

# 자기공명영상의 비지도 분할을 위한 통계적 모델기반 적응적 방법

김 태 우<sup>†</sup>

## 요 약

본 논문은 MR 영상의 비지도 분할을 위하여 MDL 원리를 이용한 통계적 모델기반의 적응적 방법을 제안한다. 이 방법에서 조직 영역을 MRF로 모델링함으로써 잡음에 대응하고, 창으로 정의되는 국소영역 내의 밝기값을 가우스 혼합으로 모델링함으로써 영상의 비균일성을 흡수한다. 분할 알고리즘은 ICM을 기반으로 하며 MAP를 근사적으로 추정하고, 모델 파라미터를 국소영역으로부터 구한다. 파라미터 추정과 분할을 위한 창의 크기는 MDL 원리를 이용하여 영상으로부터 추정한다. 실험에서 제안한 방법이 특히 비균일성이 있는 MR 영상의 분할에서 국소영역의 영상특성을 잘 반영하였으며, 기존의 방법보다 더 좋은 결과를 보여주었다.

## A Statistically Model-Based Adaptive Technique to Unsupervised Segmentation of MR Images

Tae-Woo Kim<sup>†</sup>

## ABSTRACT

We present a novel statistically adaptive method using the Minimum Description Length(MDL) principle for unsupervised segmentation of magnetic resonance(MR) images. In the method, Markov random field(MRF) modeling of tissue region accounts for random noise. Intensity measurements on the local region defined by a window are modeled by a finite Gaussian mixture, which accounts for image inhomogeneities. The segmentation algorithm is based on an iterative conditional modes(ICM) algorithm, approximately finds maximum *a posteriori*(MAP) estimation, and estimates model parameters on the local region. The size of the window for parameter estimation and segmentation is estimated from the image using the MDL principle. In the experiments, the technique well reflected image characteristic of the local region and showed better results than conventional methods in segmentation of MR images with inhomogeneities, especially.

### 1. 서 론

인간 뇌에 대한 MR 영상의 분할(segmentation)은 관심영역(ROI : region of interest)들의 볼륨(volume) 해석과 가지화와 같은 영상 분석에서 중요한 과정이다. 뇌

영상에서 관심영역은 백질(WM : white matter), 회백질(GM : gray matter), 뇌척수액(CSF : cerebrospinal fluid) 등 흔히 세 가지 군으로 분류될 수 있다. 백질과 회백질로 구성되는 뇌영역의 정확한 분할기술은 뇌조직의 여러 가지 병리학적 상태의 검출, 방사선 치료 수술 및 계획, 외과수술 계획 및 시뮬레이션(simulation), 진단 및 병소 탐색을 위한 뇌영역의 3차원 가시

<sup>†</sup> 정 회 원 : 삼성종합기술원 의료전자팀 선임연구원  
논문접수 : 1999년 9월 11일, 심사완료 : 1999년 12월 22일


화 등을 용이하게 한다. 백질과 회백질 볼륨의 정량화는 백질과 회백질의 병리가 몇몇 신경정신 질환에서 나타나는 뇌척수액 공간의 확대로 기인한 뇌조직 소실에 관여함을 밝히는 데 특별히 의미가 있다. 정상인에 대한 백질 대 회백질 볼륨의 비(比)의 정량적 분석은 다발성 경화증(MS : multiple sclerosis), 알츠하이머병(AD : Alzheimer's disease) 등과 같은 질병의 병리생리학적 연구에도 기여하는 것으로 알려져 있다. 예를 들어, 알츠하이머병의 특징적인 변화는 피질하의 대뇌변연계의 회백질 구조에서 뿐 아니라 신경피질의 회백질에서도 전형적으로 발견되지만, 병리학적 데이터는 백질이 이 질병에 관여되어 있음을 보여준다. 또한, 백질과 회백질 영역의 정위법적(stereotactic) 구별은 양전자방출단층촬영술(PET : positron emission tomography)에 의하여 측정되는 포도당 대사 또는 특정 리간드(ligand)의 흡수와 같은 기능적 활성화(functional activity)를 평가할 수 있는 구조적 템플릿(template)으로도 의미가 있다[1-3].

최근 수년 동안 디지털 영상처리 기술은 영상의 자동분할 분야에서 상당한 진보를 해 왔다. MR 영상 분할에서 현재의 분할법은 고전적 방법, 통계적 방법, 퍼지(fuzzy)방법, 신경망(neural network)방법 등으로 분류될 수 있다. 이 중 통계적 방법은 MR 영상 분할을 위하여 많은 연구자들이 폭넓게 적용하여 왔으며, 많은 경우에 있어서 성공적인 결과를 보여 주었다[4-15].

대부분의 통계적 방법은 최종 분할을 위하여 ML(maximum likelihood) 추정을 사용하며, 파라미터(parameter)의 ML 추정을 계산하기 위하여 EM(expectation-maximization) 알고리즘(algorithm)을 사용한다. EM 기반형 통계적 방법은 혼합 추정(mixture estimation)과 클러스터링(clustering)을 반복한다. 클래스(class)들을 평탄하고 부분적으로 연속적인 영역들로 모델링하는 MRF(Markov random field)는 잡음의 민감성을 감소시키며, 영역들의 부분적 연속성을 유지하도록 하는데 사용된다[16]. 이러한 통계적 분할방법은 크게 전역적 방법과 국소적 방법의 두 범주로 나뉘어질 수 있다. 창으로 정의되는 영역을 분할하는 국소적 방법인 적응적 방법의 혼합 추정은 영상에 비균일성(inhomogeneities)이 존재할 때 전역적 방법보다 더 좋은 결과를 나타낸다[17].

