



다중해상도 kd-트리와 클러스터 유효성을 이용한 점증적 EM 알고리즘과 이의 영상 분할에의 적용

Incremental EM algorithm with multiresolution kd-trees and cluster validation and its application to image segmentation

이경미
Kyoung-Mi Lee

덕성여자대학교 컴퓨터학과
Department of Computer Science, Duksung Women's University

요 약

본 논문은 효율적인 영상 분할을 수행하기 위한 다중해상도와 동적인 성질을 가지고 있는 새로운 EM 알고리즘을 제안한다. EM 알고리즘은 가장 많이 사용되고 성능이 우수한 클러스터링 방법이다. 그러나, 기존의 EM 알고리즘은 다중해상도 데이터 처리에 대한 문제점과 클러스터 개수에 대한 사전 지식 요구라는 단점을 가지고 있다. 본 논문에서는 이러한 문제점을 해결하기 위해서 E-단계에 다중해상도 kd-트리를 적용함으로써 다중해상도 데이터 처리 문제를 해결하였고, 순차적 데이터에 따라 클러스터를 할당할 수 있게 하였다. 클러스터의 유효성을 검사하기 위해서, 클러스터 병합 원칙을 이용한다. 본 논문에서는 제안하는 알고리즘을 텍스처 영상 분할에 적용하였고, 우수한 성능을 보였다.

키워드 : 클러스터링, EM 알고리즘, kd-트리, 클러스터 유효성 검사, 영상 분할

Abstract

In this paper, we propose a new multiresolutional and dynamic approach of the EM algorithm. EM is a very popular and powerful clustering algorithm. EM, however, has problems that indexes multiresolution data and requires a priori information on a proper number of clusters in many applications. To solve such problems, the proposed EM algorithm can impose a multiresolution kd-tree structure in the E-step and allocates a cluster based on sequential data. To validate clusters, we use a merge criteria for cluster merging. We demonstrate the proposed EM algorithm outperforms for texture image segmentation.

Key Words : Clustering, EM Algorithm, Kd-tree, Cluster Validate, Image Segmentation.

Received: Aug. 13, 2015
Revised : Oct. 30, 2015
Accepted: Oct. 30, 2015
† Corresponding author
kmlee@duksung.ac.kr

1. 서 론

컴퓨터 시각 및 패턴인식 분야의 다양한 문제를 해결하는데 있어서 클러스터링은 매우 중요한 부분을 차지하고 있다. k -차원의 공간에 N 개의 데이터 $x = \{x^n | n=1, \dots, N\}$ 가 주어진다 면, 클러스터링 알고리즘은 이들을 각각 J 개의 클러스터 $\{c_j | j=1, \dots, J\}$ 중 하나에 할당한다. 이때, 같은 클러스터에 속한 데이터들은 매우 유사한 특성을 가진 반면, 서로 다른 클러스터에 속한 데이터들은 높은 비유사성을 갖게 된다. 따라서, 클러스터링 알고리즘의 목적은 같은 클러스터에 속하게 되는 데이터의 공통된 특성을 찾는 것이다. 따라서, 클러스터링 알고리즘의 목적은 같은 클러스터에 속하게 되는 데이터의 공통된 특성을 찾는 것이다. 각 클러스터 c_j 는 평균 μ_j 과 공분산 Σ_j 으로 표현된다.

본 논문에서는 타원형의 클러스터링에 뛰어난 EM 알고리즘을 사용한다[1]. EM 알고리즘은 Expectation (E-단계)와 Maximization (M-단계)의 두 단계로 구성된다. E-단계에서는 알려지지 않은 변수들에 대한 분포를 예측하고, M-단계에서는 이들 변수에 대한 예측을 최대화시키는 매개변수를 찾는다. EM 알고리즘의 두 단계가 반복되면서 매개변수들이

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

실제값에 수렴하게 된다.

EM 알고리즘은 본래 모든 데이터를 가지고 실행하는 오프라인 또는 배치(batch) 형태의 알고리즘이다. 그러나, 데이터가 계속적으로 발생하는 경우엔 배치 형태의 방법은 한계가 있다. 이 문제를 해결하기 위해, Nowlan은 EM 알고리즘에 대한 점증적인 방법을 제안하였다[2]. J. Xu *et.al* [3]와 Ng *et.al* [4]는 온라인 EM 알고리즘을 동작 인식 및 온라인 예측에 적용하였다. 그러나, 이 두 방법 모두는 클러스터 개수를 미리 정해야 한다. 논문 [5]는 클러스터 개수를 미리 정하는 대신에, Allocation 단계(A-단계)에서 데이터에 따라 클러스터를 새로이 할당할 수 있는 할당 EM(EAM) 알고리즘을 소개하였다.

