

# 결정적 어닐링 EM 알고리즘을 이용한 칼라 영상의 분할

박 종현\*, 박 순영\*, 조 완현\*\*

\*목포 대학교 전자공학과, \*\*전남 대학교 통계학과

전화 : (0636) 450-2878 / 팩스 : (0636) 454-0841

## Segmentation of Color Image

### Using the Deterministic Annealing EM Algorithm

Jong Hyun Park\*, Soon Young Park\*, Wan Hyun Cho\*\*

\*Dept. of Electronics Engineering, Mokpo National University

\*\*Dept. of Statistics, Chonnam National University

E-mail : jhpark@chungkye.mokpo.ac.kr

#### Abstract

In this paper we present a color image segmentation algorithm based on statistical models. A novel deterministic annealing Expectation Maximization(EM) formula is derived to estimate the parameters of the Gaussian Mixture Model(GMM) which represents the multi-colored objects statistically. The experimental results show that the proposed deterministic annealing EM is a global optimal solution for the ML parameter estimation and the image field is segmented efficiently by using the parameter estimates.

#### I. 서론

영상분할의 궁극적인 목적은 어떤 의미에 있어서 비슷한 성격을 보여주는 각 개체를 확인하는 것으로 공식적으로는 영상을 동일한 몇 개의 영역으로 분리하는 것으로 정의된다. 즉, 주어진 영상을 구성하고 있는 각 화소를 K개의 범주나 동일한 영역 중 하나에 분류함을 의미한다. 이것은 자동인식 로봇, 원격 의학진단, 대량의 영상자료에서 검색등 그 응용범위가 매우 광범위하다.

지금까지 여러가지 영상분할 알고리즘들이 제안되고 있으며 대표적인 방법은 정칙화 이론과 여러 가지 필터를 사용하는 방법[1], 마코프 확률모형과 베이지의 추정방법[2], 가우시안 혼합모형과 EM 알고리즘방법[3], 벡터의 양자화와 군집분석방법[4]등을 생각할 수 있다. 이들 대부분의 방법들은 각 픽셀에서 관측되는 광감도를 특징벡터로 표현하여 이들에 대하여 적절한 확률모형을 가정하고, 이들 확률모형을 결정하는 모수들을 통계적 방법으로 추정하여 이용하거나 또는 각 특징벡터간의 비유사도를 계산하고, 군집알고리즘을 사용하여 분할을 실시하는 방법들을 이용한다.

본 논문에서 우리는 최근에 조합적 최적화 문제에서 많은 관심을 불러일으키고 있는 어닐링(annealing) 개념을 이용할 예정이다. 이것은 최대 엔트로피의 원리를 이용한 것으로 목적함수의 국부적 최대값의 문제를 해결할 수 있는 가장 바람직한 방법으로 알려져 있

다. 또한 우리는 주어진 칼라 영상의 각 픽셀에서 측정되는 R.G.B(Red, Green, Blue) 색상 모델을 인간의 시각인지와 밀접한 관계가 있는 H.S.I(Hue, Saturation, Intensity) 성분의 특징벡터로 변환하고 확률모형으로 가우시안 혼합모형(Gaussian Mixture Model:GMM)을 고려하여 각 개체들을 분할하는 방법을 제안하였다.

#### II. 결정적 어닐링 EM 알고리즘

먼저 관측 가능한 특징벡터로 구성되는 벡터  $\mathbf{y}$ 를 불완비자료라 하고 벡터  $\mathbf{z}$ 를 관측되지 않은 값이라 하자. 이때 완비자료  $\mathbf{x} = (\mathbf{y}, \mathbf{z})$ 로 정의하고 우리는  $\log L_c(\boldsymbol{\theta} | \mathbf{x})$ 를 완비자료에 기초하여 형성된 로그우도(log likelihood)함수라 하자. 또한  $P(\mathbf{y} | \mathbf{z}; \boldsymbol{\theta})$ 를  $\mathbf{z}$ 가 주어졌을 때  $\mathbf{Y}$ 의 조건부 확률밀도함수를 나타내고  $P(\mathbf{z}; \boldsymbol{\gamma})$ 는 모수벡터  $\boldsymbol{\gamma}$ 를 갖는 관측되지 않는 벡터  $\mathbf{Z}$ 의 확률밀도함수를 나타낸다고 하자. 그때 완비자료의 로그우도함수  $\log L_c(\boldsymbol{\theta} | \mathbf{x})$ 는 다음과 같이 주어진다.