보고된 적응적 방법[17-21]들은 혼합추정과 분할에 사용되는 국소영역(local region)인 창(window)에 속한

클래스의 수를 상수  $K$ 로 가정했다. 그러나 많은 경우 영상의 국소영역에서  $K$ 개 보다 적은 수의 클래스가 존재할 수 있으며, 파라미터 추정과 분할을 위한 창의 크기는 경험적으로 결정되었다. 예를 들면, (그림 1)에서 창에 속하는 클래스의 수를  $K=2$ 로 가정하여 설정하지만, 실제로는 창  $A$ 에서는 2개 클래스, 창  $B$ 에서는 1개 클래스가 존재한다. 이 가정은 혼합추정과 분할 과정에서 오차를 발생시키는 한 요인이 되었다.



(그림 1) 국소영역 내의 클래스—A : 2개의 클래스, B : 1개의 클래스

따라서 본 논문에서는 비균일성이 존재하는 MR 영상의 비지도 분할(unsupervised segmentation)을 위한 새로운 통계적 방법을 제안한다. 이 방법은 영상으로부터 MDL(minimum description length)원리[25, 26]를 이용하여 혼합추정을 위한 창의 크기를 추정함으로써 위의 가정을 만족시키도록 한 것이다. 제안한 방법의 분할과정은 각 국소영역에 대하여 ICM(iterative conditional modes)알고리즘[25, 26]을 기반으로 하며 근사적으로 MAP 추정[16]을 구하며, 잡음의 민감성에 대응하기 위하여 클래스를 MRF로 모델링한다. 창의 크기를 추정함으로써 비균일성이 존재하는 영상의 분할에서 혼합추정과 분할 결과를 향상시킨다.

## 2. 통계적 모델

본 논문의 비지도 적응적 분할법은 반복적 EM 알고리즘[27]과 MAP 알고리즘을 기반으로 한다. 영상

픽셀(pixel)들의 유한적 집합을  $S$ 라 하고, 관찰되지 않는 순수 영상을 모델링하기 위한 랜덤 필드(random field)를  $x=\{x_s | s \in S\}$ 라 하고, 관찰되는 영상을 모델링하기 위한 랜덤 필드를  $y=\{y_s | s \in S\}$ 라 하자.  $x_s$ 는 클래스로 구성된 유한집합  $\mathcal{Q}=\{\omega_1, \dots, \omega_K\}$ 의 원소이고,  $K$ 는 정의된 클래스의 수이며,  $y_s \in R$ 이다. 영상분할 문제는 랜덤필드의 관찰되는 영상으로부터 보이지 않는 순수영상을 추정하는 문제로 볼 수 있다.

후치(a posteriori) 확률밀도함수는 Bayes 정리[30]에 의하여 다음과 같이 표현되며,

$$p(x | y) \propto p(y | x)p(x). \tag{1}$$

여기서,  $p(x)$ 는 전치모델(prior model)로서 분할과정의 전치(a priori) 밀도이며,  $p(y|x)$ 는 측정모델(measurement model)로서 영역의 분포함수가 주어졌을 때 관찰되는 영상의 조건밀도를 나타낸다.

전치모델은 MRF로 모델링하며 픽셀의 밝기값이 부분적으로 연속이라고 가정한다. 영상에서 이웃시스템(neighborhood system)을  $N=\{N_i, i \in S\}$ 라고 정의할 때, 모든  $x \in \mathcal{Q}$ ,  $p(x) > 0$ 에 대하여 식 (2)를 만족하면 랜덤 변수  $x$ 는 MRF라고 한다.

$$p(x_i | x_j, j \neq i, j \in S) = p(x_i | x_j, j \in N_i) \tag{2}$$

여기서  $N_i$ 는 픽셀  $i$ 를 제외한 이웃 픽셀을 나타낸다. 영역 처리는 MRF에 의하여 모델링했을 때,  $x$ 의 밀도는 Hammersley-Clifford 정리[31]에 의하여 다음과 같은 Gibbs density[16]로 표현된다.

$$p(x) = \frac{1}{Z} \exp \left\{ - \sum_{C \in \mathcal{C}} V_C(x) \right\}, \tag{3}$$

여기서,  $Z$ 는 정규화 상수이며, 합산은 모든 클릭(clique)  $C$ 에 대하여 이루어진다. 클릭은 서로 이웃하는 픽셀의 집합이며, 클릭 포텐셜(potential)  $V_C$ 는 클릭  $C$ 에 속하는 픽셀들에 따라 달라진다. 본 논문의 모델은 2개의 픽셀로 구성된 클릭으로서 포텐셜은 0이 아니라고 가정한다. 클릭 포텐셜은 다음과 같이 정의된다.

$$V_C(x) = \begin{cases} -\alpha, & \text{if } x_s = x_q \text{ and } s, q \in C \\ +\alpha, & \text{if } x_s \neq x_q \text{ and } s, q \in C \end{cases} \tag{4}$$

파라미터  $\alpha$ 는 양수이며, 이웃하는 두 픽셀은 서로 다른 클래스에 속하기 보다는 같은 클래스에 속할 확률

이 높음을 나타낸다. 전치모델을 MRF로 모델링함으로써 영상에 존재하는 잡음에 대응할 수 있게 된다.