본 논문에서는 EM알고리즘의 E-단계에 다중해상도 kd-트리 구조를 적용하였고, 이를 순차적 데이터를 처리할 수 있는 할당 EAM 방법으로 실행할 수 있는 방법을 제안한다. 클러스터 구조가 과도하게 증가하는 것을 막기 위해 유효성 검사를 통해 클러스터를 합병하였다. 2장에서는 기본 EM 배치 알고리즘과 다중해상도 kd-트리를 이용한 EM 배치 알고리즘을 간단하게 설명한다. 3장에서는 kd-트리와 클러스터 유효성 검사를 포함한 새로운 할당 EM 알고리즘을 제안한다. 4장은 제안한 알고리즘을 텍스처 영상 분할에 적용한 실험결과를 보여주고, 5장에 결론이 주어진다.

2. 다중해상도 ks-트리를 이용한 EM 배치 알고리즘

본 장에서는 EM 배치 알고리즘과 다중해상도 kd-트리를 이용한 EM 배치 알고리즘을 간단하게 설명한다.

2.1 EM 배치 알고리즘

우선, EM 알고리즘은 매개변수 θ 를 예측하기 위해 최대우도(Maximum Likelihood)로 초기화한 후, E-단계와 M-단계를 반복적으로 실행하면서 계속적으로 예측을 실행한다[6]. θ 에 대한 결합 확률을 $P(x^n, j | \theta)$ 라고 하자. x^n 에 대한 주변 확률은 $P(x^n | \theta) = \sum_j P(x^n, j | \theta)$ 이다. $\bar{\theta}$ 을 현재의 예측량이라고 하면, E-단계에서는 베이지안 정리를 이용하여, j 번째 클러스터 c_j 에 의한 후행 확률을 계산한다.

$$P(j | x^n, \bar{\theta}) = \frac{P(x^n, j | \bar{\theta})}{\sum_{i=1}^J P(x^n, i | \bar{\theta})} \quad (1)$$

특히 지수 함수를 사용한다면, x^n 에 대한 주변 확률은 $P(x^n, j | \theta) = \exp\left[-(x^n - \mu_j^t) \left(\sum_j^n\right)^{-1} (x^n - \mu_j^t)'\right]$ 이 된다.

식 (1)을 이용하여, M-단계는 모든 데이터에 대해 예측된 로 그우도를 정의할 수 있다.

$$l(\theta | \bar{\theta}, X) = \sum_{n=1}^N \sum_{j=1}^J P(j | x^n, \bar{\theta}) \log P(x^n, j | \theta)$$

여기서 $l(\theta | \bar{\theta}, X)$ 는 예측량 θ 에 대해 최대화된다. M-단계는 논문 [7]에 따라 클러스터의 매개변수인 평균 μ_j 과 공분산 Σ_j 을 수정한다.

$$\mu_j = \frac{\sum_{n=1}^N x^n P(j | x^n, \bar{\theta})}{\sum_{n=1}^N P(j | x^n, \bar{\theta})} \quad (2)$$

$$\Sigma_j = \frac{\sum_{n=1}^N (x^n - \mu_j)(x^n - \mu_j) P(j | x^n, \bar{\theta})}{\sum_{n=1}^N P(j | x^n, \bar{\theta})} \quad (3)$$

기호는 전치행렬을 의미한다.

2.2 다중해상도 kd-트리를 이용한 EM 배치 알고리즘

EM 알고리즘의 속도를 향상시키기 위해, Moore는 다중해상도 kd-트리를 사용할 것을 제안하였다[8,9]. Moore는 현재 노드에 바운딩 박스를 추가하여 그 노드에 포함된 데이터의 개수에 따라 분리하는 하향식(top-down)의 다중해상도 트리를 사용하였다. 리프(leaf) 노드는 노드 내의 데이터 개수가 임계치 이하여서 더 이상 분리할 필요가 없는 노드를 의미한다. Moore는 전체 데이터의 개수의 1%를 분리 임계치로 설정하였다.

