

명암도 응집성 강화 및 분류를 통한 3차원 뇌 영상 구조적 분할

김 민 정[†] · 이 정 민^{‡‡} · 김 명 희^{***}

요 약

최근 대용량 의료영상 데이터로부터 인체 기관 또는 결환 부위 추출을 위한 영상 분할 기법이 매우 다양하게 제안되고 있으나, 뇌와 같이 다중 구조를 가지면서 구조간 경계 구분이 어려운 영상의 구조적 분할에는 한계를 가진다. 이를 위해 주로 복셀을 유한 개의 군집으로 분류하는 군집화 (clustering) 기법이 이용되나 이는 개별 복셀 단위의 연산을 수행함으로 인해 잡음의 영향을 받는 제한점이 있다. 그러므로 잡음의 영향을 최소화하고 영상 경계를 강화시키는 향상기법을 적용함으로써 보다 견고한 구조적 분할을 수행할 수 있다.

본 연구에서는 뇌 자기공명영상에 대하여 백질(white matter), 회백질(gray matter), 뇌척수액(cerebrospinal fluid)의 내부 구조를 효율적으로 추출하기 위한 필터링 기반 군집화에 의한 구조적 분할 기법을 제안한다. 우선 구조간 경계를 강화하고 구조 내 잡음을 약화시키기 위해 응집성 향상 확산 필터링 (coherence enhancing diffusion filtering)을 적용한다. 또한 이 과정을 통해 강화된 영상에 퍼지 c-means 군집화 기법을 적용하여 각 복셀이 속하는 구조에 해당하는 군집의 인덱스를 할당함으로써 구조적 분할을 수행한다.

제안된 구조적 분할기법은 기존의 가우시안 또는 일반적인 비동방성 확산 필터링과 군집화 기법을 적용한 기법에 비해 전문가의 수동분할 결과와의 일치 비율에 의한 분할 정확도를 향상시킴을 보였다. 또한 경계 부분에 있어서의 세밀한 분할을 통해 재생산 가능하고 사용자 수동 후처리를 최소화할 수 있는 결과를 제시함으로써 형태적 뇌 이상 진단을 위한 효율적인 보조 수단을 제공한다.

키워드 : 뇌 자기공명영상(MRI), 영상 분할, 확산기반 필터링, 퍼지 군집화

Structural Segmentation for 3-D Brain Image by Intensity Coherence Enhancement and Classification

Min-Jeong Kim[†] · Joong-Min Lee^{‡‡} · Myoung-Hee Kim^{***}

ABSTRACT

Recently, many suggestions have been made in image segmentation methods for extracting human organs or disease affected area from huge amounts of medical image datasets. However, images from some areas, such as brain, which have multiple structures with ambiguous structural borders, have limitations in their structural segmentation. To address this problem, clustering technique which classifies voxels into finite number of clusters is often employed. This, however, has its drawback, the influence from noise, which is caused from voxel by voxel operations. Therefore, applying image enhancing method to minimize the influence from noise and to make clearer image borders would allow more robust structural segmentation.

This research proposes an efficient structural segmentation method by filtering based clustering to extract detail structures such as white matter, gray matter and cerebrospinal fluid from brain MR. First, coherence enhancing diffusion filtering is adopted to make clearer borders between structures and to reduce the noises in them. To the enhanced images from this process, fuzzy c-means clustering method was applied, conducting structural segmentation by assigning corresponding cluster index to the structure containing each voxel.

The suggested structural segmentation method, in comparison with existing ones with clustering using Gaussian or general anisotropic diffusion filtering, showed enhanced accuracy which was determined by how much it agreed with the manual segmentation results. Moreover, by suggesting fine segmentation method on the border area with reproducible results and minimized manual task, it provides efficient diagnostic support for morphological abnormalities in brain.

Key Words : Brain MRI, Image Segmentation, Diffusion Based Filtering, Fuzzy Clustering

1. 서 론

최근 의료 분야에서의 디지털 영상은 진단, 처치 계획 및

지원 등에 필수적으로 사용되고 있으며, 점차 다양화, 대량화되는 추세에 있다. 따라서 이러한 대용량 데이터를 처리하는데 있어 영상 관독가의 수동 처리를 최소화함으로써 효율적인 수행시간을 보장함과 동시에 정확하고 재생산 가능한 분석 결과를 유도하는 기법에 대한 수요가 크게 증가하고 있다. 또한 일련의 2차원 단면영상으로부터 유용한 3차원 구조를 추출해 내는 컴퓨터 기반 처리기법을 통해 주관적으로 이루어지는 영상 관독의 한계를 극복하고 구조화된

* 본 연구는 산업자원부·교육인적자원부·노동부 지원 최우수설립지원사업과 과학기술부지원 실시간분자영상기술개발사업에 의해 부분적으로 지원받았음.

† 준희원: 이화여자대학교 컴퓨터학과 박사과정

‡ 정희원: 삼성전자 사원

*** 종신희원: 이화여자대학교 컴퓨터학과 교수

논문 접수: 2006년 6월 19일, 심사 완료: 2006년 9월 5일

정보를 얻음으로써, 질환 부위 및 미세 조직의 형태적 특성에 대한 효율적 관찰 및 분석을 용이하게 한다. 이러한 과정에서 필수적인 단계가 영상 분할 기법으로, 적용 대상 및 영상에 따라 다양한 자동, 반자동화된 영상 분할기법이 제안되어 오고 있다.

영상 분할은 영상을 특정 목적에 부합하도록 몇 개의 영역들로 분리함으로써 영상을 분석하고 상호 연관시키기 위한 선행과정으로[1], 인체 조직의 3차원 형상 복원이나 종양 등 선택적 영역의 볼륨 렌더링, 다중 영상 정합 등 고차원 영상처리 과정의 전 단계로도 수행될 수 있다. 영상 분할은 컴퓨터 비전 분야에서 2차원 영상 또는 비디오 프레임으로부터 객체를 추출하는 경우나 자기공명영상(MRI: Magnetic Resonance Imaging) 또는 컴퓨터단층촬영영상(CT: Computed Tomography) 등과 같은 3차원 의료 영상으로부터 심장, 간, 폐 등과 같은 인체기관을 추출하는데 다양하게 적용되고 있다. 특히 뇌 영상의 경우, 회백질(GM: gray matter), 백질(WM: white matter), 뇌척수액(CSF: cerebrospinal fluid) 등 다중 구조를 가지는 뇌의 경우와 같이 복잡한 해부학적 구조를 가지므로, 이를 구조적으로 분할, 정량적 측정을 도움으로써 질환 진단에 중요한 파라미터를 제공할 수 있다.

