后将其推广到类别数目是任意值的多类算法。新算法受益于FCM算法的简单性和有效性，同时又保留了水平集方法的鲁棒性。

本章的内容总体安排如下：5.2节简单回顾 Mumford-Shah 泛函数，5.3和5.4节则分别介绍了Chan-Vese模型和Chan-Vese多相算法。在5.5节从Chan-Vese模型中推导出二类算法，随后将其推广到多类算法。在5.6节用实验对算法进行评估，采用的图像有人工合成图像、仿真 MRI 图像和真实的 MRI 图像，并将分割结果和现有的算法进行比较。在5.7节中就几个重要的问题进行讨论，最后对本章的内容进行小结。

## 5.2 Mumford-Shah 泛函

设  $\Omega \subset R^2$  是有界的开区域， $I_0$  是定义域为  $\Omega$  的观察图像。 $\Omega_i$  是图像域  $\Omega$  上的一个连通、不重叠的开子集， $\Omega_i$  有着平滑的边界，这些边界的集合构成了  $\Gamma$ ，使得  $\Omega = \cup \Omega_i \cup \Gamma$ 。Mumford 和 Shah 提出通过函数最小化查找图像域  $\Omega$  的一个分解  $\Omega_i$  和图像  $I_0$  的最优平滑逼近  $u(x, y)$ <sup>[125]</sup>，要求  $u(x, y)$  在每个  $\Omega_i$  内缓慢变化，且允许其不连续地越过不同区域  $\Omega_i$  之间的边界。这就是所谓的最小拆分问题。其实质就是要寻找真正的图像边界  $\Gamma^0$ ，将图像  $I_0(x, y)$  分为若干同质区域，使得分割图像  $u(x, y)$  和原图像  $I_0(x, y)$  间的误差最小。分割可以通过对能量函数的最小化获得：

$$F^{MS}(u, \Gamma) = \lambda \int_{\Omega} (u(x, y) - I_0(x, y))^2 dx dy + \int_{\Omega \cup \Gamma} |\nabla u|^2 dx dy + \mu |\Gamma|. \quad (5.1)$$

上式中  $\mu$  和  $\lambda$  是调节参数， $|\Gamma|$  为边界曲线  $\Gamma$  的 1 维 Hausdauff 测度。式 (5.1) 中前两项保证  $u$  良好地逼近原始图像  $I_0$ ，第三项保证边界  $\Gamma$  长度最短。图像  $u(x, y)$  为能量函数  $F^{MS}(u, \Gamma)$  的最小解，当  $F^{MS}(u, \Gamma)$  取得最小值时，所得边界  $\Gamma^0$  将图像或分为若干个平滑的区域，同时保持尖锐的边界。

### 5.3 Chan-Vese 模型

Mumford-Shah 模型是现代数学中的一种自由不连续问题，由于模型中对图像中边缘等跳跃部分通过几何测度（Hausdauff 测度）项来控制，使数学逼近或数值解非常的复杂。

因此，Chan 和 Vese 提出一种简化的 Mumford-Shah 分割模型，称之为 Chan-Vese 模型<sup>[124]</sup>。在该简化模型中，Chan 和 Vese 提出将图像分为目标和背景两个区域，且每个区域是同质，或者分段平滑的。设  $I_0$  是定义在平面  $\Omega$  的图像，闭合边界  $\Gamma$  将图像  $I_0$  划分为目标  $I_o$  ( $\Gamma$  的内部  $inside(\Gamma)$ ) 和背景  $I_b$  ( $\Gamma$  的外部  $outside(\Gamma)$ ) 两个同质区域。假设图像中每个同质区域的灰度是常数，分别用平均灰度  $c_1$  和  $c_2$  表示，则简化模型的能量函数可以表示为：

$$F^{CV}(\Gamma, c_1, c_2) = \nu Area(inside(\Gamma)) + \mu Length(\Gamma) + \lambda_1 \int_{inside(\Gamma)} (I_0(x, y) - c_1)^2 dx dy + \lambda_2 \int_{outside(\Gamma)} (I_0(x, y) - c_2)^2 dx dy \quad (5.2)$$

式中， $Length(\Gamma)$  是闭合曲线  $\Gamma$  的长度， $Area(\Gamma)$  是  $\Gamma$  的内部区域面积， $\mu, \nu \geq 0$ ， $\lambda_1, \lambda_2 > 0$  是各个能量项权重系数。当闭合活动轮廓线  $\Gamma$  不在两个同质区域的真实边界  $\Gamma^0$  时， $F^{CV}(\Gamma, c_1, c_2)$  不能达到最小值；只有轮廓线位于两个同质区域的真实边界位置时， $F^{CV}(\Gamma, c_1, c_2)$  才能达到最小值。最优化式 (5.2)，就可以得到分割轮廓线  $\Gamma$  的位置以及未知数  $c_1$  和  $c_2$ ，即

$$\{\Gamma^0, c_1^0, c_2^0\} = \inf F^{CV}(\Gamma, c_1, c_2) \quad (5.3)$$

由于模型 (5.2) 利用了图像的全部信息，通过最优化式 (5.3)，就可以得到全局最优的图像分割结果。

对于 Chan-Vese 模型，Chan 和 Vese 利用 Heviside 函数建立了水平集模型：设  $\phi_0$  是根据初始轮廓线  $\Gamma_0$  构造的水平集函数，即  $\{\Gamma_0 | \phi(x, y, t=0) = \phi_0(x, y) = 0\}$ ，并设  $\phi$  为有符号距离函数(Signed Distance Function, SDF)，定义其内部为正外部为负，如图 5.1 所示：




图 5.1 Chan-Vese 模型有符号距离函数与区域划分  
Fig. 5.1 Chan-Vese model and Regions partitioned by SDF

$$\begin{aligned}
 F(\phi, c_1, c_2) = & \nu \int_{\Omega} H(\phi(x, y)) dx dy + \mu \int_{\Omega} |\nabla H(\phi(x, y))| dx dy \\
 & + \lambda_1 \int_{\Omega} (I_0(x, y) - c_1)^2 H(\phi(x, y)) dx dy \\
 & + \lambda_2 \int_{\Omega} (I_0(x, y) - c_2)^2 (1 - H(\phi(x, y))) dx dy
 \end{aligned} \tag{5.4}$$

式中的  $H$  是 Heaviside 函数，其定义为：

$$H(z) = \begin{cases} 1 & \text{if } z \geq 0 \\ 0 & \text{if } z < 0 \end{cases} \tag{5.5}$$

其导数是 Dirac 函数，用  $\delta(x)$  表示。

可以证明，以水平集函数表示的轮廓线  $\Gamma$  的长度和轮廓线的内部面积分别为：

$$\begin{aligned}
 Length(\Gamma) &= \int_{\Omega} |\nabla H(\phi)| dx dy = \int_{\Omega} \delta(\phi) |\nabla \phi| dx dy \\
 Area(inside(\Gamma)) &= \int_{\Omega} H(\phi) dx dy \\
 \int_{inside(C)} |I - c_1|^2 dx dy &= \int_{\Omega} |I - c_1|^2 H(\phi) dx dy \\
 \int_{outside(C)} |I - c_2|^2 dx dy &= \int_{\Omega} |I - c_2|^2 (1 - H(\phi)) dx dy
 \end{aligned} \tag{5.6}$$

Chan 和 Vese 用欧拉-拉格朗日方法推导出满足式 (5.4)、并以水平集函数来表达的偏微分方程如下：

$$\begin{cases} \frac{\partial \phi}{\partial t} = \delta_\varepsilon(\phi) [\mu K - \nu - \lambda_1(I_0 - c_1)^2 + \lambda_2(I_0 - c_2)^2] \\ \phi(x, y, t = 0) = \phi_0(x, y) \end{cases} \quad (5.7)$$

其中：

$$c_1 = \frac{\int_{\Omega} I_0(x, y) H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy} \quad \text{是有符号函数内部均值；}$$

$$c_2 = \frac{\int_{\Omega} I_0(x, y) (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy} \quad \text{是有符号函数外部均值；}$$

$$H_\varepsilon(z) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctg\left(\frac{z}{\varepsilon}\right) \right] \quad \text{是 } H(z) \text{ 近似的规格化形式；}$$

$$\delta_\varepsilon(z) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + z^2} \quad \text{是 } \delta(z) \text{ 近似的规格化形式；}$$

$$K = \nabla \cdot \frac{\nabla \phi}{|\nabla \phi|} \quad \text{是平均曲率。}$$

从方程 (5.7) 可以看出，偏微分方程所涉及的图像  $I_0$  的定义域是全部数据，并且方程 (5.7) 中的另外两个未知数  $c_1$  和  $c_2$  也是定义在图像定义域内，具有全局特征。因此，Chan-Vese 模型的一个显著特点就是全局优化。

## 5.4 Chan-Vese 多相模型

5.3 节介绍的 Chan-Vese 模型中只采用一个水平集函数，能将图像分割为两个同质区域。然而，一些几何特征只用一个水平集方法无法进行描述，如对于三种灰度值的像素相交点 (triple junction)。针对上述情况，Chan 和 Vese<sup>[192,126]</sup> 提出了由多个水平集函数构成的多相算法 (multiphase algorithm)，可以表示多个分区及其它一些复杂的几何结构。

在多相算法模型中，如果有  $m$  个水平集，则可以将图像划分为  $n = 2^m$  个区域，用水平集函数的零水平集表示图像中不同区域间的边界。Chan-Vese 多相算法是 Mumford-Shah 问题的简化模型，可以通过最小化下面的能量函数来获得：

$$F^{MS}(\phi, \Gamma) = \mu \cdot \text{Length}(\Gamma) + \sum_{0 \leq i \leq n} \int_{\Omega_i} (I(x, y) - c_i)^2 dx dy \quad (5.8)$$

其中,  $c_i$  是在图像  $I$  中同质区域  $\Omega_i$  的灰度均值,  $\Omega = \cup_i \Omega_i \cup \Gamma$ 。

式 (5.8) 中的  $\Gamma$  用水平集函数  $\phi(x, y, t)$  的零水平集表示。当  $m=2$ , 即应用两个水平集函数  $\phi_1$  和  $\phi_2$  时, 算法可以表示  $n=4$  个区域, 其分区情况如图 5.2 所示。四相算法的能量函数表示如下:

$$\begin{aligned}
 F_4^{MS}(\phi_1, \phi_2, \mathbf{c}) = & \int_{\Omega} (I_0 - c_{11})^2 H(\phi_1) H(\phi_2) dx dy \\
 & + \int_{\Omega} (I_0 - c_{10})^2 H(\phi_1) (1 - H(\phi_2)) dx dy \\
 & + \int_{\Omega} (I_0 - c_{01})^2 (1 - H(\phi_1)) H(\phi_2) dx dy \\
 & + \int_{\Omega} (I_0 - c_{00})^2 (1 - H(\phi_1)) (1 - H(\phi_2)) dx dy \\
 & + \mu \int_{\Omega} |\nabla H(\phi_1)| dx dy + \mu \int_{\Omega} |\nabla H(\phi_2)| dx dy,
 \end{aligned} \tag{5.9}$$

这里  $\mathbf{c} = (c_{11}, c_{10}, c_{01}, c_{00})$  是个常数矢量, 分别表示 4 个区域的灰度平均值。




图 5.2 2 个水平集函数拆分图像为 4 个区域

Fig.5.2 Partitioning of the image into four phases using two level set function

给定初始条件  $\phi_1(x, y, t=0) = \phi_{1,0}(x, y)$  和  $\phi_2(x, y, t=0) = \phi_{2,0}(x, y)$ , 式 (5.9) 分别对  $\phi_1$  和  $\phi_2$  求能量函数的最小化, 得到关于  $\phi_1$  和  $\phi_2$  的欧拉-拉格朗日方程如下:

$$\left. \begin{aligned} \frac{\partial \phi_1}{\partial t} &= \delta_\varepsilon(\phi_1) \left\{ \begin{aligned} &\mu \nabla \cdot \left( \frac{\nabla \phi_1}{|\nabla \phi_1|} \right) \\ &- \left[ ((I_0 - c_{11})^2 - (I_0 - c_{01})^2) H(\phi_2) + ((I_0 - c_{10})^2 - (I_0 - c_{00})^2) (1 - H(\phi_2)) \right] \end{aligned} \right\} \\ \frac{\partial \phi_2}{\partial t} &= \delta_\varepsilon(\phi_2) \left\{ \begin{aligned} &\mu \nabla \cdot \left( \frac{\nabla \phi_2}{|\nabla \phi_2|} \right) \\ &- \left[ ((I_0 - c_{11})^2 - (I_0 - c_{10})^2) H(\phi_1) + ((I_0 - c_{01})^2 - (I_0 - c_{00})^2) (1 - H(\phi_1)) \right] \end{aligned} \right\}. \end{aligned} \right. \quad (5.10)$$

$$\begin{aligned} c_{11} &= \text{mean}(I_0) \text{ in } \{(x, y) : \phi_1(x, y) > 0, \phi_2(x, y) > 0\} \\ c_{10} &= \text{mean}(I_0) \text{ in } \{(x, y) : \phi_1(x, y) > 0, \phi_2(x, y) < 0\} \\ c_{01} &= \text{mean}(I_0) \text{ in } \{(x, y) : \phi_1(x, y) < 0, \phi_2(x, y) > 0\} \\ c_{00} &= \text{mean}(I_0) \text{ in } \{(x, y) : \phi_1(x, y) < 0, \phi_2(x, y) < 0\}, \end{aligned} \quad (5.11)$$