$$\log L_c(\boldsymbol{\theta} | \mathbf{x}) = \log P(\mathbf{y} | \mathbf{z}; \boldsymbol{\theta}) + \log P(\mathbf{z}; \boldsymbol{\gamma}) \quad (1)$$

여기서  $\boldsymbol{\theta}$ 는 모수벡터  $\boldsymbol{\theta}$ 와 사전분포의 모수벡터  $\boldsymbol{\gamma}$ 를 포함하는 벡터이다.

그러면 우리는 관측벡터  $\mathbf{y}$ 가 주어졌을 때 모수벡터  $\boldsymbol{\theta}$ 의 최우추정량을 계산하는 방법으로 EM 알고리즘을 이용할 수 있다. EM 알고리즘은 최우추정량의 초기값으로,  $\boldsymbol{\theta}^{(0)}$ 을 취하고, 다음의 두 단계를 반복적으로 적용하여 연속되는 추정량,  $\boldsymbol{\theta}^{(1)}$ ,  $\boldsymbol{\theta}^{(2)}$ , ...을 계산하는 방법이다.

**E-Step** : 사후확률분포  $P_z^{(t)} = P(\mathbf{z} | \mathbf{y}, \boldsymbol{\theta}^{(t-1)})$ 를 계산하고 이것을 이용하여 다음의 기대값을 구한다.

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t-1)}) = E_{P_z^{(t)}}(L_c(\boldsymbol{\theta} | \mathbf{x})) \quad (2)$$

**M-Step** : 다음의 함수를 최대로 하는 모수벡터  $\boldsymbol{\theta}$ 의 추정량  $\boldsymbol{\theta}^{(t)}$ 을 계산한다.

$$\theta^{(t)} = \arg \max_{\theta} Q(\theta | \theta^{(t-1)}) \quad (3)$$

그러나 이러한 EM 알고리즘은 다음과 같은 두 가지의 단점을 갖고 있다. 첫째는 모수벡터에 대한 초기값의 선택에 따라서 우도함수가 극부적 최대값을 취하게 되는 최우추정량을 제공한다는 것이고, 둘째는 관측되지 않은 자료를 사용하여 추정량을 계산하기 때문에 과도하게 적합되는 경향이 있다는 것이다. 이러한 문제점을 해결할 수 있는 하나의 방법으로 최대 엔트로피의 원리를 이용한 결정적 어닐링 EM 알고리즘을 이용할 수 있다.

우리는 완비자료의 로그우도함수  $\log L_c(\theta | x)$ 를 고정된 모수벡터  $\theta$ 에 대하여 관측되지 않는 변수  $z$ 의 함수로 고려하고, 관측되지 않는 전체 변수공간  $\Omega_z$ 상의 비용함수로 다음을 고려해보자.

$$H(z; y, \theta) = -\log L_c(\theta | x) \quad (4)$$

그때 우리는 엔트로피의 제약조건하에서 분포공간상의 임의의 확률밀도함수  $P(z; \gamma)$ 에 관하여 기대값  $E(H(z; y, \theta))$ 를 최소로 하는 문제를 생각할 수 있다. 이 값을 통계역학에서 자유에너지로 알려져 있으며 우리가 라그랑지 승수를 사용하면 다음과 같은 목적함수를 얻게된다.

$$\mathcal{H}(P_z^{(t)}, \theta) = E_{P_z^{(t)}}(-L_c(\theta | y)) + \beta \cdot E_{P_z^{(t)}}(\log P_z^{(t)}) \quad (5)$$

그때 주어진 일반화 자유에너지,  $\mathcal{H}(P_z^{(t)}, \theta)$ 를 최소로 하는 해는 다음과 같은 깁스분포로 주어진다라는 사실이 알려져 있다.