일반적인 구조적 분할을 위해 이용되는 군집화(clustering) 기법은 주변 영역 또는 구조와의 세부적인 분류를 가능하게 하여, 복셀 단위의 연산을 수행함으로 인해 일부 복셀이 적절한 군집에 소속되지 않는 경우가 발생할 수 있다. 따라서 군집화 이전에 스케일 스페이스 필터링 등을 통한 영상 향상 단계를 추가함으로써 군집화를 최적화하는 기법들이 제안되고 있다. 그러나 일반적으로 사용되고 있는 가우시안 또는 비등방성 확산 필터링의 경우 잡음을 약화시키는 장점은 있으나 보다 효과적인 구조적 분할을 위해서는 영역 경계를 강화함과 동시에 잡음을 약화시키는 영상 향상 기법 적용을 필요로 한다.

본 연구의 목적은 잡음을 약화시키는 필터링을 통해 향상된 영상에 군집화를 적용하는 기존 기법을 개선하여, 내부 구조 경계 정보를 고려함으로써 오차를 줄임과 동시에 사용자 후처리를 최소화하는 효율적인 구조적 분할을 수행하는데 있다. 이를 위해 본 연구에서는 복잡한 구조와 잡음 속성을 나타내는 3차원 뇌 자기공명영상에 대하여 영상 경계를 강화하고 잡음을 약화시키는 응집성 향상 확산 (CED: Coherence Enhancing Diffusion) 필터링을 적용함으로써 군집화에 의한 분할결과를 최적화하는 기법을 제안한다.

제안한 분할 기법은 입력 영상에 대한 전처리 및 영역 경계 향상 처리 단계와 군집화 단계로 구성된다. 군집화 이전 단계에서는 영상 슬라이스간 명암도 차에 따른 분할 결과의 영향을 최소화하기 위한 영상 명암도 히스토그램 스트레칭을 통해 영상 명암도 분포를 정규화한다. 또한 Weickert[13, 14]에 의해 제안된 응집성 향상 확산 필터링을 적용함으로써 영상 경계를 강화시킨다. 응집성 향상 필터링은 영상 명암도의 기울기에 따른 구조 행렬의 고유치 분해를 통해 고유치가 큰 영역을 경계 영역으로 간주하고, 이 경계를 따라

가우시안 컨볼루션을 적용함으로써 경계를 향상시키는 기법이다. 군집화 단계에서는 퍼지 c-means 군집화 기법을 이용하여 강화된 영상을 구조적으로 분류한다. 이 때 군집의 개수가 적을 경우 뇌 영상과 같이 복잡한 구조를 가지는 영상에서는 영상 경계가 상세히 분할되지 않을 수 있으므로, 구조 수 보다 2배 이상 많은 군집 개수로 군집화한 후 해부학적 구조에 관한 지식을 기반으로 군집을 통합하는 것이 보다 정확한 구조적 분할 결과를 보인다.

논문의 구성은 다음과 같다. 2장에서는 의료영상 분할기법 및 특히 군집화를 통한 분할과 관련된 기존 연구에 대해 살펴보고, 3장에서는 군집화의 전단계로 영상 명암도의 균일성과 지역적 응집성을 강화시키는 전처리 및 필터링에 대해 설명한다. 4장에서는 강화된 영상에 대해 퍼지 c-means 군집화를 통한 보다 정확하고 재생산가능한 3차원 의료영상의 구조적 분할 기법에 대하여 기술한다. 5장에서는 실험 영상 및 구현 환경에 대하여 설명하고 구현 및 실험 결과를 제시한다. 마지막으로 6장에서는 결론 및 향후 연구 방향을 기술한다.

2. 구조적 영상 분할 기법

영상 분할기법은 사용되는 특징과 유형에 의해 분류된다. 특징은 픽셀 또는 복셀 명암도, 기울기 크기, 텍스쳐 측정값 등을 포함한다. 분할 기법은 이 특징들을 크게 영역 기반, 에지(edge) 기반, 분류 중 하나의 기법을 통해 적용하는 것이다[1].

에지 기반 기법은 Sobel, Prewitt, Canny 연산자 등 다양한 에지 연산자를 통해 인식된 에지를 추출하여 이를 그래프 탐색 또는 스네이크(Snake) 등의 변형 모델 기반으로 연결시켜 영역을 분할하는 기법으로, 에지 주변의 잡음을 민감한 영향을 받는 단점이 있다. 영역 기반 기법은 영상을 특정 일관성 속성에 기반한 유한 개수의 영역으로 분할하는 방법으로, 대표적인 영역 기반 기법인 영역확장 알고리즘은 영역당 최소 하나 이상의 씨앗점(seed point)을 시작으로 이웃을 탐색하여 조건을 만족하면 영역에 포함시켜 가는 기법이다. 이 기법은 씨앗점 및 분할 영역의 임계치 선택 등에 사용자 입력을 필요로 하므로 분할 결과가 사용자간 또는 데이터간 차이를 보일 수 있으며 재생산성을 보장하기 어렵다. 분류 기반 기법은 영상을 구성하는 각 복셀에 특징 값을 기반으로 한 클래스 표지(label)를 할당함으로써 비슷한 특성을 갖는 것들끼리 의미있는 집단으로 묶는 기법이다. 이 중 사용자의 사전 설정 없이 복셀 값의 통계적 특성을 이용하는 무감독 (non-supervised) 분류기법인 군집화가 주로 적용된다.

대상 기관 및 영상 특성에 따라 적절한 분할 기법을 적용할 수 있으나, 뇌와 같이 복합적 구조를 가지는 인체기관 영상에 대해서는 전체 유팽 추출뿐 아니라 내부 구조의 구분을 위한 구조적 분할이 요구되므로 경계 부분의 모호성에 의한 영향을 덜 받고 복셀 단위로 적용되는 군집화 기법이

적절하다. 또한 분할결과는 재생산 가능하여야 하고, 사용자 또는 영상에 따른 오차를 최소화할 수 있는 기법이어야 한다. 분류 기법은 주변 영역 또는 구조와의 세부적인 분류를 가능하게 하여, 복셀 단위의 연산을 수행함으로 인해 일부 복셀이 적절한 군집에 소속되지 않는 경우가 발생할 수 있다. 이를 개선하기 위해 군집화 알고리즘 자체를 개선하는 기법[7-10]과 군집화 이전에 영상 향상 등의 전처리를 수행함으로써 영상 잡음을 약화시켜 개별 복셀에 의한 잘못된 영향을 줄이는 기법[3-5]이 제안되고 있다.

