

평균내부거리를 적용한 퍼지 클러스터링 알고리즘에 의한 영상분할

유 현 재[†] · 안 강 식^{††} · 조 석 제^{†††}

요 약

영상분할은 컴퓨터비전 시스템에서 영상정보추출의 중요한 과정 중의 하나이다. 이 중에서 퍼지 클러스터링 방법은 영상 분할에 광범위하게 사용되고 있다. 대부분의 퍼지 클러스터링 방법으로는 FCM 알고리즘이 사용된다. 그러나 FCM 알고리즘은 클러스터의 중심과 데이터간의 거리에 의존하기 때문에 클러스터 크기가 다를 경우에는 데이터가 오분류될 수 있다.

본 논문에서는 클러스터 크기에 상관없이 데이터를 분류할 수 있는 평균내부거리를 이용한 퍼지 클러스터링 알고리즘을 제안하였다. 평균내부거리는 각 데이터로부터 해당 클러스터 중심까지의 거리를 평균한 값으로 클러스터의 크기와 밀도에 비례한다. 실험 결과를 통하여 제안된 방법이 분류 엔트로피와 적합도 함수에 의해서 좋은 결과를 보여주고 있음을 증명하였다.

Image Segmentation Based on the Fuzzy Clustering Algorithm using Average Intracluster Distance

Hyun-Jai You[†] · Kang-Sik Ahn^{††} · Seok-Je Cho^{†††}

ABSTRACT

Image segmentation is one of the important processes in the image information extraction for computer vision systems. The fuzzy clustering methods have been extensively used in the image segmentation because it extracts feature information of the region. Most of fuzzy clustering methods have used the Fuzzy C-means(FCM) algorithm. This algorithm can be misclassified about the different size of cluster because the degree of membership depends on highly the distance between data and the centroids of the clusters.

This paper proposes a fuzzy clustering algorithm using the Average Intracluster Distance that classifies data uniformly without regard to the size of data sets. The Average Intracluster Distance takes an average of the vector set belong to each cluster and increases in exact proportion to its size and density. The experimental results demonstrate that the proposed approach has the good results by classification entropy and validity function.

1. 서 론

영상분할은 영상을 그 구성 성분 또는 물체별로 나누는 작업을 말하며 컴퓨터에 의한 영상분석에서 반드시

다루어야 할 부분이다[1-4]. 영상분할방법에는 스펙트럼 해석(Spectrum analysis)방법, 이완화(Relaxation) 방법, 문턱치(Thresholding)방법 그리고 클러스터링(Clustering)을 이용한 방법 등이 있다. 클러스터링을 이용한 방법은 계산량과 메모리가 많이 필요하고 클러스터 개수를 미리 지정해 주어야 하는 문제점이 있으나 우수한 결과를 기대할 수 있어서 많이 연구되고 있

† 준회원 : (주)DMS 연구원
†† 준회원 : 한국해양대학교 대학원 제어계측공학과
††† 종신회원 : 한국해양대학교 제어계측공학과 교수
논문접수 : 2000년 6월 30일, 심사완료 : 2000년 9월 20일

다[5-9].

기존의 클러스터링 방법은 단순 클러스터링(Hard clustering)방법, FCM(Fuzzy C-Means)방법 그리고 PCM(Possibilistic C-Means)방법 등이 있다. 단순 클러스터링은 주어진 데이터간의 경계가 명확할 때 각 데이터의 유사도(similarity)에 따라 영역을 분할하는 방식이다. 따라서 경계가 명확하지 않을 때 실제 데이터간의 군집성을 묘사하기에 적절하지 않으며 데이터의 분포 성질이 손실될 수 있다.

이를 개선하기 위해, Bezdek은 각 데이터와 특정 클러스터 중심과의 거리에 소속정도를 부여하는 FCM 알고리즘을 제안하였다[10, 11]. 그러나 이 방법은 각 데이터로부터 클러스터들에 대한 소속정도의 합이 1이 되는 확률적 제약조건(Probabilistic constraint)을 이용하므로 소속함수 값이 소속성(Belonging)이나 적합성(Compatibility) 정도의 직관적인 개념과 항상 일치하지 않는다.