θ^t 는 EM 알고리즘의 t 번째 반복 후의 예측량이라 하자. θ^{t+1} 를 구성하는데 필요한 통계를 계산하기 위해, M-단계의 식 (2)와 (3)은 다음과 같이 변경된다.

$$\mu_j^{t+1} = \frac{\sum_{n=1}^N x^n P(j | x^n, \theta^t)}{\sum_{n=1}^N P(j | x^n, \theta^t)} \quad (4)$$

$$\Sigma_j^{t+1} = \frac{\sum_{n=1}^N (x^n - \mu_j^t)(x^n - \mu_j^t)' P(j | x^n, \theta^t)}{\sum_{n=1}^N P(j | x^n, \theta^t)} \quad (5)$$

kd-트리를 이용하는 EM 배치 알고리즘을 수행하기 위해서, 식 (4)와 (5)는 루트(root) 노드부터 계산되어진다. 만약 x 가 리프 노드라면, E-단계의 식(1), 즉 t 번째 클러스터의 후행 확률은 다음으로 대체된다.

$$P(j | \bar{x}, \theta^t) = \frac{P(\bar{x}, j | \theta^t)}{\sum_{k=1}^J P(\bar{x}, k | \theta^t)} \quad (6)$$

여기서 리프 노드가 매우 작다면, 그 노드에 포함된 데이터에 대한 후행 확률 $P(j | \bar{x}, \theta^t)$ 의 차이가 거의 없을 것이다[8]. 예를

들어, $\sum_{n=1}^N x^n P(j | \bar{x}, \theta^t) \approx P(j | \bar{x}, \theta^t) \sum_{n=1}^N x^n$ 이다. 그러나, 정확도를 유지하려는 이런 가정은 리프 노드의 개수를 데이터의 개수와 거의 같게 만들 것이며, 따라서 EM 알고리즘에 대한 시간적 이득은 거의 없게 된다. Moore는 t 번째 클러스터의 후행 확률의 최대값 $P_{\max}(j | x^n, \theta^t)$ 과 최소값 $P_{\min}(j | x^n, \theta^t)$ 사이의 차이가 작은 노드를 잘라냈다[8,9].

3. 제안하는 알고리즘

클러스터링 알고리즘의 주요 목적은 데이터에 정확하게 맞는 모델을 찾는 것이 아니라, 주어진 데이터에 대해 k 개의 클러스터에 맞는 통계학적 모델을 만드는 것이다. 따라서 적합한 클러스터 개수를 찾는 것은 클러스터링 결과에 매우 영향을 미친다. 그러나 대부분의 경우에 적합한 클러스터 개수를 결정하는 것은 쉬운 일은 아니다. 최적의 개수보다 적은 수의 클러스터가 주어진다면, EM 알고리즘은 서로 다른 클러스터를 함께 묶을 수 있다. 또한, 많은 수의 클러스터가 주어진다면, EM 알고리즘은 하나의 클러스터를 여러 개의 클러스터로 분리할 것이다. 본 장에서는 클러스터 개수에 대한 사전 정보가 없는 순차적 데이터를 클러스터링 하는 다중해상도 kd-트리를 이용한 EM 알고리즘이 제안한다.

3.1 온라인 알고리즘

2장에서 살펴본 EM 알고리즘은 오프라인 또는 배치 형태로 실행된다. 또 다른 실행 방법으로 온라인 또는 순차적 학습이 있다. 온라인 클러스터링 알고리즘은 데이터가 입력될 때마다 매개변수를 변경한다. n 번째 반복 때 데이터 x^n 이 나타난다고 하자. 온라인 알고리즘은 단계별 수식을 이용하여 식 (4)와 (5)를 아래와 같이 변경한다.

$$\mu_j^{n+1} = \frac{f_j^n(x) + \eta^n [x^n P_j^n - f_j^n(x)]}{f_j^n(1) + \eta^n [P_j^n - f_j^n(1)]} \quad (7)$$

$$\sum_j^{n+1} = \frac{f_j^n(x - \mu_j) + \eta^n [(x^n - \mu_j)(x^n - \mu_j)' P_j^n - f_j^n(x - \mu_j)]}{f_j^n(1) + \eta^n [P_j^n - f_j^n(1)]} \quad (8)$$