조건 밀도는 식 (5)와 같이 분포 파라미터  $\beta$ 를 가진 백색 가우스 프로세스(process)로 모델링된다. 여기서  $\beta = (\beta_1, \dots, \beta_K)$ 이고,  $\beta_k = (\mu_k, \Gamma_k)$ 이며,  $\mu_k$ 와  $\Gamma_k$ 는 각각 클래스  $k$ 의 평균과 분산이다. 창으로 정의되는 각 국소영역  $W$ 는  $s$ 에 대하여 완만히 변하는 함수인 분포 파라미터  $\beta$ 에 의하여 특징지어진다. 각 창마다  $\beta$ 가 다른 것은 생물학적 변화와 비균일성이 존재함을 나타낸다. 식 (3)과 (5)를 식 (1)에 치환하고 MRF [16]와 ICM[25, 26]을 적용하면 창  $W$ 에서  $s$ 의 후치 확률밀도(posterior probability density)는 식 (6)으로 표현된다. Besag[25]이 제안한 ICM은 에너지 함수의 국소적 최소값에 반복적으로 수렴해 가는 방법이며, SA(simulated annealing)에서 제어 파라미터인 온도를 순간적으로 정지시키는 것과 같다. 초기값을 잘 정하면 ICM 프로시저(procedure)는 상당히 좋은 분할 결과를 보여준다[20].

$$p(y | x) = \prod_{k=1}^K p_k(y | \beta_k) \tag{5}$$

$$= \prod_{k=1}^K \frac{1}{\sqrt{2\pi\Gamma_k}} \exp \left\{ -\frac{1}{2\Gamma_k} (y - \mu_k)^2 \right\}$$

$$p_k(x | y) \propto \exp \left\{ -\frac{1}{2\Gamma_k} (y - \mu_k)^2 - \sum_C V_C(x) \right\} \tag{6}$$

국소영역  $W$ 의 각 픽셀에서 후치분포(posteriori distribution) 함수는 식 (6)에 의하여 모든 클래스  $k = 1, \dots, K$ 에 대하여 계산된다.

### 3. 혼합추정 및 분할 알고리즘

분포 파라미터  $\beta$ 는 국소영역인 창  $W$ 로부터 추정된다. 기존의 적응적 방법에서 창  $W$ 에는  $K$ 개의 클래스가 존재한다는 가정과 한 사이클(cycle) 동안  $Q = \sqrt{\text{Card}(W)}$ 가 상수라는 가정을 만족시키기 위하여, 본 논문은 창의 크기  $Q$ 를 주어진 영상으로부터 추정한다. 한번의 반복횟수(iteration)는 하나의 창 내의 모든 픽셀에 대한 연산의 완료를 의미하며, 반복횟수의 한번의 사이클은 영상에서 모든 창에 대한 연산의 완료를 의미한다. MDL 원리[22-24]를 이용하여 창의 크기  $Q$ 는 영상으로부터 추정되며 각 픽셀마다 다른 값을 가질 수 있다. 국소영역인 창  $W$ 에서 클러스터의 개수

는 MDL 원리에 의하여 다음과 같이 결정된다.


$$\hat{k}_W = \arg \min_{1 \leq k \leq K} MDL_{W_i}(k) \quad (7)$$

$$MDL_{W_i}(k) = -\ln p(\hat{x} | y, \hat{\beta}) + tD \ln L \quad (8)$$

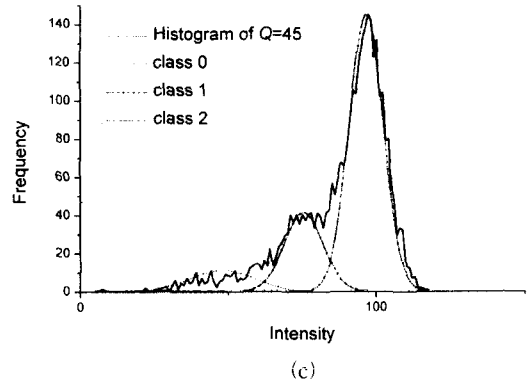
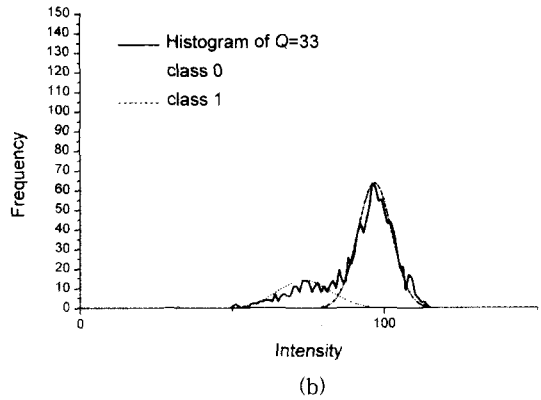
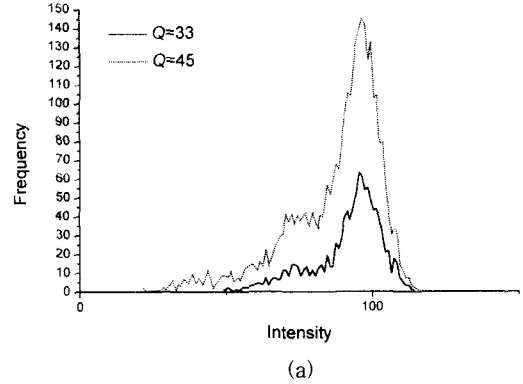
여기서  $Q_i = \sqrt{Card(W_i)} = (2i+1)$ 이고,  $i=0, \dots, M$ 이며,  $M$ 은 허용되는 창 최대크기이다. 또  $D$ 는 조정 가능한 파라미터의 수,  $L$ 은  $W$ 의 픽셀의 총수,  $t$ 는 상수를 나타낸다. 이때 모델 파라미터 추정을 위한 최적 창의 크기  $W^*$ 는 식 (9)에 의하여 결정된다.

