

論文97-34S-3-10

Possibilistic C-Mean 클러스터링과 영역 확장을 이용한 칼라 영상 분할

(Color image segmentation using the Possibilistic
C-Mean clustering and region growing)

嚴 景 培 * , 李 俊 煥 **

(Kyoung Bae Eum and Joon Whoan Lee)

要 約

영상 분할은 컴퓨터 비전 시스템의 영상 정보 추출에 있어서 중요한 단계이다. 퍼지 클러스터링 방법은 칼라 영상 분할에 있어서 널리 이용되어져 왔다. 대부분의 퍼지 클러스터링 방법은 퍼지 c-mean(FCM) 방법을 이용하고 있다. FCM 알고리즘은 데이터의 각 클래스에 관한 소속 합수 값이 1이 되는 확률적 제약 조건을 이용하고 있다. 그러나, FCM으로부터 얻어진 소속함수의 값이 belonging이나 compatibility 정도의 직관적인 개념과 항상 일치하지는 않는다. 또한, 잡음이 있는 상황에서 심각한 문제점을 갖는다. 최근에, 이와 같은 문제점을 해결하기 위해 Possibilistic C-Mean(PCM)방법이 제안되어졌다. 본 논문에서는 PCM과 영역 확장을 이용한 새로운 칼라 영상 분할 방법을 제안하였다. PCM에서는 소속함수의 값이 데이터가 각 클래스에 속하는 가능성의 정도로서 나타내어지고, 따라서, FCM에서의 문제점이 해결되어 질 수 있다. PCM을 이용한 클러스터링 방법만을 이용하여 칼라 영상 분할을 할 경우 경계선이 매끄럽지 못하거나, 영역의 내부에 많은 hole들을 포함하게 된다. 따라서, 후처리 과정으로써 영역 확장법을 이용하였다. 잡음이 있는 상황에서 제안된 방법의 결과가 FCM의 결과보다 우수함을 실험을 통하여 입증하였다.

Abstract

Image segmentation is the important step in image information extraction for computer vision systems. Fuzzy clustering methods have been used extensively in color image segmentation. Most analytic fuzzy clustering approaches are derived from the fuzzy c means(FCM) algorithm. The FCM algorithm uses the probabilistic constraint that the memberships of a data point across classes sum to 1. However, the memberships resulting from the FCM do not always correspond to the intuitive concept of degree of belonging or compatibility. Moreover, the FCM algorithm has considerable trouble under noisy environments in the feature space. Recently, the Possibilistic C-Mean(PCM) for solving above problems was proposed. In this paper, we proposed the new method using the PCM and region growing for color image segmentation. In the PCM, the membership values may be interpreted as degrees of possibility of the data points belonging to the classes. So, the problems in the FCM can be solved by the PCM. The clustering results by just PCM are not smoothly bounded, and they often have holes. So, the region growing was used as a postprocessing. In our experiments, we illustrated that the proposed method is reasonable than the FCM in noisy environments.

* 正會員, 群山大學校 컴퓨터科學科

(Dept. of Computer Science, Kunsan University.)

** 正會員, 全北大學校 電子工學科

(Dept. of Electronics Eng., Chonbuk University)

接受日字: 1996年11月12日, 수정완료일: 1997年3月13日

I. 서 론

컴퓨터 비전(computer vision)이란 투시된 영상들로부터 주어진 장면(scene)에 관한 유용한 정보를 추출하는 작업을 말한다. 즉, 여러 화소들의 배열인 영상(image)으로부터 물리적인 대상을 명확하고 의미있게

기술하도록 하는 과정을 말한다. 초기에, 컴퓨터 비전 학자들은 영역이나 경계선을 기초적인 표시자로 이용하는데에 관심을 가졌다. 영상 분할(image segmentation)은 영상을 그 구성 성분 또는 물체별로 나누는 작업을 일컫는다. 즉, 분할은 명암값, 칼라, 운동 특성, 표면특성등 공통 특성을 나타내는 화소들의 집단을 만드는 것이다. 여기서 영상 분할은 의사 결정(decision making) 과정으로 볼수도 있다. 즉, 화소들이 어떠한 장면 요소의 구성원인가를 결정하는 과정으로 생각할수 있다. 이와같이 영상 분할은 컴퓨터 비전에서 매우 중요한 단계이고 컴퓨터에 의한 영상 분석에서 반드시 다루어야 할 부분이다. 영상 분할을 통한 물체의 모습이나 구성 성분은 다음 단계에서 이어질 영상 해석이나 인지 또는 묘사에서 필요하기 때문이다.^{[11][12]}

인간의 감각 기관중 가장 중요한 부분은 눈이고 이 기관의 감각 현상인 칼라와 그것의 과학적인 표현은 우리 실생활 면에서도 아주 중요한 면을 점유하고 있다. 그것은 또한 심리학, 물리학, 생리학, 화학, 의학, 의공학, 광학, 공학, 심리 물리학등 다방면에 걸쳐서 연구되어지고 있는 분야이다. 또한, 칼라 영상을 채취하는데 가격이 떨어지고 있고, 칼라 영상이 단색조 영상에 비해 인간의 시각을 크게 향상시키므로 칼라 영상 처리 및 분석은 매우 필요한 영역이다. 따라서, 본 논문에서는 칼라 영상 분석 분야에 관한 연구를 시도하였다.

Ohta는 칼라 영상 분할에 있어서 구조적인 실험을 통하여 효율적인 칼라 속성들을 개발 하였다.^[13] 여러 가지 영상 분할 방법중에서 칼라 영상 분할을 위해서 역치에 의한 차단법(thresholding)과 클러스터링(clustering)에 의한 방법이 칼라 영상 분할을 위해 널리 이용되어져왔다. Ohlander는 칼라 영상 분할을 위해 다차원 역치에 의한 차단법을 이용하였고, 역치값들은 서로 다른 칼라좌표계에서 구해졌다.^[14] 다차원 역치에 의한 차단법은 칼라 영상과 같은 다차원 영상 데이터를 분할하기 위해 사용 되어졌으나, 이 방법은 그레이 영상을 위한 1차원적인 방법이기 때문에 다차원 데이터를 분류하는데는 제약사항이 있다.^[15] 스펙트럼 해석(spectrum analysis)방법은 칼라 영상 분할을 위한 다른 방법이 될 수 있으나 칼라 영상의 화소들을 분할하기 위해서는 물체의 칼라에 대한 선지식(prior knowledge)이 필요하다. 그러나, 많은 실제 응용분야

에 있어서 물체의 칼라에 대한 선지식을 얻는일은 매우 어려운 일이다. 따라서, 이러한 상황에서는 클러스터링 방법이 이용되어질 수 있을 것이다.^[16]

