

직관적 퍼지 C-평균 모델을 이용한 자기 공명 영상 분할 MRI Data Segmentation Using Fuzzy C-Mean Algorithm with Intuition

김태현*, 박동철**, 정태경*, 이윤식**, 민수영**

Tae-Hyun Kim*, Dong-Chul Park**, Taikyeong Jeong*, Yunsik Lee**, Soo-Young Min**

Abstract

An image segmentation model using fuzzy c-means with intuition (FCM-I) model is proposed for the segmentation of magnetic resonance image in this paper. In FCM-I, a measurement called intuition level is adopted so that the intuition level helps to alleviate the effect of noises. A practical magnetic resonance image data set is used for image segmentation experiment and the performance is compared with those of some conventional algorithms. Results show that the segmentation method based on FCM-I compares favorably to several conventional clustering algorithms. Since FCM-I produces cluster prototypes less sensitive to noises and to the selection of involved parameters than the other algorithms, FCM-I is a good candidate for image segmentation problems.

요 약

직관적 퍼지 c-평균 군집화 모델을 이용하는 자기공명 영상의 분할 방법이 본 논문에서 제안되었다. 본 논문에서 채택하는 fuzzy c-means with intuition (FCM-I)은 잡음의 영향을 줄이기 위하여 직관이라는 척도를 사용한다. 실제적 자기 공명 영상에 대해 영상 분할의 실험을 수행하고 기존의 몇몇 군집화 알고리즘과 성능을 비교하였다. 기존의 모델들과 성능을 비교한 결과, FCM-I 기반의 분할 방법은 잡음과 필요한 계수의 선택에 대해 상대적으로 강인하여, 영상 분할에 유용한 모델이 될 수 있음을 확인할 수 있었다.

Key words : Data Clustering, Clustering algorithm, MRI Segmentation

1. 서론

세계적으로 발생 횟수가 많은 뇌 질환으로 뇌졸중, 치매, 간질 등 여러 가지가 있으며, 그 중 뇌졸중과

치매는 4대 사인에 속할 만큼 많이 발생하고 있다. 이러한 뇌 관련 질병에 대한 진단 및 시술을 위하여 사용되는 자기 공명 영상(Magnetic Resonance Image)은 X-Ray 영상, 초음파 영상, CT영상 등의 다른 의료영상에 비해 환자의 해부학적 형태에 대해 더욱 정확한 정보를 제공한다. 이러한 자기공명 영상의 영상 처리 및 진단을 위한 영상 개선은 양질의 진단과 직결되기 때문에 많은 연구가 수행되어왔다[1-3]. 윤곽선 및 경계선 추출, 영상 개선 등에서 많은 연구가 수행되어 왔으며[3], 인식과 관련된 연구로는 뇌조직이나 심장과 같은 부분에서 특정 해부학적인 객체의 인식을 중심으로 연구가 진행되고 있다.

특히 자동적 의료영상 처리분야에서 연구되는 빠르고 정확한 영상 분할 기법의 적용은 환자의 진단에 큰 도움이 될 것이다. 기존의 여러 영상 분할 방법

*명지대학교 전자공학과
(Dept. of Electronics Engineering, Myong Ji University)

**전자부품연구원 시스템반도체연구본부
(System IC R&D Division, KETI)

★ 교신저자 (Corresponding author)

※본 연구는 2010년 교육과학기술부의 재원으로 한국연구재단의 지원(2010-0009655) 및 2011년 지식경제부 산업원천기술개발사업의 지원(10040191)을 받아 수행된 연구임.