Liew [9]와 Siyal [10] 등은 복셀 간의 영상 명암도 비균일성을 추정, 공간적 제약조건을 설정함으로써 분류의 모호성을 제거한 개선된 군집화 기법을 제안하였다. 또한 Zhu [7] 등은 군집화 이전에 반복적 임계치 설정을 통한 잡음 제거를 수행함으로써 군집화의 정확도를 향상시켰다. Shademan [8] 등은 퍼지 구조 내에 뇌 템플릿 영상에서의 해부학적 정의에 따른 영상정보 퓨전연산자를 포함하여 회백질, 백질 뿐 아니라 시상 (thalamus), 조가비핵 (putamen), 미상핵 (caudate nucleus) 등에 이르는 세부 구조 수준까지 분할하는 기법을 제시하였다. 군집화 이전에 필터링을 적용함으로써 분할 정확도와 효율성을 높이는 연구로는 주로 가우시안 필터링 등의 스케일 스페이스 필터링 기법들이 이용되어 왔다[3,4]. 그러나 가우시안 필터링은 잡음의 영향을 줄이는 효과만 줄 뿐 영상의 구조적 정보를 고려하지는 않으므로 실제 응용에 있어 제한적이다. 이를 개선하기 위해 Atkins [3] 등에 의해 Perona와 Malik의 비동방성 확산 기반 필터링 [11]을 적용함으로써 잡음으로부터의 영향을 최소화한 기법이 제안되었다. 이 기법은 영상의 기울기 강도가 증가함에 따라 확산 또는 평활화 정도를 감소시킴으로써 잡음 약화에 있어서 기존 기법보다 효율적이고 영역간 뚜렷한 분리를 가능하게 한다. 그러나 확산 크기 파라미터 값에 따라 과도한 영역 분리가 이루어지는 경우가 많아 뇌와 같이 복잡한 구조를 지니는 대상에 있어서 실제로 연결된 구조가 분리되어 나타나거나 경계 부분에서의 분할이 정확하지 않을 수 있다. 따라서 영상 경계를 세밀하게 강화시키면서 잡음으로부터의 영향을 차단하는 보다 효과적인 필터링의 적용이 요구된다.

최근 비동방성 확산을 기반으로 한 다양한 필터링 기법이 제안되고 있다. 이 중 널리 쓰이는 기법이 Yu [12] 등이 제안한 스페클 감소 확산 (SRAD: Speckle Reducing Anisotropic Diffusion) 필터링과 Weickert [13, 14]에 의해 제안된 응집성 향상 확산 필터링이다. 스페클 감소 확산 필터링은 적용적 필터링과 확산 모델을 접목한 기법으로 잡음에 의한 영향은 크게 줄일 수 있으나, 영역간 차이에 상대적으로 민감하게 작용하여 뇌와 같이 복잡한 구조를 가지는 영역에서 실제 영역에 비해 과도한 분할이 일어날 수 있다. 응집성 향상 필터링은 구조의 지역적 응집성을 측정하여 기울기와 윤곽선 방향으로 보다 방향성 있는 확산 과정을 진행시킴으로써, 영상 경계를 강화시키고 유동 패턴을 강조함으로써 주변 영역과 분리가 어렵고 복잡한 구조를 가지는 영상에 대한 효율적인 강화가 가능하게 한다.

살펴본 바와 같이 기존의 군집화 기법을 이용한 영상의 구조적 분할에 있어서의 효율성을 보다 개선하기 위해서는 영역 경계를 항상시킴과 동시에 정확히 유지하는 필터링 기법이 군집화 이전에 적용될 필요가 있다. 이를 통해 개별 복셀의 영향을 크게 받는 군집화 기법의 한계를 극복할 수 있다. 따라서 본 연구에서는 응집성 향상 확산 필터링에 의한 경계 영역에서의 응집성 향상 단계를 군집화 이전에 적용함으로써 복잡한 구조를 가지는 영상의 분할을 효율적으로 수행하는 기법을 제안한다. 이를 통해 보다 적은 오차를 가지는 구조적 분할 결과를 제시할 수 있을 뿐 아니라, 분할 결과에 대한 사용자 후처리를 최소화 함으로써 전자동화에 가까운 효율적인 분할 기법을 제시한다.

3. 지역적 영상 명암도 응집성 최적화

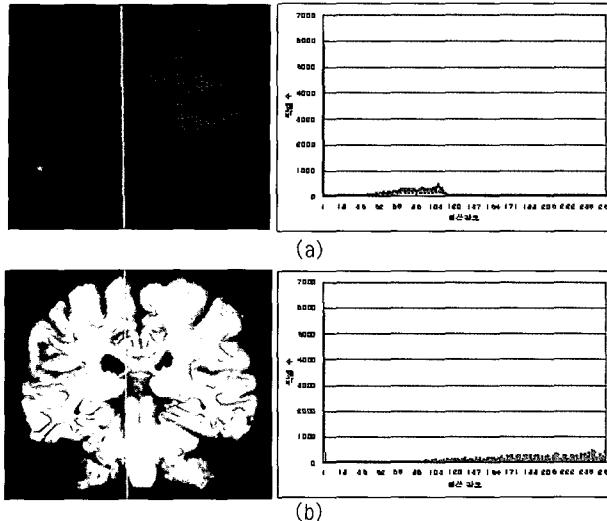
군집화를 이용한 영상 분할에 앞서 영상 명암도를 정규화하고 명암도 응집성 향상을 위한 필터링을 적용시킴으로써 구조적 분할 결과를 최적화 할 수 있도록 하는 처리 과정을 기술한다. 이 과정을 통해 영상 내 구조간 명암도 수준의 구별이 용이해 질 뿐 아니라, 잡음이 경감되고 구조간 경계가 강화된 영상을 생성할 수 있다.

3.1 영상 명암도 정규화

군집화 기법은 각 복셀을 단위로 하므로 영상 명암도 분포의 영향을 크게 받는다[2]. 특히 영상 명암도 히스토그램이 치우쳐 있을 때 또는 3차원 영상에서 슬라이스간 명암도 차이가 날 때 특정 값 차이가 크지 않게 되므로 잘못된 군집화 결과를 생성할 수 있다. 따라서 본 연구에서는 영상 명암도의 일정한 분포를 위해 히스토그램 정규화를 수행한다.

영상 명암도 또는 히스토그램 정규화는 널리 이용되는 영상 명암도의 분포 구간 확장 (stretching)기법 중 하나로, 모든 가능한 명암도 수준을 포함하기 위하여 원래의 히스토그램을 확장하고 이동시킨다. 만약 원영상 O 의 원래 히스토그램이 O_{min} (8비트 영상에서 일반적으로 0)에서 시작되고 O_{max} (8비트 영상에서 일반적으로 255)까지의 명암도 수준을 가진다면, 새로운 최소 수준 N_{min} 과 최대 수준 N_{max} 를 가지는 새로운 영상 N 을 식 (1)과 같이 구함으로써 입력 영상의 명암도 수준을 조정할 수 있다. 이 때, 새로운 최소, 최대 명암도 수준 N_{min} 과 N_{max} 은 원래의 영상 히스토그램의 양 끝에서 전체 영상 픽셀 수의 0.5%~1% 만큼의 픽셀을 제거한 후, 남은 픽셀들의 명암도 분포에서 최소, 최대 명암도 값으로 계산된다. 이와 같이 가장 밝고 어두운 픽셀을 확인하여 양 끝 범위를 무시하고, 이에 따라 중간 픽셀 값은 재분배 함에 따라, 극단적인 명암도를 가지는 픽셀들로부터의 영향을 최소화 함으로써 영상 명암도 분포를 재조정하는 기법이다. 그럼 1은 영상 명암도 정규화 적용 전, 후 영상과 그에 해당하는 명암도 히스토그램을 비교하여 나타내고 있다. 원영상이 전체적으로 어두움에 비해, 조정된 영상은 시각적으로 구별하기 용이할 뿐 아니라 전체적으로 고른 명암도 수준을 나타냄을 보인다.