클러스터링 방법중에서도, 퍼지 이론을 이용한 클러스터링 방법이 칼라 영상 분할을 위해 많이 이용되어져 왔고, 이를 가운데 퍼지 c-mean(FCM) 알고리즘이 칼라 영상 분할을 위하여 널리 이용되어져 왔다. Bezdek은 영상의 계층적인 해석을 위해 피라미드 대 이터 구조와 영역 확장기법을 이용하여 칼라 영상 분할을 시도하였다.^{[17][18]} Lim과 Lee는 역치에 위한 차단법과 FCM 알고리즘을 이용하여 2단계 칼라 영상 분할을 시도하였으며^[19], 이 방법은 클러스터의 수를 발견하기 위해 scale space 필터를 이용하는 방법을 제외하고는 Huntsberger에 의해 제안되어진 반복 알고리즘(iterative algorithm)과 매우 유사하다.^[10]

이와같이, 대부분의 퍼지 클러스터링 방법은 FCM 방법을 이용하고 있다. FCM 알고리즘은 데이터의 각 클러스터에 관한 소속함수 값이 1이 되는 확률적 제약 조건(probabilistic constraint)을 이용하고 있다. 그러나, FCM으로부터 얻어진 소속함수의 값이 belonging이나 compatibility의 정도의 직관적인 개념과 항상 일치하지는 않는다. 또한, FCM 알고리즘의 경우에는 “equal evidence”와 “ignorance”를 구분할 수가 없기 때문에 특히, 잡음이 있는 상황에서 심각한 문제점을 야기시킨다. 이는 FCM의 경우 소속함수 값이 다른 클러스터와 관계가 있는 상대적인 값이기 때문이다. 따라서, 최근에 믿음 이론(belief theory)과 가능성 이론(possibility theory)등이 이와같은 문제점을 개선하기 위해 시도돼왔다. 최근에, Raghu는 Possibilistic C-Mean(PCM)을 제안하였고, 그는 이 방법을 경계선 검출(boundary detection)과 표면 근사화(surface approximation)에 이용하였다.^{[11][12]} PCM의 경우 소속함수 값이 다른 클러스터와 관계가 없고, 속성 데이터와 해당 클러스터 중심간의 거리에만 의존하기 때문에 이러한 문제점을 해결할 수 있다.

따라서, 본 논문에서는 칼라 영상 분할을 위해 PCM을 이용하였다. 또한, 클러스터의 모양과 분포는 칼라 좌표계에 따라 달라지기 때문에 칼라 좌표계의 선택이 매우 중요하다. 따라서, 본 논문에서는 RGB, XYZ 및 Ohta 좌표계에서 실험을 행하였고, 실험 결과들을 비교 검토하였다. 그러나, 클러스터링 방법만을 이용하여 칼라 영상 분할을 할 경우 경계선이 매끄럽지 못하거나

나, 영역의 내부에 많은 hole들을 포함하게 된다. 그 이유는, 클러스터링은 속성 공간에서의 유사성만을 고려하고, 공간 영역에서의 유사성은 고려되지 않기 때문이다. PCM을 이용한 칼라 영상 분할과정에서 높은 가능성이 값을 가진 영역은 영역 확장을 위해 안정화된 seed point들을 제공할 수 있다. 유사한 생각을 FCM을 이용하여 얻은 높은 소속도를 갖는 영역을 생각할 수도 있으나, 이는 데이터가 모든 클러스터에 속하는 소속함수의 값이 합하여 1이 되는 확률적 제약조건 때문에 안정적이지 못할 수 있다. 따라서, 본 논문에서는 먼저 PCM을 이용하여 seed point들을 얻은 후 처리 과정(post processing)으로써 영역 확장법을 이용한 새로운 칼라 영상 분할 방법을 제안하였다. 실험 결과, 본 논문에서 제안한 방법의 결과가 FCM을 이용한 결과보다 우수함을 알 수 있었다.

II. 본 론

1. 칼라 좌표계

1) RGB 좌표계

우리눈은 망막의 추상체(cones of the retina)에서 세가지 시색소가 흥분함에 따라 칼리를 감지한다. 이들 색소는 각각 파장이 약 630nm(R), 530nm(G), 450nm(B)일 때 극대의 광도를 갖고 광원에서의 광도를 비교함으로써 그 빛의 색깔을 감지한다.^[13] 이 세 각의 3자극 이론은 비디오 모니터상에서 RGB 색상 모형으로 불리는 R,G,B의 세가지 색상 요소를 사용해서 색상 출력을 내는 기본원리이다. 이 좌표계는 Cartesian 좌표계에 근거하였고, R,G,B는 단위 입방체 상에서 3 꼭지점에 나타난다. 이때 R,G,B의 모든 값은 0과 1사이의 값이 된다. 또한, 이 칼라 좌표계는 가산 색계(additive model)^[14]에서 기본색의 광도를 합치면 다른색이 된다. 적색과 청색을 더해서 얻어지는 자홍(Magenta), 녹색과 파랑색이 더해서 청록(Cyan), 녹색과 빨강이 더해져 얻어지는 노랑(Yellow)은 다른 3 꼭지점에 나타난다. 검정색은 원점에 있고 흰색은 (1,1,1)의 꼭지점에 나타난다. 이 좌표계에서 그레이 스케일은 검정색과 흰색 꼭지점을 잇는 선을 따라서 나타난다.^[14]

2) CIE-XYZ 좌표계

표준 CIE 칼라 좌표계는 표준빛의 삼원색을 조합하여 만든 좌표계이다. 표준빛의 삼원색은 red(x=1, y=0,

$z=0)$, green(x=0, y=1, z=0), blue(x=0, y=0, z=1)^[1] 고 표준빛의 삼원색이 같은 값을 가지는 W점($x=1/3$, $y=1/3$, $z=1/3$)은 백색광을 나타낸다. 가시할 수 있는 삼원색 Red, Green, Blue는 빛의 스펙트럼상에서 각각 700nm, 546.1nm, 435.8nm의 파장을 가지며, 말굽 모양의 경계선의 좌표값을 가진다. 그러므로, 가시할 수 있는 영역은 말발굽 곡선안의 영역이 된다.

그러나, 칼라 모니터의 디스플레이의 한계로 표현할 수 있는 색깔은 말발굽 곡선안의 일정한 내부 영역으로 제한된다.^[14] 그러므로, 모니터 RGB 좌표계와 CIE-XYZ 좌표계와의 관계는

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} 0.628 & 0.346 & 0.150 \\ 0.346 & 0.588 & 0.070 \\ 0.026 & 0.144 & 0.780 \end{pmatrix} \begin{pmatrix} r \\ g \\ b \end{pmatrix} \quad (1)$$

$$\begin{pmatrix} r \\ g \\ b \end{pmatrix} = \begin{pmatrix} 0.628 & 0.346 & 0.150 \\ 0.346 & 0.588 & 0.070 \\ 0.026 & 0.144 & 0.780 \end{pmatrix}^{-1} \begin{pmatrix} x \\ y \\ z \end{pmatrix} \quad (2)$$

여기서, r, g, b와 x,y,z는 각각 R, G, B와 X, Y, Z의 정규화된 값이다.