Krishnapuram은 소속정도를 각 데이터와 클러스터 중심간의 절대거리에만 의존하는 PCM 알고리즘을 제안하여 FCM 알고리즘이 가지는 상대성 문제를 해결하고자 하였다[6, 12]. 그러나 이 알고리즘은 각 영역에 해당하는 클러스터 크기와 초기 클러스터 중심을 사전에 알아야하므로 Scale Space Filtering과 같은 전처리 과정이 필요하다[13].

FCM 알고리즘은 각 데이터가 클러스터 중심에 속하는 소속정도를 부여하므로 데이터로부터 각 클러스터 중심까지의 거리가 같으면 같은 소속정도를 가진다. 그러므로 중심탐색에 있어 클러스터 크기가 다른 경우에는 문제점이 발생한다. 이러한 문제점을 해결하기 위하여 본 논문에서는 평균내부거리를 적용한 퍼지 클러스터링 알고리즘을 제안하였다.

제안된 알고리즘은 각 데이터로부터 내부클러스터까지의 거리에 의해 소속정도를 부여하고 중심을 탐색한다. 내부클러스터는 평균내부거리 안에 속하는 데이터 집합을 말하며 클러스터의 크기와 밀도에 비례한다. 그러므로 소속정도를 클러스터 크기에 상관없이 균일하게 부여할 수 있었고 중심탐색능력도 향상시킬 수 있었다. 그리고 제안된 퍼지 클러스터링 알고리즘을 영상에 적용하여 영상분할을 시도하였고 분할된 영상의 평가는 Bezdek과 Xie-Beni의 적합도 함수를 적용한 F -함수(F -function)를 이용하였다[11, 14].

2. FCM 알고리즘

FCM 알고리즘은 퍼지 클러스터링 알고리즘 중에서 가장 폭넓게 사용되는 알고리즘이다. 이 알고리즘은 식 (1)과 같이 각 데이터와 각 클러스터 중심과의 거리를 고려한 유사도를 측정한 후 유사도에 기초한 목적함수를 최소화할 수 있도록 데이터 집합을 분할하는 알고리즘이다.

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^m \|x_j - v_i\|^2 \quad (1)$$

여기서, 모든 데이터 j 에 대해 $\sum_{i=1}^c u_{ij} = 1$ 이다. n 은 데이터의 개수, c 는 클러스터의 개수 그리고 m 은 퍼지 정도를 나타내는 가중치 지수이다. $X = \{x_1, x_2, \dots, x_n\}$ 인 데이터 벡터 집합과 $V = \{v_1, v_2, \dots, v_c\}$ 인 클러스터 중심들 사이의 소속 정도를 $c \times n$ 인 행렬 $U (= u_{ij})$ 로 나타낼 수 있다.

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

여기서, $d_{ij} = \|v_i - x_j\|$,

($i = 1, 2, \dots, c$; $j = 1, 2, \dots, n$),

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

식 (2)에서 u_{ij} 는 j 번째 데이터가 i 번째 클러스터에 속하는 소속정도를 나타내고, 식 (3)에서 v_i ($1 \leq i \leq c$)는 i 번째 클러스터 중심이다. 여기서 m 이 1보다 큰 경우에 모든 i, j 에 대해서 $v_i \neq x_j$ 를 만족한다면 위의 식을 만족할 때만 (U, V) 가 J_m 의 최소화를 가능하게 한다. 이 알고리즘은 식 (2)와 식 (3)의 과정을 반복하므로 J_m 은 어떤 정해진 값으로 수렴한다.

이 알고리즘은 데이터로부터 클러스터 중심에 이르는 거리의 합을 최소화하는 조건에 의해 소속정도가 부여된다. 이렇게 부여된 소속정도에 의해 중심 탐색이 이루어지므로 클러스터 크기가 같은 경우에는 군집화가 잘 이루어지지만, 클러스터 크기가 다른 경우에는 작은 클러스터에 많은 소속정도를 주어 잘못된 군


집화가 이루어진다.