$$N_{x,y} = \frac{N_{\max} - N_{\min}}{O_{\max} - O_{\min}} \times (O_{x,y} - O_{\min}) + N_{\min}, \quad \forall x, y \in 1, N. \quad (\text{식 } 1)$$



(그림 1) 영상 명암도 정규화 적용 전 (a), 적용 후 (b) 영상 및 명암도 분포 변화

3.2 명암도 응집성 향상을 위한 확산 필터링

응집성 향상 확산 필터링[13,14]은 Perona와 Malik에 의해 제안된 기본적인 비등방성 확산 기반 필터링 기법[11]을 기반으로, 영상경계를 강화하는 반면 스파클 잡음을 감소시키기 위해 구조 텐서 (또는 구조 행렬)를 정의한다. 구조 텐서는 지역적 이웃 내의 기울기 벡터의 공분산 행렬과 관련된다. 기울기 벡터들은 지역적 방위를 추정하는 충분한 통계적 정보를 제공하며, 구조 텐서의 고유 벡터들은 영상 내 지역적 이웃 내의 마루(ridge)의 방향을 추정한다. 확산 텐서는 구조 행렬의 고유벡터로부터 얻어지고 이 때의 고유치들은 각 주축 방향에서의 확산 강도이다[15]. 2차원 구조 행렬은 각 픽셀에서 영상 명암도의 기울기를 이용하여 계산되며, 멀티 스케일 구조 행렬은 가우시안 컨볼루션 속성을 식 (3)에 의해 식 (2)와 같이 표현된다.

$$J(I) = \begin{pmatrix} j_{xx} & j_{xy} \\ j_{yx} & j_{yy} \end{pmatrix} = \begin{pmatrix} K_\rho * I_x^2 & K_\rho * (I_x I_y) \\ K_\rho * (I_x I_y) & K_\rho * I_y^2 \end{pmatrix}. \quad (\text{식 } 2)$$

$$K_\rho(x, y) = (2\pi\rho^2)^{-1} * \exp\left(\frac{x^2 + y^2}{2\rho^2}\right). \quad (\text{식 } 3)$$

위 두 식은 고유치 분해를 이용하여 식 (4)와 같이 재구성 될 수 있다. 이 때, w_1, w_2 는 고유 벡터이고 T 는 전치행렬을 나타낸다. 고유치들은 구조 행렬의 행렬식을 0으로 만드는 방정식인 식 (5)를 계산함으로써 구해진다.

$$J(I) = (\omega_1 \quad \omega_2) \begin{pmatrix} \mu_1 & 0 \\ 0 & \mu_2 \end{pmatrix} \begin{pmatrix} \omega_1^T \\ \omega_2^T \end{pmatrix}. \quad (\text{식 } 4)$$

$$x^2 - (j_{xx} - j_{yy})x - j_{xy}^2 = 0, \quad \mu_{1,2} = \frac{1}{2} \left(j_{xx} + j_{yy} \pm \sqrt{(j_{xx} - j_{yy})^2 + 4j_{xy}^2} \right) \quad (\text{식 } 5)$$

영상의 지역적 응집성을 앞서 정의된 구조 행렬의 고유치를 내림차순으로 μ_1, μ_2 라 할 때 ($\mu_1 - \mu_2$)으로 식 (6)과 같이 정의되며, 이 값은 비등방성 구조일수록 커지는 속성을 가진다. 따라서 $\mu_1 \approx \mu_2 \approx 0$ 인 경우 일정한 영역, $\mu_1 > \mu_2 \approx 0$ 인 경우 직선 영역, $\mu_1 > \mu_2 > 0$ 인 경우 구석 영역으로 분류할 수 있다[13, 14].

$$\mu_1 - \mu_2 = \sqrt{(j_{xx} - j_{yy})^2 + 4j_{xy}^2}. \quad (\text{식 } 6)$$

확산 텐서의 정의는 시간 t 를 기준으로 식 (7)과 같이 할 수 있고, div 는 확산 식에서의 발산 연산자를 의미한다.

$$\frac{\partial I(x, y, t)}{\partial t} = \text{div}[D \nabla I],$$

$$D(I) = (\omega_1 \quad \omega_2) \begin{pmatrix} \mu_1 & 0 \\ 0 & \mu_2 \end{pmatrix} \begin{pmatrix} \omega_1^T \\ \omega_2^T \end{pmatrix}. \quad (\text{식 } 7)$$

또한 텐서의 각 요소는 식 (8)과 같이 정의될 수 있다. 이 고유치들은 k 가 상수일 때, 식 (9)와 같이 확산 속도 c_1, c_2 를 결정할 수 있다[15].

$$d_{xx} = \frac{1}{2} \left(c_1 + c_2 + \frac{(c_1 - c_2)(j_{xx} - j_{yy})}{\alpha} \right),$$

$$d_{yy} = \frac{1}{2} \left(c_1 + c_2 - \frac{(c_1 - c_2)(j_{xx} - j_{yy})}{\alpha} \right),$$

$$d_{xy} = \left(\frac{(c_2 - c_1)j_{xy}}{\alpha} \right),$$

$$\alpha = \sqrt{(j_{xx} - j_{yy})^2 + 4j_{xy}^2}. \quad (\text{식 } 8)$$

$$c_1 = \max(0.01, 1 - e^{-(\mu_1 - \mu_2)^2/k^2});$$

$$c_2 = 0.01. \quad (\text{식 } 9)$$

위에서 정의된 확산 텐서를 영상에 적용하기 위하여 마스크 형태로 표현하면 그림 2와 같이 나타낼 수 있다. 그림에서 i, j 는 각각 현재 픽셀의 행과 열을 나타내며, $a_{i,j}, b_{i,j}, c_{i,j}$ 는 각각 i, j 에서 위의 d_{xx}, d_{yy}, d_{xy} 정의에 의해 계산된 텐서 요소 값을 나타낸다. 시간 t 에 따른 매 확산 반복시마다 그림에서와 같은 컨볼루션 연산이 이전 시간 $t-1$ 에서의 영상에 반복적으로 적용되며, 반복은 이전 시간과 현재 시간에서의 영상 명암도 변화 차이가 일정 임계치 이하로 떨어질 때 종료된다.