$$W^* = \arg \min_W (\hat{k}_W = K) \quad (9)$$

혼합추정에서 창 크기  $Q$ 의 초기치가 주어지면 창에서 클러스터의 수는 MDL 원리를 이용하여 계산된다. 추정된 클래스의 수가 기준치  $K$ 와 같으면 분할을 위한 모델 파라미터는 창  $W$ 에서 추정되며, 그렇지 않으면  $Q$ 는 증가되고  $W$ 에서 클래스의 수가  $K$ 가 될 때까지 이전의 과정을 반복한다. 이러한 프로세스는 적응적 분할에서 기존의 방법보다 보다 타당한 파라미터 추정을 가능하게 한다. (그림 2)와 (그림 3)은 창 크기 초기치  $Q=33$ 이 주어 졌을 때, 추정된 창의 크기와 히스토그램을 보여준다. (그림 2)는 창의 크기  $Q=33$ 과  $Q=45$ 일 때의 창을 보여주며, (그림 3(a))는 창 내에서의 히스토그램을 보여준다. 또 (그림 3(b))와 (c)는 창 내에서의 MDL 원리를 이용하여 추정된 클래스의 수를 나타내며, (그림 3(b))는 창의 크기  $Q=33$ 일 때 창 내에 존재하는 클래스의 수는 2개, (그림 3(c))는 창의 크기  $Q=45$ 일 때 창 내에 존재하는 클래스의 수는 3개임을 나타낸다. 본 논문에서 제안한 분할 알고리즘의 흐름



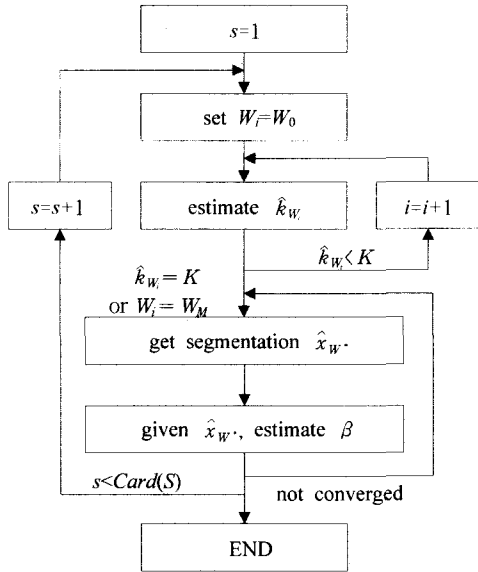
(그림 2) 국소영역 크기의 추정의 예 :  
(a) 초기치 ( $Q=33$ ), (b) 추정치( $Q=45$ )



(그림 3) 창의 크기에 따른 창 내의 히스토그램 :  
(a) 히스토그램, (b)  $Q=33$  일 때와  
(c)  $Q=45$  일 때의 추정된 클래스 수

도를 (그림 4)에 도시하였다. 영상 전체에서 각 픽셀마다 분포 파라미터를 계산하기에는 계산량이 많으므로 파라미터의 추정은 적정 거리가 떨어진 격자점에서 계산되고, 격자점 아닌 픽셀에 대해서는 쌍선형 보간(bilinear interpolation)[30]이 이용된다. 제안한 방법은 MR

영상 분할에서 3차원적 방법으로 확장이 가능하며, 이때의 모든 연산은 복셀(voxel) 단위로 이루어진다. 국소영역  $W$ 도 3차원으로 확대되어 복셀들로 이루어진 직육면체 형태를 가지게 된다.



(그림 4) 제안한 적응적 분할 방법의 흐름도

분할하고자 하는 픽셀에서 추정된 창크기  $Q$ 에 대하여 분할은 혼합추정과 클러스터링을 반복하는 EM 추정이며, 다음 식과 같이 표현된다.

$$\hat{x} = \arg \max_x p(x | y, \hat{\beta}) \tag{10}$$

$$\hat{\beta} = \arg \max_{\beta} p(y | \beta) \tag{11}$$

EM 추정이 완료되면 최종적인 모델 파라미터가 구해진다. 구해진 모델 파라미터로부터 국소영역의 최종 분할은 다음 식과 같이 수행된다.

$$f(y) = \arg \max_{k \in Q} p_k(x | y, \hat{\beta}) \tag{12}$$

추정된 국소영역에서 각 픽셀마다 모든 클래스  $k$ 에 대하여  $p_k(x | y, \hat{\beta})$ 를 구하고 그 픽셀에서  $p_k(x | y, \hat{\beta})$ 를 최소화하는 클래스가 최종 분할 클래스로 선택된다.