可以通过下式分别求得：

$$\begin{aligned} c_{11} &= \frac{\int_{\Omega} I_0(x, y) H(\phi_1(x, y)) H(\phi_2(x, y)) dx dy}{\int_{\Omega} H(\phi_1(x, y)) H(\phi_2(x, y)) dx dy} \\ c_{10} &= \frac{\int_{\Omega} I_0(x, y) H(\phi_1(x, y)) (1 - H(\phi_2(x, y))) dx dy}{\int_{\Omega} H(\phi_1(x, y)) (1 - H(\phi_2(x, y))) dx dy} \\ c_{01} &= \frac{\int_{\Omega} I_0(x, y) (1 - H(\phi_1(x, y))) H(\phi_2(x, y)) dx dy}{\int_{\Omega} (1 - H(\phi_1(x, y))) H(\phi_2(x, y)) dx dy} \\ c_{00} &= \frac{\int_{\Omega} I_0(x, y) (1 - H(\phi_1(x, y))) (1 - H(\phi_2(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi_1(x, y))) (1 - H(\phi_2(x, y))) dx dy} \end{aligned} \quad (5.12)$$

计算灰度均值  $\mathbf{c} = (c_{11}, c_{10}, c_{01}, c_{00})$ ，求解关于  $\phi_1$  和  $\phi_2$  的偏微分方程，可以得到进化曲线  $\Gamma_1$  和  $\Gamma_2$ 。在能量函数 (5.9) 最小时，进化曲线将停止在图像中的目标边缘，完成图像分割。



式 (5.10) 表明, Chan-Vese 多相算法构成了一个耦合的非线性偏微分方程组系统。在用水平集方法对两个算法进行数值实现时, 式中的双曲项需要用中心差分方式逼近。中心差分是二阶精度的差分格式, 在用前向 Euler 时间离散时, 要求离散时间步长  $\Delta t = O(\Delta x^2)$ , 这是一个非常严格的离散约束<sup>[118]</sup>, 造成在求解式 (5.10) 时迭代次数较多, 收敛较慢。这种离散时间步长上的严格约束, 可以通过隐含实现方法在某种程度上降低。然后, Smereka 证明了这种实现方式在拓扑结构发生变化时会引入误差, 半隐含的方式可以部分减轻其计算负担<sup>[200]</sup>。

## 5.5 多类分割算法

在本文的 2.3.3 小节中已经对 FCM 算法进行了介绍。但是为了描述的方便, 本小节首先简单回顾 FCM 算法, 然后介绍二类分割算法, 并将其推广到多类情形。

### 5.5.1 FCM 算法

FCM 聚类算法是由 Bezdek 等<sup>[179]</sup>发展和推广使用的, 它是K-均值算法的改进版本, 是一种软分割算法。FCM 分类是通过以下目标函数最小化实现的。

$$J_f = \sum_{j=1}^C \sum_{(x,y) \in \Omega} [u_j(x,y)]^b \|I_0(x,y) - m_j\|^2, \quad (5.13)$$

这里,  $\Omega$  是图形的定义域,  $u_j(x,y) \in [0,1]$  是处在点  $(x,y)$  的像素相对于聚类类别  $j$  的模糊隶属度值, 它受概率约束  $\sum_{j=1}^C u_j(x,y) = 1$ ;  $b > 1$  是模糊指数, 控制聚类分析的总体模糊度。  $I_0(x,y)$  表示像素  $(x,y)$  的灰度值;  $m_j$  是类别  $j$  的聚类中心;  $C$  是已知的聚类类别数。  $\|\cdot\|$  是距离测度, 一般采用欧氏距离。

分别求目标函数  $J_f$  对聚类中心  $m_j$  和模糊隶属度  $u_j$  最小化值, 得到以下计算式:

$$m_j = \frac{\sum_{(x,y) \in \Omega} [u_j(x,y)]^b I_0(x,y)}{\sum_{(x,y) \in \Omega} [u_j(x,y)]^b} \quad (5.14)$$

$$u_j(x,y) = \frac{(1/\|I_0(x,y) - m_j\|^2)^{1/(b-1)}}{\sum_{k=1}^C (1/\|I_0(x,y) - m_k\|^2)^{1/(b-1)}} \quad (5.15)$$

式中  $j=1,2,\dots,C$ 。

### 5.5.2 二类算法

本小节首先将 FCM 算法和 Chan-Vese 模型关联起来，然后推导出新的算法。

在 FCM 算法中，设  $C = 2$ ， $b = 2$ ，即讨论二类聚类分析问题。假定聚类中心  $m_1$  和  $m_2$  已知，根据式 (5.15) 可以得到模糊隶属度函数：

$$u_1(x, y) = \frac{(1/\|I_0(x, y) - m_1\|^2)}{(1/\|I_0(x, y) - m_1\|^2) + (1/\|I_0(x, y) - m_2\|^2)}$$

$$u_2(x, y) = \frac{(1/\|I_0(x, y) - m_2\|^2)}{(1/\|I_0(x, y) - m_1\|^2) + (1/\|I_0(x, y) - m_2\|^2)}.$$

考虑两个模糊隶属度函数值之差：

$$u_1(x, y) - u_2(x, y) = \frac{\|I_0(x, y) - m_2\|^2}{\|I_0(x, y) - m_1\|^2 + \|I_0(x, y) - m_2\|^2} - \frac{\|I_0(x, y) - m_1\|^2}{\|I_0(x, y) - m_1\|^2 + \|I_0(x, y) - m_2\|^2}.$$

令

$$\lambda_1(x, y) = \lambda_2(x, y) = \frac{1}{\|I_0(x, y) - m_1\|^2 + \|I_0(x, y) - m_2\|^2},$$

所以

$$u_1(x, y) - u_2(x, y) = -\lambda_1 \|I_0(x, y) - m_1\|^2 + \lambda_2 \|I_0(x, y) - m_2\|^2, \quad (x, y) \in \Omega. \quad (5.16)$$

将式 (5.16) 代入式 (5.7)，并忽略面积项  $v$ ，得

$$\frac{\partial \phi(x, y)}{\partial t} = \delta_\varepsilon(\phi(x, y)) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi(x, y)}{|\nabla \phi(x, y)|} \right) + (u_1(x, y) - u_2(x, y)) \right]. \quad (5.17)$$

为了平衡方括号中两项在系统中的作用，为第二项加入加权系数  $\omega_R$ ，得到二类算法模型：

$$\frac{\partial \phi}{\partial t} = \delta_\varepsilon(\phi) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi}{|\nabla \phi|} \right) + \omega_R \cdot (u_1 - u_2) \right], \quad \omega_R \in R^+. \quad (5.18)$$

式 (5.18) 中，令  $u_1$  和  $u_2$  分别表示待分割目标和背景，算法可以从背景中分离出待分割目标，其边界用水平集函数的零水平集表示。

### 5.5.3 多类算法

在二类分割算法中，用一个水平集函数，将图像分割为目标区域和背景两个类别。要区分更多的类别，最直观和简单的方案就是增加水平集的数目，每个类别用一个独立的水平集表示。然而，在引入多个水平集后，随之而来的是区域之间的重叠和空洞问题。解决的办法通常是增加约束项，来阻止分割过程中重叠和空洞的出现。研究人员已经提出了几种解决方案。Zhao 在其工作<sup>[127]</sup>中，通过拉格朗日乘子  $\lambda$  在能量函数中增加了非重叠约束  $\oint_{\Omega} (\sum_{j=1}^C H(\phi_j) - 1)^2 dx$ 。相似的方案在Samson等的工作<sup>[201]</sup>中也可以看到。然而，该策略使得优化问题变得相当的复杂。Paragios 和 Deriche 提出了一个替换方案，人工耦合项  $\sum_{j=1}^C H_i(i, \phi_j(s)) |\nabla \phi_j(s)|$  通过附加参数  $\beta$  引入到进化方程中<sup>[202]</sup>。该方案存在的问题是附加参数  $\beta$  的选择问题，固定的  $\beta$  不能保证任意图像的分割结果不重叠<sup>[203]</sup>。另一个不同的方案是由Vese 和 Chan<sup>[126]</sup>提出的。在他们的多相算法中， $n$  个水平集可以表示  $2^n$  区域。该算法隐含地采用了不重叠和空洞的约束，不需要而外的约束力。然而，当区域数目不是 2 的幂次时，比如 3 时，出现空的区域 (empty regions)。有时，该算法会产生不需要的分割结果。Brox 和 Weickert 在其工作<sup>[204]</sup>中引入了区域竞争的概念，来避免重叠和空洞的出现。相似的解决方案也被 Mansouri 等<sup>[205]</sup>人采用。该策略的实施在增加不多计算代价的情况下解决了重叠和空洞的问题，算法保持了简单的形式，容易实现，能够处理任意数目的区域分割问题。本文跟随文献<sup>[204, 205]</sup>中的思路，采用类似的方案来解决重叠和空洞问题。

将式 (5.18) 表示的二类分割算法推广到多类目标的分割，算法的模型如下：

$$\frac{\partial \phi_j}{\partial t} = \delta_{\varepsilon}(\phi_j) \left[ \mu \nabla \cdot \left( \frac{\nabla \phi_j}{|\nabla \phi_j|} \right) + \omega_R (u_j - \max_{i \neq j} (u_i)) \right], \quad \omega_R \in R^+, \quad j = 1, 2, \dots, C. \quad (5.19)$$

式 (5.19) 中，方程方括号中的第一项称之为调整项，它控制着进化曲线的平滑性。调整项提供了一个控制进化界面的手段，允许算法来处理噪声图像，同时也提供了一个尺度来对目标进行分组。第二项  $(u_j - \max_{i \neq j} (u_i))$  引入了一个耦合约束，来考虑阻止区域间出现重叠和空洞。该耦合不同于前文介绍的耦合力或耦合项，由于最大隶属度值的计算可以预先计算，而且不需要更新，因而不会增加太多的计算负担。

正如前文所述，进化方程中的双曲项需要一个相当严格的时间按步长的约束，这会降低算法的收敛速度。另外，曲率项系数  $\mu$  通常凭经验或通过实验方法确定，它的设置使得噪声去除和图像分割之间难以做出妥协。因为噪声去除安排在图像预处理阶段进行，因而算法中考虑去除调整项，来降低计算复杂度。在图像预处理阶段，采用了Perona

和 Malik 提出的各向异性扩散滤波器<sup>[194]</sup>。该滤波器在去除噪声的同时，能够最大限度地保留边缘的属性，扩散操作也可以来代替平均曲率运动对水平集进行调整<sup>[193, 131]</sup>。该滤波器的数值实现方法有多种，包括显式方案<sup>[194]</sup>、半隐式方案<sup>[206]</sup>和加性算子分裂方案(AOS)<sup>[207]</sup>等。其中加性算子分裂方案在保证计算精度的条件下，效率高。本文选择AOS方案，还因为它的简单性和有效性，且没有附加参数。最后，为了将速度场从零水平集扩展到所有的水平集，算法中取  $\delta_\varepsilon(\phi) = 1$ 。因而，算法可以简化为如下形式：

$$\frac{d\phi_j}{dt} = \omega_R(u_j - \max_{i \neq j}(u_i)), \quad \omega_R \in R^+, \quad j = 1, 2, \dots, C. \quad (5.20)$$

概括来说，提出的多类分割算法包括以下步骤：

- (1) 图像滤波处理(各向异性扩散滤波器);
- (2) 对图像进行 FCM 分析，获得模糊隶属度集  $\mathbf{u} = \{u_j \mid j = 1, 2, \dots, C\}$ ;
- (3) 初始化  $\phi_j$  为有符号函数;
- (4) 根据式 (5.20) 进化曲线;
- (5) 周期性重初始化  $\phi_j$  为有符号距离函数;
- (6) 重复步骤(4)和(5)直到算法收敛。

#### 5.5.4 各向异性扩散滤波

图像在采集过程中有可能会混入各种噪声，噪声的特性也许各不相同。在进行图像分析之前，通常需要对图像进行滤波处理。图像的滤波处理可由不同的滤波器来实现。本小节介绍一种基于扩散原理的滤波算法，称之为各项异性扩散滤波器。该滤波其是 Perona 和 Malik<sup>[194]</sup> 在 1990 年提出的。各项异性扩散滤波器利用了图像的一个重要的局部特征——梯度模值，它包含了一种机制，将图像的滤波过程与图像边缘的检测过程二者结合起来。

##### (1) P-M 方程

各项异性扩散滤波器的扩散偏微分方程具有如下形式：

$$\frac{\partial I}{\partial t} = \text{div}[g(\|\nabla I\|) \cdot \nabla I], \quad (5.21)$$

初始条件为：

$$I(x, y, t = 0) = I_0(x, y)。$$

这里  $\nabla$  是梯度算子， $\|\cdot\|$  表示幅度， $\text{div}(\cdot)$  是散度算子， $I_0$  是原始图像， $g(\|\nabla I\|)$  称之为扩散率函数，或边缘停止函数。滤波过程会生成一序列逐渐平滑的图像，这些图像用隐含的时间参数索引，输出的图像包含较低的噪声水平。扩散过程在越过梯度幅度大的边界时受到阻碍，而在梯度幅度小的边界处扩散受到促进。 $k$  是常数，通过实验确定，用来区分梯度是由噪声产生的还是由边缘产生的。Perona 和 Malik 定义了两种扩散函数：

$$g(\|\nabla I\|) = \frac{1}{1 + (\|\nabla I\|/k)^2} \quad (5.22)$$

和

$$g(\|\nabla I\|) = \exp(-(\|\nabla I\|/k)^2)。 \quad (5.23)$$

在扩散过程中，梯度幅度  $\|\nabla I\|$  作为边缘检测子。如果  $\|\nabla I\| \geq k$ ，则  $g(\|\nabla I\|) \rightarrow 0$ ，抑制扩散； $\|\nabla I\| \leq k$ ，则  $g(\|\nabla I\|) \rightarrow 1$ ，促进扩散。通常，大的  $k$  值比小的  $k$  值在均匀区域产生更平滑的结果。因此， $k$  作为门限控制扩散过程。