$$P^{(t)}(z; \theta^{(t-1)}) = \frac{\exp(-\beta H(z))}{\sum_{z' \in \Omega_z} \exp(-\beta H(z'))} \\ = \frac{(P(y | z; \theta) P(z; \gamma))^\beta}{\sum_{z' \in \Omega_z} (P(y | z'; \theta) P(z'; \gamma))^\beta} \quad (6)$$

따라서 우리는 모수  $\beta$ 에 의하여 결정되는 새로운 사후분포  $P^{(t)}(z; \theta^{(t-1)})$ 를 얻게된다.

다음으로 고정된 사후확률분포  $P^{(t)}(z; \theta^{(t-1)})$ 에 대하여 모수벡터  $\theta$ 에 관하여 일반화 자유에너지  $\mathcal{H}(P_z^{(t)}, \theta)$ 의 최소값을 주는 모수벡터의 값을 구해야 한다. 그런데 일반화 자유에너지는 다음과 같은 형태로 주어진다

$$\mathcal{H}(P_z^{(t)}, \theta) = Q_\beta(\theta | \theta^{(t-1)}) + \beta \cdot E_{P_z^{(t)}}(\log P_z^{(t)}) \quad (7)$$

위의 방정식에서 오른쪽쪽의 두 번째 항은 모수벡터  $\theta$ 와 독립이므로 우리는 첫 번째 항에 대하여 최소값을 갖는 모수벡터를 구하면 된다. 따라서 이것은 원래 EM 알고리즘의 M-step에 해당되고 우리는 우도방정식의 해를 구하여 모수벡터의 추정값을 구한다.

그런데 우리가 EM 알고리즘의 초기단계에서 계산한 모수벡터의 추정량은 실제 모수벡터 값과는 차이가 많이 일어나므로 E-step의 초기단계에서는 사후확률분포의 영향력을 가능한 낮게 하고, 반복계산이 진행될수록 영향력을 높여 가는 방법을 사용해야 한다. 따라

서 이러한 목적을 달성하기 위하여 우리는 원래의 EM-알고리즘에 어닐링 루프라고 부르는 새로운  $\beta$ -루프를 첨가하고, 또한 원래의 사후확률분포를 모수  $\beta$ 를 갖는 새로운 사후확률분포로 대신한다. 최종적으로 우리는 다음과 같은 결정적 어닐링 EM 알고리즘을 얻게된다.

**Algorithm**

```
INITIALIZE 모수벡터의 초기값과 사전확률분포 결정;
 $\theta \leftarrow \theta^{(0)}, P_z \leftarrow P_z^{(0)}$ ;
온도 T에 초기값을 부여
 $T = \frac{1}{\beta} \leftarrow T_0$ ;
WHILE T > T_FINAL;
    t = 0;
    REPEAT
        E-Step : 사후확률분포  $P_z^{(t)} = P(z | y, \theta^{(t-1)})$ 를
            계산하고 다음의 기대값을 구한다;
             $Q_\beta(\theta | \theta^{(t-1)}) = E_{P_z^{(t)}}(-\log L_c(\theta | x))$ 
        M-Step : 다음의 함수를 최소로 하는 모수벡터  $\theta$ 의
            추정량  $\theta^{(t)}$ 을 계산;
             $\theta^{(t)} = \arg \max_{\theta} Q(\theta | \theta^{(t-1)})$ 
        t = t + 1;
    UNTIL 수렴조건;
    온도를 낮춘다  $T \leftarrow \eta \cdot T$ ;
    추정량의 값을 바꾼다
 $\theta^{(0)} \leftarrow \theta^{(t)}, P_z^{(0)} \leftarrow P_z^{(t)}$ ;
```

**III. 영상분할에서 가우시안 혼합모형에 응용**

먼저  $y = (y_1, \dots, y_n)$ 를 주어진 칼라영상의 n개의 픽셀에서 관측되는 특징벡터라 하자. 또한 이들 각각의 픽셀은 g개의 서로 다른 개체 또는 무늬 중 하나에 속하고, 이때 관측되지 않는 벡터  $z = (z_1, \dots, z_n)$ 은 각 픽셀이 특정한 개체를 표시하는 집단 표시변수벡터를 나타내자. 그러면 영상분할은 관측벡터  $y$ 가 주어졌을 때 관측되지 않는 표시벡터  $z$ 를 추론하는 문제로 볼 수 있으며 제안된 어닐링 EM 알고리즘을 적용하여 해결할 수 있다.