3) Ohta 좌표계

패턴 인식의 속성 추출에 있어서, 속성의 분산(variance)이 크다면 그 속성은 큰 분별력을 가진다고 말할 수 있다. 그래서, Ohta 등은 K.L.(Karhunen Loeve)변환을 이용하여 커다란 분별력을 가진 칼라 속성을 추출하기 위한 시도를 하였다. S를 분할되어지는 영역이라고 하고, Σ 를 영역 S에서 R,G,B의 공분산(covariance) 행렬이라고 하자. 또한, $\lambda_1, \lambda_2, \lambda_3$ 를 공분산 행렬의 고유치(eigenvalue)라고 하고 크기는 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ 라고 하자. $\mathbf{W}_i = (\mathbf{W}_{Ri} \mathbf{W}_{Gi} \mathbf{W}_{Bi})^t$ for $i = 1, 2, 3$ 을 λ_i 에 일치하는 공분산 행렬의 고유 법터라 하자. 그때, 칼라 속성 $\mathbf{X}_1, \mathbf{X}_2$ 와 \mathbf{X}_3 는 다음과 같이 정의되어 진다.

$\mathbf{X}_i = \mathbf{W}_{Ri} \cdot R + \mathbf{W}_{Gi} \cdot G + \mathbf{W}_{Bi} \cdot B$ ($\|\mathbf{W}_i\|=1$, $i = 1, 2$ 와 3) $\mathbf{X}_1, \mathbf{X}_2$ 와 \mathbf{X}_3 는 상관 관계가 없고, \mathbf{X}_1 은 가장 큰 분산값을 갖는다는 점에서 가장 좋은 속성이다. Ohta는 여러 칼라 영상의 실험을 통하여, 각 실험 영상들의 공분산 행렬의 고유벡터값이 $\mathbf{W}_1 = (\frac{1}{3}, \frac{1}{3}, \frac{1}{3})^t$, $\mathbf{W}_2 = (\frac{1}{2}, 0, -\frac{1}{2})^t$ 나 $(-\frac{1}{2}, 0, \frac{1}{2})^t$, $\mathbf{W}_3 = (-\frac{1}{4}, \frac{1}{2}, -\frac{1}{4})^t$ 과 같이 얻어지는 것을 발견하였고, 칼라 정보 표현을 위한 중요한 성분인 3개의 orthogonal한 칼라 속성을 실험을 통하여 다음과 같이 정의하였다.

$$I_1 = (R + G + B)/3$$

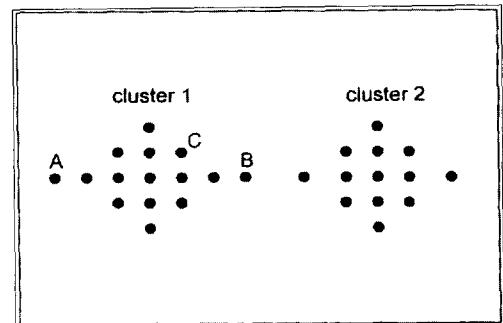
$$\begin{aligned} I_2 &= (R-B)/2, \text{ 또는 } (B-R)/2 \\ I_3 &= (2G-R-B)/4 \end{aligned} \quad (3)$$

2. FCM과 PCM의 비교

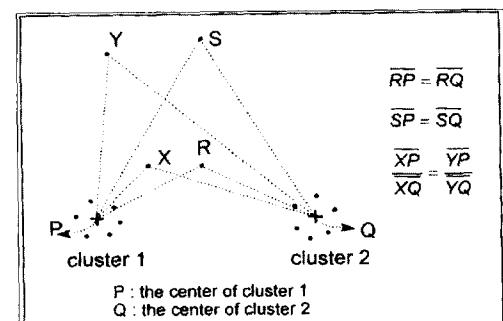
그림 1의 예제들은 FCM 알고리즘에서 사용되어진 확률적 제약조건과 관련되어진 문제를 설명한다. 그림 1(a)는 2개의 클러스터를 포함하고 있는 상황을 보여 준다. FCM은 데이터 A와 B가 클러스터 1의 중심으로부터 같은 거리에 위치하고 있음에도 불구하고 클러스터 1에 속하는 소속함수 값이 다른 값을 갖게 된다. 이와 같은 상황은 데이터 B가 클러스터 2에 속하는 소속함수 값을 증가시키기 위해 클러스터 1에 속하는 소속함수 값을 감소시키는 제약 조건으로부터 야기된다. 유사하게, 데이터 A와 C에서 C가 A보다 클러스터 1의 중심으로부터 가까워에도 불구하고 데이터 A와 C의 클러스터 1에 속하는 소속함수 값은 같다. 이는 FCM 알고리즘에서 클러스터에 속하는 데이터의 소속함수 값이 상대적인 값이기 때문에 발생한다. 즉, 소속함수 값은 모든 다른 클러스터에 속하는 데이터의 소속함수 값에 의존한다.

그림 1(b)는 2개의 클러스터의 외부에 4개의 데이터를 갖는 다른 상황을 보여준다. 여기서, P와 Q는 클러스터의 중심이다. 직관적으로, 데이터 S는 R보다 클러스터 중심으로부터 외곽에 있으므로 보다 작은 소속함수 값을 가져야 한다.(여기서, RP=RQ 이고 SP=SQ이다.) 그러나, FCM은 S와 R에 0.5로 동일한 소속함수 값을 부여한다. 또한, 데이터 X와 Y에 있어서 X는 Y보다 클러스터 1의 중심으로부터 가깝고, Y는 클러스터 1의 중심으로부터 거리가 매우 떨어진 잡음으로 볼 수 있다. 여기서, XP:XQ와 YP:YQ의 거리의 비율이 같다고 하면, FCM은 X나 Y가 클러스터 1에 속하는 소속함수 값을 동일하게 부여한다. 즉, 잡음으로 볼 수 있는 Y나 클러스터 1에 속하는 데이터로 볼 수 있는 X에 FCM은 같은 소속함수 값을 부여한다. 반면에, PCM은 S보다 R에, Y보다 X에 큰 소속함수 값을 부여한다. 이와 같은 이유는 본론의 3절에서 언급된 FCM의 소속함수값 개선식(5)과 PCM의 소속함수값 개선식(8)로부터 알 수 있는 바와 같이, FCM의 소속함수 값은 데이터가 속하는 클러스터 중심과의 거리뿐만 아니라, 모든 다른 클러스터 중심과의 거리에도 관계가 있는 상대적인 값이기 때문에 이와 같은 문제가 발생한다. 그러나, PCM의 소속함수 값은 데이터가 속하는

클러스터 중심과의 거리에만 관련이 있기 때문에, 그럼 1(b)에서 Y와 같은 잡음과 클러스터 1에 속하는 데이터 X를 구분할 수 있다. 반면에, FCM은 이와 같은 상황에서 X와 Y에 동일한 소속함수 값을 부여하기 때문에 Y와 같은 잡음과 클러스터 1에 속하는 데이터 X를 구분할 수 없다.