## (2) 正则化 P-M 方程

You 等<sup>[208]</sup>证明 P-M 方程给出的初值问题可能是病态的，在特定的条件下，P-M 方程的稳态解不具有对于初始条件的连续依赖性，此时 P-M 方程是不稳定的。因而，Catté 等提出了正则化的 P-M 方程，也称为 CLMC 模型<sup>[206]</sup>：

$$\frac{\partial I}{\partial t} = \text{div}(g(\|\nabla I_\sigma\|) \cdot \nabla I), \quad (5.24)$$

式中

$$I_\sigma(x, y, t) = G_\sigma * I_0(x, y, t)。$$

$G_\sigma$  表示方差为  $\sigma$  的 Gauss 函数。

数学已经证明，式 (5.24) 是一个完全的适定问题，具有如下性质：

- ① 存在唯一的连续依赖于初值  $I_0(x, y)$  的解。这一性质保证了图像非线性扩散是稳定的。
- ② 服从极值原理，即

$$\inf_{\Omega} \{I_0(x, y)\} \leq I(x, y, t) \leq \sup_{\Omega} \{I_0(x, y)\}$$

这意味着，在较大尺度上所得的解  $I(x, y, t)$  中，将不会产生在较小尺度上不存在的水平集。因此  $I(x, y, t)$  将变得越来越‘简单’，因而 P-M 方程将生成一个尺度空间。

③ 平均灰度不变，即

$$\frac{1}{|\Omega|} \int_{\Omega} I(x, y, t) dx dy = \mu = \frac{1}{|\Omega|} \int_{\Omega} I_0(x, y) dx dy$$

④ 收敛于常数稳态解，即

$$u(x, y, t) \xrightarrow{t \rightarrow \infty} \mu$$

⑤ 李亚普诺夫函数递减性。即对于任何凸函数  $r(\cdot)$

$$L(t) = \int_{\Omega} r(u(x, y, t)) dx dy$$

是时间  $t$  的单调递减函数，且下界为  $\int_{\Omega} r(\mu) dx dy$ 。

(3) P-M 方程的数值实现

① 显式方案：

Perona 和 Malik<sup>[194]</sup>给出了 P-M 方程的显式方案：

$$I_s^{n+1} = I_s^n + \frac{\tau}{|\eta_s|} \sum_{p \in \Gamma_s} g(\|\nabla I_{s,p}^n\|) \nabla I_{s,p}^n \quad (5.25)$$

式中，下标  $s, p$  为指示网格点坐标的整数矢量； $\Gamma_s$  表示以  $s$  为中心的四点邻域点集；而  $\nabla I_{s,p}^n = I_p^n - I_s^n$ 。

式 (5.25) 可以看作是对于  $\text{div}[g(\|\nabla I\|)]$  算子的一种特殊的“半点”离散化格式。

大量实验表明，按照式 (5.25) 的显式方案，在时间步长  $\Delta t < 0.25$  的情况下，即使采用式 (5.22) 的边沿检测算子，数值解也是稳定的。原因在于显式方案采用的空间平均和时间延迟隐含了正则化效应，克服了 P-M 方程的病态性质。

② 半隐式方案

对于正则化 P-M 方程，Weickert 提出了半隐式的方案<sup>[207]</sup>：

$$I_s^{n+1} = I_s^n + \tau \sum_{p \in \Gamma_s} \frac{g_p^n + g_s^n}{2} (I_p^{n+1} - I_s^{n+1}) \quad (5.26)$$

式中  $g_s^n := g(\|\nabla I_{\sigma,s}^n\|)$  表示边缘函数在  $s$  点的值，是由正则化图像  $I_{\sigma}^n = G_{\sigma} * I^n$  的梯度模值代入边缘函数  $g(\cdot)$  得到的。

采用半隐式方案，导致一个线性联立方程组，用矩阵—矢量形式表达，可以写成如下形式：

$$I^{n+1} = I^n + \tau A^n I^{n+1} \quad (5.27)$$

式中  $I^n$  和  $I^{n+1}$  分别表示在  $n$  和  $n+1$  时刻的矢量图像，是按照某种扫描方式从图像数据  $I_{ij}$  ( $i=1,2,\dots,M$ ,  $j=1,2,\dots,N$ ) 转换而成的  $MN$  维列矢量； $A^n$  是  $MN \times MN$  维矩阵，它的元素为：

$$a_{s,p} = \begin{cases} (g_p^n + g_s^n)/2, & p \in \Gamma_s \\ -\sum_{p \in \Gamma_s} (g_p^n + g_s^n)/2, & p = s \\ 0, & other \end{cases}$$

令  $I$  表示  $MN \times MN$  的单位矩阵，则式 (5.27) 的解可以表示为：

$$I^{n+1} = (I - \tau A^n)^{-1} I^n \quad (5.28)$$

为了克服由于系数矩阵过大所带来的求逆的困难，常采用 Jacobi 迭代或 Gauss-Siedel 迭代算法来求解线性联立方程组。

### ③ 加性算子分裂方案

为了提高计算效率和精度，Weickert 等<sup>[207]</sup>提出了加性算子分裂方案 (Additive Operator Splitting, AOS) 算法。

首先分别对  $I^n$  的行和列个做一维扩散，得到两个中间结果  $I_1^{n+1}$  和  $I_2^{n+1}$ ，有

$$\begin{cases} (I - 2\tau A_x^n) I_1^{n+1} = I^n \\ (I - 2\tau A_y^n) I_2^{n+1} = I^n \end{cases} \quad (5.29)$$

然后求二者的平均值最为一次完整的迭代结果：

$$I^{n+1} = \frac{1}{2} (I_1^{n+1} + I_2^{n+1})$$

即

$$I^{n+1} = \frac{1}{2} [(I - 2\tau A_x^n)^{-1} + (I - 2\tau A_y^n)^{-1}] I^n \quad (5.30)$$

AOS 算法是绝对稳定的,可以在保证精度的前提下,选用尽可能大的时间步长以提高效率。也就是说,采用 AOS 方案算法时,时间步长的选择不是出于稳定性的考虑,而是出于精度和效率的折中考虑。

正则化 P-M 方程的半隐式 AOS 算法归纳如下:

当完成  $I^n$  后:

令  $f_{ij} = I_{ij}^n$ ;

A. 计算  $f_\sigma = G_\sigma * f$ ,  $\|\nabla f_\sigma\|$ ,  $g_{ij} = g(\|\nabla f_\sigma\|)$

B. 对  $i=1,2,\dots,M$

a. 计算  $(I - 2\tau A_{x,i}^n)$  的三对角线上的元素:  $(\alpha_k^{(i)}, k=1,2,\dots,N)$ ,

$(\beta_k^{(i)}, k=1,2,\dots,N-1)$ ,  $(\gamma_k^{(i)}, k=2,3,\dots,N)$ ;

b. 采用 Thomas 算法求解  $(I - 2\tau A_{x,i}^n)I_{1,i}^{n+1} = I_{1,i}^n$ ,  $i=1,2,\dots,M$ , 得到  $I_1^{n+1}$ ;

C. 对  $j=1,2,\dots,N$

a. 计算  $(I - 2\tau A_{y,j}^n)$  的三对角线上的元素:

b. 采用 Thomas 算法求解  $(I - 2\tau A_{y,j}^n)I_{2,j}^{n+1} = I_{2,j}^n$ ,  $j=1,2,\dots,N$ , 得到  $I_2^{n+1}$ ;

D. 计算  $I^{n+1} = \frac{1}{2}(I_1^{n+1} + I_2^{n+1})$ , 完成一次迭代。

不论采用显式方案或半隐式方案,停止迭代的时间往往由实验确定。时间不足时图像中可能仍残存明显的噪声,而时间过长时则会造成图像的明显模糊化。

在多类分割算法中,采用正则化 P-M 方程的半隐式 AOS 算法对含噪 MRI 图像进行滤波处理。

## 5.6 实验结果

本节将通过实验确认提出的算法,算法测试限于 2 维灰度图像。测试图像包括人工合成图像、仿真 MRI 图像和真实 MRI 图像。算法的分割结果与 Chan-Vese 模型和 Chan-Vese 多相算法以及 Wang 等提出的改进 FCM 算法(MFCM)<sup>[98]</sup>。

参数设置:滤波阶段, Gauss 核宽度 3, 标准差 1, 滤波门限 10。

FCM 阶段:模糊指数  $m=2$ , 聚类类别数根据待分割目标图像分别设置。

水平集阶段:  $\omega_k = 7$ 。

迭代终止条件:最大迭代次数 100, 或者新分入像素比率小于  $10^{-4}$ 。

Chan-Vese 模型和多相算法迭代终止条件:

最大迭代次数 2000 次, 或者能量函数标化率小于  $10^{-4}$ 。



### 5.6.1 合成图像分割实验

首先用多类分割算法分割一个人工合成图像，图像包括感兴趣目标和背景，图像大小 100 像素×100 像素。实验中采用了不同的初始化方式，初始化曲线在待分割目标外部（图 5.3a），内部（图 5.3b），任意位置（图 5.3c）和多初始化（图 5.3d）。图中蓝色曲线为初始化曲线，红色表示进化过程，白色为最后边界的最后位置。分割结果显示，无论何种初始化形式，算法都收敛到正确的分割结果，表明算法对初始化位置不敏感。




图 5.3 人工合成图像分割结果

初始轮廓（蓝色曲线），中间进化曲线（紫色）和最后分割结果（白色曲线）

Fig.5.3 Segmentation results of synthetic image. Initial contours (blue circles), middle evolving curves (magenta lines), and the final segmentation results (white lines).

为了论证提出的算法在噪声条件下的分割性能，尝试分割人工合成噪声图像，图像分别添加高斯噪声(均值为 0 方差为 0.02) 和椒盐噪声(噪声强度 0.05)。在滤波器阶段，参数设置：时间步长 1.5，迭代次数 3。本文算法的分割结果和 Chan-Vese 模型分割结果进行比较。Chan-Vese 模型分割中，递归次数最大为 500 次，或者能量函数变化率小于  $10^{-3}$ ，两种噪声条件下都设置曲率项系数  $\mu = 0.1 \times 255^2$ 。图 5.4 为两种算法的分割结果。从分割结果可以看到，在高斯噪声条件下，两个算法获得了相似的分割结果，而在椒盐噪声条件下，本文提出的算法分割结果明显优于 Chan-Vese 模型的分割结果。这个分割结果在表 5.1 提供的定量分析中得到了确认。




图 5.4 噪声人工合成图像分割：原始图像 (a)，添加高斯噪声图像（叠加初始曲线）(b)，Chan-Vese 算法分割结果 (c)，本文算法分割结果 (d)；添加椒盐噪声图像（叠加初始曲线）(e)，Chan-Vese 算法分割结果 (f)，本文算法分割结果 (g)

Fig. 5.4 Segmentation results of a synthetic image with different noises. Original image (a), original image corrupted by Gaussian noise (overlapped with initial curves) (b), corresponding result of C-V model (c) and result of our algorithm (d); original image corrupted by salt & pepper noise (overlapped with initial curves) (e), corresponding result of C-V model (f) and result of our algorithm (g).

表 5.1 不同噪声条件下的性能指标

Tab. 5. 1 Performance indexes under different noise types

		Kappa	$r_{fp}$	$r_{fn}$
Gaussian	C-V model	99.63	0.42	0.33
	our method	99.20	0.99	0.62
salt & pepper	C-V model	95.87	7.22	1.28
	our method	99.07	1.10	0.76


人工合成图像分别添加高斯噪声和椒盐噪声，实验进行 100 次，对分割结果进行统计。统计结果见表 5.1。定量评估采用的性能指标为 Kappa 指标，假阳性率  $r_{fp}$  和假阴性率  $r_{fn}$  [209]。100 次实验的平均结果见表 5.1。从表 5.1 可以看出，在高斯噪声条件下，两种算法分割结果非常接近，Chan-Vese 算法稍稍好于我们提出的算法。在噪声条件下，

多类分割算法的分割结果明显优于 Chan-Vese 算法的分割结果。较低的性能指标表明 Chan-Vese 算法对椒盐噪声较为敏感。比较试验结果显示多类分割算法具有较好的噪声鲁棒性。

### 5.6.2 仿真 MRI 图像分割实验

在本小节，用多类分割算法分割仿真 MRI 图像，T1-加权图像添加不同等级的噪声。图像从 BrainWeb 网站<sup>[43]</sup>下载，切片厚度 1mm，图像大小  $181 \times 217 \times 181$  体素。T1 加权图像首先去除非脑组织，然后进行分割。用 Chan-Vese 多相算法对该组测试图像也进行了分割，分割结果和多类分割算法的分割结果进行比较。

在滤波阶段，时间步长设置为 0.5，门限设置为 10；递归次数分别设置为 2 和 3 次（分别对应 107<sup>th</sup> 切片和 94<sup>th</sup> 切片的分割）。在 FCM 处理阶段，聚类数目  $C$  设置为 4，分别对应 WM, GM, CSF 和背景。多类分割算法采用多初始化形式：12×12 种子圆圈均匀内地分布在图像域内。Chan-Vses 多相算法采用 2 个水平集初始化，每个水平集包含 8×8 个种子圆圈。






图 5.5 不同噪声条件下的仿真 MRI 图像分割: 107<sup>th</sup> 切片添加 7% Rician 噪声: 本文算法: 初始化(a), GM 分割结果 (b), WM 分割结果 (c); Chan-Vese 多相算法( $\mu = 0.0075 \cdot 255^2$ ): 初始化 (e), GM 分割结果 (f), WM 分割结果 (g); 标准图像 GM (d) 和 WM (h); 94<sup>th</sup> 切片添加 9% Rician 噪声: 本文算法: 初始化 (i), GM 分割结果 (j), WM 分割结果 (k); Chan-Vese 多相算法( $\mu = 0.01 \cdot 255^2$ ): 初始化 (m), GM 分割结果 (n), WM 分割结果 (o); 标准图像 GM (l) 和 WM (p)

Fig. 5.5 Segmentation results on simulated MRI images with added noise. 107<sup>th</sup> slice with 7% Rician noise: initialization conditions (a) and results of GM (b) and WM(c) of our algorithm, initialization conditions (e) and results of GM (f) and WM (g) of the C-V multiphase model with  $\mu = 0.0075 \cdot 255^2$ ; the ground truths of GM(d) and WM (h). 94<sup>th</sup> slice with 9% Rician noise: initial conditions (i) and results of GM (j) and WM (k) of our algorithm, initial conditions (m) and results of GM (n) and WM (o) of the C-V multiphase model with  $\mu = 0.01 \cdot 255^2$ ; the ground truths of GM(l) and WM(p).