3. 평균내부거리를 적용한 퍼지 클러스터링 알고리즘에 의한 영상분할


본 논문에서는 클러스터 크기가 다른 경우에 잘못된 소속정도를 가지는 FCM 알고리즘의 문제점을 개선하고자 평균내부거리를 적용한 퍼지 클러스터링 알고리즘을 제안하였다.

제안된 알고리즘은 먼저 평균내부거리 안쪽에 속하는 데이터들의 집합을 내부클러스터라 정의한다. 그리고 각 데이터로부터 내부클러스터까지의 거리에 의존하여 소속정도를 부여한다. 그러므로 클러스터의 크기에 상관없이 균일하게 소속정도를 부여하고 각 클러스터 중심을 정확하게 찾을 수 있다.

(그림 1)에서 C1과 C2는 각 클러스터의 중심이고 a와 b는 각 클러스터의 평균내부거리이다. d1과 d2는 데이터로부터 클러스터 중심까지의 거리를 나타내고 X1, X2는 각 클러스터에서 동일한 소속정도를 나타낸다. (a)의 FCM 알고리즘에서 X1은 큰 클러스터에 가깝게 위치하고 있지만 동일한 소속정도를 부여한다. 하지만 (b)의 제안된 알고리즘에서는 내부클러스터를 고려하므로 클러스터 크기가 다르더라도 균일한 소속정도를 부여한다.



(a) FCM 알고리즘 (d1=d2)



(b) 제안된 알고리즘 (d1-a=d2-b)

(그림 1) 두 개의 클러스터에서 동일한 소속 정도를 가지는 FCM과 제안된 알고리즘의 데이터 집합

제안된 알고리즘의 목적함수는 평균내부거리를 고려한 각 데이터로부터 클러스터 중심까지의 거리이다. 그러므로 소속정도는 중심으로부터 데이터에 이르는 분산 정도를 최소화하도록 한다. 제안된 알고리즘의 목적함수와 평균내부거리는 다음과 같다.

3.1 목적함수

제안된 알고리즘의 목적함수는 각 데이터로부터 각 내부클러스터까지의 거리가 최소가 되는 응집성을 고려하여 데이터 집합을 분할하도록 설계한다.

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^m \|x_j - v_i\|^2 \quad (4)$$

여기서, 모든 j 에 대해 $\sum_{i=1}^c u_{ij} = 1$ 이고 η_i 는 적당한 양의 정수로 내부클러스터 크기를 나타낸다. 식 (4)에서 첫 번째 항은 데이터로부터 클러스터 중심 사이의 거리를 가능한 작게 유지하도록 하고, 두 번째 항은 각 내부클러스터 크기에 비례하여 거리를 보정하도록 한다. 그러므로 목적함수를 최소화하는 조건을 만족하는 소속정도 u_{ij} 를 클러스터 크기에 따라 균일하게 부여할 수 있다. m 이 1보다 큰 경우에 모든 i, j 에 대해서 $v_i \neq x_j$ 를 만족한다면, J_m 을 최소화하도록 하는 조건 (U, V) 는 다음과 같다.

$$u_{ij} = \left\{ \sum_{k=1}^c \left(\frac{d_{ij} - \eta_i}{d_{kj} - \eta_k} \right)^{\frac{2}{m-1}} \right\}^{-1}, \quad (5)$$

$$\text{여기서, } d_{ij} = \|v_i - x_j\|,$$

$$(i = 1, 2, \dots, c ; j = 1, 2, \dots, n),$$

$$v_i = \frac{\sum_{j=0}^n (u_{ij})^m x_j}{\sum_{j=0}^n (u_{ij})^m} \quad (6)$$

제안된 알고리즘은 식 (5)와 식 (6)의 과정이 반복되므로, J_m 은 어떤 정해진 값에 수렴한다.

3.2 평균내부거리

평균내부거리 η_i 는 해당 클러스터의 크기와 밀도에

관한 정보로 클러스터 크기에 따라 다른 값을 가진다. Krishnapuram은 η_i 를 식 (7)을 이용하여 추정하였는데 이는 퍼지 분할을 먼저 실행하고 퍼지 분할로부터 얻은 정보를 가지고 구한다[12].

$$\eta_i = K \frac{\sum_{j=1}^n (u_{ij})^m d_{ij}^2}{\sum_{j=1}^n (u_{ij})^m} \quad (7)$$

여기서 K 는 보통 1보다 작은 값을 선택하는데 이는 데이터 개수가 많을 경우 η_i 를 크게 설정하면 발산할 위험이 있기 때문이다.