$\frac{b_{i-1,j} + b_{i,j+1}}{4}$	$\frac{c_{i,j+1} + c_{i,j}}{2}$	$\frac{b_{i+1,j} + b_{i,j+1}}{4}$
$\frac{a_{i-1,j} + a_{i,j}}{2}$	$\frac{a_{i-1,j} + 2a_{i,j} + a_{i+1,j} + c_{i-1,j} + 2c_{i,j} + c_{i+1,j}}{2}$	$\frac{a_{i+1,j} + a_{i,j}}{2}$
$\frac{b_{i-1,j} + b_{i,j-1}}{4}$	$\frac{c_{i,j-1} + c_{i,j}}{2}$	$-\frac{b_{i+1,j} + b_{i,j-1}}{4}$

(그림 2) 확산 텐서 컨볼루션

4. 군집화 기반 영상의 구조적 분할

본 장에서는 3장에서 얻어진 지역적 응집성 강화된 영상

에 대해 영상 명암도 군집화를 통해 3차원 영상을 구조적으로 분할하는 기법에 대해 설명한다.

4.1 퍼지 c-means 군집화 기반 분할

MRI 뇌 영상에서 백질, 회백질, 뇌척수액 등의 내부 구조는 각 영역마다 다른 형태와 불규칙한 명암도를 갖는다. 따라서, 각 영상에서 이들을 분할하기 위해서 숨겨진 분할정보에 대해 최적화된 분할결과를 얻을 수 있어야 한다. 기대치-최소화 (EM: Expectation Maximization) 기법은 불완전한 정보에 대한 예측을 통하여 숨겨진 정보의 최적화된 해를 찾아내는데 유용한 알고리즘이다[17]. 최적화된 분할결과를 얻기 위해, 입력된 MRI 영상으로부터 백질, 회백질, 뇌척수액 등 내부구조의 숨겨진 정보를 얻기 위한 추정 단계를 거쳐 구해진 해를 개선하기 위해 다시 이를 이용하여 수렴 단계를 거쳐 국부적인 최적치를 얻도록 한다. 기대치-최소화 알고리즘 중에서 가장 간단한 예가 k-means 기법이며, 이를 일반화 한 것이 퍼지 c-means 기법이다.

K-means는 초기값에서부터 추정 및, 최대화 과정을 반복시키면서 중심을 찾고, 최적화된 중심으로부터 최소의 거리를 갖도록 원소를 적절한 집합으로 구획한다. 데이터 집합 $X = \{x_1, \dots, x_n\}, x_i \in \{R^d\}$ 이 주어졌을 때, 구획화된 분류 알고리즘의 목적은 $c \in \{1, 2, \dots, n\}, (c \geq 2)$ 개의 자가 유사 집단으로 나누는 것이다. 즉, 이 집단 또는 군집들은 X 의 구획을 c 개로 구성한다. 일반적인 군집화 기법들은 군집의 수준을 나타내는데 이용되는 기준 (criterion) 또는 목적 (objective) 함수 정의를 필요로 한다[1]. 특정 문제에 적합하게 설계된 다양한 목적 함수들이 존재하나, 가장 널리 이용되는 함수는 식 (12)와 같은 오차 제곱의 합 (sum-of-squared-error) J 이다. 여기서 c 와 n 은 각각 군집과 데이터 점들의 개수를 나타낸다. 정의된 J 를 최소화하기 위해 군집 중심들의 초기 추정치에서 시작하여 매 반복마다 군집 중심을 갱신하는 기대치-최소화 방식을 따른다.

$$J = (U, v) = \sum_{i=1}^c \sum_{k=1}^n u_{ik} d_{ik}^2 \quad (\text{식 } 10)$$

벡터 v 는 군집 $u_i \in U, 1 \leq i \leq c$ 에 대한 군집 중심을 나타내며 식 (11)과 같이 계산된다.

$$v = \frac{\sum_{k=1}^n u_{ik} x_k}{\sum_{k=1}^n u_{ik}}, \forall_i \quad (\text{식 } 11)$$

d_{ik} 는 x_k 와 v_i 사이를 측정한 거리 또는 유사성으로, 거리 측정치로 유클리디안 (Euclidean) 거리를 이용할 때 다음 식 (12)와 같이 정의된다.

$$d_{ik} = \sum_{i=1}^c \sum_{x_k \in u_i} \|x_k - v_i\|^2 \quad (\text{식 } 12)$$

$u_{ik} = u_i(x_k)$ 는 집합 $X = \{x_1, \dots, x_n\}$ 의 원소 x_k 에서 군집 w_i 에 대한 소속되는 정도를 나타내며, 행렬 $U = [u_{ik}]$ 는 각 열이 데이터 벡터 x_k 에 대응하고, 각 행이 c 개의 군집 u_i 중

의 하나에 대응한다. 이때, u_{ik} 를 해석함으로써 X 의 군집 분석 결과를 나타낼 수 있다. 데이터 점 x_k 가 군집 w_i 중 하나의 멤버이거나 ($u_{ik}=1$) 멤버가 아닐 때 ($u_{ik}=0$) 군집화가 견고한 것으로 간주된다. 하나의 군집에 대해 한 객체의 소속 수준이 높을수록 해당 객체는 해당 군집의 프로토타입에 보다 유사한 것으로 볼 수 있다. 견고한 군집화를 위해 소속 값 u_{ik} 는 다음 식 (13)을 만족해야 한다.

$$\begin{aligned} u_{ik} &\in \{0,1\}, \forall_{i,k}, \\ \sum_{i=1}^c u_{ik} &= 1, \forall_k, \\ 0 < \sum_{k=1}^n u_{ik} &< n, \forall_i. \end{aligned} \quad (\text{식 } 13)$$

$u_{ik} = 1 \Leftrightarrow x_k \in u_i$ 이므로 식 (10)에서 정의된 목적 함수 J 는 다음 식 (14)와 같이 재정의된다.

$$J = (U, v) = \sum_{i=1}^c \sum_{x_k \in u_i} \|x_k - v_i\|^2 \quad (\text{식 } 14)$$

이 기법을 일반화한 것이 퍼지 군집화로, 이는 연속적 소속 함수를 만드는 하나의 데이터 점이 여러 군집에 부분적으로 소속되는 군집들의 부분적 일치를 고려한다. “퍼지”라는 개념은 데이터가 하나의 군집에 포함되거나 되지 않거나의 문제가 아니라 각 군집에 대한 소속 수준을 나타내는 연속적 값을 가지는 것을 말한다. 이 경우 소속값 u_{ik} 는 식 (13)의 $u_{ik} \in \{0,1\}, \forall_{i,k}$ 대신에 식 (15)와 같은 조건을 만족해야 하며, 목적함수는 식 (16)과 같이 주어진다[1]. $m \in [1, \infty)$ 은 퍼지를 위한 가중치 파라미터로, m 이 커질수록 소속값들 간의 차가 커짐으로써 빠르게 수렴된다.