接受日:2011年 06月 27日, 修正完了日: 2011年 07月 29日
掲載確定日: 2011年 08月 04日

중 경계(Thresholding) 기법은 영역의 동질성을 보장하지만 경계기법이 픽셀을 토대로 수행되기 때문에 영상 영역에 대한 연관성이 없이 단순한 음영 차에 의해 영역을 분할한다. 한편 신경망 알고리즘을 통한 영상 분할의 수행 역시 활발히 연구되어왔는데, 신경망을 이용한 영상 분할의 경우 영상 영역에 대한 연관성, 수행 결과의 수렴도에서 다른 방법들 보다 좋은 결과를 얻을 수 있으며 높은 정보압축률 또한 갖고 있다. Kohonen이 제안한 SOM(Self-Organizing Map) 알고리즘[4]은 일찍이 영상 분할에 사용이 시도되었으나[5], 결과의 수렴을 보장받을 수 없고 잡음에 대한 면역력이 없다는 문제점을 갖고 있었다. 기존의 알고리즘들이 입력 데이터와 가장 유사한 승자 뉴런만을 갱신하는 반면에, CNN(Centroid Neural Network) 알고리즘에서는 승자 뉴런을 입력 데이터와 가까이, 패자 뉴런을 입력 데이터에서 멀리 위치하도록 뉴런의 갱신이 이루어진다. CNN알고리즘은 학습완료 후 군집의 대표가 해당 군집에 소속된 데이터들의 한 가운데 위치하게 되는데, 이로 인해 각 군집의 데이터 일부가 서로 유사한 경우 이를 효과적으로 학습할 수 없다는 단점을 가지며, 잡음이 많은 데이터에 대한 면역력 또한 갖지 못한다는 단점이 있다.

기존 알고리즘들의 이러한 문제점들을 해결하기 위하여 적은 초기 매개변수로 실시간 적용이 수월하고, 수행시간에 비하여 우수한 영상 개선 효과를 보이며, 잡음에 대한 면역이 강한 알고리즘을 이용하는 자기공명 영상 분할기법이 필요로하게 되는데, 본 논문에서는 기존에 제안되었던 군집화 알고리즘과의 비교 실험으로 적은 초기 매개변수와 빠른 속도로, 잡음에 대한 면역력이 높은 영상 분할의 수행 방법을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 영상 분할을 위해 사용되었던 SOM, FCM, CNN 그리고 PFCM 알고리즘을 간략하게 정리하며, 3장에서는 본 논문에서 채택된 FCM-I 모델을 설명한다. 또한 4장에서는 자기공명 영상을 이용한 실험을 이용하여 FCM-I 기반의 영상분할 기법의 유용성을 살펴봄, 5장에서는 결론을 기술하였다.

II. 영상 분할을 위한 군집화 알고리즘

1. Self Organizing Map (SOM)

SOM 알고리즘은 Teuvo Kohonen에 의해 개발되어 기초 신경망 이론의 발전에 기여했다. 분류되지 않은 데이터 집합을 $X=(x_1, x_2, \dots, x_N)$, i 뉴런의 연결 가중치는 $w_i=(w_{i1}, w_{i2}, \dots, w_{iN})$ 로 표현하며, 연결 가중치 벡터들의 초기 값은 임의의 값으로 할당한다. 입력

데이터와 출력 뉴런 사이의 유사거리 측정은 식(1)과 같이 유클리드 거리(Euclidean Distance)를 사용하며, 입력 데이터와 가장 유사한 승자 뉴런은 식(2)를 통해 선택된다.

$$\|x - w_i\| = \sqrt{\sum_{p=1}^N (x_p - w_{ip})^2} \quad (1)$$

$$\|x - w_i\| = \min_p \|x - w_p\| \quad (2)$$

입력 데이터와 가장 유사한 승자뉴런에 대해 입력 데이터에 가까워지도록 연결 가중치를 식(3)에 따라 갱신한다.

$$w_{ij}(n+1) = \begin{cases} w_{ij} + \eta(n)[x_{ij} - w_{ij}(n)] & , i \text{ is in } N_d(n) \\ w_{ij}(n) & , \text{otherwise} \end{cases} \quad (3)$$

$$\eta = \eta_0 \left(1 - \frac{n}{T}\right) \quad (4)$$

여기서 T는 총 반복 학습횟수를 나타낸다.