#### 4. 실험결과 및 토론

분할 성능의 평가를 위하여 MR영상은 GE 1.5 Tesla Signa 스캐너(scanner)를 이용하여 정적 상태에서 SPGR (spoiled gradient recalled echo) 시퀀스(sequence)의 축방향 평면(axial plane)으로 획득되었으며, 픽셀크기 0.86 mm, 슬라이스(slice) 두께 1.5 mm, TE = 3500 ms, TR = 14500 ms이다. 먼저 영상에서 대뇌영역은 문턱치화(thresholding), 영역확장법, 수동편집에 의하여 분리하였으며, 분리된 대뇌영역에서 백질, 회백질, 뇌척수액의 분할을 시도하였다. 클래스 비균일성이 있는 MR 영상에 대한 분할방법을 비교하기 위하여 (그림 5(a))의 정상 영상을  $y' = y(1 + i/w)$ 을 이용하여 (그림 5(b))와 같은 비균일성이 있는 영상을 얻었다. 여기서  $y$ 는 픽셀값,  $i=1, \dots, w$ ,  $w$ 는 영상의 폭을 나타낸다.



(a) 정상 영상, (b) 비균일성을 가진 영상

(그림 5) SPGR MR 영상 :  
(a) 정상 영상, (b) 비균일성을 가진 영상

분할 성능을 비교하기 위하여 전역적 ICM, 적응적 ICM, 제안한 방법의 분할 결과를 서로 비교한다. 전역적 ICM[26]은 혼합추정과 클러스터링을 영상전체를 고려하는 방법이며, 적응적 ICM[17, 18]은 혼합추정과 클러스터링을 영상의 국소영역에 대하여 수행하는 방법이다. 분할 결과의 비교 척도는 식 (13)으로 정의되는 kappa statistic[28, 29]으로 알려진 유사도(similarity index)를 사용한다.


$$I = 2 \frac{|A \cap B|}{|A| + |B|} \tag{13}$$

여기서  $A$ 와  $B$ 는 비교 대상의 분할 결과 영상이다.


(그림 5(a))의 정상인의 MR영상에 대하여 (그림 6(a))는 전역적 ICM, 적응적 ICM, 제안한 방법의 분할 결과를 보여준다. 분할 결과에서 가장 밝은 부분은 백질

을 나타내고 약간 어두운 부분은 회백질을 나타내며 어두운 부분은 뇌척수액(CSF)을 의미한다. 전역적 ICM과 제안한 방법의 분할은 비교적 좋은 결과를 보여주지만, 기존의 적응적 ICM방법은 다른 두 방법보다 오차를 많이 발생시킴을 알 수 있다. 이는 기존의 적응적 방법에서 각 픽셀마다 파라미터 추정과 분할을 위한 국소영역인 창  $W$ 의 크기가 일정하고 일정한 크기의 국소영역에  $K$ 개의 클래스가 존재한다는 가정이 만족하지 않기 때문으로 볼 수 있다. 반면 제안한 방법은 다른 방법에 비하여 국소 영역의 특징을 잘 반영하고 있음을 볼 수 있다. 적응적 ICM 방법의 창크기는 경험적으로 결정한 값으로서  $Q=44$ 로 하였다. 본 논문의 방법에서는 국소영역인 창의 크기를 주어진 영상으로부터 추정하였으며, 각 슬라이스에 대한  $Q$ 의 평균과 표준편차를 (그림 7)에 보여준다. 그림에서 모든 슬라이스에서 창크기의 평균과 표준편차가 동일하지 않음을 알 수 있다. 실험에서 사용된 MR영상은 뇌의 AC (anterior commissure) 부분으로부터 머리의 윗부분까지 10장의 축방향 슬라이스(axial slice)이다. 추정된 국소영역 창으로부터 추정된 분포 파라미터는 기존의 경험적 방법에 의한 고정된 크기의 창에 대한 분포 파라미터의 추정보다 더 좋은 분할 결과를 보여준다. (그림 8(a))는 (그림 5(a))의 중간 행 부분의 창들에 대한 클러스터의 중심을 보여준다. 영상으로부터 추정된 창크기의 평균치는 적응적 방법에 있어서 창크기의 결정시에 좋은 하나의 방법이다. (그림 9(a))에서는 회백질과 백질에 대하여 3가지 분할방법과 수동분할과의 유사도를 비교하였다. 기존의 적응적 방법과 제안한 방법이 생물학적 조직변화에 대응하여 분할할 수 있고, 제안한 방법이 더 좋은 결과를 보여주며, (그림 6(a))와 상응하는 결과를 나타낸다.