图 5.5 中给出了两个切片 107<sup>th</sup> 切片添加 7% Rician 噪声, 94<sup>th</sup> 切片添加 9% Rician 噪声及其分割结果。从图 5.5 分割结果可以看到, 在视觉上 Chan-Vese 多相算法结果显得比较‘嘈杂’, 而多类分割算法在各个噪声级别上都取得了良好的分割结果。表 5.2 为图 5.5 试验的定量评价结果。表 5.2 中的统计结果显示, 在 7% 噪声下, Chan-Vese 多相算法的总体误差 ( $r_{fp} + r_{fn}$ ) 为 灰质 19.37%, 白质 12.99%。多类算法的总体误差为灰质 13.33% 和白质 5.96%; 9% 噪声条件下, Chan-Vese 多相算法的总体误差灰质

23.31% 白质 12.95%，而多类算法对应的总体误差为 19.46% 和 7.58%。多类算法的总体误差优于 Chan-Vese 多相算法。

表 5.2 图 5.5 中实验的性能指标 (%)

Tab. 5.2 Performance indexes (%) of experiments in Fig. 5.5

	noise level (%)	GM			WM		
		Kappa	$r_{fp}$	$r_{fn}$	Kappa	$r_{fp}$	$r_{fn}$
C-V	7	89.94	5.96	13.41	93.83	11.70	1.29
Multiphase	9	87.92	8.13	15.18	93.84	11.49	1.46
	7	93.14	3.82	9.51	97.02	2.89	3.07
our method	9	90.39	11.03	8.43	96.24	4.52	3.06

在噪声条件下的实验中，用多类算法和 C-V 多相算法来分割 20 幅添加了不同等级噪声的 MRI 图像(第 84 到第 103 切片)，通过实验比较两个算法的性能。图 5.6 中绘制了不同噪声等级下两个算法分割结果的平均 Kappa 曲线。曲线图清楚地表明，在不同噪声等级条件下，多类算法分割结果优于 C-V 多相算法。本章提出的多类算法有更好的分割性能，以及良好的噪声鲁棒性。

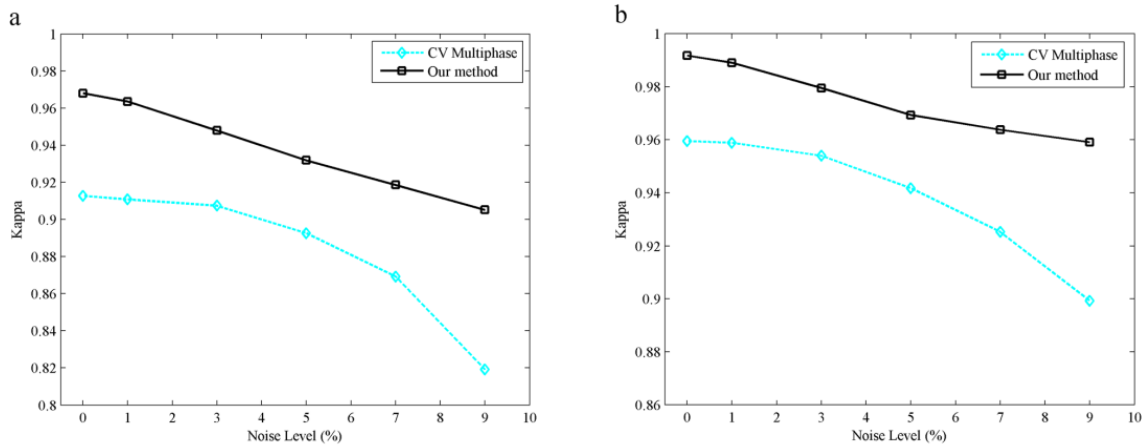


图 5.6 不同噪声下 20 切片的分割结果的平均相似度曲线图：(a) 灰质；(b) 白质  
Fig. 5.6 Curves of average Kappa indexes for segmentation 20 slices with different noise levels:  
(a) gray matter; (b) white matter.



### 5.6.3 真实 MRI 图像分割实验

在本小节,用多类算法分割真实的 T1-加权 MRI 图像。实验图像从 IBSR<sup>[180]</sup>网站下载,数据集中除了包括真实采集的 MRI 图像外,该数据集还提供了手动分割结果作为‘金标准’,方便用户评价算法。图像在实验前先去除了非脑组织。

在真实 MRI 分割实验中,实验图像取自不同的数据集,切片位置也不同。为了与现有算法进行比较,该数据集也采用 SPM5<sup>[43]</sup>和 BrainSuite 2 软件<sup>[114]</sup>进行了分割实验。分割结果见图 5.7 和图 5.8,对应分割结果的统计指标见表 5.3 和 5.4。




图 5.7 真实 MRI 图像分割实验结果对比: (a) 原始图像与 mask; (b) SPM5 分割结果; (c) BrainSuite 2 分割结果; (d) 多类算法分割结果 (第一行: 灰质,第二行: 白质)

Fig. 5.7 Comparison of segmentation results of different algorithms: (a) original image and mask; GM and WM segmentation results of (b) SPM5, (c) BrainSuite 2, and (d) our multiclass algorithm.

表 5.3 图 5.7 中真实 MRI 图像实验结果的统计指标 (%)

Tab. 5.3 Statistical indexes (%) of experiments on real MRI image in Fig. 5.7

	GM			WM		
	Kappa	$r_{fp}$	$r_{fn}$	Kappa	$r_{fp}$	$r_{fn}$
SPM5	79.33	10.81	27.16	87.55	3.80	19.19
BrainSuite 2	79.59	0.22	33.76	89.02	24.10	0.46
Our Method	94.75	3.25	7.06	87.50	28.23	0.28

图 5.7 中为显示了一个切片的分割结果，表 5.3 为三种方法的分割结果的统计指标。从图像的灰质分割结果来看，SPM5 和 BrainSuite 2 的分割结果明显不如本文的多类分割算法的分割结果。SPM5 将部分白质错误地分割到灰质类别中，以及算法在进行去除非脑组织的操作中的遗留组织可能是影响分割结果质量的主要因素。本文的多类分割算法的在白质分割结果与 BrainSuite 2 算法的分割结果相近。表 5.3 的统计结果印证了该分割结果。

图 5.8 显示了另一个切片的分割结果，表 5.4 为三种算法分割结果的统计指标。整体而言，三种算法都取得了不错的分割结果。与手动分割结果性比，本文算法的灰质分割结果优于其它两种算法的分割结果。BrainSuite 2 由于灰质分割结果不够‘光滑’，因而性能相对指标较低。而 SPM5 的分割性能依然受到非脑组织的影响。三种算法的白质分割结果比较接近，BrainSuite 2 算法略优于其它两种算法。Wang 等人提出的 MFCM 算法中采用了该切片图像进行实验，Wang 等<sup>[98]</sup>提供了分割结果的定量评价，表 5.4 中也列出其定量指标。从表 5.4 可以看出，本文的多类算法的白质和灰质分割的 Kappa 指标均超过了 95%。表中提供的所有指标均优于 Wang 等人提出的 MFCM 算法的分割性能。这些统计指标也明显优于 FCM 相关的其它算法的分割结果（见[98]中表 3）。




图 5.8 真实 MRI 图像分割实验结果对比：(a) MRI 图像（叠加本文算法初始轮廓）与手动分割结果；(b) SPM5 分割结果；(c) BrainSuite 2 分割结果；(d) 多类算法分割结果（第一行：灰质，第二行：白质）  
 Fig. 5.8 Comparison of segmentation results of different algorithms: (a) MRI image (overlapped with initial curves of multiclass algorithm) and manual segmentation result; GM and WM segmentation results of (b) SPM5, (c) BrainSuite 2, and (d) our multiclass algorithm.

表 5.4 图 5.8 中真实 MRI 图像分割性能指标 (%)

Tab. 5.4 Performance indexes (%) experiments on real MRI image in Fig. 5.8

	GM			WM		
	Kappa	$r_{fp}$	$r_{fn}$	Kappa	$r_{fp}$	$r_{fn}$
MFCM <sup>[98]</sup>	91.58	2.48	13.44	94.22	7.92	3.87
SPM5	89.34	7.35	13.33	93.57	1.86	10.45
BrainSuite 2	86.94	2.10	21.49	96.91	3.05	3.13
Our Method	96.45	0.18	6.69	95.89	7.51	0.99

图 5.8 显示了数据集 IBSR\_18 中每个切片的 Kappa 指标统计曲线。整个数据集的平均 Kappa 指标为：白质 82.48% 灰质 91.42%。Wang 等提出的 MFCM 算法的平均相似度指标为白质 75.98% 灰质 81.90% (见文献[98]中图 11 和有关描述)。多类算法的分割结果明显优于 MFCM 算法。




图 5.8 真实 T1-加权 MRI 数据集中每个切片的 Kappa 指标

Fig. 5.8 Kappa indexes of each image slice in real T1-wighted MRI data volume.

表 5.5 10 个真实 MRI 数据集分割结果平均指标 (%)

Tab. 5.5 Average Kappa indexes (%) of segmentation experiments on ten real MRI datasets

	SPM5			BrainSuite 2			Our method		
	GM	WM	AVG	GM	WM	AVG	GM	WM	AVG
均值	83.30	87.02	85.16	80.94	85.53	83.23	90.27	83.30	86.78
标准差	5.83	1.96	3.05	4.61	5.98	4.32	0.90	2.98	1.67



---

表 5.5 中为三种分割算法对 IBSR9-18 共计 10 个真实 MRI 数据集的分割结果的平均 Kappa 指标和标准差。从表中数据可以看出，本文提出的多类分割算法在灰质分割上取得了良好的分割结果，而白质分割指标不如其它两种算法，表明白质的分割质量还有待进一步提高。而 SPM5 算法在白质分割结果中获得良好的分割。总体平均性能指标上，本文提出的算法与手工分割结果有更高的平均重叠度。

## 5.7 算法比较与问题讨论

与 Chan-Vese 多相算法<sup>[192, 126]</sup>相比较，多类算法算法具以下几个优点：

多相算法在区域数目不是 2 的幂的时候，必须要引入“空”的区域，这个“空”的区域在统计上是没有定义的。而在多类分割算法中，类的数目是预先明确指定的。当某一类的像素数目小于某一门限值时，将去除该类别，因而不会有空的类产生，多类分割算法可以处理任意类别数的分类问题。

在 Chan-Vese 模型<sup>[124]</sup>和多相算法<sup>[192, 126]</sup>中，参数  $\mu$  发挥着尺度的角色：小的  $\mu$  值用来检测小的目标，大的用来检测大的目标，或者对分割目标进行分组。在噪声情况下，噪声去除需要靠调整参数  $\mu$  来实现。在实际应用中，该参数很难确定，尤其是在缠绕的小结构与噪声同时存在的情况下，算法难以在小目标和噪声之间做出折中处理。而在本文提出的多类分割算法中，将噪声去除和图像分割两个过程分开，可以分别来考虑噪声去除和分割质量，能够更加有效地来处理这两个问题。噪声图像的实验结果也表明了这一点。

在实验中，多类分割算法采用了多种子的初始化方式。这种初始化方式倾向于使算法收敛到全局最小，同时能够加快算法的收敛速度。这种初始化方式也被 Chan 和 Vese 在其论文中应用。然而 Chan-Vese 模型在某些特定的初始化方式下，不会收敛到全局最小<sup>[126]</sup>。Gibou 和 Fedkiw<sup>[193]</sup>提供一个分割失败的例子。在本文用其分割脑组织时，也发现算法收敛到非期望的结果。这在某种程度上说明该算法对初始条件具有一定的敏感性。

在真实 MRI 图像的分割实验中，本文对多类算法和 Wang 等提出的 MFCCM 算法的分割结果进行了比较。在 MFCCM 算法中，通过搜寻窗和邻域窗分别引入了非局部和局部空域信息来提高分割的准确度，同时去除噪声。其中搜寻窗部分算法是基于非局部均值算法的<sup>[97]</sup>。在非局部均值算法中，参数  $h$  控制着欧氏距离权值的衰减。该参数主要依赖于噪声方差的大小。算法同时受窗口大小的严重影响：小的邻域窗和搜寻窗，算法仅限于抑制高频噪声，而对低频噪声无能为力；而大的邻域窗和搜寻窗，算法去除了低频噪声，因对对小的细节不再敏感，而将其平滑掉<sup>[210]</sup>。