SOM 알고리즘은 식(3)을 이용한 반복 학습을 통해 최적화된 결과를 얻을 수 있다. 그러나 SOM 알고리즘은 수렴을 보장할 수 없고, 수행중인 SOM의 결과를 함수로 나타낼 수도 없으며, 잡음에 대한 면역력이 없다는 문제점을 갖고 있다.

2. Fuzzy C-Means (FCM)

Bezdek에 의해 제안되어 널리 사용되고 있는 FCM 알고리즘은 목적함수로 식(5)과 같이 정의 된다[6].

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

여기서 d_{ij} 는 입력 x_j 와 군집의 코드벡터인 v_i 사이의 Euclidean 거리를 나타내며, u_{ji} 는 군집(i)와 입력(j)사이의 멤버십 등급이다. m은 가중지수, c는 군집의 수, n은 입력데이터의 수이다. 또한 멤버십 등급의 합은 식(6)와 같이 항상 1로 제안한다.

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

Bezdek은 목적함수를 최소화시키기 위한 조건을 다음과 같이 제안하였다. 식(7), (8)은 멤버십 등급과 각 군집의 코드벡터를 갱신하기 위한 식이다.

$$u_{ji} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{kj}}{d_{ij}}\right)^{\frac{2}{m-1}}}, \quad 1 \leq i \leq c, 1 \leq k \leq n \quad (7)$$

$$v_i = \frac{\sum_{j=1}^n u_{ji}^m x_j}{\sum_{j=1}^n u_{ji}^m}, \quad 1 \leq i \leq c \quad (8)$$

FCM에서는 식(7)과 식(8)을 반복적으로 실행하여, 코드벡터를 학습시켜 최적화된 군집결과를 얻는다[7].

3. Centroid Neural Network (CNN)

CNN 알고리즘은 k-means와 SOM 같은 기존 알고리즘이 매 학습마다 연결 가중치를 수정하는 것과 달리, 승자와 패자의 연결 가중치를 각각 설정하여 현재와 이전 학습에서의 뉴런의 상태에 대한 정보를 통해 가중치를 변화시킨다. CNN의 목적함수는 다음의 식(9)와 같이 표현된다.

$$\min(W) \{ \mathcal{J}(W; X) = \sum_{i=1}^M \sum_{j=1}^{N_i} \|X_i(j) - W_i\|^2 \} \quad (9)$$

분류되지 않은 데이터 집합을 $X = (x_1, x_2, \dots, x_N)$, 뉴런 i 의 연결 가중치는 $w_i = (w_{i1}, w_{i2}, \dots, w_{iN})$ 로 표현했을 때 승자뉴런 j 와 패자뉴런 i 의 연결 가중치 갱신은 다음과 같다.

$$w_j(n+1) = w_j(n) + \frac{1}{n_j+1} [x(n) - w_j(n)] \quad (10)$$

$$w_j(n+1) = w_j(n) - \frac{1}{n_j-1} [x(n) - w_j(n)] \quad (11)$$

여기서 $w_j(n)$ 과 $w_i(n)$ 은 승자 뉴런과 패자 뉴런의 연결 가중치를 표현하며, N_j 와 N_i 는 현재 학습에서 군집 j, i 에 속한 데이터의 수를 의미한다. 그러나 CNN 알고리즘은 학습 완료 후 군집의 대표값이 해당 대표값에 소속된 데이터들의 한 가운데 위치하게 되며, 만약 서로 다른 군집의 데이터들 일부가 유사하여 겹치게 되면 이를 효과적으로 분류할 수 없게 된다. 또한 잡음에 대한 면역성 역시 보장받지 못한다. CNN에 대한 보다 자세한 내용은 [8]에서 찾을 수 있다.