$$0 \leq u_{ik} \leq 1, \forall_{i,k} \quad (\text{식 } 15)$$

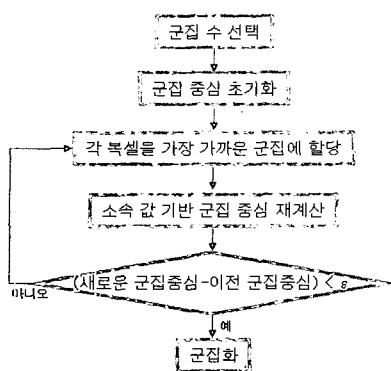
$$J = (U, v) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2 \quad (\text{식 } 16)$$

퍼지 c-means의 목적 함수를 최소로 하는 소속 값과 중심 값은 식 (17)과 같이 u_{ik} 와 v_i 에 의해 계산된다. k-means와 비교하여 퍼지 c-means는 퍼지 파라미터에 의한 예측된 군집 중심의 계산과 소속 할당을 위한 갱신규칙에 있다. (그림 3)은 퍼지 c-means 군집화에 의한 영상 분할 과정을 나타낸다.

$$u_{ik} = \left[\sum_{j=1}^c \left(\frac{\|x_k - v_j\|}{\|x_k - v_i\|} \right)^{\frac{2}{m-1}} \right]^{-1}, \quad v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (\text{식 } 17)$$

이 알고리즘은 목적함수 J 의 지역적 최소값 또는 안장점(saddle point)으로 수렴된다. 식 (18)과 같은 종료조건을 만족하지 않는다면 새로운 중앙값을 식 (17)로부터 구한 후 소속 값을 구하는 작업을 반복한다.

$$E = \sum_{i=0}^n \sum_{j=0}^c (u_i(x_j)_{new} - u_i(x_j)_{old}), E \leq \epsilon. \quad (\text{식 } 18)$$



(그림 3) 퍼지 c-means 군집화에 의한 영상 분할 과정

퍼지 c-means 군집화의 목적함수는 특정 군집에 대해 중심에 가까울수록 높은 소속 값이 할당되고, 중심에서 멀어질수록 낮은 소속 값이 할당될 때 최소화된다. 군집화 후 각 데이터는 각 군집에 대한 소속 값과 상관관계가 성립되므로, 식 (18)이 만족될 때, 각 데이터에 가장 높은 소속 값을 가지는 군집을 할당함으로써 데이터의 분할이 수행된다[9].

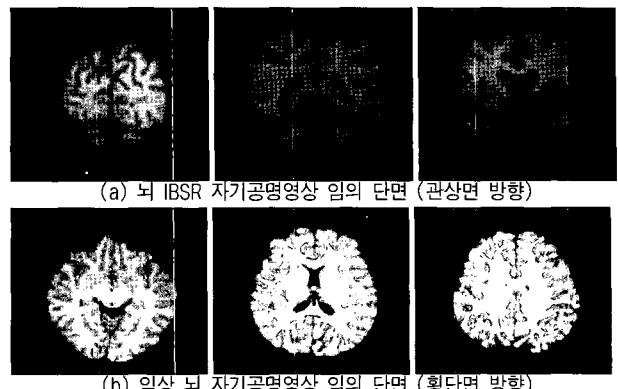
4.2 군집 통합에 의한 구조적 분할 최적화

해부학적 지식 기반 군집화의 기본 개념은 과도한 군집화에 의해 생성된 관심영역을 반복적으로 분류하고 레이블링하는 것이다[6]. 일반적으로 초기 군집화 단계에서 구조의 개수보다 많은 수의 군집으로 영상 데이터를 분류하게 되는데 이는 서로 다른 영역이 하나의 군집으로 잘못 분류되는 경우를 감소시킨다. 이러한 단계는 뇌 영상과 같이 서로 다른 영역이 일부 특성에서 매우 가깝거나 영역 내 명암도 분포 또는 평균치가 유사한 다른 영역이 존재함으로 인해 경계 영역이 제대로 분리되지 않아 여러 조작이 하나의 군집에 할당되는 경우 필수적이다. 일반적으로 뇌 영상의 경우 경계 영역을 정확하게 분리하기 위해서는 해부학적 구조의 2배수 정도의 군집 개수를 지정한다. 또한 과도하게 분할된 여러 군집을 통합하는 과정이 비록 해부학적 사전 지식을 필요로 하지만, 잘못 분리된 군집을 수동으로 분리하는 것 보다 간단한 작업이기 때문에 분할 정확도 및 수행시간 면에서 효율적이라고 볼 수 있다.

5. 구현 및 결과

5.1 구현 환경 및 실험 영상

제안한 구조적 분할 기법은 Pentium IV [3.4GHz CPU, 2GB RAM, Windows 2000 professional] 플랫폼 상에서 Visual C++ 언어, GSL (GNU Scientific Library)를 사용하여 구현하였다. 실험에 사용한 뇌 영상 데이터는 하버드 의과대학 매사추세츠 병원에서 인터넷을 통해 서비스하는 IBSR (Internet Brain Segmentation Repository)[16]으로부터 획득한 $256 \times 256 \times 60$ 크기의 T1 자기공명영상과 삼성서울 병원으로부터 획득한 $256 \times 254 \times 108$ 크기의 실제 임상용 1.5 Tesla T1 자기공명영상이다. (그림 3)은 실험영상 중 일



(그림 4) 실험 영상

부 단층영상을 나타낸 것이다.

5.2 구현 및 실험 결과

본 연구에서는 응집성 향상 필터링과 퍼지 c-means 군집화를 통한 뇌 영상의 구조적 분할 기법을 제시하였다. 그림 5는 IBSR 영상에 대해 영상 명암도 히스토그램 정규화 수행 후 각각 다른 스케일 스페이스 필터링 적용에 따른 영상 향상 결과를 비교하여 보여주고 있으며, (a)-(c)는 가우시안 필터링 적용 결과, (d)-(f)는 Perona와 Malik에 의해 제안된 비등방성 확산 필터링 적용 결과이고, (g)-(i)는 본 연구에서 군집화 단계 이전에 적용한 응집성 향상 확산 필터링 적용 결과이다. 가우시안 필터링과 일반 비등방성 확산 필터링에 비해 응집성 향상 확산 필터링을 적용한 결과가 잡음을 약화시키고 영역 경계를 뚜렷하게 강화하는 효과를 보인다.