---

在对非局部均值算法进行评估中，当滤波器参数  $h$  小于噪声标准差  $\sigma$  时，噪声不能被有效去除；而在  $h$  大于噪声标准差  $\sigma$  时，图像的一些细节被平滑掉。因此，非局部均值依赖于噪声方差的准确估计。当噪声方差估计偏离其真实值时，将影响到滤波效果。然而，对于给定的噪声污染的图像，要准确地估计其噪声参数也绝非简单的事情。很显然，任何不准确的估计都会造成滤波效果的降低。

正如作者自己指出的，非局部均值算法适应于纹理或周期性图像，应为这类图像中有大量的冗余信息<sup>[211]</sup>。而对于 MRI 图像，特别是有一些细小结构的脑部图像，这种所谓的冗余信息较少。为了避免细小结构被平滑掉，Wang 等在其算法中引入了局部信息，来平衡非局部信息。然而要在噪声去除和图像分割质量之间做出折中处理是非常困难的。

多类算法与 MFCM 算法不同。在多类算法中，噪声是通过预处理阶段的各向异性扩散滤波器降低的，然后是 FCM 预分割，水平集方法完成最后的分割。脑组织间没有明确的边界，形状不固定，模糊逻辑框架则考虑到了这种模糊性和不确定性，将每个像素以不同的隶属度值分配给各个组织类别。与硬分割算法相比，基于模糊的逻辑框架能够保留更多的细节信息。水平集方法则使分割更准确，能够保持平滑的区域边界。与 MFCM 算法的结果相比，多类算法有更好的分割性能。

另外，正如作者自己指出的，MFCM 算法有着代价高昂的计算负担。在我们的测试中，分割一副  $256 \times 256$  像素大小的 MRI 图像，需要耗时超过 2 小时。而多类算法分割则仅仅需要大约 20 秒的时间，包括预处理和 FCM 预分割阶段（在 PC 机上运行，MATLAB 下编程，E5200 CPU 和 2G RAM 硬件配置）。

BrainSuite 2 是一个自动的脑皮层识别工具，包括头皮和头骨去除，图像灰度不均匀补偿，基于体素的组织分类和拓扑校正，透视图等功能。在组织分类模块中，采用了基于部分容积的分类技术，透过 Gibbs 先验结合了像素的空域信息。在本文的对比实验中，采用了组织分类模块来分割脑组织。

SPM5 是由伦敦学院大学开发的另一款用于 MRI, fMRI, PET, EEG 等分析的工具软件，在 MRI 图像处理领域被广泛采用。在组织分割中，算法包括了配准、偏置场校正、组织分类等模块。算法用高斯模型来描述组织类别，用 EM 算法来估计最优参数。用仿射变换将脑解剖组织映射到标准的 International Consortium of Brain Mapping (ICBM)/Montreal Neurological Institute (MNI)空间，并完成组织分割。

在对真实 MRI 图像的分割实验中，本文提出的多类算法和 SPM5 以及 BrainSuite 2 工具包的分割结果进行了比较。本文提出的多类算法在灰质分割中取得了良好的结果，而 SPM5 在白质分割结果中取得最好的分割性能。而从 10 个 MRI 数据集的分割结果上

---

看，本文提出的多类分割算法获得了最好的平均分割性能，然而白质的分割结果指标不能令人满意，还有待进一步提高。结合空域信息或者结合先验知识可能是提高分割性能的一个重要手段。

## 5.8 本章小结

本章在对 Chan-Vese 模型和 Chan-Vese 多相算法研究的基础上，提出了一个多类算法来分割脑组。算法由一组常微分方程组成。算法中，每个组织类别用一个水平集表示。算法中施加了一个约束来阻止隶属于不同类的区域间重叠和空洞的出现。各项异性扩散滤波器用来消除噪声影响，同时用来代替曲率项调整曲线的进化。这种处理松弛了对时间步长的约束，使得算法更快地收敛。用合成图像，仿真和真实的 MRI 图像对算法进行了测试和评估。分割结果与 Chan-Vese 多相算法以及 MFCM 等算法进行了比较。结果表明多类算法有较高的分割准确度，小的计算代价，和良好的噪声鲁棒性。

---

## 6 结论与展望

### 6.1 结论

本文首先提出了一个基于直方图分析的算法，从 MRI 图像中分割不同的脑组织。算法首先用混合高斯模型逼近归一化的图像灰度直方图，通过 EM 算法估计混合高斯模型中各个高斯分量的参数。获得的参数用于产生约束项。算法中用基于统计特征的约束项代替经典几何活动轮廓模型中的停止项，来控制水平集曲线的进化。基于直方图分析的算法克服了经典几何活动轮廓模型过度依赖图像梯度信息的缺陷，以及由于对图像高斯平滑操作带来的边界点定位精度的下降的不足。在几何活动轮廓模型中，这种平滑操作一方面是为了降低噪声的影响，另一方面则是为了扩大力的作用范围。在新算法中，曲线进化过程中能够可以自动地调整曲线进化的方向（收缩和膨胀），而在经典几何活动轮廓模型中，曲线进化只能在一个方向（收缩或膨胀）进行，而且需要预先确定。算法通过了仿真和真实 MRI 图像的实验验证。

其次，本文提出了一个改进算法，原始算法是由 Suri 提出的基于区域的几何活动轮廓模型。文中首先在数学上证明了原始算法潜在的稳定性问题。针对稳定性问题，提出了改进算法。由于采用了新的区域项，新算法解决了原始算法的稳定性问题，以及分割结果对某些参数敏感的问题。新的算法可以从包括 T1-加权、T2-加权和 PD-加权图像在内的不同模态的 MRI 脑部图像中分割出白质、灰质和脑脊液，且收敛速度更快。文中，用仿真和真实的 MRI 图像对算法进行了评估。定量和定性的分析表明改进的可行性和有效性。通过其它算法的分割结果进行定量比较，显示改进后的算法有较好的分割性能。提出的模糊区域指示子在自适应水平集算法中得到了应用。从图像模糊聚类分析中获得模糊信息提供了全局的约束，使得进化曲线能够自适应地改变进化方向（膨胀和收缩）。算法中采用的模糊逻辑框架，考虑了 MRI 图像中的模糊性和不确定度，允许以不同的隶属度值将一个像素分类到各个组织类。提出的方法从 FCM 算法和水平集方法中受益：模糊聚类方法提供区域信息，而水平集方法保持组织区域分段连续的平滑特性。实验结果表明 FCM 和水平集结合能有效提高分割准确度。

最后，本文提出了一个多类算法来分割脑组织。算法由一组常微分方程组成，其中每个水平集表示一个组织类别。算法中用 max 算子引入了一个约束项，来阻止代表不同类的区域间的重叠和空洞。各向异性扩散滤波用来滤除图像中的噪声，同时代替曲率项来对水平集的进化进行调整。这种安排松弛了算法对时间步长的严格约束，因而使得算法有更快的收敛速度。用人工合成图像、仿真和真实的 MRI 图像对图像进行了测试。定

---

量分割定性分析表明多类算法有较高的分割准确度，低的计算代价以及良好的噪声鲁棒性。

算法中采用了多种子的初始化方式，该初始化方式不需要确切知道待分割目标的位置，需要较低的人工干预程度，因而提高了算法的自动化水平。该初始化方式能够有效加快算法的收敛速度，降低算法对初始化条件的敏感度，也能够避免算法陷入局部最小。

作为结论，本文的贡献主要有：

- (1) 提出了基于直方图的非参数化变形模型来分割脑组织。在算法中，有限高斯混合模型用来逼近图像的归一化灰度直方图；期望最大化算法用来估计混合模型中各个高斯分量的参数。用获得参数产生的约束项控制曲线的进化过程。算法克服了传统几何活动轮廓模型对图像梯度信息的依赖以及由于高斯平滑造成的边界定位精度下降的缺陷。
- (2) 根据对 Suri 的算法的稳定性分析，提出了改进的基于区域的几何活动轮廓模型。新算法解决了原始算法存在的稳定性问题。算法能够从不同模态的 MRI 图像中分割脑组织，与原算法相比较，新算法有较高的分割准确度和较少的迭代次数。
- (3) 提出了多类分割算法。算法由一组常微分方程表示。算法包括各项异性扩滤波器、模糊 C-均值分割和水平集分割等三个阶段。算法容易实现，计算复杂度低，同时有较高的分割准确度和良好的鲁棒性。
- (4) 提出了 FCM 和水平集方法结合的框架。模糊信息为曲线进化提供了全局的约束，操纵着曲线进化的方向。而且，模糊逻辑框架考虑了部分容积效应，与硬分割算法比较，能包含更多的信息。水平集算法使分割结果更准确，且保持分割边界的良好平滑性。

## 6.2 未来工作

未来工作包括以下内容：

- (1) 灰度不均匀。MRI 图像中的灰度不均匀主要是由射频线圈的缺陷引起的，它会改变给定组织的绝对灰度。未来算法中应该考虑对存在的灰度不均匀进行校正，同时保留有用信息。
- (2) 部分容积问题。在本文提出的算法中，集成的 FCM 步骤隐含地考虑了部分容积效应问题。未来应用中，在涉及到低分辨率的 MRI 图像时应该明确考虑部分容积效应问题。
- (3) 三维应用。提出算法的应用范围限于二位灰度图像。二维图像往往不能提供

---

充足的信息，而在三维图像中，相邻切片将能够提供更多的信息，有助于提高分割准确度。下一步工作将考虑将现有算法扩展到三维情况。

- (4) 解剖结构的分割。脑解剖结构的异常变化往往与一些特定的疾病有着紧密的联系。通过在数字 MRI 图像中分割神经解剖结构，能够为脑部有关疾病的诊断和治疗效果评估提供依据。下一步工作将对解剖结构的分割进行研究，尝试将现有算法应用于解剖结构的分割，尤其是灰质结构的分割。

---

## 参 考 文 献

- [1] Gonzalez R F, Woods R E. Digital Image Processing (Second Edition), Prentice Hall. 阮秋琦, 阮宇智译. 北京: 电子工业出版社, 2003.
- [2] Brummer M E, Merseerau R M, Eisner R L et al. Automatic detection of brain contours in MRI data sets. *IEEE T. Med. Imag.*, 1993, 12:153–166.
- [3] Sandor S, Leahy R. Surface-based labeling of cortical anatomy using a deformable atlas. *IEEE T. Med. Imag.*, 16:41–54, 1997.
- [4] Kapur T, Grimson E, Wells W et al. Segmentation of brain tissue from magnetic resonance images. *Med. Im. Anal.*, 1996, 1(2):109–127.
- [5] Aboutanos G B, Dawant B M. Automatic brain segmentation and validation: image-based versus atlas-based deformable models. In *Medical Imaging, SPIE Proc.*, 1997, 3034: 299–310.
- [6] Atkins M S, Mackiewich B T. Fully automatic segmentation of the brain in MRI. *IEEE T. Med. Imag.*, 17:98–109, 1998.
- [7] Momenan R, Hommer D, Rawlings R et al. Intensity-adaptive segmentation of single-echo T1-weighted magnetic resonance images. *Human Brain Mapping*, 1997, 5:194–205.
- [8] Rajapakse J C, Giedd J N, Rapoport J L. Statistical approach to segmentation of single-channel cerebral MR images. *IEEE T. Med. Imag.*, 1997, 16:176–186.
- [9] Wang Y, Adah T, Kung S et al. Quantification and segmentation of brain tissues from MR images: a probabilistic neural network approach. *IEEE T. Image. Process.*, 1998, 7:1165–1181.
- [10] Liang Z, MacFall J R, Harrington D P. Parameter estimation and tissue segmentation from multispectral MR images. *IEEE T. Med. Imag.*, 1994, 13:441–449.
- [11] Kaufhold J, Schneider M, Willsky A S et al. A statistical method for efficient segmentation of MR imagery. *Int. J. Patt. Rec. Art. Intel.*, 1997, 11:1213–1231.
- [12] Tsai C, Manjunath B S, Jagadeesan R. Automated segmentation of brain MR images. *Patt. Rec.*, 1995, 28: 1825–1837.
- [13] Reddick W E, Glass J O, Cook E N et al. Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks. *IEEE T. Med. Imag.*, 1997, 16(6): 911–918.
- [14] Santago P, Gage H D. Statistical models of partial volume effect. *IEEE T. Image Process.*, 1995, 4:1531–1540.
- [15] Bullmore E, Brammer M, Rouleau G et al. Computerized brain tissue classification of magnetic resonance images: a new approach to the problem of partial volume artifact. *Neuroimage*, 1995, 2:133–147.
- [16] Johnston B, Atkins M S, Mackiewich B et al. Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI. *IEEE T. Med. Imag.*, 1996, 15:154–169.
- [17] Laidlaw D H, Fleischer K W, Barr A H. Partial-volume bayesian classification of material mixtures in MR volume data using voxel histograms. *IEEE T. Med. Imag.*, 1998, 17:98–107.
- [18] Clark M C, Hall L O, Goldgof D B et al. MRI segmentation using fuzzy clustering techniques. *IEEE Eng. Med. Biol.*, 1994, 13(5): 730–742.
- [19] Brandt M E, Bohan T P, Kramer L A et al. Estimation of CSF, white and gray matter volumes in