3.3 제안된 알고리즘의 수행 절차

제안된 알고리즘의 수행 절차는 다음과 같다.

단계 1: 초기 클러스터 수($2 \leq c < n$)와 퍼지 가중치 지수($1 < m < \infty$)를 결정 한다.

단계 2: 다음 조건을 만족하는 퍼지 c 분할 $U^{(0)}$ 를 초기화한다.

$$\sum_{j=1}^c u_{ij} = 1, \quad 0 < \sum_{j=1}^n u_{ij} < n, \\ 1 \leq i \leq c, \quad 1 \leq j \leq n.$$

단계 3: 식 (6)에서 각 클러스터 중심값 $v_i^{(l)}$ 을 구한다. ($l = 0, 1, 2, \dots$).

단계 4: 식 (7)에서 평균내부거리 η_i 를 구한다.

단계 5: 퍼지 c 분할 $U^{(l+1)}$ 을 계산한다. 단, $\eta_i \neq d_{ij}$ 일 때.

단계 6: 만약 $\|U^{(l+1)} - U^{(l)}\| \leq \epsilon$ 이면 알고리즘을 종료하고 그렇지 않으면 단계 3으로 이동하여 반복 수행한다.

제안된 알고리즘은 데이터로부터 내부클러스터까지의 거리에 의해 소속정도가 부여되기 때문에 크기에 상관없이 균일한 소속정도가 부여되고 각 클러스터 중심을 잘 찾는다.

4. 실험 및 고찰

본 논문에서는 디지털 카메라로부터 130×130 픽셀 크기의 영상을 획득하여 실험하였다. 또한, 클러스터링

결과를 평가하기 위하여 분류 엔트로피(Classification Entropy)와 적합도 함수(S-function)를 이용하여 새로운 적합도 함수 $F(=CE \times S)$ 를 정의하였다.

분류 엔트로피는 퍼지 분할 후 각 데이터와 클러스터 중심의 관계를 나타내는 함수로 각 데이터가 클러스터의 중심에 잘 분류될수록, 즉 애매한 데이터 개수가 적을수록 낮은 값을 가진다. 그리고 응집성과 분할성에 관한 적합도 함수는 클러스터 중심으로부터 데이터까지의 거리를 작게 하여 응집성을 높이고, 클러스터 중심간의 거리를 크게 하여 분리성을 높이도록 설계되므로 클러스터의 분류가 잘 될수록 낮은 값을 가진다.

식 (8)은 Bezdek에 의해 제안된 분류 엔트로피이고 식 (9)는 Xie-Beni에 의해 제안된 응집성과 분할성에 관한 적합도 함수이다[11, 14].

$$CE = -\frac{1}{k} \left[\sum_{m=1}^M \sum_{n=1}^N \sum_{i=1}^c \{u_{mn}^i \log(u_{mn}^i)\} \right] \quad (8)$$


$$S = \frac{\sum_{i=1}^c \sum_{m=1}^M \sum_{n=1}^N (u_{mn}^i)^2 \|x_{mn} - v_i\|^2}{k \left[\min_{i \neq j} (\|v_i - v_j\|) \right]} \quad (9)$$

여기서 k 는 데이터의 개수 $M \times N$ 이고, u_{mn}^i 는 퍼지 분할 후의 소속정도를 나타낸다. 그리고 $\frac{1}{k} \sum_{i=1}^c \sum_{m=1}^M \sum_{n=1}^N (u_{mn}^i)^2 \|x_{mn} - v_i\|^2$ 은 데이터와 클러스터간의 응집성을, $\left(\min_{i \neq j} [\|v_i - v_j\|] \right)$ 는 각 클러스터 중심간의 분할성을 나타낸다. 이러한 적합도 함수에 의해서 이웃한 점들에 대한 균일성(Uniformity)과 동질성(Homogeneity)이 나타나기도 한다.