비균일성을 가지는 영상인 (그림 5(b))에 대해서 (그림 6(b))는 언급한 3가지 분할 방법의 분할결과를 나타낸다. 전역적 ICM방법은 (그림 6(b))와 (그림 9(b))에 보이는 바와 같이 국소 영역의 영상특성을 잘 반영하지 못하므로 비교적 오차가 많은 결과를 보여준다. 기존의 적응적 ICM 방법은 전역적 방법보다는 좋은 결과를 나타내지만 제안한 방법보다는 결과가 떨어진다. 기존의 적응적 방법은 창크기를 경험적으로 결정한  $Q=44$ 로 하였고, 한 싸이클 동안 고정된 값이므로 고정된 창크기는 모든 픽셀에서 파라미터 추정과 분할을 올바르게 진행되는 것이 아님을 볼 수 있다.




(그림 6) 전역적 ICM방법(좌), 적응적 ICM 방법(중), 제안한 방법(우)을 적용한 분할 결과 : (a) 정상 영상에 대한 2차원적 방법, 비균일성이 있는 영상에 대한 (b) 2차원적 방법과 (c) 3차원적 방법

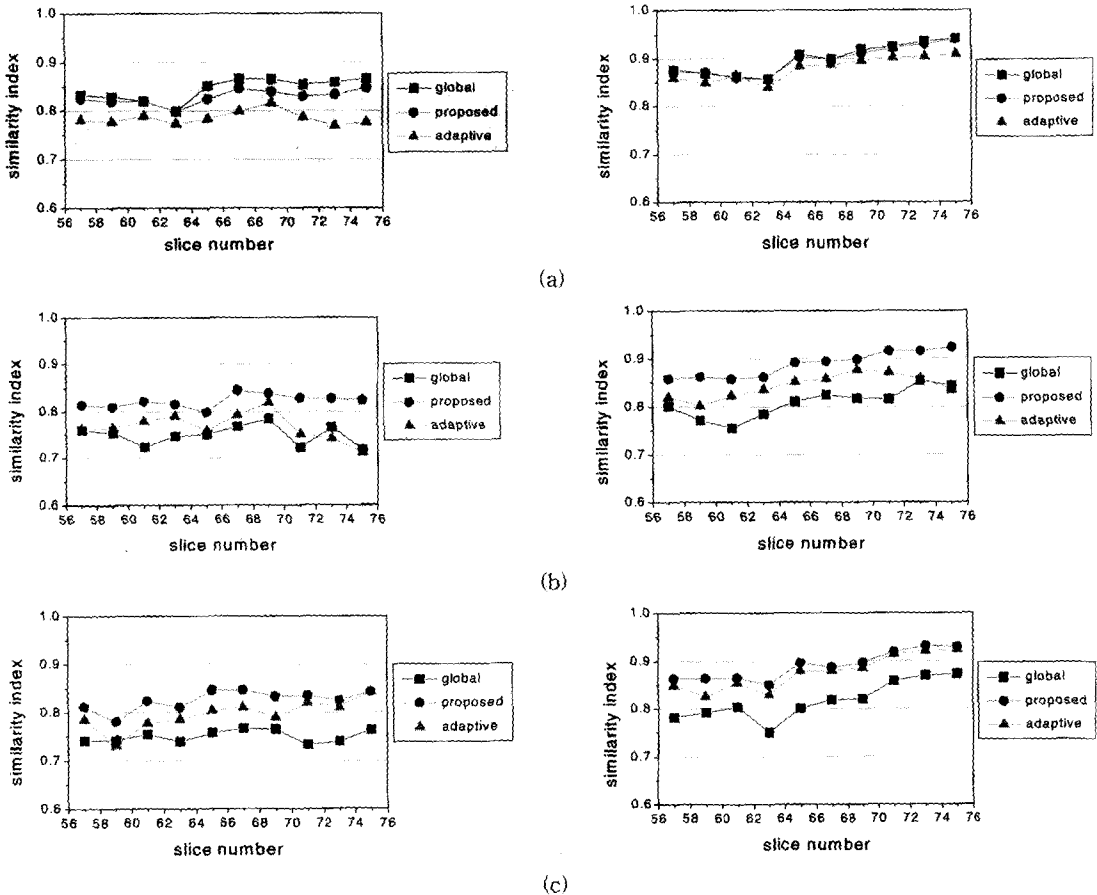


(그림 7) 제안한 방법에 의한 각 슬라이스로부터 추정된 창크기  $Q$ 의 변화(57 = 뇌의 아래부분)

비균일성이 있는 영상에 대하여 (그림 8(b))에서 적응적 방법과 제안한 방법이 조직의 비균일성에 대응할 수 있음을 보여준다. 제안한 방법이 영상의 각 화소마다 창의 크기를 추정하여 국소영역의 영상특성을 더 잘 반영하므로 더 좋은 결과를 나타냄을 알 수 있다. (그림 6(b))와 (그림 9(b))에서도 제안한 방법의 분할



(그림 8) 영상의 중간 행 부분의 창들에 대한 클러스터 중심(전역적 방법: G-GM과 G-WM, 적응적 방법: A-GM과 A-WM, 제한한 방법: P-GM과 P-WM): (a) (그림 2 (a)), (b) (그림 2 (b))



(그림 9) 회백질(좌)과 백질(우)에 대한 수동분할과의 유사도 비교 (global: 전역적 ICM, proposed: 제안한 방법, adaptive: 적응적 ICM):


(a) 정상 영상에 대한 2차원적 방법, 비균일성이 있는 영상에 대한 (b) 2차원적 방법과 (c) 3차원적 방법

결과가 더 좋음을 보여준다.