(a)



(b)

그림 1. 2개의 클러스터를 갖는 데이터 집합의 예
Fig. 1. Example of a data set with 2 clusters.

3. 칼라 영상 분할 방법

FCM은 Bezdek에 의하여 제안되어진 클러스터링 알고리즘이다. FCM 알고리즘의 목적(objective) 함수와 FCM의 소속함수값 개선식은 다음 식(4),(5)와 같이 주어진다.^{[15][16]}

$$J(L, U) = \sum_{i=1}^c \sum_{j=1}^N (u_{ij})^m d_{ij}^2 \quad (4)$$

$$\text{where } \sum_{i=1}^c u_{ij} = 1 \text{ for all } j$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c (\frac{d_{ik}}{d_{kj}})^{\frac{2}{(m-1)}}} \quad (5)$$

위 식(4)에서, $L = (\beta_1, \dots, \beta_c)$ 는 prototype의

c -tuple이고 d_{ij}^2 은 미지의 패턴 x_i 와 각 클러스터의 중심 β_i 와 사이의 거리이다. N 은 속성 데이터의 총 개수이고, c 는 클러스터의 갯수이다. $U = [u_{ij}]$ 는 퍼지 c -partition 행렬이라고 불리우는 $C \times N$ 행렬이다. 여기에서, u_{ij} 는 클러스터 β_i 에서 속성 데이터 x_j 의 소속함수 값이고, $m \in [1, \infty]$ 는 퍼지화라고 불리워지는 가중치 지수이다.

윗 식(5)에서 k 는 해당되는 클러스터이고 c 는 클러스터의 갯수이며, d_{kj} 는 미지의 속성 데이터 x_j 와 클러스터의 중심 β_k 와 사이의 거리이다.

윗 식(4)에서 확률적 제약조건을 완화시킬 때, 평가 함수(criterion function)가 모든 소속함수 값을 0으로 최소화하여, 쓸모없는 해를 얻을수 있다. 여기서, 모든 클러스터에서 그 클러스터에 속하는 정도(degree)가 명확한 속성 데이터에는 가능한 한 높은 소속함수 값을 부여하고 그렇지 못한 속성 데이터에는 낮은 소속함수 값을 부여하고자 한다. 이와 같은 조건을 만족하는 목적 함수가 최근에 Raghu에 의해 제안되어졌고, PCM의 목적 함수는 다음과 같다.^{[11][12]}

$$J_m(L, U) = \sum_{i=1}^c \sum_{j=1}^N (u_{ij})^m d_{ij}^2 + \sum_{i=1}^c n_i \sum_{j=1}^N (1-u_{ij})^m \quad (6)$$

윗 식에서 n_i 는 적절한 양수 값이다. 윗식의 첫번째 항은 속성 데이터로부터 클러스터 중심사이의 거리를 가능한 한 작게 유지하고 반면에 두번째 항은 쓸모없는 해를 얻는 것을 피하기 위해 u_{ij} 를 가능한 한 크게 유지하도록 한다.

$X = \{x_1, x_2, \dots, x_n\}$ 을 속성 데이터의 집합이라고 하고, $L = (\beta_1, \dots, \beta_c)$ 을 클러스터의 중심들의 집합이라고 하자. 또한, d_{ij}^2 은 속성 데이터 x_j 로부터 클러스터 중심 β_i 와의 거리라고 하고, $U = [u_{ij}]$ 는 가능성 소속함수 값들로 이루어진 $C \times N$ 행렬이라고 하자. 위와 같은 가정하에 U 는 $u_{ij} = [1 + (d_{ij}^2/n_i)]^{-1}$ 이라면, $J_m(L, U)$ 를 위한 전역 최소치가 될 것이다.

prototype을 위한 필요 조건은 FCM과 동일하다. 먼저, 필요조건과 소속함수값 개선식을 유도하기 위해 U 의 행과 열이 서로 독립이다는 것을 주목해보자. 그러므로, U 에 관해 $J_m(L, U)$ 를 최소화 하는 것은 u_{ij} 각각의 값에 관해 다음 목적 함수를 최소화 시키는 것과 동일하다.

$$J_m^j(\beta_i, u_{ij}) = u_{ij}^m d_{ij}^2 + n_i (1-u_{ij})^m \quad (7)$$

윗(7)식을 u_{ij} 에 관해 미분하고, 미분값을 0으로 놓을 때 소속함수값 개선식인 다음식을 얻을수 있다.

$$u_{ij} = \frac{1}{1 + \left(\frac{d_{ij}^2}{n_i} \right)^{\frac{1}{m-1}}} \quad (8)$$

(8)식으로부터, u_{ij} 의 값이 [0,1] 사이에 놓여있다는 것을 알수 있다. 목적 함수에서 새로 더해진 두 번째 항은 prototype의 변수들이나 거리 척도에 대해 독립이므로, 그들 변수들에 관해 윗(6)식의 미분치는 FCM의 미분치와 동일하다. 그러므로, 최적화를 위한 prototype에서 필요조건은 FCM형태의 알고리즘을 위한 이론들에서 필요 조건들과 같다.

각 반복에서, u_{ij} 의 개선된 값은 클러스터 중심 β_i 와 x_j 사이의 거리에만 의존한다. prototype의 compatibility관점에서 볼 때, 다른 클러스터에 관해 속성 데이터의 위치가 관계가 없어야 되고, 단지 클러스터에서 속성 데이터의 소속함수 값은 데이터가 클러스터 중심으로부터 얼마나 멀어졌는가에 의해 결정되어야 한다. 여기서, 클러스터 중심의 개선은 선택되어진 거리 척도에 의존하고, 과정은 FCM의 방법과 동일하다. 또한 (8)식에서 소속 함수값은 Zimmermann과 Zysno에 의해 제안된 소속함수의 형태와 매우 유사하다는 것을 알수 있다.

식(8)은 클러스터 β_i 를 위한 가능성 분포함수를 나타낸다. 이것을 P_i 라 표기한다. m 의 값은 최종 가능성 c -partition의 fuzziness와 가능성 분포의 형태를 결정한다. m 이 1일 때, 소속함수는 hard값이고, $m \rightarrow \infty$ 일 때 소속함수는 극대의 퍼지화된 값을 갖게 된다. n_i 의 값은 클러스터에서 속성 데이터의 소속함수 값이 0.5가 되는 거리를 결정한다. 그러므로, 그것은 각 클러스터를 위하여 가능성 분포의 적절한 대역폭에 의존하여 선택되어 지는것이 필요하다. 만일, 모든 클러스터가 유사하다면 모든 클러스터를 위한 n_i 의 값이 동일하게 될 것이다. 일반적으로, n_i 는 클러스터 β_i 의 형태와 크기에 밀접한 관계가 있다고 말할 수 있다. 또한, 다른 측면에서 볼 때, n_i 는 목적 함수에서 두번째항이 첫번째 항과 비교하여 얼마나 중요한가를 나타내는 상대적인 정도를 결정한다.