4.1 퍼지 클러스터링에 의한 데이터 집합 분류

실험을 위해서 데이터 개수가 8, 19 그리고 53개로 이루어진 서로 다른 크기의 클러스터를 가지는 (그림 2), (그림 3)과 같은 데이터 집합 A 를 고려하자. (그림 2)는 데이터 집합 A 를 FCM 알고리즘으로 분할한 결과이다. 여기서 상대적으로작은 두 개의 클러스터를 하나의 클러스터로 분류하고 상대적으로 큰 클러스터를 두 개로 나누어 중심 탐색을 하고 있는데 이는 FCM 알고리즘이 데이터로부터 클러스터 중심에 이르는 거리의 합을 최소화하는 조건에 의해 소속정도가

결정되기 때문이다.



(그림 2) FCM 알고리즘에 의한 실험 데이터 집합 A의 중심



(그림 3) 제안된 알고리즘에 의한 실험 데이터 집합 A의 중심

(그림 3)은 데이터 집합 A를 제안된 알고리즘으로 분할한 결과이다. 그림에서 알 수 있듯이 제안된 알고리즘에서는 데이터로부터 내부클러스터 까지의 거리에 의해 소속정도가 부여되므로 각 클러스터 중심을 잘 찾을 뿐만 아니라 데이터도 명확하게 분류한다.

<표 1>은 데이터 집합 A를 제안된 알고리즘과 FCM 알고리즘으로 분할할 때 각각의 분류 엔트로피와 적합도 함수의 값을 나타낸다. 각각의 값으로 보아 제안된 알고리즘에 의해서 클러스터가 더 잘 분류된다.


<표 1> 각 클러스터링 기법의 성능 비교(집합 A)

	FCM	제안된 방법
클러스터의 중심	(6.0428, 21.1668)	(6.0891, 9.0729)
	(16.9771, 18.3205)	(6.4278, 21.9989)
	(20.9085, 18.7888)	(20.1533, 18.9993)
CE	0.2776	0.1913
S	0.3798	0.2745

4.2 퍼지 클러스터링에 의한 영상분할


본 논문에서는 제안된 알고리즘의 성능을 평가하기 위하여 FCM 알고리즘과 제안된 알고리즘을 영상분할에 적용하였다.

(그림 4)는 디지털 카메라로 얻은 영상 1을 FCM 알고리즘과 제안된 알고리즘에 적용한 F-함수 값을 나타낸다. 초기 중심값은 임의로 선택하였으며 퍼지 가중치 m 은 2로 하고 클러스터 개수는 2개에서 7개까지 변화하면서 F-함수를 구하였다. 그림에서 알 수 있듯이 제안된 알고리즘으로 영상을 분할할 경우에 F-함수의 값이 더 작게 나온다. 즉, 제안된 알고리즘에 의한 클러스터링이 FCM 알고리즘에 의한 클러스터링보다 성능이 더 우수함을 알 수 있다.




(그림 4) 영상 1의 F-함수

(그림 5)는 제안된 알고리즘을 이용하여 영상 1을 분할한 결과이다. 여기서 사용한 F -함수는 각 데이터가 클러스터 중심에 잘 분류될수록, 데이터와 클러스터 중심과의 응집성과 각 클러스터 중심간의 분할성이 좋을수록 최소값을 가지며 클러스터링의 성능도 우수하다. 그러므로 클러스터의 개수가 3일 때 분할된 영역이 사람의 시각적 평가 조건과 가장 일치함을 알 수 있다.



(a) 영상 1 (b) 영상 1의 히스토그램




(c) 3개의 영역 (d) 4개의 영역 (e) 5개의 영역


(그림 5) 제안된 알고리즘에 의한 영상 1의 분할

(그림 6)은 영상 2에 대한 F -함수 값을 그래프로 나타낸 것이다. 여기서 FCM 알고리즘의 최적 분할 성능은 클러스터를 3개로 나눌 때 이고 제안된 알고리즘은 4개로 나눌 때이다.