제한한 알고리즘의 3차원 방법을 SPGR MR영상 집

합에 적용하였다. 영상의 크기는 256×256이며 124장의 슬라이스들로 구성된 영상 집합이다. (그림 6(c))와 (그

림 9(c)에서 제안한 방법이 전역적 방법이나 적응적 방법보다 좋은 결과를 보여주었으며, 2차원 분할 방법과 달리 3차원 분할 방법은 슬라이스간의 비균일성에도 대응하는 장점이 있다. (그림 10)은 수동분할과 자동분할 결과의 3차원 볼륨 렌더링(volume rendering)한 영상이다. (그림 10(a))는 문턱치화, 영역확장법, 수동편집에 의하여 분할한 뇌영역의 렌더링 결과이며, (그림 10(b))는 회백질과 백질에 대한 수동분할의 렌더링 결과이고, (그림 10(c))는 제안한 알고리즘의 3차원 방법에 의하여 분할한 백질과 회백질의 렌더링 결과이다. 그림에서 수동분할과 비교하여 제안한 방법의 백질과 회백질의 분할 결과가 시각적으로 큰 차이가 없음을 볼 수 있다.



(그림 10) 뇌영역과 회백질(좌)과 백질(우)의 볼륨 렌더링 결과 : (a) 뇌영역, (b) 수동분할, (c) 비균일성이 있는 영상에 대하여 제안한 방법의 3차원 분할

## 5. 결 론

본 논문에서는 MR영상의 비지도 분할을 위하여 MDL 원리를 이용한 통계적 적응적 방법을 제안하였다. 제안한 방법은 전치 파라미터와 측정 파라미터 뿐 아니라 창의 크기도 주어진 영상으로부터 추정하므로 비지도 분할 방법에 더 근접한 방법이다. 영역 클래스를 MRF로 모델링함으로써 잡음에 대응하도록 했으며, 파라미터 추정과 분할을 위한 국소영역인 창은 MDL 원리를 이용하여 추정하였다. 영상의 각 화소에서 추정된 창크기의 평균치는 기존의 적응적 방법의 창크기 결정시에 좋은 기준으로 이용할 수 있다. 제안한 알고리즘의 적응성은 스캐너 자기장의 비균일성과 조직의 생물학적 변화에 대응하는 결과를 보였으며, 비균일성을 가지는 영상에 대하여 국소영역의 영상특성을 잘 반영하였으며, 기존의 방법보다 더 좋은 분할 결과를 보여주었다. 이 방법은 기존의 적응적 방법의 적용이 어려웠던 다양한 MR 영상 분할에 유용할 것이다.


## 참 고 문 헌

- [1] Kelvin O. Lim and Adolf Pfefferbaum, "Segmentation of MR Brain Images into Cerebrospinal Fluid Spaces, White and Gray Matter," *Journal of Computer Assisted Tomography*, Vol.13, pp.588-593, 1989.
- [2] Malone MJ, Szoke MC, "Neurochemical changes in white matter aged human brain and Alzheimers disease," *Arch Neurol*, Vol.42, pp.1063-1066, 1985.
- [3] Brun A, Englund, "A white matter disorder in dementia of the Alzheimer type : a pathoanatomical study," *Ann. Neurol.*, Vol.19, pp.253-262, 1986.
- [4] J. C. Bezdek, L. O. Hall, L. P. Clarke, "Review of MR image segmentation techniques using pattern recognition," *Medical Physics*, Vol.20, pp.1033-1048, 1993.
- [5] L. P. Clarke, R. P. Velthuizen, M. A. Camacho, J. J. Heine, M. Vaidyanathan, L. O. Hall, R. W. Thatcher, and M.L. Silbiger, "MRI Segmentation : Methods and Applications," *Magn. Reson. Imag.*, Vol.13, pp.343-368, 1995.
- [6] Terry L. Jernigan, Gray A. Press, John R. Hesselink,