n_i 를 추정(estimate) 하기위한 다음 식들이 Raghu에 의해 제안 되어졌다.^{[11][12]}

$$n_i = K \frac{\sum_{j=1}^N u_{ij}^m d_{ij}^2}{\sum_{j=1}^N u_{ij}^m} \quad (9)$$

식(9)에서 N은 속성 데이터의 갯수이고 K는 1이다. 여기서, n_i 는 소속함수에 의해 가중치된 (weighted) 클러스터 β_i 의 평균 내부 거리이다. 본 논문에서는 n_i 를 추정하기 위해 다음식을 이용하였다.

$$n_i = \frac{\sum_{x_j \in (\Pi_i)_a} d_{ij}^2}{|(\Pi_i)_a|} \quad (10)$$

$(\Pi_i)_a$ 는 Π_i 의 적절한 α -cut이다. 여기서, n_i 는 클러스터 β_i 에 속하는 소속 정도가 높은 속성 데이터들의 평균 클러스터 내부 거리이다. 또한, n_i 의 값은 모든 반복을 위하여 고정되어 있다. 그것은, n_i 가 각 반복마다 변화되어 질 때, 불안정한 상태로 갈수있기 때문이다. 본 논문에서는 (10)식을 이용하여 초기의 퍼지 partition에 근거한 n_i 를 위한 근사치를 구했다.

본 논문에서 사용되어진 PCM 알고리즘은 다음과 같다.

The possibilistic clustering algorithm

```

Fix the number of clusters;
Fix m;
Initialize the possibilistic C-partition;
Estimate  $n_i$  using (10);
Repeat
    Update the prototype using  $U'$ 
    Compute  $U'^{+1}$  using (8);
Until ( $||\Delta U|| \leq \epsilon$ );

```

윗 PCM 알고리즘에서 처음에는 먼저 분류하기 위한 클러스터의 수를 정하고, 퍼지화의 정도를 나타나는 m값을 설정한다. 여기서, PCM 알고리즘의 결과들은 여느 클러스터링 알고리즘과 마찬가지로 초기화에 의존한다. PCM 알고리즘에서, 각각의 데이터는 동시에 모든 클러스터들과 관계가 있는 것이 아니라, 한 번에 한 클러스터들과만 관계가 있으므로 많은 양의 이동성을 갖지는 않는다. 그러므로, 알고리즘이 전역 최소치로 수렴하기 위해 좋은 초기치 값이 요구되어 진다. 따

라서, 초기의 가능성 c-partition 값을 얻기 위해 어느 적절한 클러스터링 알고리즘이 사용되어 질수 있다. 그 뒤, 식 (10)을 이용하여 n_i 값을 추정하였고, 앞과정에서 얻어진 소속함수 값을 이용하여 prototype을 생성하고, 생성된 prototype을 이용하여 식 (8)에 의해 소속함수 값을 생성한 뒤, 생성된 소속함수 값과 이전 과정에서 얻어진 소속함수 값을 뺀 결과가 정지조건 값보다 크면 이와같은 과정을 반복하고, 작을 경우는 알고리즘을 끝낸다. 또한, PCM 알고리즘에서 prototype의 생성은 선택되어진 거리 척도에 의존한다. 다른 거리척도는 다른 알고리즘을 야기시킨다. 거리척도가 FCM 알고리즘의 경우와 마찬가지로 norm metric으로부터 유도되어진 내적이라면

$$d_{ij}^2 = (\mathbf{x}_j - \mathbf{C}_i)^T \mathbf{A}_i (\mathbf{x}_j - \mathbf{C}_i) \quad (11)$$

C_i 는 클러스터 β_i 의 중심이고, 클러스터 중심의 생성은 다음 식(12)에 의해 생성 되어진다.

$$\mathbf{C}_i = \frac{\sum_{j=1}^N u_{ij}^m \mathbf{x}_j}{\sum_{j=1}^N u_{ij}^m} \quad (12)$$

4. 영역 확장법

기하학적인 근접성(geometrical proximity)은 영상 분할에서 매우 중요하다. 이웃(neighborhood)에 놓여 있는 화소들은 같은 영역에 속하거나 유사한 성질을 갖는 경향이 있다. 그러므로, 영상 분할 알고리즘은 연결된 영역을 얻기위해 근접성(proximity)과 동질성(homogeneity) 관점에서 고려되는 것이 좋다. 또한, 클러스터링은 속성공간에서 행해지기 때문에 FCM이나 PCM에 의한 클러스터링 방법만을 이용하여 칼라 영상 분할을 할 경우, 경계선이 매크로지 못하거나 영역의 내부에 많은 hole들을 포함하게 된다. 따라서, 본 논문에서는 FCM과 PCM을 이용하여 seed point를 얻고 이를 기초로 후처리 과정으로써 영역 확장법을 적용하였으며, 예상된 바와같이 PCM의 경우 보다 안정된 seed point로부터 영역 확장이 되는 것을 확인할 수 있었다. 여기서, 영역 확장법은 각영역의 seed point들로부터 확장을 시작하여 전체 영상을 채울 때까지 확장을 수행한다.

seed point들을 얻기위한 알고리즘은 다음과 같다.

The algorithm for getting the seed points
Implement the PCM;
IF Max membership ≥ average membership
IF Number of Max membership = 1 THEN
Labeling;
ELSE
IF(1st biggest membership - 2nd biggest membership) ≥ T THEN
Labeling;
ELSE Unlabeling;
Else Unlabeling;

위 알고리즘은 먼저 PCM을 수행한 후, 데이터가 각 클러스터에 속하는 소속함수의 값이 평균 소속함수 값보다 큰지를 따져본 후에, 평균 소속함수 값보다 큰값이 1개일 경우는 해당 클러스터 번호를 라벨링하고, 2개이상일 경우는 가장 큰 소속함수 값으로부터 2번째로 큰 소속함수 값을 뺀값의 차가 문턱치 T보다 클 경우에는 가장 큰 소속함수 값에 해당하는 클러스터 번호를 라벨링하고, 그렇지 않을 경우에는 라벨링을 하지 않는다. 이와같은 과정을 모든 데이터에 대해 수행하여 각 클러스터에 해당하는 seed point들을 얻고, 이 seed point들로부터 시작하는 영역 확장법을 이용하여 칼라 영상 분할 결과들을 얻었다. 위 알고리즘에서 평균 소속함수 값과 문턱치 T는 1/클러스터수이다. 또한, 영역 확장의 전처리 과정으로서 안정화된 seed point들을 얻기 위해 필터링이 수행되어 졌다.

III. 실험 및 결과

본 논문에서는 실험을 위하여 SUN-5 workstation을 이용하였다. 실험을 위한 영상으로 512 * 480 크기의 칼라 영상을 부 표본화(subsampling)한 256 * 240 크기의 칼라 영상 Peppers와 Collins를 이용하였다. 또한, 칼라 좌표가 영상 분할 결과에서 어떤 영향을 미치는가를 알기 위해 RGB, Ohta, XYZ등과 같은 여러 칼라 좌표계에서 실험을 하였다.