4. Possibilistic Fuzzy C-Means(PFCM)

PFCM 알고리즘에서는 기존 알고리즘들의 문제를 해결하기 위해 새로운 방법으로 문제에 접근하였다. FCM 알고리즘에서 멤버십을 계산할 때, 하나의 데이터에 대해 모든 대표값들을 이용하여 계산하지만, PCM 알고리즘에서는 전형성을 계산할 때, 하나의 데이터에 대해 하나의 대표값만을 이용하므로 PFCM 알고리즘에서는 이러한 성질을 이용하여 새로운 모델을 제안하였다. 식(12)는 PFCM 알고리즘의 목적함수이다[9].

$$\min(U, T, V) \left\{ \sum_{k=1}^c \sum_{i=1}^n (au_{ik}^m + bt_{ik}^n) D_{ik}^2 + \sum_{k=1}^c \gamma_i \sum_{i=1}^n (1 - t_{ik})^\eta \right\} \quad (12)$$

여기서 멤버십은 식(6)을 만족하며, $0 \leq u_{ik}, t_{ik} \leq 1$, $a > 0, b > 0, m > 1, \eta > 1, 1 < c < n$ 이다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{jk}}{D_{ik}} \right)^{\frac{2}{m-1}}}, 1 \leq i \leq c, 1 \leq k \leq n \quad (13)$$

$$t_{ik} = \frac{1}{1 + \left(\frac{b}{\gamma_i} D_{ik}^2 \right)^{\frac{1}{\eta-1}}}, 1 \leq i \leq c, 1 \leq k \leq n \quad (14)$$

$$V_i = \frac{\sum_{k=1}^n (au_{ik}^m + bt_{ik}^n) X_k}{\sum_{k=1}^n (au_{ik}^m + bt_{ik}^n)}, 1 \leq i \leq c \quad (15)$$

PFCM 알고리즘은 목적함수를 유도하기 위해 PCM 알고리즘에서 사용되는 전형성과 FCM 알고리즘에서 사용하였던 멤버십을 사용하며, 이를 바탕으로 식(15)를 유도해 내었다. PFCM 알고리즘의 시간복잡도는 $O(N)$ 이다. 이 알고리즘을 통해 FCM 알고리즘의 잡음 문제, PCM 알고리즘의 매개변수 설정 문제 및 초기 값 문제에 대해 개선된 성능을 보여 준다[10]. 그러나 여전히 잡음 문제를 안고 있으며, PFCM 또한 사용자 매개변수의 수가 많고, 계산량이 상대적으로 많다.

III. 직관적 Fuzzy C-Means 모델

2장에서 살펴본 알고리즘들은 각각의 장점과 함께 문제점을 가지고 있다. SOM, FCM, CNN 등은 잡음에 대한 면역성을 보장할 수 없으며, PFCM 알고리즘은 FCM 알고리즘의 잡음 문제를 제거하기 위하여 제안되었으나, 잡음 문제 이외의 더 많은 문제점들을 만들고 있다. 이러한 문제점을 보다 효과적으로 제거하기 위해 직관적 C-Means (FCM-I) 모델을 제안되었다[11]. FCM-I 모델에서는 식(16)과 같이 새로운 목적함수를 정의 하였다.

$$\min(I, V) \{ J_m(I, V, X) = \sum_{k=1}^c \sum_{i=1}^n (I_{ik}) \|X_k - V\|^2 \} \quad (16)$$

기본적으로 FCM 알고리즘의 목적함수와 동일하나 멤버십 대신 직관적인 멤버십(Intuitive Membership : I_{ik})을 사용한다. I_{ik} 는 기존의 멤버십을 이용하여 식(17)과 같이 계산된다.

$$I_{ik} = \sum_{l=1}^c (u_{ik})^\eta |u_{ik} u_{lk}|, 1 \leq i \leq c, 1 \leq k \leq n \quad (17)$$

I_{ik} 는 식(17)을 통해 잡음(Outlier)에 대하여 높은 멤버십 값을 부여했던 FCM 알고리즘을 개선하기 위해 고안되었으며, 각 군집에 대해 서로 배타적인 성격을 가지게 되어 직관적인 분류 효과를 가져 올 수 있다. 또한 η 를 이용하여 멤버십의 가중치 정도를 선택할 수 있다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ik}}{D_{jk}}\right)^{\frac{2}{m-1}}}, 1 \leq i \leq c, 1 \leq k \leq n \quad (18)$$