- 
- hydrocephalic children using fuzzy clustering of MR images. *Computerized Medical Imaging and Graphics*, 1994, 18:25–34.
- [20] Reiss A L, Hennessey J G, Rubin M et al. Reliability and validity of an algorithm for fuzzy tissue segmentation of MRI. *J. Comp. Assist. Tom.*, 1998, 22:471–479.
- [21] Pham D L, Prince J L. An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Patt. Rec. Let.*, 1999, 20(1): 57–68.
- [22] Soltanian-Zadeh H, Windham J P, Peck D J. Optimal linear transformation for MRI features extraction. *IEEE T. Med. Imag.*, 1996, 15:749–767.
- [23] Ge Y, Fitzpatrick J M, Dawant B M et al. Accurate localization of cortical convolutions in MR brain images. *IEEE T. Med. Imag.*, 1996, 15:418–428.
- [24] Davatzikos C, Bryan R N. Using a deformable surface model to obtain a shape representation of the cortex. *IEEE T. Med. Imag.*, 1996, 15:785–795.
- [25] McInerney T, Terzopoulos D. Medical image segmentation using topologically adaptable surfaces. *Lecture Notes in Computer Science*, 1997, 1205:23–22.
- [26] Xu C, Pham D L, Prince J L et al. Reconstruction of the central layer of the human cerebral cortex from MR images. In *Proc. 1st Int. Conf. Med. Im. Comput. Comp. Assist. Intervent.*, 1998:482–488.
- [27] McAuliffe M J, Eberly D, Fritsch D S et al. Scale-space boundary evolution initialized by cores. *Lecture Notes in Computer Science*, 1996, 1131:173–172.
- [28] Wang Y, Staib L H. Boundary finding with correspondence using statistical shape models. In *Proc. IEEE Conf. Comp. Vis. Patt. Rec.*, 1998: 338–345.
- [29] Davatzikos C, Vaillant M, Resnick S et al. A computerized method for morphological analysis of the corpus callosum. *J. Comp. Assist. Tom.*, 1996, 20: 88–97.
- [30] Ashton E A, Berg M J, Parker K J et al. Segmentation and feature extraction techniques, with applications to MRI head studies. *Mag. Res. Med.*, 1995, 33:670–677.
- [31] Ghanei A, Soltanian-Zadeh H, Windham J P. A 3D deformable surface model for segmentation of objects from volumetric data in medical images. *Computers in Biology and Medicine*, 1998, 28:239–253.
- [32] Szekely G, Kelemen A, Brechbuhler C, Gerig G. Segmentation of 2-D and 3-D objects from MRI volume data using constrained elastic deformations of flexible Fourier contour and surface models. *Med. Im. Anal.*, 1996, 1:19–34.
- [33] Vemuri B C, Guo Y, Leonard C M et al. Fast numerical algorithms for fitting multiresolution hybrid shape models to brain MRI. *Med. Im. Anal.*, 1997, 1:343–362.
- [34] Tek H, Kimia B B. Volumetric segmentation of medical images by three-dimensional bubbles. *Comp. Vis. Im. Understand.*, 1997, 65:246–258.
- [35] Arata L K, Dhawan A P, Broderick J P et al. Threedimensional anatomical model-based segmentation of MR brain images through principal axes registration. *IEEE T. Biomed. Eng.*, 1995., 42:1069–1078
- [36] Pien H H, Desai M, Shah J. Segmentation of MR images using curve evolution and prior information. *Int. J. Patt. Rec. Art. Intell.*, 1997, 11:1233–1245.
- [37] Joshi S C, Miller M I, Grenander U. On the geometry and shape of brain sub-manifolds. *Int. J. Patt. Rec. Art. Intell.*, 1997, 11:1317–1343.
- [38] Zhu Y, Yan H. Computerized tumor boundary detection using a hopfield neural network. *IEEE T. Med.*



- 
- Imag., 1997, 16:55–67.
- [39] Kamber M, Shinghal R, Collins D L, et al. Model-based 3-D segmentation of multiple sclerosis lesions in magnetic resonance brain images. *IEEE T. Med. Imag.*, 1995., 14:442–453
- [40] Clark M C, Hall L O, Goldgof D B et al. Automatic tumor segmentation using knowledge based techniques. *IEEE T. Med. Imag.*, 1998, 17 (2): 187-201.
- [41] Vaidynathan M, Clarke L P, Heidtman C et al. Normal brain volume measurements using multispectral MRI segmentation. *Magnetic Resonance Imaging*, 1997, 15 (1): 87-97.
- [42] Cocosco C A, Kollokian V, Kwan R K S et al. Brainweb: online interface to a 3D MRI simulated brain database [DB]. <http://www.bic.mni.mcgill.ca/brainweb>, 2006-06-12/2006-10-21.
- [43] Statistical Parametric Mapping. [www.fil.ion.ucl.ac.uk/spm/software/spm5/](http://www.fil.ion.ucl.ac.uk/spm/software/spm5/)
- [44] 谢逢, 罗立民, 田雪芹, 胡刚. 基于知识的人脑三维医学图象自动分析显示系统. *自动化学报*, 1997, 23(4): 496-501
- [45] 林亚忠. 基于GIBBS随机场模型的医学图像分割算法研究 (博士论文). 第一军医大学, 2004.
- [46] 聂生东, 章鲁, 顾顺德, 陈璞. 磁共振图像分割. *国外医学生物医学工程分册*, 1999, 22(6): 348-355.
- [47] Lundervold A, Storvik G. Segmentation of brain parenchyma and cerebrospinal fluid in multispectral magnetic resonance images. *IEEE T. Med. Imag.*, 1995, 14 (2): 339~349.
- [48] Kunt M. Edge detection: a tutorial review. *IEEE ICASSP*, 1982, 7:1172-1175.
- [49] Canny J. A computational approach to edge detection. *IEEE T. PAMI*, 1988, 8(6):679-698.
- [50] Staib L H, Duncan J S. Boundary finding with parametrically deformable models. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2002, 14(11):1061~1075.
- [51] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models. *International Journal of Computer Vision*, 1988, 1 (4): 321-331.
- [52] Luo S, Li R, Ourselin S. A new deformable model using dynamic gradient vector flow and adaptive balloon forces. In Lovell B. editor, *APRS Workshop on Digital Images Computing*, Brisbane, Australia, 2003:232-238.
- [53] Xu C, Prince J L. Snakes, shapes and gradient flow. *IEEE T. Image Process.*, 1998, 7(3): 359-369.
- [54] Jiang C Y, Zhang X H, Huang W J et al. Segmentation quantification of brain tumor. In *IEEE Symposium on Virtual Environments, Human-Computer Interfaces and Measurement Systems*. Boston, MA, USA, 2004: 61-66.
- [55] Ganser K A, Dickhaus H, Metzner R, et al. A deformable digital brain atlas system according to Talairach and Tournoux. *Medical Image Analysis*, 2004, 8: 3-22.
- [56] Shan Z Y, Yue G H, Liu J Z. Automated histogram-based brain segmentation in T1-weighted three-dimensional magnetic resonance head images. *NeuroImage*, 2002, 17: 1587-1598.
- [57] Jack C R, O'Brien P C, Rettman D W et al. FLAIR histogram segmentation for measurement of leukoaraiosis volume. *Journal of Magnetic Resonance Imaging*, 2001, 14: 668-676.
- [58] Xue J H, Zhang Y J, Lin X G. Threshold selection using cross-entropy and fuzzy divergence. *SPIE*, 1998, 3561:152-162.
- [59] Chang Y L, Li X B. Adaptive image region-growing. *IEEE T. Image Process.*, 1994, 3(6): 868-872.
- [60] Adams R, Bischof L. Seeded region growing. *IEEE T. PAMI*, 1994, 16(6):641-7.
- [61] Heinonen T, Dastidar P, Eskola H et al. Applicability of semi-automatic segmentation for volumetric analysis of brain lesions. *Journal of Medical Engineering and Technology*, 1998, 22:173-8.

- 
- [62] Tamez-Pena J G, Totterman S, Parker K. Unsupervised statistical segmentation of multispectral volumetric MR images. P of SPIE, 1999, 3661:300-311.
- [63] Pohle R, Toennies K D. Segmentation of medical images using adaptive region growing. Proceedings of SPIE, 2001, 4322:1337-1346.
- [64] Manousakas I N, Undrill P E, Cameron G et al. Split-and Merge segmentation of magnetic resonance medical images: performance evaluation and extension to three dimensions. Computers and Biomedical Research, 1998, 31:393-412.
- [65] Yung-Chieh L, Yu-Pao T, Yi-Ping H et al. Comparison between immersion-based and toboggan-based watershed image segmentation. IEEE T. Image Process., 2006, 15(3): 632-640.
- [66] Meyer F. An overview of morphological segmentation. International Journal of Pattern Recognition and Artificial Integence, 2001, 15(7):1089-1118.
- [67] Sijber F, Scheunders P, Verhoye M et al. Watershed based segmentation of 3D MR data for volume quantization. Journal of Magnetic Resonance Imaging, 1997, 15:679-688.
- [68] Bueno G, Musse O, Heitz F et al. 3D Watershed-based segmentation of internal structures within MR brain Images. Proceedings of SPIE, 2000, 3979:284-293.
- [69] Grau V, Mewes O, Alcaniz M et al. Improved watershed transform for medical image segmentation using prior information. IEEE T. Med. Imag., 2004, 23(4):447-459.
- [70] Geman D, Geman S. Stochastic relaxation, Gibbs distribution and Bayesian restoration of images. IEEE T. PAMI, 1984, 6(6):721-741.
- [71] Clifford P. Markov random fields in statistics. In Grimmett, G. R., Welsh, D. J. A. Disorder in Physical Systems: A Volume in Honour of John M. Hammersley. Oxford University Press, 1990.
- [72] Wells W M, Grimson W E L, Kinkins R et al. Adaptive segmentation of MRI data. IEEE T. Image Process., 1996, 15:429-442.
- [73] Held K, Kops E P, Krause B J et al. Markov random field segmentation of brain MR images. IEEE T. Med. Imag., 1997, 16(6):878-886.
- [74] Leemput K V. Probabilistic Brain Atlas Encoding Using Bayesian Inference. Medical Image Computing and Computer-Assisted Intervention, 2006, (1): 704-711.
- [75] Desco M, Gispert J D, Reig S et al. Statistical segmentation of multidimensional brain datasets. Proceedings of SPIE, 2001, 4322: 184-193.
- [76] Zhang Y, Brady M, Smith S. Segmentation of brain MR images through a hidden Markoc random field model and the expectation maximization algorithm. IEEE T. Med. Imag., 2001, 20(1):45-57.
- [77] Solomon J, Butman J A, Sood A. Segmentation of brain tumors in 4D MR images using the Hidden Markov model. Computer Methods and Programs in Biomedicine, 2006, 84:76-85.
- [78] 边肇祺, 张学工等. 模式识别 (第二版). 北京: 清华大学出版社, 2000.
- [79] Dunn J C. A Fuzzy Relative of The ISODATA Process and Its Use in Detecting Compact Well Separated Cluster. J. Cybernet, 1974, 3:32-57.
- [80] Bezdek J C. Pattern Recognition with Fuzzy Objective Function Algorithms. New York: Plenum Press, 1981.
- [81] Bezdek J C. A Convergence Theorem for the Fuzzy ISODATA Clustering Algorithm. IEEE T. PAMI, 1980, 1(2):1-8.
- [82] Rosenberger C, Chehdi K. Unsupervised Clustering Method with Optimal Estimation of the Number

- 
- of Clusters: Application to Image Segmentation. In Proceedings of 15th International Conference on Pattern Recognition. Barcelona Spain, 2000, 1:656-659
- [83] 王培珍, 陈维南. 基于模糊聚类 and 二维阈值的图像分割. 东南大学学报, 1998, 6:74-78
- [84] 丁震, 胡钟山, 杨静宇. 一种基于模糊聚类的图像分割方法. 计算机研究与发展, 1997, 7:536-541
- [85] Hui Yuan, Khorram S, Dai X L. Applications of Simulated Annealing Minimization Technique to Unsupervised Classification of Remotely Sensed Data. In: IGARSS'99 Proceedings of IEEE 1999 International Conference on Geoscience and Remote Sensing Symposium. Hamburg Germany. 1999, 1:134~136
- [86] Selim S Z, Alsultan K. A Simulated Annealing Algorithm for the Clustering Problem. Pattern Recognition, 1991, 24(10):1003-1008.
- [87] Chaudhuri D, Chaudhuri B B. A Novel Multiseed Nonhierarchical Data Clustering Technique. IEEE SMC, 1997, 27(5):871-877.
- [88] Postaire J G, Zhuang R D, Lecocq-Botte C. Cluster Analysis by Binary Morphology. IEEE T. PAMI, 1993, 15(2):170-180.
- [89] Pham D L. Spatial models for fuzzy clustering. Computer Vision and Image Understanding, 2001, 84: 285-97.
- [90] Ahmed M N, Yamany S M, Mohamed N et al. A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data. IEEE T. Med. Imag., 2002; 21(3):193-199.
- [91] Shen S, Sandham W, Granat M et al. MRI fuzzy segmentation of brain tissue using neighborhood attraction with neural-network optimization. IEEE Trans. on Information Technology in Biomedicine, 2005, 9(3): 459-67.
- [92] Boskovitz V, Guterman H. An adaptive Neuro-Fuzzy System for automatic Image Segmentation and Edge Detection. IEEE Trans. on Fuzzy Systems, 2002, 10(2): 247-262.
- [93] Masulli F, Schenone A. A fuzzy clustering based segmentation system as support to diagnosis in medical imaging. Artificial Intelligence in Medicine, 1999, (16):129-147.
- [94] Yang A M, Zhou Y M, Li X G et al. A Region-based Image Segmentation Method with Kernel FCM. Fuzzy Information and Engineering, 2007, 40:902-910.
- [95] Chen S, Zhang D Q. Robust Image Segmentation using FCM with Spatial Constraints based on New kernel-induced Distance Measure. IEEE Trans. System, Man, and Cybernetics-part B: Cybernetics, 2004, 34(4):1907-1916.
- [96] Zhang D, Chen C. A novel kernelized fuzzy c-means algorithm with application in medical image segmentation. Artificial Intelligence in Medicine, 2004, 32:37-50.
- [97] Buades A, Morel J M. A non-local algorithm for image denoising. In: Proc. of International Conference on Computer Vision and Pattern Recognition, 2005, pp. 60-65.
- [98] Wang J Z, Kong J, Lu Y H et al. A modified FCM algorithm for MRI brain image segmentation using both local and non-local spatial constraints. Computerized Medical Imaging and Graphics, 2008, 32: 685-698.
- [99] Hou Z, Qian W, Huang S et al. Regularized fuzzy cmeans method for brain tissue clustering. Pattern Recognition Letters, 2007, 28: 88-94.
- [100] Xue J H, Pizurica A, Philips W et al. An integrated method of adaptive enhancement for unsupervised segmentation of MRI brain images. Pattern Recognition Letters, 2003, 24:2549-60.