대부분의 영상 분할 결과는 사람의 시각에 의해 평가되어 진다. 여기서, 주요한 문제는 영상 분할 결과를 평가하기 위한 uniform criteria가 없다는 것이다. 영상 분할 결과를 평가하기 위해, J. Liu에 의해 개발된 척도를 이용하였다.^[17] 물론, 수작업에 의해 분할된 결과에 근거해 잘못라벨된 률(mislabelling rate)을 계산하기 위한 여러 시도가 있었다. 그러나, 이 방법은

손에 의해 분할된 결과가 정확하다는 것을 확신할 수 없는 어려움이 있다. 또한, 잘못라벨된 률을 이용한 방법은 영상의 진 라벨(true label)이 알려진, 합성된 영상(synthesized image)에서만 가능하다는 점이다. 그리고, 실 영상(real image)에서는 이 방법을 이용하기가 어려운 문제점이 있다. 합성된 영상 뿐만 아니라 실 영상들의 분할 결과를 평가하기 위해, 본 논문에서는 다음 평가함수 (evaluation function)를 이용하였다.^[17]

$$E = \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}} \quad (13)$$

여기서, R은 분할되어진 영상의 영역의 수이고 A_i 는 분할되어진 i 번째 영역의 면적(화소의 갯수)이다. e_i 는 영역 i 의 칼라 오차로써 다음과 같이 정의되어진다.

$$e_i = \sum_{j=1}^{A_i} \sqrt{(P1_{ij} - P2_{ij})^2 + (P1'_{ij} - P2'_{ij})^2 + (P1''_{ij} - P2''_{ij})^2} \quad (14)$$

여기서, $P1$, $P2$ 와 $P3$ 는 칼라 좌표 $P1 - P2 - P3$ 의 각각의 성분(예를 들면, RGB 좌표계에서 R, G와 B)를 나타낸다. $P1^j$ 는 $P1P2P3$ 칼라 좌표계에서 화소 j 의 칼라를 나타내고, $P2^j$ 는 분할된 영상에서 같은 화소의 부여된 칼라를 나타낸다. E의 값이 작을수록 분할된 결과가 좋다는 것을 의미하고, $\frac{e_i^2}{\sqrt{A_i}}$ 항은 커다란 칼라 오차를 가진 영역이나, 작은 영역에 불리함을 주는 항이다.

e_i 는 분할된 영역이 적절한 속성에 의해 잘 분할됐는지 아닌지를 나타내는 값이다. 커다란 e_i 값은 분할된 영역이 적절한 속성에 의해 표현되지 않았다는 것을 의미한다. 본 논문에서 E값은 영상 크기에 의해 정규화(normalize)되었고 1/1000단위로 스케일 되어졌다. 서로 다른 칼라 좌표계에서 본 연구에서 이용된 평가함수를 이용하여 영상 분할 결과를 평가하기위해, RGB좌표계 이외의 좌표계에서 영상 분할된 결과는 비교를 위하여 RGB 좌표계로 변환되어야 한다. 이는 서로 다른 좌표계에서 칼라 오차가 서로 다른 스케일을 갖기 때문에, 비교할 수 없는 이유 때문이다. 따라서, 본 논문에서는 RGB좌표계로 변환될 수 있는 좌표계만 이용하였다.

그림 2(a)는 칼라 영상 "Collins"의 원 영상이고, 그림 2(b)의 RGB좌표계에서 칼라 영상 "Collins"의 분

귀밑의 뺨에서 검정색의 음영진 영역이 입술의 색깔과 같은 빨간색의 영역으로 잘못 분할된 것을 알 수 있고 눈썹과 눈사이의 어두운색의 그늘진 영역이 빨간색영역으로 잘못 분할된 것을 알 수 있다. 또한, 오른쪽이마의 어두운색의 그늘진 영역 역시 빨간색영역으로 잘못 분할된 것을 알 수 있다.

그림 2(c)의 Ohta좌표계에서 분할 결과는 전반적으로 양호하였다. RGB에서 잘못 분할되었던 이마, 눈주위와 광대뼈 부근의 그늘진 영역들이 잘 분할되어진 것을 알 수 있다. 그럼 2(d) XYZ 좌표계에서 칼라 영상 분할 결과는 전반적으로 좋지 않았다. 영상 분할 결과를 보면 원 영상에서 빨간 입술영역이 음영진 색깔과 비슷한 색조를 띤 것을 알 수 있다. 그리고 원쪽 눈가와 이마 부분의 분할 결과가 좋지 않은 것을 볼 수 있다. 특히, 이 클러스터들의 중심은 XYZ 값에 의해(92.7, 85.7, 94.6)과 (92.1, 85.2, 95.5)로 아주 유사한 클러스터 중심값을 갖는 것을 알 수 있다.

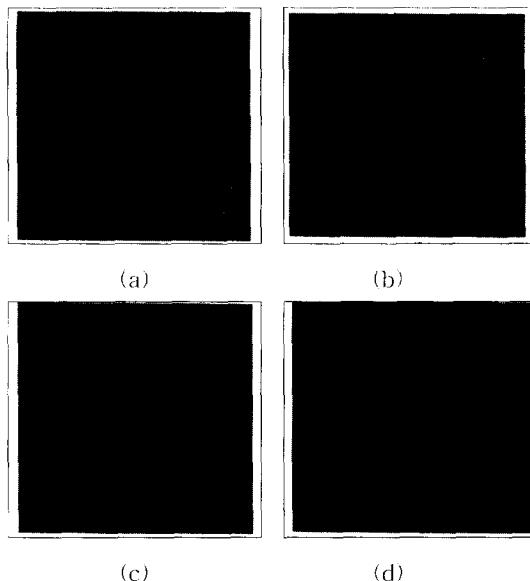


그림 2. (a) 칼라영상 “Collins”, (b) RGB, (c) Ohta, (d) XYZ

Fig. 2. (a) Color image “Collins”, (b) RGB, (c) Ohta, (d) XYZ

본 논문에서 사용된 평가함수 E 를 사용해 얻은 실험 결과(PCM의 결과)는 표 1과 같다.

표 1에서 보는바와 같이 칼라 영상 “Peppers”와 “Collins”에 대해 실험을 행하였고, RGB와 Ohta좌표계에서 양호한 실험 결과들을 얻었다. 평가함수의 오차

값은 적은 값일 수록 좋다. 클러스터의 모양(shape)과 분포(distribution)가 칼라 좌표계에 따라 달라지기 때문에, 본 논문의 실험에서 칼라 영상 분할에 있어서 영상 분할 알고리즘 뿐만이 아니라 칼라 좌표계 역시 매우 중요하다는 것을 알 수 있었다.

표 1. 칼라 영상들의 서로 다른 좌표계에서 평가함수 값

Table 1. The evaluation error of color images in the different color spaces.

| 영상의 종류 | RGB | Ohta | XYZ |
|---------|--------|--------|--------|
| Peppers | 1093.2 | 1171.2 | 1185.5 |
| Collins | 293.7 | 248.7 | 291.2 |

영상 분할의 결과들은 다음과 같은 조건에 의해 평가되어 진다.