멤버십 함수는 기존의 FCM 알고리즘의 멤버십을 사용하며 식(18)과 같이 사용한다. FCM-I 모델의 대표값을 학습하기 위해 식(19)를 사용하며, 식(19)는 아래와 같이 유도 된다.

$$\begin{aligned} J_i(I, V, X) &= \sum_{k=1}^n (I_{ik})^r (X_k - V_i)^2, 1 \leq i \leq c \\ \frac{\delta J_k}{\delta V_i} &= \sum_{k=1}^n (I_{ik})^r (-2)(X_k - V_i) = 0 \\ \sum_{k=1}^n (I_{ik})^r X_k - \sum_{k=1}^n (I_{ik})^r V_i &= 0 \\ \therefore V_i &= \frac{\sum_{k=1}^n (I_{ik})^r X_k}{\sum_{k=1}^n (I_{ik})^r}, 1 \leq i \leq c \end{aligned} \quad (19)$$

FCM-I 모델은 식(18)(19)을 이용하여 반복적으로




Fig. 1. Example of MRI data (a) Original MRI data (b) MRI data with outliers

그림 1. MRI 뇌촬영 데이터의 예제 (a) 원본 MRI 데이터 (b) Outlier가 포함된 MRI 데이터

각 군집의 대표값들을 학습한다. 이 알고리즘은 식(6)와 같이 멤버십에 대한 제약조건은 여전히 존재한다. 그러나 I_{ik} 가 $2 \leq c \leq n$ 라면 식(20)의 제약조건을 갖게 되며, 이 알고리즘의 복잡도는 $O(N)$ 이다.

$$0 \leq I_{ik} \leq c-1, \forall i, k \quad (20)$$

FCM-I 모델은 FCM 알고리즘의 잡음(Outlier)을 효과적으로 제거하기 위해 만들어 졌다. 또한 PFCM 알고리즘과 달리 초기화에 민감하지 않고, 대용량 데이터에 이용가능하며, 매개변수 설정 값들이 존재 하지 않으므로 효과적이고 직관적으로 데이터를 학습하고

결과 값을 도출 할 수 있다. FCM-I에 관한 더욱 자세한 내용은 [11]에서 찾을 수 있다.

IV. 실험 및 결과

앞에서 살펴본 기존의 알고리즘들과 본 논문에서 제안하는 알고리즘의 성능을 평가하기 위하여 의학 영상 분할 분야에서 널리 사용되는 IBSR(the Internet Brain Segmentation Repository) database의 MRI(Magnetic Resonance Imaging) 데이터를 이용하여 실험을 수행하였다[12]. 실험 데이터는 그림 1에 보여지는 바와 같이, 전체 화소의 0.2%에 해당하는 Normal Distribution Noise (Salt-Pepper Noise)가 포함된 MRI 뇌 영상이다. 각 알고리즘은 실험적 방법을 통해 최상의 결과를 보여준 계수들을 이용하였다.

실험의 결과는 RMSE(Root Mean Square Error)와 SNR(Signal-to-Noise Ratio)의 두 측면에서 성능의 평가가 이루어졌다. 실험의 결과는 표 1에 요약되어 있는데, FCM-I 모델은 잡음의 영향을 가장 적게 받으며, 가장 훌륭한 영상 분할 결과를 보여주었다.




Fig. 2. (a) noisy image and Segmented images(3X) (b) SOM, (c) FCM, (d) CNN, (e) PFCM, (f) FCM-I
그림 2. 영상 분할의 결과(3배 확대영상) (a) 잡음영상 (b) SOM, (c) FCM, (d) CNN, (e) PFCM, (f) FCM-I

또한 영상의 대조도 역시 자기 공명 영상 관독에 큰 영향을 미친다. 본 논문에서 제안한 FCM-I을 이용한 영상 분할의 결과와 기존 알고리즘들의 출력 결과는 그림 2와 같다. 그림 2는 잡음을 포함한 원본 영상과 각 알고리즘의 수행 결과 영상을 3배 확대한 것이다.