- 
- [101] Cai W, Chen S, Zhang D. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. *Pattern Recognition*, 2007, 40:825–38.
- [102] Karmakar G C, Dooley L. A Generic Fuzzy Rule Based Technique for Image Segmentation. In: *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing*. Salt Lake City, UT USA. 2001, 3:1577-1580.
- [103] Udupa J K, Wei L, Samarasekera S et al. Fuzzy Connectedness and Object Definition: Theory, Algorithms and Applications in Image Segmentation. *Graphical Models and Image Processing*, 1996, 58(3): 246-261.
- [104] Udupa J K, Saha P K, Lotufo R A. Fuzzy Connected Object Definition in Images with Respect to Co-Objects. In *Proc. Int'l Soc. For Optical Eng-(SPIE) Conf. Medical Imaging*, 1999, 3661:236-235.
- [105] Udupa J K, Punam K, Saha P K et al. Relative Fuzzy Connectedness and Object Definition: Theory, Algorithms, and Applications in Image segmentation. *IEEE Trans on Pattern Analysis and Machine Intelligence*. 2003, 24(11):1485-1500
- [106] Liew A W C, Leung S H, Lau W H. Fuzzy Image Clustering Incorporating Spatial Continuity. *IEE Proc-Vis. Image Signal Process*, 2000, 147(2):185-192
- [107] Liew A W C, Yan H. Adaptive Spatial Constraint fuzzy clustering for image segmentation. *IEEE International Fuzzy System Conference*, 2001, 801-804.
- [108] Liew A W, Yan H. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation. *IEEE T. Med. Imag.*, 2003, 22(9):1063-1075.
- [109] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm. *J. Royal Statist. Soc., Ser. B*, 1977, 39(1): 1-38.
- [110] Jiang C. The use of mixture models to detect effects of major genes on quantitative characteristics in a plant-breeding experiment. *Genetics*, 1994, 36(1):383-394.
- [111] Redner R, Walker H F. Mixture densities, maximum-likelihood estimation and the EM algorithm (review). *SIAM Rev.*, 1984, 26(2):195-237.
- [112] Little R, Rubin D. On jointly estimating parameters and missing data by maximizing the complete-data likelihood. *Am. Statist.*, 1983, 37(3): 218-200.
- [113] Kapur T, Grimson W E L, Kikinis R et al. Enhanced spatial priors for segmentation of magnetic resonance imagery. In: Wells, W M, Colchester, A C F, Delp S. (Eds.), *Medical Image Computing and Computer-Assisted Intervention—MICCAI '98*. Lecture Notes in Computer Science. Springer, Berlin, 1998:457–468.
- [114] Shattuck D W, Leahy R M. BrainSuite: An automated cortical surface identification tool. *Medical Image Analysis*, 2002, 6:129-142.
- [115] Hashimoto A, Kudo H. Ordered-subsets EM algorithm for image segmentation with application to brain MRI. In *IEEE Nuclear Science Symposium*, Lyon, France, 2000.
- [116] Osher S, Sethian J A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 1988, 79(1):12-49.
- [117] Osher S, Shu C W. High-order essentially non oscillatory schemes for Hamilton—Jacobi equation. *SIAM Journal of Numerical Analysis*, 1991, 28(4):907-922.
- [118] Osher S, Fedkiw R. *Level Set Methods and Dynamic Implicit Surfaces*. New York: Springer-Verlag, 2003.

- 
- [119] Giga Y. Surface Evolution Equation--A Level Set Method. Lipchitz Lecture Notes 44, Germany: University of Bonn, 2002: 56-85.
- [120] Richard T Y H, Osher S. Total Variation and Level Set Based Methods in Image Science. Los Angeles: University of Cambridge, 2005.
- [121] Malladi R, Sethian J A, Vemuri B. Shape modeling with front propagation: A level set approach. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, 17(2):158-174.
- [122] Caselles V, CaRe T, Coil T et al. A geometric model for active contours in image processing. Numeric Math, 1993, 66(1): 1-31.
- [123] Caselles V, Kimmel K, Sapim G. On geodesic active contour. International Journal of Computer Vision, 1997, 22(1): 61-79.
- [124] Mumford D, Shah J. Optimal approximation by piecewise smooth functions and associated variational problems. Communications on Pure and Applied Mathematics, 1989, 42(6): 577-685.
- [125] Chan T, Vese L. Active contours without edges. IEEE T. Image Process., 2001, 10(2): 266-277.
- [126] Vese L A, Chan T F. A multiphase level set framework for image segmentation using the Mumford and Shah model. International Journal of Computer Vision, 2002, 50(3): 271-293.
- [127] Zhao H K, Chan T, Merriman B et al. A variational level set approach to multiphase motion. International Journal of Computer Physics, 1996, 127(12): 179-195.
- [128] Baillard C. Barillot C, Bouthemy P. Robust Adaptive Segmentation of 3D Medical Images with Level Sets. Research Report, INRIA, Rennes, France Nov. 2000.
- [129] Zeng X, Staib L H, Schultz RT et al. Segmentation and measurement of the cortex from 3-D MR images using coupled-surfaces propagation. IEEE T. Med. Imag., 1999, 18(10): 927-937.
- [130] Yang J, Duncan J S. 3D Image segmentation of deformable objects with shapeappearance joint prior models. MICCAI, Montreal, Canada, 2003: 573-580.
- [131] Goldenberg R, Kimmel R, Rivlin E et al. Cortex segmentation - a fast variational geometric approach. IEEE T. Med. Imag., 2001, 20(10): 1467-1475
- [132] Ballester M A G, Zisserman A, Brady M. Segmentation and measurement of brain structures in MRI including confidence bounds. Medical Image Analysis, 2000, 4: 189-200.
- [133] Shen D, Herskovits E H, Davatzikos C. An adaptive-focus statistical shape model for segmentation and shape modeling of 3-D brain structures. IEEE T. Med. Imag., 2001, 20: 257- 270.
- [134] Suri J S. Two-dimensional fast magnetic resonance brain segmentation. IEEE Engineering in Medicine and Biology Magazine, 2001, 20(4): 84-95.
- [135] Christensen G E, Hoshi S C, Miller M I. Volumetric Transformation of Brain Anatomy. IEEE Trans. Med. Imag., 1997, 16:864-877.
- [136] Amatur S C, Piraino D, Takefuji Y. Optimization neural networks for the segmentation of magnetic resonance images. IEEE T. Med. Imag., 1992, 11 (2): 215-220.
- [137] Cohen L D, Cohen I. Finite-element methods for active contour models and balloons for 2D and 3D images, IEEE Trans.on PAMI, 1993, 15(11):1131-1147.
- [138] McInerney T, Terzopoulos D. T-Snakes: topology adaptive snakes, Medical Image Analysis, 2000, 4:73-91.
- [139] Xu C Y, Prince J.L. Gradient vector flow: A new external force for snakes, IEEE Proc. Conf. On

- 
- Comp.Vis. Patt. Recog, 1997: 66-71.
- [140] Caselles V, Kimmel R, Sapiro G. Geodesic active contours. *International Journal of Computer Vision*, 1997, 22(1): 61-79.
- [141] Yezzi A, Kichenassamy S, Kumar A et al. A geometric snake model for segmentation of medical imagery. *IEEE T. Med. Imag.*, 1997, 16(2): 199-209.
- [142] Siddiqi K, Lauriere Y B, Tannenbaum A et al. Area and length minimizing flows for shape segmentation. *IEEE T. Image Process.*, 1998, 7: 433-443.
- [143] Lobregt S, Viergeber M A. A Discrete Dynamic Contour Model. *IEEE T. Med. Imag.*, 1995, 14(1): 12-24.
- [144] 陈明. 医学图像融合中配准方法的研究. 学位论文, 第一军医大学, 1997年7月:23-30.
- [145] Ranganath S. Contour Extraction from Cardiac MRI Studies Using Snakes. *IEEE T. Med. Imag.*, 1995, 14(2): 328-338.
- [146] Xu C Y, Prince J L. Generalized Gradient Vector Flow External Forces for Active Contours. *Signal Processing*, 1998, 71 (2):121-139.
- [147] MacDonald D, Avis D, Evans A.C. Proximity Constraints in Deformable Models for Cortical Surface Identification. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 1998:650-659.
- [148] MacDonald D, Kabani N, Avis D et al. Automated 3D Extraction of Inner and outer Surfaces of Cerebral Cortex from MRI. *NeuroImage*, 2000, 12(3):340-356.
- [149] Durikovic R, Kaneda K, Yamashita H. Dynamic Contour: A Texture Approach and Contour operations. *The Visual Computer*, 1995, 11: 277-289.
- [150] Sethian J A. A Fast Marching Level Set Method for Monotonically Advancing Fronts. *Proceedings of the National Academy of Science*, 1996, 4:1591-1595.
- [151] Suri J S, Liu K, Laxminarayan S N et al. Shape Recovery Algorithms Using Level Set in 2D/3D Medical Imagery: A State of-the-Art Review. *IEEE Trans. on Information Technology in Biomedicine*, 2002, 6(1): 8-28.
- [152] Suri J S. Computer Vision, pattern Recognition, and Image Processing in Left Ventricle Segmentation: Last 50 Years. *J. Pattern Anal. Applicat.*, 2000, 3:209-242.
- [153] Leventon M E, Grimson W, Eric L et al. Statistical Shape Influence in Geodesic Active Contours. *Proceedings of Computer Vision Pattern Recognition (CVPR)*, 2000, 1:316-323.
- [154] Kichenassamy S, Kumar A, Olver P et al. Conformal Curvatures Flows: From Phase Transitions to Active Vision. *Arch. Rational Meth. Anal.*, 1996, 134 (3): 275-301.
- [155] Siddiqi K, Tannenbaum A, Zueker S W. Hyperbolic Smoothing of Shapes. In *Proc. 6th Int. Conf. Comput. Vision (ICCV)*, Bombay, India, 1:215-221, 1998.
- [156] Malladi R, Sethian J A. An  $O(N \log N)$  Algorithm for Shape Modeling. *Appl. Math. Proc. Nat. Academy Sci.*, 1996, 93 (18):9389-9392.
- [157] Sethian J A. *Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics. Computer Vision and Materials Science.* Cambridge University Press, 1999.
- [158] Sussman M, Smeraka P, Osher S. A Level Set Approach for Computing Solution to Incompressible Two-Phase Flow. *J. Comput. Phys.*, 1994, 114:146-159.