여기서 학습 매개변수 $\eta^n = \left(1 + \frac{\lambda^n}{\eta^{n-1}}\right)^{-1}$ ($\frac{1}{n} \leq \eta^n \leq 1$)이고, λ^n ($0 \leq \lambda^n \leq 1$)는 감쇄 인자로 n 에 따라 점차적으로 감소한다. $f_j^n(x)$ 은 $f_j^n(x) = f_j^{n-1}(x) + \eta^{n-1} [x^{n-1} P_j^{n-1} - f_j^{n-1}(x)]$ 으로 정의되고, $f_j^n(1)$ 와 $f_j^n(x - \mu_j)$ 도 같은 방식으로 정의된다.

kd-트리를 이용하는 온라인 EM 알고리즘을 수행하기 위해서, 식 (7)과 (8)은 루트 노드에서부터 계산되어진다. x^n 이 리프 노드라면, s 번째 반복에서 E-단계의 식 (6)은 s 번째 클러스터의 후행 확률을 다음과 같이 대체할 수 있다.

$$P(j | x^n, \theta^s) = \frac{P(x^n, j | \theta^s)}{\sum_{k=1}^J P(x^n, k | \theta^s)} \quad (9)$$

3.2 점증적 할당 알고리즘

EM 알고리즘에서 적절한 클러스터 개수를 선택하는 문제를 해결하기 위해, 점증적 알고리즘은 온라인 모델링에 적합한 자원 할당 방식을 적용하였다[5]. 새로운 데이터가 입력될 때마다, 데이터 신규 임계치에 따라 할당 EM 알고리즘은 기존의 클러스터 매개변수를 갱신하거나 새로운 클러스터를 추가한다.

점증적 클러스터 알고리즘은 적은 수의 클러스터 개수 ($J_0 \leq J$)를 초기화 하면서 시작하거나, 아니면 사전에 정의된 클러스터 없이 시작할 수 있다($J_0 = 0$). 알고리즘은 J_0 개의 클러스터를 초기화하고, 평균 μ_j^0 은 랜덤(random)하게, 공분산 Σ_j^0 은 단위 행렬로 초기화한다. 데이터에 대한 사전 지식이 없다면, 알고리즘은 클러스터 없이 시작한다.

새로운 데이터 x^n 가 입력될 때마다, 제안하는 알고리즘은 기존 클러스터의 평균과 비교하여 가장 가까운 클러스터 $C_{nearest}$ 를 찾는다. 이 때, 리프 노드라면 식 (9)를, 그렇지 않다면 식 (6)을 이용하여 클러스터와의 거리를 계산한다. 신규성 평가에 따라, 가장 가까운 클러스터에 대한 후행 행렬은 임계치 ε^n 보다 커야만 한다

$$P(nearest | x^n, \bar{\theta}) > \varepsilon^n. \quad (10)$$

임계치는 큰 값으로 초기화 되고($\varepsilon^0 = \varepsilon_{max}$), 반복될 때마다 가장 작은 값 ε_{min} 이 될 때까지 감쇄 인자값 γ ($0 < \gamma < 1$)을 곱한다.

식 (10)을 만족하는 경우는 데이터 x^n 이 어떤 클러스터와도 비슷하지 않는 상황으로, x^n 으로 새로운 클러스터를 만들고 클러스터의 개수를 증가시킨다. 이 단계를 Allocation(A-단계)라 한다. 새로 생성된 클러스터는 다음과 같이 초기화된다[5,10]:

$$\begin{aligned} \mu_{J+1} &= x^n, \\ \Sigma_{J+1} &= \kappa (x^n - \mu_{nearest})(x^n - \mu_{nearest})', \\ J &= J + 1, \end{aligned} \quad (11)$$

여기서 κ 는 중첩 요소 상수이고, $\mu_{nearest}$ 는 x^n 에서 가장 가까운 클러스터의 평균이다.