그림 2에서 볼 수 있듯이 SOM, FCM, CNN 그리고 PFCM은 원본 영상의 잡음(Outlier)을 입력 데이터로 인식하며, 결과 영상에서도 그 흔적이 남아있다. 반면 FCM-I 모델의 결과 영상은 주변 영역에 비해 화소값이 지나치게 높거나 낮은 잡음 화소에 배타성을 이용하여 작은 멤버십 값을 부여하여 이를 효과적으로 제거할 수 있었다. 그림 3에서는 각 알고리즘의 수행에 대한 결과영상의 원 영상에 대한 성능을 볼 수 있는데, 각 알고리즘 당 15회의 실험 후 RMSE 와 SNR 평균값과 표준편차를 나타낸다. 각 실험에서 초기 값

Table 1. Segmentation results on MRI data with outliers by different algorithms

표 1. Outlier가 포함된 영상의 각 알고리즘별 영상 분할 결과

	SOM	FCM	CNN	PFCM	FCM-I
RMSE	14.13	14.01	13.02	7.69	5.92
SNR	25.12	25.19	25.85	30.40	32.68
parameter	$\eta=0.5$	$m=1.5$	-	$m=1.2$ $\eta=4.5$ $a=1$ $b=3$	$m=1.2$ $\eta=1.2$ $\Upsilon=1.0$

은 무작위로 설정된 값을 사용하였다. 그림 3에서 보여지듯이 FCM-I 모델은 여타 알고리즘에 비해 우수한 영상 분할 결과를 보여주며, 비교적 높은 원 영상에 대한 재구성 정도를 보여준다. PFCM의 경우 영상 분할 수행 후 원본보다 밝은 화소와 어두운 화소 사이의 차이가 적어졌음을 볼 수 있으며, 이와 같은 대조도의 저하는 곧 영상 판별력의 저하로 이어지게 된다. 반면에, FCM-I의 경우 배타성에 의한 학습 수행결과로 밝은 화소는 더 밝게, 어두운 화소는 더 어둡게 차이를 벌려 줌으로써 영상 판별력을 높여주는 것을 볼 수 있다.

V 결론

본 논문에서는 영상 분할에 효과적인 직관적 FCM 모델을 제안하였으며, 이를 의료 영상인 자기 공명 영상에 적용하였다. 기존의 알고리즘들은 화소 영역

의 동질성 문제, 영역의 연관성 문제, 매개변수 설정 문제, 잡음에 대한 면역성 문제 등을 갖고 있었으며 이를 해결하기 위해 더 많은 문제를 만들어냈다. 제안된 FCM-I 모델과 SOM, FCM, CNN, PFCM등의 기존의 알고리즘들을 의료영상 분할문제에 적용하여 유용성을 평가하기 위하여, 의학 영상 분할 분야에서 널리 사용되는 IBSR(Internet Brain Segmentation Repository) database의 데이터를 이용하여 실험을 수행하였다[12]. 실험 결과 제안된 FCM-I 모델이 기존의 알고리즘들에 비해 RMSE 와 SNR의 측면에서 매우 향상된 결과를 얻을 수 있었다. 또한, 제안된 FCM-I 모델은 기존의 알고리즘들이 가지고 있던 문제들을 효과적으로 해결하며, 특히 잡음 면역력과 대조도, 처리속도에서 유리한 결과를 확인하였다. 앞으로




Fig. 3. Comparison of segmentation result in terms of : (a) RMSE and (b) SNR

그림 3. 각 알고리즘의 영상 분할 결과 (a) RMSE (b) SNR

로 더 많은 실험을 통하여 다양한 의료영상에 적용을 기대해본다.