또한 우리는 각 픽셀에서 관측되는 특징벡터  $y_j$ 에 대응하는 확률벡터  $Y_j$ 의 분포로 유한혼합모형을 많이 가정하며, 특히 각 집단의 주변 확률밀도함수로 평균이  $\mu_i$ 이고 공분산 행렬이  $\Sigma_i$ 인 다변량 정규분포,  $\phi(y_j; \mu_i, \Sigma_i)$ 를 사용한다. 그러면 확률벡터  $Y_j$ 의 확률밀도함수는 다음과 같은 형태로 주어진다.

$$P(y_j) = \sum_{i=1}^g \pi_{ij} \phi(y_j; \mu_i, \Sigma_i), \quad (j=1, \dots, n) \quad (8)$$

여기서  $\pi_{ij}$ 는 j번째 픽셀이 i번째 객체에 속할 사전확률을 나타낸다. 또한 각 픽셀의 구조에 대하여 공간적 관련 성격을 무시하고, 이들이 서로 독립적이며 동일한 분포를 따른다고 가정하면 그때 표시벡터  $Z$ 의 사후확률분포는 다음과 같이 주어진다.

$$P(z; \gamma) = \prod_{i=1}^n \prod_{j=1}^g \pi_{ij}^{z_{ij}} \quad (9)$$

여기서  $Z_{ij}$ 는  $j$ 번째 픽셀이  $i$ 번째 그룹에 속하면 1을 갖고 그렇지 않으면 0을 갖는 확률변수를 나타내고  $\pi_i$ 는 모든 객체  $j$ 가  $i$ 번째 객체에 속할 사전확률을 나타낸다.

반면에 영상분석에서 가정하는 공통된 성격으로 확률표시벡터  $\mathbf{z}$ 가 주어졌을 때 특징벡터의 조건부 확률 분포가 각 픽셀간에 독립적으로 분포한다는 것이다. 그때 이러한 가정 하에서 특징벡터  $\mathbf{y}$ 의 확률밀도함수는 다음과 같이 주어진다.

$$P(\mathbf{y} | \mathbf{z}; \Theta) = \prod_{i=1}^g \prod_{j=1}^n P_i(\mathbf{y}_j; \theta_i)^{z_{ij}} \quad (10)$$

여기에서  $\theta_i$ 는 평균벡터  $\mu_i$ 와 공분산 행렬  $\Sigma_i$ 을 포함한다. 그러므로 확률벡터  $\mathbf{Y}$ 의 로그우도함수는 다음과 같다.

$$\log L_c(\Theta | \mathbf{x}) = \sum_{i=1}^g \sum_{j=1}^n Z_{ij} \log P_i(\mathbf{y}_j; \theta_i) \quad (11)$$

그러면 어닐링 EM 알고리즘의  $t$  번째 반복계산의 E-step은 관측자료  $\mathbf{y}_j$ 가 주어졌을 때 관비자료 로그우도함수  $\log L_c(\Theta | \mathbf{x})$ 에 대한 조건부 기대값의 계산을 요구한다. 그런데  $\log L_c(\Theta | \mathbf{x})$ 이 관측되지 않은 각 픽셀의 그룹표시변수  $Z_{ij}$ 들의 선형결합으로 주어지기 때문에 E-step은 확률변수  $Z_{ij}$ 대신에 다음과 같이 주어지는 이것의 조건부 기대값,  $E\{Z_{ij} | \mathbf{y}_j, \Theta^{(t-1)}\}$ 으로 대체함을 의미한다. 그런데 이것은  $(t-1)$ 번째 반복계산 후에  $j$ 번째 측정값이  $i$ 번째 그룹에 속할 사후확률의 추정량을 의미하며 어닐링 EM 알고리즘의 E-step에 의하여 다음과 같이 계산된다.