데이터 x^n 이 기존의 클러스터 중에 하나와 유사하다면, M-단계는 식 (7)과 (8)을 이용하여 x^n 과 가장 유사한 클러스터의 평균과 공분산을 갱신한다. 이때 클러스터의 평균이 데이터 x^n 를 향해 움직이는 반면, 공분산은 x^n 로 표현된 공분산 행렬로 움직인다. 그러나, 이런 갱신은 공분산의 역행렬을 매 반복마다 계산해야 하므로 비효율적이다. 따라서, 단계별 수식을 이용하여 $(\Sigma_j^n)^{-1}$ 을 직접적으로 갱신하는 방법을 사용한다[5].

$$\Sigma_{jR}^n = \Sigma_j^n + \beta \frac{\Sigma_j^n}{d} I_d \quad (12)$$

3.3 클러스터 유효성 검사

두 개의 클러스터 j_1 과 j_2 가 있다고 하자. V(validation)-단계에서는 두 클러스터가 얼마나 잘 분리되었나를 검사하기 위해, 다음과 같은 합병 평가값을 계산한다:

$$\sum_{n=1}^N P(j_1 | x^n, \theta_{j_1}) P(j_2 | x^n, \theta_{j_2}) \quad (13)$$

클러스터 분포의 선형적 결합을 위해, 식 (9)는 아래와 같이 변경된다:

$$P(j|x^n, \bar{\theta}) = \frac{\pi_j P(x^n, j | \bar{\theta})}{\sum_{k=1}^J \pi_k P(x^n, k | \bar{\theta})}$$

여기서 매개변수 π_k ($0 < \pi_k \leq 1$)는 혼합 가중치로 $\sum_{k=1}^J \pi_k = 1$ 이다.

합병 평가값이 임계치보다 크다면, 이는 두 클러스터가 유사하므로 하나의 클러스터로 합병되어야 함을 의미한다. 새로이 합병된 클러스터 m 은 다음과 같이 초기화된다:

$$\begin{aligned} \pi_m &= \pi_{j_1} + \pi_{j_2} \quad , \\ \mu_m &= \frac{\pi_{j_1} \times \mu_{j_1} + \pi_{j_2} \times \mu_{j_2}}{\pi_{j_1} + \pi_{j_2}} \quad , \\ \Sigma_m &= \frac{\pi_{j_1} \times \sum_{j_1} + \pi_{j_2} \times \sum_{j_2}}{\pi_{j_1} + \pi_{j_2}} \quad , \\ J &= J - 1 \end{aligned} \tag{14}$$

알고리즘 I은 지금까지 설명한 제안하는 알고리즘을 보여주고 있다.

4. 텍스처 영상 분할 및 결과

클러스터링은 주어진 영상을 유사한 특징을 보이는 부분 영역으로 나누는 영상 분할을 위해 매우 유용한 알고리즘이다[11]. 본 장에서는 제안하는 EM 알고리즘을 텍스처 영상 분할에 적용하고, EM 배치 알고리즘, EAM 알고리즘의 실험결과와 비교한다.

알고리즘 I. 제안하는 알고리즘
Algorithm I. Proposed algorithm

```

For some clusters  $j=1 \dots J_0$ ,
Initialize  $\mu_j^0$  randomly.
Initialize  $\Sigma_j^0$ .
 $J = J_0$ 
 $n = 0$ 
Create a kd-tree with empty node.
For all data  $x^n$ ,
E-step:
    If  $x^n$  is a leaf node,
        Find the nearest cluster  $C_{nearest}$  using Eq. (9).
    else
        Find the nearest cluster  $C_{nearest}$  using Eq. (6).
If Eq. (10) is satisfied,
    A-step: Allocate and initialize a new cluster using Eq. (11).
else
    M-step: Update the center and the inverse covariance matrix results using Eq. (7) and (12), respectively.
If  $\epsilon^n > \epsilon_{min}$ ,  $\epsilon^{n+1} = \gamma \epsilon^n$ .
 $n = n + 1$ 
For all clusters  $j = 1 \dots J$ ,
    V-step: If the merge criteria, Eq. (13), is large,
            the corresponding two clusters are merged using Eq. (14).
    
```

4.1 실험 영상

제안하는 알고리즘은 256×256 크기의 Brodatz 텍스처 영상을 결합하여 만든 영상에 적용되었다[12]. 그림 1은 두 개(그림 1의 맨 위, D8과 D84), 네 개(그림 1의 가운데, D19, D21, D36과 D37), 다섯 개(그림 1의 맨 아래, D77, D84, D55, D53과 D24)의 텍스처들이 결합되어 만들어진 텍스처 영상을 보여주고 있다. 본 논문에서는 두 개의 Brodatz 텍스처 영상을 결합한 영상 20개, 4개의 결합 영상 13개, 5개의 결합 영상 4개를 실험 영상으로 사용하였다.