첫째, 분할되어진 영상의 영역들은 칼라나 texture 같은 속성에 관해 균일(uniform)하고, 동질성을 가져야 된다. 둘째, 영역들은 simple해야 되고, 영역 내부에 많은 hole들이 포함되지 말아야 된다. 셋째, 인접한 영역들은 현저히 다른 특성을 가져야 한다. 넷째, 각 영역의 경계들은 simple해야되고 매끄러워야 한다. 그러나, 식(13)에서 사용되어진 평가 척도는 위의 여러가지 조건들을 만족하지 않는다. 위의 여러가지 조건들을 만족하는 평가 척도를 얻는것은 어렵다. 따라서, 영상 분할에 있어서 중대한 문제점은 분할 결과를 평가할수 있는 uniform criteria가 없다는 점이다. 따라서, 대부분의 영상 분할 결과들은 사람의 시각에 의해 평가되어 진다.

그림 3(a)는 칼라 영상 “Peppers”的 원 영상이고, 그림 3(b)는 RGB좌표계에서 PCM에 의해서만 클러스터링된 결과이고, 이 결과에서 볼 수 있는바와 같이 PCM에 의해서만 클러스터링된 결과는 경계선이 매끄럽지 못하고 영역의 내부에 많은 hole들을 갖는다. 따라서, 그림 3(c)와 3(d)에서는 후처리 과정으로써 영역 확장법을 이용하였다. 그림 3(c)는 RGB좌표계에서 PCM과 영역확장법을 이용한 결과이고, 그림 3(d)는 FCM과 영역 확장법을 이용한 결과이다. 그림 3(d)에서 앞부분의 가운데 있는 녹색 고추의 왼쪽 하단부가 빨간 고추와 같은 영역으로 잘못 분할되어 진 것을 알 수 있고, 가운데 빨간고추와 우측의 빨간 고추들에서 조명에 의해 하얗게 변사된 잡음 부분이 녹색고추와 같은 영역으로 잘못 분할 되어진 것을 알 수 있다. 반면에,

은 영역으로 잘못 분할 되어진 것을 알 수 있다. 반면에, 그림 3(c)에서는 이러한 부분들이 잘 분할 되어진 것을 알 수 있다.

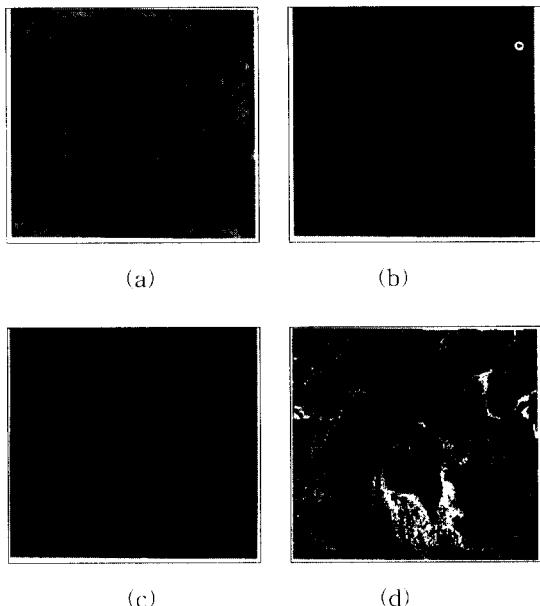


그림 3. (a) 칼라영상 "Peppers", (b) PCM, (c) PCM 과 영역확장, (d) FCM과 영역확장

Fig. 3. (a) Color image "Peppers", (b) PCM, (c) PCM and region growing, (d) FCM and region growing.

이와같은 상황을 보다 자세히 살펴보기 위해 그림4를 살펴보면, 그림 4(a)는 PCM에 의해 얻어진 결과중 각 클러스터에 속하는 소속함수 값이 0.2이상인 seed point들을 나타내고, 그림 4(b)는 FCM에 의해 얻어진 결과중 소속함수 값이 0.6이상인 seed point들을 나타낸다. 그리고 각 seed point들은 해당 클러스터의 중심 칼라에 의해 나타내어졌다. 이 그림 4에서 알 수 있는바와 같이, 가운데 빨간고추와 우측의 빨간고추들에서 조명에 의해 하얗게 반사된 잡음 부분이 seed point들을 얻기 위해 FCM을 이용한(그림 4(b)) 경우에는 0.6이상의 높은 소속함수 값을 갖는 반면에, PCM(그림 4(a))을 이용한 경우에는 0.2이하의 낮은 소속함수 값을 갖는 것을 그림 4를 통하여 알 수 있다. 그림 3(a)에서 가운데 빨간고추와 우측의 빨간고추들에서 조명에 의해 하얗게 반사된 잡음 부분은 다른 클러스터의 중심과의 색차 거리가 크지만, FCM을 이용한 경우 하얗게 반사된 잡음 부분이 빨간색 고추영역이나 검정색 배경영역에 비해 녹색 고추영역에 상대적인 거리가 가

깝기 때문에 높은 소속함수 값을 갖게 된다. 반면에, PCM의 경우 소속함수 값이 단지 데이터와 클러스터 중심과의 거리에만 의존하고 하얗게 반사된 잡음 부분은 다른 클러스터 중심과의 색차거리가 크기 때문에 낮은 소속함수 값을 갖게 된다. 앞에서도 언급한 바와 같이, 이와같은 상황은 FCM에 의해 얻어진 소속함수 값이 상대적인 값이기 때문에 발생한다. 즉, FCM에서 소속함수 값은 데이터가 다른 클러스터에 속하는 소속함수 값과 관련이 있기 때문이다. 따라서, FCM의 경우 "equal evidence"와 "ignorance"를 구분할 수 없다. 반면에, PCM의 소속함수 값은 데이터와 해당 클러스터의 중심과의 거리에만 의존하기 때문에 이러한 문제를 해결할 수 있다. 위의 실험을 통하여 본 논문에서 제안한 방법의 결과가 FCM를 이용한 결과 보다 우수함을 알 수 있었다.