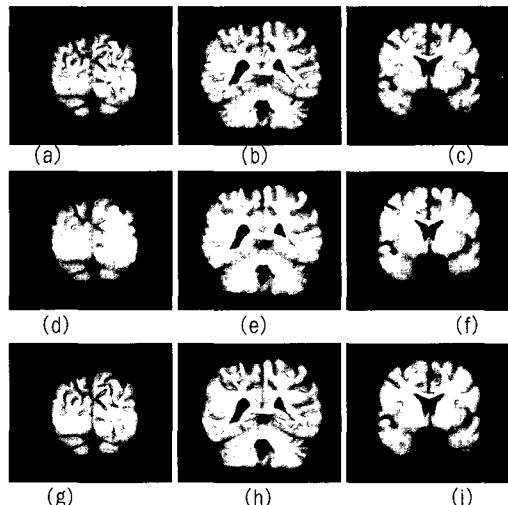
(그림 6)은 (그림 5)에서 얻어진 향상된 영상에 대하여 퍼지 c-means 군집화를 적용하여 백질과 회백질 영역으로 분리한 결과를 나타낸다. 군집의 수는 7개로 설정하였고, 명암도 오름차순 기준으로 1-5번 째 군집에 할당된 영역은 회백질 영역(청록색), 6, 7번 째 군집에 할당된 영역은 백질 영역(노란색)으로 통합하여 분리하였다. (a)-(c)는 필터링을 적용하지 않은 군집화 결과를 나타내며, (d)-(f), (g)-(i), (j)-(l)는 각각 가우시안 필터링, 일반 비등방성 확산 필터링, 응집성 향상 확산 필터링 적용 후 군집화를 수행한 결과를 나타낸다. 가우시안 필터링과 일반 확산 필터링을 이용한 분할 결과의 경우, 잡음에 의한 영향은 줄어들었으나 백질로 분리된 영역이 끊어져 나타나거나 경계 영역이 모호하게 분할되는 결과를 보임에 반해, 응집성 향상 필터링 적용 결과는 경계 영역에서 뚜렷하게 분할됨을 보인다.

(그림 7)은 임상 뇌 자기공명영상에 대하여 (그림 6)과 같이 각각 다른 필터링을 적용한 후 퍼지 c-means 군집화 기법을 적용한 결과를 비교하여 나타낸다. 군집의 개수는 동일하게 7개로 설정하였고, 1번 째 군집이 뇌척수액(자홍색), 2-5번 째 군집이 회백질(청록색), 6, 7번 째 군집이 백질(노란색)에 각각 통합, 대응되었다.

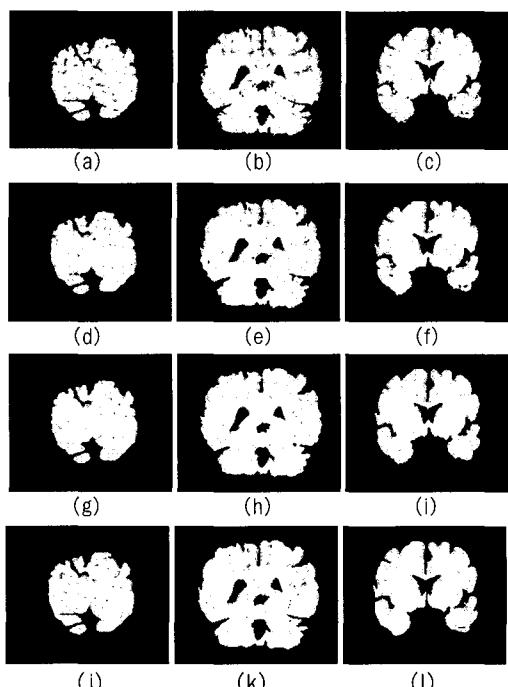
본 연구에서 제시한 뇌 영상 구조적 분할기법의 정확도 검증을 위해 각각의 필터링과 퍼지 c-means 군집화에 의해 분할된 각 구조별 블록 데이터에 대하여 수동 분할결과와의 일치 비율을 계산하였다. IBSR 영상의 분할 기준으로는

IBSR에서 함께 제공되는 백질, 회백질로만 분할된 영상을 기준으로 하고 임상 자기공명영상은 전문가 수동분할 결과를 비교 기준으로 삼았다. 각 기법에 의한 분할 정확도 비율은 <표 1>과 같다. 분할 오차는 Tanimoto 계수[10]에 의해 계산되었으며, 이 계수는 대상 기법 또는 기준 기법에 의해 동일 군집으로 분류된 복셀 개수에 대한 두 기법에 의해 동시에 분류된 복셀 개수의 비율을 나타낸다.

실험 결과, 가우시안 필터링 또는 Perona와 Malik에 의해

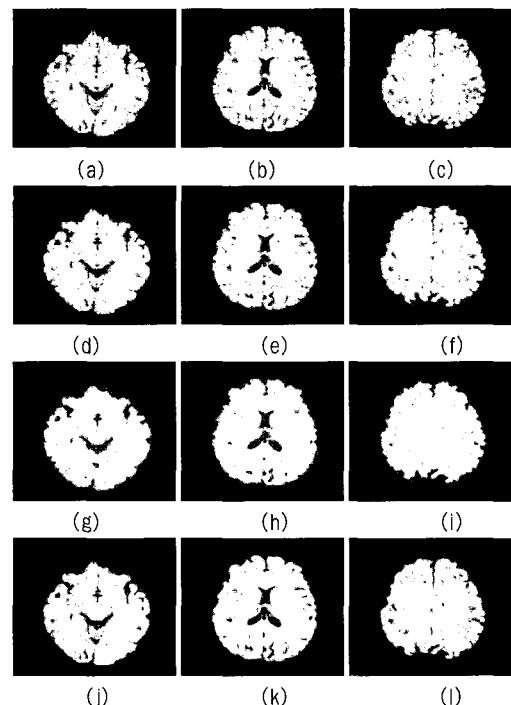


(그림 5) 필터링 적용에 따른 IBSR 자기공명영상 향상 결과 비교 ((a)-(c) 가우시안 필터링, (d)-(f) 일반 비등방성 확산 필터링, (g)-(i) 응집성 향상 필터링)



(그림 6) 필터링 종류에 따른 IBSR영상의 퍼지 c-means 군집화 결과 비교 ((a)-(c) 필터링 적용하지 않은 경우, (d)-(f) 가우시안 필터링, (g)-(i) 일반 비등방성 확산 필터링, (j)-(l) 응집성 향상 필터링)

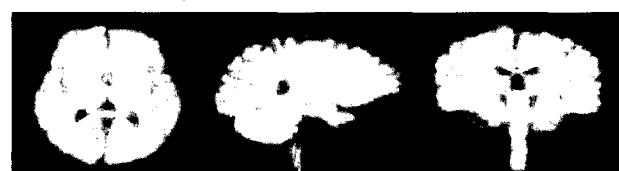
제안된 일반 비등방성 확산 필터링과 퍼지 c-means 군집화를 통해 얻어진 분할결과에 비해 제안 기법에 의해 분할된 결과가 보다 정확함을 알 수 있다. 특히 백질, 회백질과 같이 상대적으로 식별이 용이한 영역뿐 아니라 뇌척수액 영역과 같이 분할이 어려운 영역에서 보다 정확한 분할 결과를 보였다. (그림 8)은 제안기법에 의해 구조적으로 분할된 임상 자기공명영상의 볼륨 렌더링 결과 단면 일부를 보여주고 있다.