텍스처는 영상의 공간 주파수와 방향으로 특징을 표현할 수 있다. 본 논문에서는 Gabor 필터를 이용하여 텍스처의 특징을 표현하였다[13]. Gabor 필터는 공간과 주파수에서 최적의 국부 해상도를 제공하기 때문에, Gabor 필터는 텍스처 분할 및 분류에 많이 사용되어진다. d 개의 Gabor 필터로 텍스처 영상의 각 픽셀은 d 차원의 특징 공간에서 점으로 표현될 수 있다. 본 논문에서는 영상의 각 픽셀을 24(d 개의 Gabor 필터를 사용하여 표현하였다. 4개의 최고 방사형 주파수에 대해 각각 6개의 방향에 대한 필터를 사용하였다. 실험에 사용된 매개변수 값은 $\epsilon_{max} = 0.7$, $\epsilon_{min} = 0.07$, $\gamma = 0.999$, $\kappa = 0.9$, $\beta = 0.3$ 이다.

4.2 실험 결과

텍스처의 특징이 구해지면, 제안하는 알고리즘은 픽셀을 클러스터링한다. 그림 1은 EM 배치 알고리즘(그림 1(b),(c),(d)), 할당 EM 알고리즘(EAM) [5](그림 1(e))과 제안하는 EM 알고리즘(그림 1(f))의 실험 결과를 보여준다. EM 배치 알고리즘은 $J = 2$ (그림 1(b)), 4(그림 1(c)), 5(그림 1(d))일 때 구해진 분할 결과이다. 올바른 J 가 주어졌을 때 가장 좋은 영상 분할 결과를 얻을 수 있다. 즉, 두 개의 텍스처 영상 결합으로 만들어진 그림 1의 가장 위쪽 영상은 $J=4$, 5일 때 하나의 텍스처가 여러 영역으로 분할됨을 알 수 있다. 또한, 5개의 텍스처 영상 결합으로 만들어진 그림 1의 가장 아래쪽 영상은 $J=2$, 4일 때 여러 텍스처가 하나의 영역으로 합쳐져서 분할됨을 보여주고 있다. 반면에, 그림 1(e)과 그림 1(f)는 클러스터 없이 시작하지만 ($J_0 = 0$), 최종적으로 최적의 클러스터를 구할 수 있음을 보여준다. 그림 1(d)는 제안하는 알고리즘이 더 적은 분할 오류를 가지고 있음을 시작적으로 보여주고 있다.

EM 알고리즘은 데이터를 보여주는 순서에 따라 실험 결과에 영향을 미치므로, 각 실험 영상의 실험 결과를 구하기 위해 40개의 서로 다른 픽셀 순서를 적용한 분할 결과의 평균값을 계산하였다. Brodatz 텍스처 결합 영상의 분할 결과는 EM 배치 알고리즘은 평균 69.56%, 할당 EM 알고리즘(EAM)은 평균 74.12%, 제안하는 EM 알고리즘은 평균 90.78%으로 제안하는 알고리즘의 분할 성능이 뛰어남을 보여주고 있다(표 1).

또한, 본 논문에서는 Randen의 실험에서 사용된 11개의 텍스처 영상을 사용하였다[14]. 같은 방법으로 각 영상에 대해 40번의 서로 다른 픽셀 순서를 적용하였고, EM 배치 알고리즘은 평균 72.18%, 할당 EM 알고리즘(EAM)은 평균 82.36%, 제안하




그림 1. 텍스처 분할 결과: (a) Brodatz 텍스처 결합 영상, (b) EM 배치 알고리즘 실험 결과 영상(J = 2), (c) EM 배치 알고리즘 실험 결과 영상(J = 4), (d) EM 배치 알고리즘 실험 결과 영상(J = 5), (e) EAM 알고리즘 실험 결과 영상, (f) 제안하는 EM 알고리즘 실험 결과 영상
 Fig. 1. Texture segmentation results: (a) original composite textured images, (b) using the batch EM algorithm(J = 2), (c) using the batch EM algorithm(J = 4), (d) using the batch EM algorithm(J = 5), (e) EAM [5] and (f) proposed EM algorithm

는 EM 알고리즘은 평균 92.12%의 영상 분할률을 획득하였다.