참고문헌

- [1] R. Turner, et al., "Challenges of imaging structure and function with MRI," *IEEE Trans. Engineering in Medicine and Biology*, vol.19, pp.42-54, 2000.
- [2] L.Amini, et al., "Automatic segmentation of thalamus from brain MRI integrating fuzzy clustering and dynamic contours," *IEEE Trans. Bio medical Engineering*, vol.51, pp.800-811, 2004.
- [3] M. Gudmundsson, E. El-Kwa, M. Kabuka, "Edge detection in medical images using a genetic algorithm," *IEEE Trans. Medical Imaging*, vol.17, pp.469-474, 1998.
- [4] T. Kohonen, "The Self-Organizing Map," *Proc. of IEEE*, Vol.78, pp.1464-1480, 1990.
- [5] C. Chuang, et al., "Application of Self Organizing Map for cerebral cortex reconstruction," *International Journal of Computational Intelligence Research*, vol.3, no.1, 2007.
- [6] J. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum, 1981.
- [7] P. Wang and H. Wang, "A Modified FCM algorithm for MRI brain image segmentation," *International Seminar of Future Bio Medical Information Engineering*, 2008.
- [8] D.-C. Park, "Centroid Neural Network for Unsupervised Competitive Learning," *IEEE Trans. Neural Networks*, vol. 11, pp.520-528, 2000.
- [9] N.R. Pal, K. Pal, and J. Bezdek, "A Possibilistic Fuzzy C-Means Clustering Algorithm," *IEEE Trans. Fuzzy Systems*, vol.13, no.4, pp.517-530, 2005.
- [10] R. Krishnapuram and J. Keller, "A Possibilistic Approach to Clustering," *IEEE Trans. Fuzzy Systems*, vol.1, no.2, pp.98-110, 1993.
- [11] D. Park, "Intuitive Fuzzy C-Means Algorithm for MRI Segmentation," *Proc. of ICISA*, 2010.
- [12] The Internet Brain Segmentation Repository (IBSR), <http://www.cma.mgh.harvard.edu/ibsr/>

저 자 소 개

박 동 철 (정회원)



1980년 : 서강대학교 전자공학과 졸업 (공학사)
1982년 : 한국과학기술원 전기 및 전자공학과 (공학석사)
1990년 : Univ. of Washington, Seattle, Dept. of Electrical Eng. (공학박사)

1990년-1994년: FIU Dept. of Eelct. and Comp. Eng. 조교수

1994년 3월~현재 : 명지대학교 전자공학과 교수.
<주관심분야> 지능 컴퓨팅, 신호처리

김 태 현 (학생회원)



2010년 : 명지대학교 정보공학과 졸업 (공학사)
2011년 : 명지대학교 대학원 전자공학과 (석사과정)

<주관심분야> 신경망, 인공지능, 신호처리, 영상처리

정 태 경 (정회원)



1992년: 명지대학교 졸업 (공학사)
2000년 : U. of Texas, Austin, Dept. of Elect. & Comp. Eng. (공학석사)
2004년 : U. of Texas, Austin, Dept. of Elect. & Comp. Eng. (공학박사)

2004년-2006년: NASA GSFC

2006년 9월~현재 : 명지대학교 전자공학과 교수
<주관심분야> 통신회로설계, 고성능반도체설계, 신호처리

이 윤 식 (정회원)

1981년 : 서강대학교 전자공학과
졸업 (공학사)
1983년 : 한국과학기술원 전자계
산학과 (공학석사)
1993년 : Univ. of South Florida
Dept. of Computer Engineering
(공학박사)

2005년 3월~현재 : 전자부품연구원 시스템 반도체
연구본부장

<주관심분야> 반도체설계자동화, FPGA, 신호처리

민 수 영 (정회원)

1987년 : 인하대학교 전자공학과
졸업 (공학사)
1993년 3월~현재 : 전자부품연구
원 시스템 반도체 연구본부 선임
연구원
<주관심분야> 자동차 통신
네트워크, 무선통신 Protocol,
시스템 소프트웨어