

PCM 알고리듬을 이용한 칼라 영상 분할

원 종 운*, 조 석 제**

Color Image Segmentation Using Possibilistic C – Means(PCM) Algorithm

Jong-Un Won, Seok-Je Cho

Abstract

This paper presents a segmentation algorithm for color images based on SSF(Scale Space Filtering) and PCM(Possibilistic C – Means) algorithm. FCM(Fuzzy C – Means) algorithm which has been used extensively in color image segmentation uses the probabilistic constraint that the memberships of a data point across the classes sum to 1. The memberships resulting from FCM, however, do not always correspond to the intuitive concept of the degree of belonging or compatibility. Moreover, the algorithms may have a considerable trouble to in noisy environments.

Recently, to resolve above drawback, PCM algorithm was proposed. The result of PCM and FCM depends on the number of clusters and the initial center values of the each cluster. And, if the PCM is applied for color image segmentation, there is the disadvantage that one needs to estimate the bandwidth η . So, in this paper, SSF is used for estimating the information (the number, the initial center values and the bandwidth) of the clusters, and the information of the clusters is used to PCM for color image segmentation.

1장 서 론

영상 분할(Image segmentation)이란 영상을 대상물과 배경 등의 의미있는 부분으로 나누거나, 서로 비슷한 속성을 가지는 부분으로 나누는 것이다. 영상에서 물체를 나타내는 대부분의 유용한 특징 정보가 서로 다른 영역간에 위치하기 때문에 영상 인식 및 분류, 해석의 과정에서 처리하여야 할 데이터의 양을 줄일 수 있어 널리 연구되고 있다.

영상 분할 기술은 주로 흑백 영상 해석에 초점을 맞추어 왔다. 칼라의 경우 인간이 인지할 수 있는

* 한국해양대학교 대학원

** 한국해양대학교 이공대학 제어계측공학과 부교수

종류에는 수천가지가 존재한다. 영상획득 기술의 발전과 더불어 칼라 영상의 사용이 보편화되었고, 칼라 영상에서는 흑백 영상에서 이용하는 명암도 이외에 다양한 좌표계로부터 특징 정보를 추출하여 이용할 수 있어, 영상을 분할 할 때 이용할 수 있는 특징 정보의 양이 많다는 이점 때문에 칼라 영상을 분할하고자 하는 연구가 계속되고 있다^{[1]~[12]}.

칼라 영상 분할 방법 가운데 클러스터링 방법이 널리 사용되었으며, 특히 FCM(Fuzzy c-means) 방법이 보편적으로 사용되었다. 이러한 방법은 우수한 결과를 얻을 수 있으나, 클러스터의 개수와 초기 중심값을 정해주어야 하고, 연산량이 많은 문제점이 있다. 클러스터의 개수와 초기 중심값은 화소들의 칼라 속성에 대한 히스토그램을 분석하므로서 추정할 수 있다.

FCM 알고리듬에 의한 클러스터링 방법은 모든 클러스터에 대한 소속함수(Membership) 값의 합이 1이 되는 확률적 제약 조건(Probabilistic constraint)을 가지고 있다. 소속함수 값은 해당 클러스터에만 관계있는 것이 아니라 다른 모든 클러스터와 관계있다. 이러한 제약 조건 때문에, FCM 알고리듬은 항상 정확한 클러스터의 원형(Prototype)을 추정하는 것은 아니다. 또한 FCM 알고리듬에 의한 소속함수의 값이 클러스터에 대한 실질적인 소속 정도와 항상 일치하지 않으며, 잡음에 민감한 편이다^{[6][13]}.

그래서, 최근에는 가능성 이론(Possibility theory)에 기초하여 Raghu가 PCM (Possibilistic c-means) 알고리듬을 제안하였고^[13], 그는 이 방법을 경계선 검출(Boundary detection)과 표면 근사화(Surface approximation)에 이용하였다^[14]. PCM 알고리듬의 경우에는 FCM 알고리듬과는 달리 소속함수 값은 다른 클러스터와는 관계가 없고, 속성 데이터와 해당 클러스터 중심간의 거리에만 의존하기 때문에, FCM 알고리듬에서와 같은 문제점은 발생하지 않는다. 그러나, PCM 알고리듬은 FCM 알고리듬을 먼저 실행하여 FCM 알고리듬에서 얻은 소속함수 값을 이용하여 파라미터를 추정하는 복잡한 과정을 거치는 문제점이 있다.