(그림 7)은 영상 2를 각 알고리즘에 대해 최적의 분할 개수로 영상을 분할한 결과이다. FCM 알고리즘에 의해 분할된 영상 (c)를 보면 중앙의 흰색 원 부분을 다른 클러스터에 편입시키고 있다. 이는 FCM 알고리즘이 데이터로부터 각 클러스터 중심에 이르는 거리에 의하여 소속정도를 부여하기 때문에 상대적으로 아주 작은 영역은 손실된다. 하지만 제안된 알고리즘에 의해 분할된 영상 (d)는 각 클러스터 크기를 보정해주는 목적함수에 의해 클러스터링이 이루어지기 때문에 아주 작은 영역도 손실되지 않는다. 이는 제안된 알고리즘의 클러스터링 성능이 FCM 알고리즘의 클러스터링 성능보다 우수하기 때문이다.



(그림 6) 영상 2의 F -함수




(a) 영상 2 (b) 영상 2의 히스토그램




(c) FCM 알고리즘 (3개의 영역) (d) 제안된 알고리즘 (4개의 영역)

(그림 7) 최적의 분할 개수에 의한 영상 2의 분할


(그림 8)은 명확하게 4개의 영역으로 구분되면서도 한 영역이 다른 영역에 비해 아주 작은 영상 3에 대하여 분할한 결과를 나타낸다. 히스토그램 (d)와 (f)로 알 수 있듯이 FCM 알고리즘으로 영상을 분할한 결과는 상대적으로 작은 영역을 찾지 못하고 있지만 제안된 알고리즘으로 영상을 분할한 결과는 작은 영역도 잘 찾고 있다. 즉, 제안된 퍼지 클러스터링 알고리즘의 성능이 FCM 알고리즘보다 더 우수하며 이를 이용하여 영상을 분할할 경우에 더 좋은 결과를 얻을 수 있음을 보여준다.



(a) 영상 3 (b) 영상 3의 히스토그램



(c) FCM 알고리즘 (d) (c)영상의 히스토그램



(e) 제안된 알고리즘 (f) (e)영상의 히스토그램

(그림 8) 4개의 영역을 가진 영상 3의 분할

5. 결 론

본 논문에서는 평균내부거리를 적용한 퍼지 클러스터링 알고리즘을 제안하였다. 평균내부거리는 각 데이터로부터 해당 클러스터 중심까지의 거리를 평균한 값으로 클러스터의 크기와 밀도에 비례한다. 제안된 알고리즘은 평균내부거리 안쪽에 속하는 데이터들의 집합을 내부클러스터라 정의하고, 각 데이터로부터 내부클러스터까지의 거리를 최소화 하는 목적함수를 설계하여 클러스터 크기에 상관없이 균일한 군집화를 가능하게 하였다. 기존의 FCM 알고리즘의 목적함수는 각 데이터로부터 클러스터 중심까지의 거리를 최소화 하기 때문에 클러스터 크기가 다른 경우에 잘못된 소속 정도를 가진다. 그러므로 클러스터 중심을 제대로 찾지 못하고 데이터를 오분류한다. 제안된 알고리즘은 이러한 문제점을 해결할 뿐만 아니라, 크기가 작은 클러스터 중심도 탐색할 수 있다.

제안된 알고리즘의 성능을 평가하기 위하여 제안된 알고리즘을 영상에 적용하여 실험하였다. 그 결과 제안된 알고리즘이 기존의 FCM 알고리즘보다 영상분할 성능이 더 우수함을 알 수 있었다. 이는 제안된 알고리즘의 클러스터링 성능이 우수하기 때문이다.


그러나 FCM 알고리즘과 제안된 알고리즘 등의 퍼지 클러스터링 알고리즘은 데이터가 가지는 특징 정보만을 이용하여 클러스터링을 하기 때문에 데이터에 잡음이 있을 경우에는 분할 성능이 좋지 않다. 이러한 문제점은 영역 확장법 등의 후처리 과정을 통해 해결할 수 있으나, 데이터에 잡음이 있을 경우에도 최적의 결과를 얻을 수 있는 연구가 필요하다.