- 
- [159] Zhang Y J, Gerbrands J. Objective and quantitative segmentation evaluation and comparison. *Signal Processing*, 1994, 39(1-2):43-54.
- [160] Hoover A, Jean-Baptiste G, Jiang X et al. An experimental comparison of range image segmentation algorithms. *IEEE T. PAMI*, 1996, 18(7): 673-689.
- [161] Sonka M, Hlavac V, Boyle R. *Image Processing, Analysis and Machine Vision (Second Edition)*. USA: Brooks/Cole, Thomson Asia PteLed, 1999:123-133.
- [162] Yezzi A, Tsai A, Willsky A. A Statistical Approach to snakes for Bimodal and Trimodal Imagery. In *Proceedings of IEEE International Conference on Computer Vision*. Kerkyra, Greece, 1999: 898-903.
- [163] David W, David J R. Maximum likelihood estimates of the parameters of a mixture of two regression lines. *Communications in Statistics*, 1974, 3(10):995-1005.
- [164] Frank R J, Grabowski T J, Damasio H. Voxelwise percentage tissue segmentation of human brain MRI. *Soc. Neurosci. Abstr.*, 1995, 21: 694-699.
- [165] Savitzky A, Golay M J E. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, 1964, 36:1627-1639.
- [166] Aitnouri E, Wang S R, Ziou D et al. Estimation of Multi-Modal Histogram's PDF using a Mixture Model. *Journal of Neural, Parallel & Scientific Computation*, 1999, 7(1):103-118.
- [167] Kulkarni S, Chatterji B N. Accurate shape modeling with front propagating using adaptive level sets. *Pattern Recognition Letters*, 2002, 23:1559-1568.
- [168] Abd-Elmageed W, Smith C E. Mixture models for dynamic statistical pressure snakes. In *IEEE International Conference on Pattern Recognition*. Quebec, Canada, 2002:721-724.
- [169] Zhou J, Chan K L, Chong V F H et al. Extraction of brain tumor from MR images using one-class support vector machine. In *Proc. of IEEE Engineering in Medicine and Biology Conference (EMBC)*, Shanghai, China, pp. 6411– 6414, 2005.
- [170] Autti T, Raininko R, Vanhanen S L et al. MRI of the normal brain from early childhood to middle age. *Neuroradiology*, 1994, 36(8): 644–648.
- [171] Rusinek H, De Leon M J, and George A E et al., Alzheimer disease: measuring loss of cerebral gray matter with MR imaging. *Radiology*, 1991, 178:109–114.
- [172] Pham D L, Prince J L. *An adaptive fuzzy segmentation algorithm for three-dimensional magnetic resonance images*. *Information Processing in Medical Imaging*, Springer-Verlag, London, 1999: 140-153.
- [173] Awate S P, Zhang H, Gee J C. A fuzzy nonparametric segmentation framework for DTI and MRI analysis: with applications to DTI-tract extraction. *IEEE T. Med. Imag.*, 2007, 26(11): 1525-1536.
- [174] Leemput K V, Maes F, Vandermeulen Det al. Automated model-based tissue classification of MR images of the brain. *IEEE T. Med. Imag.*, 1999, 18(10): 897-908.
- [175] Leemput K V, Maes F, Vandermeulen Det al. A unifying framework for partial volume segmentation of brain MR images. *IEEE T. Med. Imag.*, 2003, 22(1): 105-119.
- [176] Cho W H, Park S C, Lee M E et al. Segmentation for medical image using a statistical initial process and a level set method. *Medical Imaging and Augmented Reality*, Springer Berlin/ Heidelberg, pp. 380-388, 2006.
- [177] Poon C S, Brain M. Image segmentation by a deformable contour model incorporating region

- 
- analysis. *Physics in Medicine and Biology*, 1997, 42(9): 1833-1841.
- [178] Suri J S. White Matter/Gray Matter boundary segmentation using geometric snakes: a fuzzy deformable model. In Proc. of Second International Conference on Advances in Pattern Recognition (ICAPR), Rio de Janeiro, Brazil, 2001:331-338.
- [179] Bezdek J C, Hall L O, Clarke L P. Review of MR image segmentation techniques using pattern recognition, *Medical Physics*, 1993, 20(4):1033-1048.
- [180] Internet Brain Segmentation Repository. <http://www.cms.mgh.harvard.edu/ibsr/>.
- [181] Zijdenbos A P, Dawant B M, Margolin R A et al. Morphometric analysis of white matter lesions in MR images: method and validation, *IEEE T. Med. Imag.*, 1994, 13(4): 716-724,.
- [182] BrainSuite. <http://www.loni.ucla.edu/Software/BrainSuite/>.
- [183] Chaudhury K N, Ramakrishnan K R. Stability and convergence of the level set method in computer vision. *Pattern Recognition Letters*, 2007, 28(7): 884-893.
- [184] Amadiou O, Debreuve E, Barlaud M et al. Inward and outward curve evolution using level set method. In Proc. of IEEE International Conference in Image Processing (ICIP), KOBE, JAPAN, 1999, 3:188-192.
- [185] Yezzi Y, Tsai A, Willsky A. Binary and ternary flows for image segmentation. In Proc. of IEEE International Conference in Image Processing (ICIP), KOBE, JAPAN, 1999, 2: 1-5.
- [186] Jalba A C, Wilkinson M H F, Roerdink J B T M. CPM: a deformable model for shape recovery and segmentation based on charged particles, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2004, 26(10): 1320-1335.
- [187] Saini S. Radiologic measurement of tumor size in clinical trials: Past, present, and future. *American Roentgen Ray Society*, 2001, 176(2): 333-334.
- [188] Auttib T, Raininko R, Vanhanen S Let al. MRI of the normal brain from early children to middle age. *Neuroradiology*, 1994. 36, 644-648.
- [189] Xue H, Ruan S, Moretti B et al. Fuzzy modeling of knowledge for MRI brain structure segmentation. In: Proc. of International Conference on Image Processing (ICIP2000), 2000:617-620.
- [190] Koepfler G, Lopez C, Morel J M A multiscale algorithm for image segmentation by variational method. *SIAM Journal of Numerical Analysis*, 1994, 31(1), 282-299.
- [191] Chan T F, Esedoglu S. A multiscale algorithm for Mumford-Shah image segmentation. UCLA Tech. Rep. CAM03-77, 2003.
- [192] Chan T, Vese L. Image segmentation using level sets and piecewise constant Mumford-Shah model. UCLA Tech. Rep. CAM00-14, 2000.
- [193] Gibou F, Fedkiw R. A fast hybrid k-means level set algorithm for segmentation. In Proc. of International Conference on Statistics and Mathematics, 2005: 281-291.
- [194] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1990, 12 (1): 629-639.
- [195] Song B, Chan T. A fast algorithm for level set based optimization. UCLA CAM Report 02-68, 2002.
- [196] Lie J, Lysaker M, Tai X C. A binary Level set method and some applications to Mumford-Shah Image Segmentation. *IEEE T. Image Process.*, 2006, 15(5):1171-1181.
- [197] Lysaker M, Tai X C. A variant of the level set method and applications to image segmentation. *Mathematics of Computation*, 2006, 75(25): 1155-1174.



- 
- [198] Shi Y G, Karl W C. A fast level set method without solving PDES. In: Proc. of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP 2005), 2005: 97-100.
- [199] Esedoglu S, Tsai R. Threshold dynamics for the piecewise constant Mumford-Shah functional. UCLA. CAM Report 04-63, 2004.
- [200] Smereka P. Semi-implicit level set methods for curvature and surface diffusion motion. Journal of Scientific Computing, 2003, 19(1-3): 439-456.
- [201] Samson C, Blanc-Féraud L, Aubert G et al. A level set model for image classification. International Journal of Computer Vision, 2000, 40(3):187–197.
- [202] Paragios N, Deriche R. Coupled geodesic active contour regions for image segmentation: A level set approach. In: Proc. of 6th European Conference on Computer Vision, 2000, 2: 224-240.
- [203] Brox T, Weickert J. Level set segmentation with multiple regions. IEEE T. Image Process., 2006, 15(10), 3213-3218.
- [204] Brox T, Weickert J. Level set based image segmentation with multiple regions. Pattern Recognition, Springer LNCS, 2004, 3175: 415-213.
- [205] Mansouri A, Mitiche A, Feghali U. Spatio-temporal motion segmentation via level sets partial differential equations. In: IEEE Southwest Symposium on Image Analysis and Interpretation, 2002: 243-247.
- [206] Catte F, Lions P L, Morel J M et al. Image selective smoothing and edge detection by nonlinear diffusion, SIAM Journal on Numerical Analysis, 1992, 29 (1): 1895–1909.
- [207] Weickert J, Romeny B, Viergever M. Efficient and reliable scheme for nonlinear diffusion filtering. IEEE T. Image Process., 1998, 7(3): 398–410.
- [208] You Y L, Xu W Y, Tannenbaum A et al. Behavioral analysis of anisotropic diffusion in image processing. IEEE on PAMI, 1990, 12:629-639.
- [209] Dou W, Ren Y, Wu Q et al. Fuzzy kappa for the agreement measure of fuzzy classifications. Neurocomputing, 2007, 70:726–734.
- [210] Lukin A. A multiresolution approach for improving quality of image denoising algorithm. In: Proc. of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP-2006), 2006, 2: 857-860.
- [211] Buades A, Coll B, Morel J M. On image denoising methods. CMLA Tech. Rep. 2004-15, 2004.

---

## 攻读博士学位期间发表学术论文情况

1. 陈志彬, 邱天爽, Su Ruan. 基于直方图拟合和的 MRI 图像水平集分割.中国生物医学工程学报. 2008 (1).
2. 陈志彬, 邱天爽, Su Ruan. 一种基于 FCM 和 Level Set 的 MRI 医学图像分割方法. 电子学报, 2008 (9).
3. CHEN ZhiBin, QIU TianShuang, Su Ruan. A brain tissue segmentation approach integrating fuzzy information into level set method. IEEE International Conference on Automation and Logistics 2008, Qingdao, China.
4. CHEN ZhiBin, QIU TianShuang, Su Ruan. Fuzzy Adaptive Level Set Algorithm for Brain Tissue Segmentation. IEEE International Conference on Signal Processing 2008, Beijing, China.
5. CHEN ZhiBin, QIU TianShuang, Su Ruan. A Multiclass Image Segmentation Using Level Set Method. Submitted to Pattern Recognition Letter.
6. CHEN ZhiBin, QIU TianShuang, Su Ruan. A Segmentation Algorithm for Brain MR Images using Fuzzy Model and Level Sets. Submitted to International Journal of Innovative Computing, Information and Control.

---

## 致 谢

真诚地感谢我的导师邱天爽教授，感谢他几年来的教诲和指导。他严谨的学风，真诚的态度，和蔼的笑容给我留下了深刻的印象。他严于律己、宽以待人的胸怀令人钦佩。感谢他几年来对我学业上的指导和帮助，对我生活上的关怀与理解。

感谢我的导师 Su RUAN 教授，感谢她几年来的耐心与帮助，感谢她不辞辛苦，一次次为我修改论文，感谢她在法期间给我生活上的无微不至的关怀和帮助。真诚地感谢她，祝福她。

感谢大连理工大学的殷福亮教授、郭成安教授、毛德祥教授，感谢他们教授给我的专业知识，感谢给予我的生活和学业上的帮助。也感谢电信学院为我提供帮助和便利的所有老师们。

感谢实验室里所有的老师以及师兄师姐师弟和师妹们，特别是张旭秀老师、孙永梅老师，感谢他们为我树立的良好榜样；感谢朱勇老师、郭冬梅老师、李森老师，唐洪老师、毕峰老师、郭莹师姐给予我的启发和帮助；感谢李小兵老师、林相波老师，与他（她）们的讨论使我开阔了思路。

感谢我的父母，感谢他们一直以来给予的关注，感谢他们养育了我，培养了我。感谢我的岳父母，感谢他们对我以及我的妻子关怀和帮助，感谢他们多年来照顾我的女儿。

感谢我的妻子，感谢她的理解和支持，感谢她对家庭、孩子和我的照顾。感谢我的女儿，感谢她的勤奋和努力，感谢她带给家庭的荣誉和欢乐。

---

## Résumé

L'objectif de la thèse est de développer une méthode automatique pour segmenter les tissus cérébraux (la matière grise, la matière blanche et le liquide céphalo-rachidien) à partir des images IRM, fournissant ainsi des mesures quantitatives et précises du cerveau. Dans cette thèse, nous avons développé trois modèles déformables non-paramétriques en intégrant l'information statistique et l'information floue des images pour segmenter le cerveau en différents types de tissus. Nous présentons d'abord une méthode basée sur l'analyse de l'histogramme. La répartition de l'intensité des images est modélisée par le modèle de mélanges gaussiens (MMG). Les paramètres du MMG sont estimés par l'algorithme «Expectation Maximization». Ensuite, ils sont utilisés pour guider l'évolution des courbes pour atteindre la segmentation des tissus cérébraux. Nous proposons ensuite une amélioration d'un algorithme basé sur les contours actifs orientés région avec la contrainte géométrique. Grâce à la nouvelle expression proposée, il permet de résoudre le problème de stabilité sous-jacente associé à l'algorithme d'origine, et réalise une convergence rapide. Enfin, nous présentons une segmentation de multi-classes en intégrant une segmentation floue dans la méthode level sets. Elle utilise un ensemble d'équations différentielles ordinaires. Chacune d'elles représente une classe à segmenter. Cette approche réduit la complexité de calcul par rapport à l'algorithme multi-phase existant, permettant donc d'accélérer la vitesse de convergence. Toutes les méthodes ont été évaluées avec des images IRM simulées et réelles. Les analyses quantitatives sont données. Les résultats sont très encourageants.

Mots clés : Segmentation, level sets, Multi-classe, modèle déformable, IRM cérébrale, Logique Floue.

## Abstract

The research goal of this thesis is to develop an automatic segmentation method to segment brain MRI images into different tissues (gray matter, white matter, and cerebrospinal fluid), providing quantitative and precise brain measurements. In this dissertation, we have developed three non-parametric deformable models integrating statistical information and fuzzy information of images to segment the brain into different tissue types from multi types of MRI images. We firstly present a histogram analysis based algorithm, where the intensity distribution of the MRI images is modeled via the mixture Gaussian model (MGM). The parameters of components in MGM are estimated via the Expectation Maximization (EM) algorithm. Then the estimated parameters are used to guide the evolution of the level set curves to achieve the brain tissue segmentation. We then propose an improved algorithm to region-based geometric active contour. Thanks to the new regional term, the new algorithm solves the underlying stability problem associated with the original algorithm, and achieves convergence with less iteration number compared with the original algorithm. Finally, we present a multiclass algorithm by integrating fuzzy segmentation with the level set methods. The algorithm uses a set of ordinary differential equations; each of them represents a class to be segmented. The multiclass algorithm reduces the computational complexity compared with the existing multiphase algorithm, so speeds up the convergence rate. All algorithms are evaluated with simulated and real MRI images, and quantitative analyses are provided. The results are very encouraging.

Keywords : Segmentation, level sets, Multi-class, deformable models, brain IRM, Fuzzy logic.