본 논문에서는 스케일 공간 필터링을 이용하여 클러스터의 개수와 초기 중심값과 함께 PCM 알고리듬에 필요한 파라미터를 추정할 수 있는 데이터를 구하고, 구해진 데이터를 이용하여 PCM 파라미터를 추정하는 변형된 PCM 알고리듬을 이용하여 영상을 분할하는 알고리듬을 제안한다. 제안된 알고리듬은 PCM 알고리듬에 앞서 실행되어야하는 퍼지 분할(Fuzzy partition)의 과정이 생략되어 연산 시간을 상당히 감소시키는 좋은 결과를 얻고 있다.

본문의 구성은 2장에서 스케일 공간 필터링(Scale space filtering)에 대하여 설명하고, 3장에서는 클러스터링 방법에 대해서 설명한다. 4장에서는 제안한 방법을 이용하여 칼라 영상에 적용하여 제안된 방법과 기존의 방법을 실험을 통해 유용성을 보이며 5장에서는 결론을 짓는다.

2장 스케일 공간 필터링을 이용한 타당한 클러스터 선택

영상의 물체 또는 배경 영역들은 비슷한 속성을 가지고 있어, 화소들의 칼라 속성에 대한 히스토그램에서 두드러진 마루 영역을 형성한다. 따라서 히스토그램에서 두드러진 마루 영역을 추정하면, 분

할하여야 할 클러스터의 개수를 추정할 수 있다.

히스토그램을 분석하기 위해서는 먼저 가우시안 필터를 이용하여 히스토그램을 평활화시켜야 한다. 이때 가우시안 필터의 크기를 나타내는 표준 편차에 따라 히스토그램의 평활화 정도가 달라진다. 즉, 표준 편차가 점차 커짐에 따라 두드러진 마루 영역은 존재하고, 의미 없는 작은 마루들은 소멸한다. 그러나, 표준 편차가 너무 큰 경우에는 원하는 마루 영역들 까지 소멸하게 된다. 따라서, 원하는 두드러진 마루 영역들이 나타날 수 있는 표준 편차를 가지는 가우시안 필터를 이용하여 히스토그램을 평활화시켜야 한다.

영상 분할에서 클러스터의 개수를 미리 정의했을 경우에는 원하는 개수의 마루가 나타나도록 적당한 표준 편차로 히스토그램을 평활화시킬 수 있다. 그러나, 대부분의 경우 분할하고자 하는 클러스터의 개수에 대해 사전에 알기 어렵다. 본 논문에서는 Witkin이 제안한 스케일 공간 필터링 방법^[15]을 이용하여 두드러진 마루영역을 나타낼 수 있는 표준 편차를 찾아 히스토그램을 평활화시킨다.

평활화된 히스토그램의 1차 미분과 2차 미분을 이용하여 골의 위치를 기준으로 마루 영역을 구분한다. 평활화된 골의 위치는 실제 골의 위치와 맞지 않으며, 골의 영역은 인접한 마루 영역들이 혼존하는 곳으로 일정한 허용범위를 두어 마루 영역을 구분하여야 한다. 허용범위는 골의 위치를 기준으로 인접한 마루위치까지 거리의 1/2에 해당하는 거리를 허용범위로 잡았다.

이렇게 얻어진 각 칼라 요소에 대한 마루 영역들을 3차원 칼라 공간 상에 교차시켜 서로 교집합하는 영역을 실제 클러스터를 추정할 수 있는 타당한 클러스터의 후보 영역으로 정한다. 이들 후보 영역들 가운데 각 영역에 포함된 화소의 개수가 일정 수준 이상에 해당하는 후보 영역들만을 타당한 클러스터로 선택한다. 이렇게 얻어진 타당한 클러스터들은 실제 클러스터화 유사하다. 이들 타당한 클러스터를 이용하여 클러스터링에 필요한 클러스터의 개수와 초기 중심값 그리고, 클러스터의 대역폭을 추정한다.

3장 클러스터링에 의한 영상 분할

칼라 영상 분할 방법으로 클러스터링에 의한 영상 분할 방법들이 많이 사용되고 있다. 클러스터링 방법은 클러스터의 개수와 초기 중심값을 미리 설정해두어야 하고, 연산량이 많은 문제점이 있으나, 우수한 결과를 얻을 수 있어 널리 연구되고 있다. 이들 클러스터링에 의한 방법들 가운데 FCM이 지금까지 널리 사용되었다.