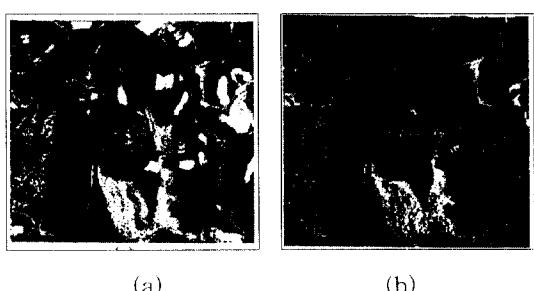


그림 4. (a) 소속함수값이 0.2 이상인 PCM의 seed point들, (b) 소속함수값이 0.6 이상인 FCM의 seed point들

Fig. 4. (a) Seed points of PCM over 0.2 (membership), (b) Seed points of FCM over 0.6 (membership)

IV. 결 론

영상 분할은 영상을 명암, 칼라, 운동 특성, 표면 특성 등 공통 특성을 나타내는 화소들의 집단을 만드는 과정으로 영상 인식을 위한 매우 중요한 단계이다. 그동안 칼라 영상 분할을 위해 여러가지 방법들이 이용되어져 왔고 그중에서도 FCM 방법은 칼라 영상 분할을 위해 널리 이용되어져 왔다. 그러나, FCM의 경우 "equal evidence"와 "ignorance"를 구분할 수 없다. 이는 FCM의 경우 소속 함수 값이 다른 클러스터와 관계가 있는 상대적인 값이기 때문이다. 따라서, FCM의 경우 잡음이 있는 상황에서는 분할시 문제점을 야기하게된다. 그러나, PCM의 경우 소속 함수 값이 다

스터 중심간의 거리에만 의존하기 때문에 이러한 문제점을 해결할 수 있었고, 칼라 영상에서 실험을 통하여 본 논문에서 제안한 방법이 FCM을 이용한 방법보다 우수함을 입증하였다.

본 논문에서는 먼저 PCM만을 이용하여 클러스터링을 하였다. 앞에서 언급한 바와 같이 클러스터의 모양과 분포는 칼라 좌표계에 따라 달라지기 때문에, 여러 칼라 좌표계에서 실험을 행하였고, RGB 와 Ohta 좌표계에서 양호한 분할 결과를 얻었다. 여기서, 칼라 영상 분할에 있어서 분할 알고리즘 뿐만아니라 칼라 좌표계 역시 매우 중요하다는 것을 알수 있었다. 그러나, PCM에 의해서만 클러스터링된 결과는 경계선이 매끄럽지 못하고 영역의 내부에 많은 hole 들이 있었고, PCM에 의해서만 분할된 결과를 평가하기 위해 (13)식과 같은 평가 척도를 이용하였으나, 이 척도는 앞에서 언급된 좋은 분할을 얻기위한 여러 조건들을 만족하지 않았다. 따라서, 본 논문에서는 PCM의 후처리 과정으로써 영역 확장을 이용하였고, 안정화 된 seed point들을 얻기 위해 영역 확장의 전처리 과정으로서 필터링이 행해지고, 이후에 영역 확장을 시도하였다. 또한, 분할된 결과는 사람의 시각에 의해 평가 되어졌다.

본 논문에서는 PCM과 영역 확장을 이용한 새로운 칼라 영상 분할 방법을 제안하였고, 제안된 방법은 의료 영상 분석 및 위성 사진 분석등 여러 관련 분야에 이용될 수 있으리라 생각된다. 앞으로 칼라 영상 분할 시 분할 결과를 정확히 평가할 수 있는 평가 척도 개발에 관해 더 연구할 예정이다. 또한, 색의 차이를 어떻게 정의하느냐 하는 문제는 매우 중요한 문제중의 하나이다. 따라서, 인간이 느끼는 색차이를 보다 정확히 표현할 수 있는 척도에 관해서 계속 연구할 예정이고, unsupervised 형태의 칼라 영상 분할에 관해서도 연구할 계획이다.

* 본 연구는 한국과학재단의 1994년 후반기 해외 Post Doc. 연수 지원으로 이루어 졌음.

참 고 문 헌

- [1] N.R. Pal and S.K. Pal, "A review on image segmentation technique," Pattern Recognition, Vol. 26, No. 9, pp. 1277-1294, 1993.

- [2] R.M. Haralick and L.G. Shapiro, "Image segmentation techniques," CVGIP, Vol.29, pp. 100-132, 1995.
- [3] Y. Otha, T. Kanade and T. Sakai, "Color information for region segmentation," CGIP, Vol. 13, pp. 224-241, 1980.
- [4] R. Ohlander, K. Price, and D.R. Reddy, "Picture segmentation using a recursive region splitting method," CGIP, Vol. 8, pp. 313-333, 1978.
- [5] T. Uchiyama and M.A. Arbib, "Color image segmentation using competitive learning," IEEE Trans. on PAMI, Vol. 16, pp. 1197-1206, Dec. 1994.
- [6] S.A. Shafer and T. Kanade, "Color vision," Encyclopedia of Artificial Intelligence, pp. 124-131, Wiley, New York, 1987.
- [7] L. A. Zadeh, "Fuzzy sets," Information Control, Vol. 8, pp.338-353, 1965.
- [8] J.C. Bezdek and M.M. Trivedi, "Low level segmentation of aerial image with fuzzy clustering," IEEE Trans. SMC, SMC-16, pp. 589-598, 1986.
- [9] Y.W. Lim and S.U. Lee, "On the color image segmentation algorithm based on the thresholding and fuzzy c-means techniques," Pattern Recognition, Vol. 23, pp. 935-952, 1990.
- [10] T.L. Huntsberger, C.L. Jacobs and R.L. Cannon, "Iterative fuzzy image segmentation," Pattern Recognition, Vol. 18, pp. 131-138, 1985.
- [11] 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, Feb. 1995.
- [12] R.Krishnapuram, J.M.Keller, "A possibilistic approach to clustering", IEEE Trans. on Fuzzy Systems, Vol. 1, No. 2, pp.98-110, 1993
- [13] M.J. Daily, "Color image segmentation using Markov Random Fields," IEEE Proc. Computer Society Conference, San Diego, pp. 304-312, June 1989.

- [14] A.K. Jain, "Fundamentals of Digital Image Processing," Englewood Cliffs, NJ, Prentice Hall Intl., 1989.
- [15] J.V. Ryzin, "Classification and Clustering," Academic Press, New York, 1977.
- [16] J.C. Bezdek, "Pattern Recognition with Fuzzy Objective Function algorithm," New York, Plenum Press, 1981.
- [17] J. Liu and Y.H. Yang, "Multiresolution Color Image Segmentation," IEEE Trans. on PAMI, Vol. 16, No. 7, pp. 689-700, July 1994

저자 소개



嚴 景 培(正會員)

1984년 전북대학교 전자공학과(공학사). 1986년 전북대학교 대학원 전자공학과(공학석사). 1990년 전북대학교 대학원 전자공학과(공학박사). 1995년 ~ 1996년 캐나다 토론토대학교 전기 및 컴퓨터공학과 박사후 연구원(Post Doc.). 1989년 ~ 현재 군산대학교 컴퓨터화학과 부교수. 주관심분야는 영상처리 및 병렬처리, 퍼지이론 및 신경회로망

李 俊 煥(正會員)

1980년 한양대학교 전자공학과(공학사). 1982년 한국과학원 전기 및 전자공학과 졸업(공학석사). 1990년 미국 미주리대학교 전기 및 컴퓨터공학과 졸업(공학박사). 1985년 ~ 현재 전북대학교 전자공학과 부교수. 주관심분야는 인공지능, 영상처리 및 인식, 퍼지이론 및 신경회로망