(그림 7) 필터링 종류에 따른 임상 자기공명영상의 퍼지 c-means 군집화 결과 비교 ((a)-(c) 필터링 적용하지 않은 경우, (d)-(f) 가우시안 필터링, (g)-(i) 일반 비등방성 확산 필터링, (j)-(l) 응집성 향상 필터링)

<표 1> 수동분할 결과와의 영역별 부분적 일치 비율

데이터	필터링	영역별 일치 비율		
		가우시안 필터링 + 군집화	일반 비등방성 확산 필터링 + 군집화	제안 기법
IBSR 영상	백질 영역	0.8332	0.8451	0.8630
	회백질 영역	0.9137	0.9453	0.9553
임상 영상	백질 영역	0.9636	0.9535	0.9814
	회백질 영역	0.8535	0.8825	0.9306
	뇌척수액 영역	0.6903	0.4943	0.7473



(그림 8) 뇌 자기공명영상 구조적 분할 3차원 렌더링 결과

6. 결론 및 향후 연구

본 연구에서는 복잡한 구조를 가지는 뇌 영상에 대하여 잡음을 약화시키고 영상 경계를 강화하는 필터링을 통한 폐지 군집화 기법을 제안함으로써 백질, 회백질, 뇌척수액 등 뇌 내부 구조의 분할 정확도를 향상시키고자 하였다. 제안 기법에 대한 실험 결과는 수동 분할영상과의 일치 비율에 있어서 제안 기법이 기존 기법에 비해 향상된 정확도를 나타내었다. 또한 복잡한 구조에 있어서의 불연속성을 거의 보이지 않음으로써 시각적으로 견고한 결과를 보였으며, 이는 사용자 수동 후처리를 최소화함으로써 분할 결과의 재생산성 및 효율성을 보장할 뿐 아니라 수행시간을 크게 줄일 수 있다.

향후 연구로는 스케일 스페이스 계층구조를 이용한 다중 스케일 필터링과 군집화 기법을 적용함으로써 잡음에 견고하고 보다 신속하게 수행되는 구조적 분할 기법을 제안할 필요가 있다. 또한 통계학적 정보 또는 평균화 영상을 이용하여 보다 미세한 뇌 하부 구조의 자동, 반자동 분할을 위한 기법을 제시하고자 한다.

참 고 문 헌

- [1] Milan Sonka, J. Michael Fitzpatrick, "Handbook of Medical Imaging, Vol.2: Medical Image Processing and Analysis", SPIE Press, 2000.
- [2] Mark S. Nixon, Alberto S. Aguado, "Feature Extraction and Image Processing", Elsevier, 2005.
- [3] M. Stella Atkins and Blair T. Mackiewich, "Fully Automatic Segmentation of the Brain in MRI", IEEE Transactions on Medical Imaging, Vol.17, No.1, pp.98-107, 1998.
- [4] 윤옥경, 김동희, 박길홍, "스케일 스페이스 필터링과 퍼지 클러스터링을 이용한 뇌 자기공명영상의 분할", 멀티미디어학회 논문지 제3권 제4호, 2000.
- [5] Yee Leung, Jiang-She Zhang, and Zong-Ben Xu, "Clustering by Scale-space Filtering", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.22, No.12, pp.1396-1410, 2000.
- [6] Matthew C. Clark, Lawrence O. Hall, Dmitry B. Goldgof, et al., "MRI Segmentation using Fuzzy Clustering Techniques", IEEE Engineering in Medicine and Biology, pp.730-42, 1994.
- [7] Wanlin Zhu, Tianzi Jiang, "Automation Segmentation of PET Image for Brain Tumors", IEEE Nuclear Science Symposium & Medical Imaging Conference, 2003.
- [8] Azad Shademan, Hamid Soltanian-Zadeh, "Information Fusion Approach for Detection of Brain Structure in MRI", SPIE Medical Imaging, 2002.
- [9] Alan Wee-Chung Liew, and Hong Yan, "An Adaptive Spatial Fuzzy Clustering Algorithm for 3-D MR Image Segmentation", IEEE Transactions on Medical Imaging, Vol.22, No.9, pp.1063-75, 2003.
- [10] M.Y. Siyal, Lin Yu, "An Intelligent Modified Fuzzy C-means Based Algorithm for Bias Estimation and Segmentation of Brain MRI", Pattern Recognition Letters, Vol.26, pp.2052-62, 2005.

- [11] Pietro Perona and Jitendra Malik, "Scale-space and Edge Detection using Anisotropic Diffusion", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.12, No.7, pp.629-39, 1990.
- [12] Yongjian Yu and Scott T. Acton, "Speckle Reducing Anisotropic Diffusion", IEEE Transactions on Image Processing, Vol.11, No.11, pp.1260-70, 2002.
- [13] Joachim Weickert, "Coherence-enhancing Diffusion Filtering", International Journal of Computer Vision, Vol.31, No.2, pp.111-27, 1999.
- [14] Joachim Weickert, "Multiscale Texture Enhancement", Computer Analysis of Images and Patterns, Lecture Notes in Computer Science, Vol.970, pp.230-37, 1995.
- [15] Khaled Z. Abd-Elmoniem, Abou-Bakr M. Youssef, and Yasser M. Kadah, "Real-time Speckle Reduction and Coherence Enhancement in Ultrasound Imaging via Nonlinear Anisotropic Diffusion", IEEE Transactions on Biomedical Engineering, Vol.49, No.9, pp.997-1014, 2002.
- [16] IBSSR(Internet Brain Segmentation Repository), <http://www.cma.mgh.harvard.edu/ibsr>.
- [17] Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification", John Wiley & Sons. 2001.



김민정

e-mail : kimmj@ewhain.net

2000년 이화여자대학교 컴퓨터학과(학사)

2002년 이화여자대학교 컴퓨터학과(석사)

2002년~현재 이화여자대학교 컴퓨터학과
박사과정

관심분야: 의료영상처리, 영상정합, 영상가
시화, 가상현실 등



이정민

e-mail : tlseo@ewhain.net

2004년 숭실대학교 컴퓨터학과(학사)

2006년 이화여자대학교 컴퓨터학과(석사)

2006년~현재 삼성전자 사원

관심분야: 의료영상처리, 문자영상처리,
가상현실 등



김명희

e-mail : mhkim@ewha.ac.kr

1979년 서울대학교 계산통계학과(석사)

1986년 독일 괴팅겐대학교 전자계산학과
(박사)

1987년~현재 이화여자대학교 컴퓨터학과
교수

1999년~현재 이화여자대학교 컴퓨터 그래픽스/가상현실 연구센터
센터장

관심분야: 의료·문자영상처리, 혼합·가상현실, 컴퓨터 그래픽스