그러나, FCM 알고리듬에서는 데이터의 각 클러스터에 관한 소속 정도의 합이 1이 되는 확률적 제약 조건을 이용하고 있다. FCM 알고리듬의 경우 소속 정도가 다른 클러스터와 관계가 있는 상대적인 값이기 때문에, FCM 알고리듬으로부터 얻어진 소속 정도가 실질적인 소속 정도나 유사성 정도의 직관적인 개념과 항상 일치하지는 않고, FCM 알고리듬의 경우에는 잡음이 있는 상황에서 심각한 문제점을 야기시킨다.

이러한 문제점을 해결하기 위해 Raghu는 가능성 이론에 기초한 PCM(Possibilistic c-means)을

고리듬을 개발하였다. 그러나, PCM 알고리듬은 클러스터의 대역폭을 추정하기 위해 퍼지 분할을 먼저 실해하여야 한다. 따라서, 기존의 PCM 알고리듬은 상당한 연산량을 필요로 한다. 이러한 기존의 PCM 알고리듬에서 클러스터의 대역폭 추정을 변형하여 변형된 PCM 알고리듬을 제안한다. 변형된 PCM 알고리듬에서는 클러스터의 대역폭을 추정하기 위해 퍼지 분할이 필요없어 연산량이 상당히 줄일 수 있다.

3. 1 FCM에 의한 영상 분할

FCM 알고리듬은 식(3-1)과 같은 목적함수를 최소화할 수 있도록 데이터 집합을 분할하는 방법이다.

$$\begin{aligned} J_m(U, V) &= \sum_{i=1}^c \sum_{k=1}^N (U_{ik})^m (d_{ik})^2, \\ d_{ik} &= \|x_k - v_i\|, \quad 1 \leq m < \infty \\ \sum_{i=1}^c u_{ik} &= 1, \text{ for all } k. \end{aligned} \quad (3-1)$$

여기서, $x_k (1 \leq k \leq N)$ 는 d차원의 데이터 벡터이고, $X = \{x_1, x_2, x_3, \dots, x_N\}$ 는 데이터 벡터 집합이고, $v_i (1 \leq i \leq C)$ 는 데이터 벡터들로 이루어진 C개 클러스터 가운데 i 번째 클러스터의 중심을 나타내고, $V = \{v_1, v_2, v_3, \dots, v_C\}$ 는 C개 클러스터의 중심 벡터들의 집합이다. m 은 퍼지 정도를 나타낸다. m 이 1인 경우에는 K-means방법과 같고 m 이 1보다 큰 값을 가지고 그 값이 클 수록 퍼지정도가 강하게 된다. u_{ij} 는 i 번째 데이터가 j 번째 클러스터에 속하는 소속 정도를 나타낸다. U는 u_{ij} 로 이루어지는 퍼지 분할을 나타내고, d_{ij} 는 i 번째 데이터와 j 번째 클러스터의 중심사이의 거리를 나타내는 내적이다.

m 이 1보다 큰 경우에 모든 i, j 에 대해서 $x_i \neq v_i$ 를 만족한다고 가정하면, 다음 조건식들을 만족할 때만 (U, V) 가 J_m 의 최소화를 가능하게 한다.

$$u_{ik} = \left\{ \sum_{j=1}^c \left(\frac{d_{ki}}{d_{kj}} \right)^{\frac{2}{m-1}} \right\}^{-1}, \text{ for all } i, k \quad (3-2)$$

$$v_i = \frac{\sum_{k=1}^N (u_{ik})^m x_k}{\sum_{k=1}^N (u_{ik})^m}, \text{ for all } i \quad (3-3)$$

FCM 알고리듬은 식(3-2)와 식(3-3)의 과정을 반복하므로서 J_m 은 어떤 정해진 값에 수렴하게 된다. FCM 알고리듬의 수행 과정은 다음과 같다.

단계 1 : 클러스터의 수 C 를 $2 \leq C \leq N$ 의 범위안에서 정하고, 퍼지 정도를 나타내는 $m \in [1, \infty)$

을 고정시고, $U(0)$ 는 임의로 초기화 하고, 반복횟수를 나타내는 p 는 1로 설정

단계 2 : $U(p-1)$ 과 식(3-3)을 이용하여 클러스터의 중심 $\{v_i^{(p)}\}$ 를 계산

단계 3 : $\{v_i^{(p)}\}$ 와 식(3-2)을 이용하여 $U(p)$ 를 다시 생성

단계 4 : $U(p)$ 와 $U(p-1)$ 을 비교한다.

$\|U(p) - U(p-1)\| \leq \epsilon$ 을 만족한다면 끝내고, 그렇지 않으면, p 를 1증가시키고, 단계 2로 돌아간다.