참 고 문 헌

- [1] Y. W. Lim and S. U. Lee, "On the Color Image Segmentation Algorithm Based on the Thresholding and the Fuzzy C-Means Techniques," *Pattern Recognition*, Vol.23, No.9, pp.935-952, 1990.
- [2] H. Rhee and K. Oh, "A Design and Analysis of Objective Function Based Unsupervised Neural Networks of Fuzzy Clustering," *Neural Processing Letters*, Vol.4, pp.83-95, 1996.
- [3] D. N. Chun, "A Method of Clustering and Image Segmentation Based on Fuzzy Genetic Algorithm," Dept. of Computer Science. KAIST, pp.26-34, 1996.
- [4] R. C. Gonzalez, and R. E. Woods, *Digital Image Processing*, Addison Wesley, pp.443-457, 1992.
- [5] J. C. Bezdek and M. M. Rivedi, "Low Level Segmentation of Aerial Images with Fuzzy Clustering," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol.SMC-16, No.4, pp.589-598, 1986.
- [6] R. Krishnapuram and J. M. Keller, "A Possibilistic Approach to Clustering," *IEEE Trans. on Fuzzy Systems*, Vol.1, No.2, pp.98-110, 1993.
- [7] T. A. Runkler and J. C. Bezdek, "Alternating Cluster Estimation : A New Tool for Clustering and Function Approximation," *IEEE Trans. on Fuzzy Systems*, Vol.7, No.4, pp.377-393, 1999.
- [8] P. R. Kersten, "Fuzzy Order Statistics and Their Application to Fuzzy Clustering," *IEEE Trans. on Fuzzy Systems*, Vol.7, No.6, pp.708-712, 1999.
- [9] Y. El-Sonbaty and M. A. Ismail, "Fuzzy Clustering for Symbolic Data," *IEEE Trans. on Fuzzy Systems*, Vol.6, No.2, pp.195-204, 1998.
- [10] James C. Bezdek, "A Convergence Theorem for the Fuzzy ISODATA clustering algorithms," *IEEE Trans. on Pattern Anal. and Machine Intell.*, Vol. PAMI-2, No.1, pp.1-8, 1980.
- [11] N. Pal and J. Bezdek, "On Cluster Validity for the

Fuzzy C-Means Model," *IEEE Trans. on Fuzzy Systems*, Vol.3, No.3, pp.370-379, 1995.

- [12] R. Krishnapuram, H. Frigui and O. Nasraoui, "Fuzzy and Possibilistic Shell Clustering Algorithms and Their Application to Boundary Detection and Surface Approximation," *IEEE Trans. on Fuzzy Systems*, Vol.3, No.1, pp.29-60. 1995.
- [13] A. P. Witkin, "Scale-Space Filtering," *Processing IJCAI-83*, pp.1019-1022, 1983.
- [14] X. Xie and G. Beni, "A Validity Measure for Fuzzy Clustering," *IEEE Trans. on Pattern Anal. and Machine Intell.*, Vol.13, No.8, pp.841-847, 1991.



유 현 재

e-mail : hjyou@dms21.co.kr
 1998년 한국해양대학교 제어계측
 공학과 졸업(학사)
 2000년 한국해양대학교 대학원
 제어계측공학과(공학석사)
 2000년 (주) 리얼테크닉


2000년~현재 (주)DMS 연구원
 관심분야 : 컴퓨터 비전, 패턴 인식 등



안 강 식

e-mail : morssola@ce.kmaritime.ac.kr
 1999년 한국해양대학교 제어계측
 공학과 졸업(학사)
 1999년~현재 한국해양대학교
 대학원 제어계측공학과
 석사과정

관심분야 : 칼라 영상 처리, 패턴 인식, 신호 처리 등



조 석 제

e-mail : sjcho@hanara.kmaritime.ac.kr
 1982년 경북대학교 전자공학과
 졸업(학사)
 1988년 경북대학교 대학원 전자
 공학과(공학석사)
 1991년 경북대학교 대학원 전자
 공학과(공학박사)

1991년~현재 한국해양대학교 기계·정보공학 부/제어
 계측공학과 부교수

관심분야 : 신호 처리, 영상 처리, 컴퓨터 비전, 패턴 인식 등