References

표 1. 평균 텍스처 분할율

Table 1. Average texture segmentation rate

Parameter	Brodatz texture[12]	Randen texture[14]
EM[1]	69.56%	72.18%
EAM[5]	74.12%	82.36%
Our proposed method	90.78%	92.12%

5. 결론

EM 알고리즘은 강한 통계학 기저, 최적값에 대한 이론적 보장, 쉽게 설명할 수 있는 결과, 잡음이나 편향된 데이터에도 유용한 장점을 가지고 있다. 본 논문에서는 다중해상도 문제와 클러스터 개수에 대한 사전 지식의 문제를 해결하기 위해 다중해상도 kd-트리를 이용한 새로운 할당 EM 알고리즘을 제안하였다. 제안하는 알고리즘은 텍스처 영상 분할에 적용되었고, 제안하는 알고리즘이 EM 배치 알고리즘보다 분할 결과가 뛰어남을 보여주었다.

[1] A.P. Dempster, N.M. Laird and D.B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm (with discussion)," *Journal of the royal statistical society B*, vol. 39, no. 1, pp. 1-38, 1977.
 [2] S.J. Nowlan, "Soft competitive adaptation: neural network learning algorithms based on fitting statistical mixtures," PhD thesis, School of Computer Science, Carnegie Mellon University, 1991.
 [3] J. Xu, G. Ye, Y. Wang, G. Herman, B. Zhang and J. Yang, "Incremental EM for probabilistic latent semantic analysis on human action recognition," *Proceedings of the IEEE conference on advanced video and signal based surveillance*, 2009.
 [4] S.-K. Ng, G.J. McLachlan and A.H. Lee, "An incremental EM-based learning approach for online prediction of hospital resource utilization," *Artificial Intelligence in Medicine*, vol. 36, pp. 257-267, 2006.
 [5] K.-M. Lee, "Elliptical clustering with incremental growth and its application to skin color region segmentation," *Journal of the Korean Information Science Society*, vol. 31, no. 9, pp. 1161-1170, 2004.
 [6] S.-S. Kim and J.-H. Kang, "Improved expectation and maximization via a new method for initial values,"

Journal of the Korean Institute of Intelligent Systems,
vol. 13, no. 4, pp. 416-426, 2003.

- [7] L. Xu, M.I. Jordan, and G.E. Hinton, "An alternative model for mixtures of experts," *Advances in neural information processing systems*, vol. 7, pp. 633-640, 1995.
- [8] A.W. Moore, "Very fast EM-based mixture model clustering using multiresolution kd-tree," *Advances in neural information processing systems*, vol. 11, pp. 543-549, 1999.
- [9] S.-K. Ng and G.J. McLachlan, "Speeding up the EM algorithm for mixture model-based segmentation of magnetic resonance images," *Pattern recognition*, vol. 37, no. 8, pp. 1573-1589, 2004.
- [10] J. Platt, "A resource-allocating network for function interpolation," *Neural computation*, vol. 3, no. 2, pp. 213-225, 1991.
- [11] S.-B. Roh, T.-C. Ahn, Y.-S. Baek and Y.-S. Kim, "Space partition using context fuzzy c-Means algorithm for image segmentation," *Journal of the Korean Institute of Intelligent Systems*, vol. 20, no. 3, pp. 368-374, 2010.
- [12] P. Brodatz, *Textures: A photographic album for artists and designers*, Dover publications, NY, 1966.
- [13] J.G. Daugman, "An information- theoretic view of analogue representation in striate cortex," *Computational neuroscience*, In E.L. Schwartz (Eds.), Cambridge, MA: MIT Press, pp. 403- 424, 1990.
- [14] T. Randen and J.H. Husøy, "Filtering for texture classification: a comparative study," *IEEE transactions on pattern analysis and machine intelligence*, vol. 21, no. 4, pp. 291-310, 1999.

저 자 소 개



이경미(Kyoung-Mi Lee)

1993년 : 덕성여자대학교 전산학과 이학사
1996년 : 연세대학교 전산학과 이학석사
2001년 : 미 U. of Iowa, 전산학과 이학박사
2003년~현재 : 덕성여자대학교 컴퓨터학과
교수

관심분야 : Pattern recognition, Multimedia Retrieval

Phone : +82-2-901-8348

E-mail : kmlee@duksung.ac.kr