3. 2 PCM 알고리듬에 의한 영상 분할

PCM 알고리듬은 식(3-4)의 목적함수를 최소화할 수 있도록 데이터 집합을 분할하는 알고리듬이다.

$$J_m(L, U) = \sum_{i=1}^c \sum_{k=1}^n (u_{ij})^m d_{ij}^2 + \sum_{i=1}^c \eta_i \sum_{k=1}^n (1 - u_{ij})^m \quad (3-4)$$

여기서 η_i 는 적당한 양의 정수로 이에 대한 내용은 뒤에 언급하겠다. 첫 번째항은 속성 데이터로부터 클러스터 중심사이의 거리를 가능한 작게 유지하고, 반면에 두 번째 항은 쓸모없는 해를 얻는 것을 피하기 위해 u_{ij} 를 가능한 크게 유지하도록 하여 하찮은 해를 피하도록 한다.

$X = \{x_1, x_2, x_3, \dots, x_N\}$ 는 특징 벡터 집합, $L = (\beta_1, \beta_2, \beta_3, \dots, \beta_c)$ 를 클러스터의 중심 벡터 집합, $d_{ij}^2 (i = 1, 2, 3, \dots, C; j = 1, 2, 3, \dots, N)$ 는 특징점 x_j 에서 클러스터의 중심 β_i 사이의 거리이고, $U = [u_{ij}]$ 는 가능성 소속 정도로 이루어진 $C \times N$ 행렬이다. U 가 식(3-5)를 만족한다면, U 는 $J_m(L, U)$ 를 위한 전역 최소치가 된다.

$$u_{ij} = \left\{ 1 + \left(\frac{d_{ij}^2}{n_i} \right)^{1/(m-1)} \right\}^{-1} \quad (3-5)$$

$$v_i = \frac{\sum_{j=1}^n (u_{ij})^m x_j}{\sum_{j=1}^n (u_{ij})^m} \quad (3-6)$$

식(3-5)는 클러스터 β_i 를 위한 가능성 분포 함수를 나타내며, 이것을 Π_i 라고 표시한다. m 값은 최종 가능성 c-partition의 퍼지화(Fuzziness)와 가능성 분포의 형태를 결정한다. $m = 1$ 일 때, 소속 정도는 hard값을 가지고, $m \rightarrow \infty$ 일 때 소속 정도는 최대로 퍼지화된 값을 가지게 된다.

η_i 는 클러스터에서 특징 데이터의 소속 정도가 0.5가 되는 거리를 정의한다. 이와 같이 η_i 는 각 클러스터에 대한 가능성 분포의 적절한 대역폭에 따라 선택될 필요가 있다. 만일, 모든 클러스터가 비슷할 것 같으면, η_i 는 모든 클러스터에 대해 동일하게 되어야 할 것이다. 이처럼 η_i 는 클러스터의 전체 모양과 크기에 관계되는 것이 타당하다. Raghu는 η_i 를 식(3-7)과 식(3-8)을 이용하여 추정하였다.

$$\eta_i = K \frac{\sum_{j=1}^n u_{ij}^m d_{ij}^2}{\sum_{j=1}^n u_{ij}^m} \quad (3-7)$$

여기서, K 는 보통 1로 선택한다. η_i 는 클러스터 β_i 의 평균 퍼지 클러스터 내부 거리(Average fuzzy intracluster distance)에 비례한다.

$$\eta_i = \frac{\sum_{x_j \in (\Pi_i)_a} d_{ij}^2}{|(\Pi_i)_a|} \quad (3-8)$$

여기서, $(\Pi_i)_a$ 는 Π_i 의 적절한 수준의 $a-cut$ 이다. η_i 는 클러스터 β_i 에 속하는 소속 정도가 높은 특징 벡터들의 평균 클러스터 내부 거리(Average intracluster distance)이다.

PCM 알고리듬은 식(3-5)과 식(3-6)의 과정을 반복하므로서 J_m 은 어떤 정해진 값에 수렴하게 된다. PCM 알고리듬에 의한 영상 분할 알고리듬은 다음과 같다.

단계 1 : 모든 변수를 임의로 초기화
 단계 2 : 퍼지 분할을 하여 클러스터의 대역폭을 추정
 단계 3 : 식(3-5)을 이용하여 $U(p)$ 를 구한다.
 단계 4 : 식(3-6)을 이용하여 클러스터의 중심 $\{v_i^{(p)}\}$ 를 계산한다.
 단계 5 : $U(p)$ 와 $U(p-1)$ 을 비교한다.
 만약 $\|U(p) - U(p-1)\| \leq \epsilon$ 을 만족하면 끝낸다.
 그렇지 않으면, p 를 1증가시키고 단계 3으로 되돌아간다.