$$\begin{aligned} \tau_i(\mathbf{y}_j)^{(t)} &= E\{Z_{ij} | \mathbf{y}_j, \Theta^{(t-1)}\} \\ &= \text{pr}\{Z_{ij} = 1 | \mathbf{y}_j, \Theta^{(t-1)}\} \\ &= \frac{\{\pi_i^{(t-1)} \phi_i(\mathbf{y}_j; \mu_i^{(t-1)}, \Sigma_i^{(t-1)})\}^\beta}{\sum_{h=1}^g \{\pi_h^{(t-1)} \phi_h(\mathbf{y}_j; \mu_h^{(t-1)}, \Sigma_h^{(t-1)})\}^\beta} \end{aligned} \quad (12)$$

다음으로  $t$ 번째 반복에서 M-step은 함수  $Q_\beta(\Theta; \Theta^{(t-1)})$ 의 값을 최대로 만드는 모수의 값  $\Theta^{(t)}$ 을 계산하는 것이다. 우리가 조건부 독립성을 만족하는 특징벡터  $\mathbf{y}_j$ 의 확률분포로 다변량 정규분포를 사용하면  $i$ 번째 그룹의 평균벡터와 공분산 행렬의 추정량은 다음의 수식으로 계산된다.

$$\begin{aligned} \mu_i^{(t)} &= \frac{\sum_{j=1}^n \tau_i^{(t-1)}(\mathbf{y}_j) \cdot \mathbf{y}_j}{\sum_{j=1}^n \tau_i^{(t-1)}(\mathbf{y}_j)} \quad (13) \\ \Sigma_i^{(t)} &= \frac{\sum_{j=1}^n \tau_i^{(t-1)}(\mathbf{y}_j) (\mathbf{y}_j - \mu_i^{(t)}) (\mathbf{y}_j - \mu_i^{(t)})^T}{\sum_{j=1}^n \tau_i^{(t-1)}(\mathbf{y}_j)} \end{aligned}$$

또한 모든 픽셀  $j$ 가  $i$ 번째 객체에 속한 사전확률  $\pi_i$ 의  $t$ 번째 추정량은 다음에 의해서 주어진다.

$$\pi_i^{(t)} = \frac{\sum_{j=1}^n \tau_i^{(t-1)}(\mathbf{y}_j)}{n}, \quad (i=1, \dots, g) \quad (14)$$

따라서 영상분할은 각 픽셀  $j$ 에 대하여 이것이  $i$ 번째 객체에 속할 사후확률  $\tau_i(\mathbf{y}_j)^{(t)}$ 을 계산하고 이중 최대값을 갖는 그룹에 픽셀  $j$ 를 할당함으로써 이루어진다.

#### IV. 실험 및 결과

제안된 영상분할 알고리즘의 효율성을 실험하기 위하여  $100 \times 100$ 의 픽셀로 구성되고 각 픽셀은 R.G.B 세 개의 색상으로 이루어진 그림 1(a)의 peppers 영상을 사용하였으며 이 영상을 인간의 시각인지와 밀접한 관계가 있는 H.S.I 색상모델로 변환한 후에 색상성분과 관계가 있는 hue와 saturation성분만을 사용하여 2차원의 특징벡터를 구성하였다[5]. 그림 1(b)는 변환된 H.S.I 모델에서 각 픽셀에 대한 hue와 saturation성분을 2차원 극좌표 평면 위에 표시한 결과로서 원래의 peppers영상에서 관찰할 수 있는 것처럼 픽셀들을 3개의 동질의 특성을 가지고 있는 그룹으로 분류할 수 있음을 볼 수 있다.