- "Methods for Measuring Brain Morphologic Features on Magnetic Resonance Images," *Arch Neurol*, Vol.47, pp.27-32, 1990.
- [7] Nitin K. Tanna, Mark I. Kohn, David N. Horwich, Paul R. Jolles, Robert A. Zimmerman, Wayne M. Alves, Abass Alavi, "Analysis of Brain and Cerebrospinal Fluid Volumes with MR Imaging : Impact on PET Data Correction for Atrophy," *Radiology*, Vol.178, pp.123-130, 1991.
- [8] Harvey E. Cline, William E. Lorensen, Ron Kikinis, and Ferenc Jolesz, "Three-Dimensional Segmentation of MR Images of the Head Using Probability and Connectivity," *Journal of Computer Assisted Tomography*, Vol.14, pp.1037-1045, 1990.
- [9] Michael W. Vannier, Robert L. Butterfield, Douglas Jordan, William A. Murphy, Robert G. Levitt, Mokhtar Gado, "Multispectral Analysis of Magnetic Resonance Images," *Radiology*, Vol. pp.221-224, 1985.
- [10] Z. Liang, R. J. Jaszczak, and R. E. Coleman, "Parameter estimation of finite mixtures using EM algorithm and information criteria with application to medical image processing," *IEEE Trans. Nucl. Sci.*, Vol.39, pp.1126-1133, 1992.
- [11] Hwan Soo Choi, David R. Haynor, and Yongmin Kim, "Partial Volume Tissue Classification of Multichannel Magnetic Resonance Images-A Mixel Model," *IEEE Trans. Medical Imaging*, Vol.10, pp.395-407, 1991.
- [12] W. A. Ashton, M. J. Berg, K. J. Parker, J. Weisberg, C. W. Chen, and L. Ketonen, "Segmentation and feature extraction techniques with applications to MRI head studies," *Magn. Reson. Med.*, Vol.33, pp.670-677, 1995.
- [13] Sai Prasad Raya, "Low-Level Segmentation of 3-D Magnetic Resonance Brain Images-A Rule-Based System," *IEEE Trans. Medical Imaging*, Vol.9, pp.327-337, 1990.
- [14] P. Santago and H. D. Gage, "Quantification of MR brain images by mixture density and partial volume modeling," *IEEE Trans. Medical Imaging*, Vol.12, pp.566-574, 1993.
- [15] Charles DeCarli, Joe Maisog, Declan G. M. Murphy, Diane Teichberg, Stanley I. Rapoport, and Barry Horwitz, "Method for Quantification of Brain, Ventricular, and Subarachnoid CSF Volumes from MR Images," *Journal of Computer Assisted Tomography*, Vol.16, pp.274-284, 1992.
- [16] Stuart Geman and Donald Geman, "Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images," *IEEE Trans. Pattern Anal. Machine Intell.*, Vol.PAMI-6, pp.721-741, 1984.
- [17] A. Peng and W. Pieczynski, "Adaptive mixture estimation and unsupervised local Bayesian image segmentation," *Graph Models Image Processing*, Vol.57, pp.389-399, 1995.
- [18] Jagath C. Rajapakse, Jay N. Giedd, and Judith L. Rapoport, "Statistical Approach to Segmentation of Single-Channel Cerebral MR Images," *IEEE Trans. Medical Imaging*, Vol.16, pp.176-186, 1997.
- [19] Jagath C. Rajapakse, Jay N. Giedd, Charles Decali, John W. Snell, Alan McLaughlin, Yolanda C. Vauss, Amy L. Krain, Susan Hamburger and Judith L. Rapoport, "A Technique for Single-Channel MR Brain Tissue Segmentation : Application to A Pediatric Sample," *Magn. Reson. Imag.*, Vol.14, pp.1053-1065, 1996.
- [20] T. N. Pappas, "An adaptive clustering algorithm for image segmentation," *IEEE Trans. Signal Processing*, Vol.40, pp.901-914, 1992.
- [21] Yves Delignon, Abdelwaheb Marzouki, and Wojciech Pieczynski, "Estimation of Generalized Mixtures and Its Application in Image Segmentation," *IEEE Trans. Image Processing*, Vol.6, pp.1364-1375, 1997.
- [22] G. Schwarz, "Estimating the dimension of a model," *Ann. Statistics*, Vol.6, pp.461-464, 1978.
- [23] J. Rissanen, "Modeling by Shortest Data Description," *Automatica*, Vol.14, pp.465-471, 1978.
- [24] D. A. Langan, J. W. Modestino, and J. Zhang, "Cluster validation for unsupervised stochastic model-based image segmentation," *Proc. ICIP*, Vol.2, pp.197-201, 1994.
- [25] J. Besag, "On the statistical analysis of dirty pictures," *J. Roy. Stat. Soc.*, Vol.48, pp.259-302, 1986.

- [26] Jong-Kae Fwu and Peter M. Djuric, "Unsupervised Vector Image Segmentation by a Tree Structure-ICM Algorithm," *IEEE Trans. Medical Imaging*, Vol.15, pp.871-880, 1996.
- [27] A. P. Dempster, N. M. Laird and D. B. Rubin, "Maximum Likelihood from Incomplete Data via the EM Algorithm," *J. Royal Statistical Society Ser. B*, Vol.39, pp.1-38, 1977.
- [28] Alex P. Zijdenbos, Benoit M. Dawant, Richard A. Margolin, and Andrew C. Palmer, "Morphometric Analysis of White Matter Lesions in MR Images : Method and Validation", *IEEE Trans. Medical Imaging*, Vol.13, pp.716-724, 1994.
- [29] B. Johnston, M. S. Atkins, B. Mackiewich, and M. Anderson, "Segmentation of Multiple Sclerosis Lesions in Intensity Corrected Multispectral MRI," *IEEE Trans. Medical Imaging*, Vol.15, pp.154-169, 1996.
- [30] R. O. Duda and P. E. Hart, *Pattern Classification and Scene Analysis*. New York : Wiley, 1973.
- [31] J. Besag, "Spatial interaction and the statistical analysis of lattice systems," *J. Roy. Statist. Soc. B*, Vol.36, pp.192-225, 1974.



## 김 태 우

e-mail : twkim2@samsung.co.kr

1990년 한양대학교 전자통신공학과  
졸업(학사)

1992년 한양대학교 대학원 전자통  
신공학과(공학석사)

1995년 한양대학교 대학원 전자통  
신공학과(공학박사)

1995년~1997년 한양대학교 산업과학연구소 선임연구원

1997년~현재 삼성종합기술원 의료전자랩 선임연구원

관심분야 : 영상처리, 인공 신경망, 영상복합화, 뇌지도화 등