그림 1. 실험에 사용한 영상  
(a) peppers image(100×100)  
(b) H와 S의 극좌표 평면에서의 픽셀들의 분포

영상분할은 같은 종류의 집단에 속한 샘플들을 하나의 개체로 분류함으로써 수행되기 때문에 각 픽셀들을 개체의 수만큼 효율적으로 집단화시킬 수 있는 방법이 중요하다. 실험은 먼저 기존의 EM알고리즘과 제안된 어닐링 EM 알고리즘의 집단화 특성을 살펴보기 위하여 각각의 다른 초기 조건을 사용하여 알고리즘들을 그림1의 데이터에 적용하였으며 그 결과가 그림2에 나타나 있다.

그림 2의 (a)는 그룹의 중심에 해당하는 값들을 초기 위치로 선택한 경우이며 (b)와 (c)는 초기 위치를 임의적으로 선택한 경우이다. EM 알고리즘과 어닐링 EM 알고리즘을 수행하기 위하여 필요한 초기 조건 중에서 공분산  $\Sigma_i^0$ 는 성분이 0.01인 주 대각선 행렬을 사용하고 사전확률은 서로 동일하게 삼았으며 (즉  $g=3$ 인 경우  $\pi_i^0=1/3$ ) 초기 평균벡터  $\mu_i^0$ 는 그림 2의 (a), (b), (c)에서 선택된 초기 위치를 사용하여서 전체 우도 함수가 최대가 되는 모수를 추정하였다. 그림 2의 (d), (e), (f)는 EM 알고리즘을 사용하여 세 집단으로 수렴시킨 후에 추정된 평균벡터  $\mu$ 와 공분산 행렬  $\Sigma$ 를 사용하여  $(\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu) = 1$ 을 만족시키는 타원체를 표시한 결과로서 EM알고리즘이 주어진 샘플들을 어떤 형태로 집단화시킬 수 있는지를 쉽게 알아 볼 수 있다[6]. 예측한 바와 같이 그룹의 중심으로 초기위치를 시작한 경우는 어닐링 EM 알고리즘의 경우와 비슷하게 수렴된 형태를 갖게 되었으나 초기 조건을 임의적으로 선택한 경우는 수렴된 결과가 각각 다르게 나타났으며 이것은 전체 우도함수가 초기 조건에 의존한 국부적으로 최대가 됨을 의미한다. 위와 같이 일관성이 부족한 세 개의 집단으로 수렴된 결과를 사용하여 영상을 분류할 시에는 정확도가 떨어지게 되며 특히 그림 2(f)의 경우는 한 개의 집단이 다른

집단에 거의 포함되어서 3개의 객체로 분할은 불가능하다. 그림 2의 (g), (h), (i)는 제안된 어닐링 EM 알고리즘을 사용한 결과로서 초기 조건과는 독립적으로 robust하게 일정한 형태로 수렴함을 볼 수 있는데 이것은 전체 우도함수가 초기조건에 상관없이 global하게 최대가 됨을 의미한다. 여기서  $T = 0.4$ 를 사용하였으며 모든 실험에서 수렴 조건으로는 전체 우도함수의 변화량이 0.001% 미만일 경우로 하였다.

초기조건

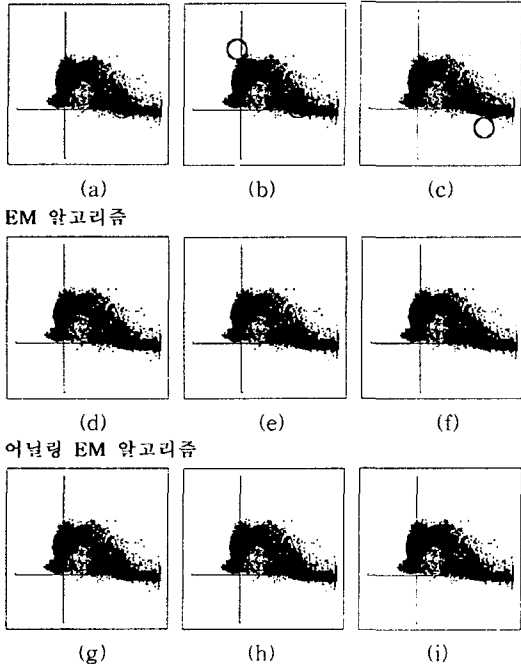


그림 2. 세 종류의 초기조건에 EM 알고리즘과 어닐링 EM 알고리즘을 적용한 결과

그림 3은 임의적으로 선택된 초기조건을 사용하여 EM 알고리즘과 어닐링 EM 알고리즘을 두 종류의 다른 영상에 적용하여서 분할한 경우를 보여준다. 제안된 알고리즘이 각각의 객체를 더욱 정확하게 분할할 수 있으며 특히 예지 부근에서 세밀한 영상 정보들이 시각적으로 적합하게 분류됨을 관찰할 수 있다.




그림 3. EM 알고리즘과 어닐링 EM 알고리즘의 영상 분할 결과

(a) airplane 영상, (b) airplane 영상에 대한 EM 알고리즘 결과, (c) airplane 영상에 대한 어닐링 EM 알고리즘 결과, (d) peppers 영상, (e) peppers 영상에 대한 EM 알고리즘 결과, (f) peppers 영상에 대한 어닐링 EM 알고리즘 결과

결과적으로 제안된 어닐링 EM 알고리즘은 초기조건에 의존하지 않고 최적의 전체 우도함수의 조건에 수렴하게 됨으로서 각 샘플들을 이상적으로 집단화시킬 수 있으며 이 결과를 바탕으로 영상을 효율적으로 분할할 수 있음을 볼 수 있다.

V. 결론

본 논문에서는 통계적 확률모형에 기반을 둔 칼라 영상의 분할 방법을 제안하였는데 먼저 칼라영상의 각 픽셀에 대한 R.G.B 색상모델을 인간의 시각인지와 비슷한 H.S.I 성분의 특징벡터로 변환하고 확률모형으로 가우시안 혼합모형(GMM)을 사용하여 각 개체들을 분할하였다. GMM의 모수벡터 추정방법으로서 기존의 EM알고리즘이 초기조건에 의존한 우도함수의 극부적 최대값을 제공하는 문제점을 개선하기 위하여 새로운 모수추정방법인 어닐링 EM알고리즘이 유도되었다.

제안된 방법은 모수벡터를 추정하는데 최대엔트로피의 원리를 이용하므로써 초기조건과는 독립적으로 최적의 전체 우도함수의 조건에 수렴되게 할 수 있었다. 실험을 통하여 제안된 어닐링 EM 알고리즘의 robust한 동작상태를 관찰할 수 있었으며 이 결과를 바탕으로 칼라 영상이 효율적으로 분할됨을 볼 수 있었다.

본 알고리즘을 수행하기 위하여 필요한 초기 온도 T 값의 선택과 감소비율이 최적의 전체우도함수에 수렴하는데 미치는 영향은 차후 연구에서 진행될 예정이다.

참고문헌

- [1] M. Unser, A. Aldroubi, and M. Eden(1991), Recursive regulation filters: Design, properties and applications. IEEE Transactions on PAMI, Vol 13, No
- [2] Stuart Geman and Donald Geman, stochastic relaxation, Gibbs distributions and the Bayesian restoration of images, IEEE Trans. PAMI, vol6, 1984, 721-741
- [3] G.J. McLachlan, S.K. Ng, G.J. Galloway, and D. Wang(1998), Clustering of Magnetic Resonance Images, Technical Report, Department of Mathematics, University of Queensland.
- [4] Thomas Hofmann and Joachim M. Buhman (1997), Paiwise Data Clustering by Deterministic Annealing, IEEE Transactions on PAMI, vol 19, No 1, 1-13.
- [5] Serge Belongie, Chad Carson, Hayit Greenspan, and Jitendra Malik, Color- and Texture-Based Image Segmentation Using EM and Its Application to Content-Based Image Retrieval. IEEE Computer Society, pp. 675-682, Jan. 1998.
- [6] Patricia McKenzie, Michael Alder, The EM algorithm used for Gaussian Mixture Modelling and its Initialization, Pattern Recognition in practice IV, Vlieland, 1994.