3.3 변형된 PCM 알고리듬에 의한 영상 분할

PCM 알고리듬의 문제점은 대역폭에 해당하는 파라미터 η_i 를 추정하기 위해 퍼지 분할 과정을 도입해야 한다는 것이다. PCM 알고리듬을 shell 클러스터링에 이용하는 경우에는 shell 클러스터들의 원하는 두께를 사전에 알 수 있으므로 이러한 문제는 큰 단점이 되지 않는다. 그러나, PCM 알고리듬을 칼라 영상 분할에 이용할 경우 영상의 각 영역에 해당하는 클러스터들의 대역폭은 사전에 알 수 없다. 클러스터의 대역폭에 대한 사전 정보가 없다면, η_i 를 추정하기 위해서는 퍼지 분할을 먼저 실행하고, 퍼지 분할로 부터 얻은 정보를 식(3-7), 식(3-8)에 적용하여 η_i 를 추정한다. 이러한 방법으로 η_i 를 추정하는 것은 퍼지 분할 과정을 도입하므로 전체 PCM 알고리듬 과정이 복잡해지며, 퍼지 분할에 필요한 연산량이 많아 상당한 연산 시간이 걸리는 단점이 있다. 따라서, 영상 분할에 PCM 알고리듬을 이용할 때 대역폭 η_i 를 추정하는 것은 문제가 된다.

본 논문에서는 스케일 공간 필터링 과정에서 구한 타당한 클러스터에 속하는 데이터를 이용하여 영상의 각 영역에 대한 대역폭 η_i 를 추정하였다. η_i 는 클러스터에서 특징 데이터의 소속 정도가 0.5가 되는 거리를 정의하며, 각 클러스터에 대한 가능성 분포의 적절한 대역폭에 따라 선택될 필요가 있다. 스케일 공간 필터링 방법에서 얻은 타당한 클러스터에 속하는 데이터들은 식(3-8)과 같이 소속 정도가 높은 (P_i)_a의 데이터라고 생각할 수 있다. 따라서, 클러스터의 개수와 초기 중심값을 추정하기 위해 사용한 스케일 공간 필터링 방법에서 얻어진 타당한 클러스터에 속하는 데이터들의 평균 내부 거리를 구하여 η_i 를 추정하므로서, η_i 를 추정하기 위한 퍼지 분할 과정을 생략하여 전체 영상 분할 과정을 단순화시키며, 퍼지 분할에 해당하는 연산량을 감소시켰다. i 번째 클러스터의 평균 내부 거리 η_i 는 다음과 같다.

$$\eta_i = \frac{\sum_{x_j \in P_i} d_{ij}^2}{n(P_i)} \quad (3-9)$$

여기서, d_{ij}^2 는 i 번째 클러스터의 중심 $v_i^{(0)}$ 에서 데이터 $x_j \in P_i$ 까지 거리이고, P_i 는 i 번째 타당한 클러스터에 속하는 데이터의 집합이고, $n(P_i)$ 는 P_i 의 데이터의 개수이다.

η_i 는 모든 반복 과정에서 고정될 수도 있고, 각 반복마다 변할 수도 있지만, 각 반복마다 η_i 를 변화시킬 때, 불안정한 상태로 빠질 수 있다. 변형된 PCM 알고리듬은 식(3-5)과 식(3-6)의 과정을 반복하므로서 J_m 은 어떤 정해진 값에 수렴하게 된다. 변형된 PCM 알고리듬에 의한 영상 분할 알고리듬은 다음과 같다.

단계 1 : 스케일 공간 필터링을 하여

타당한 클러스터 선택

단계 2 : 타당한 클러스터로부터 클러스터 개수 C ,

초기 중심값 $v_i^{(0)}$ 과 η 를 추정한다.

퍼지 정도를 나타내는 $m \in (1, \infty)$, 과

반복 횟수를 나타내는 $p = 1$ 로 설정한다.

단계 3 : 식(3-5)를 이용하여 $U(p)$ 를 구한다.

단계 4 : 식(3-6)을 이용하여 클러스터의 중심 $v_i^{(p)}$ 를 계산한다.

단계 5 : $U(p)$ 와 $U(p-1)$ 을 비교한다.

만약 $\|U(p) - U(p-1)\| \leq \epsilon$ 을 만족하면 끝낸다.

그렇지 않으면, p 를 1 증가시키고 단계 3 으로 되돌아간다.

4장 실험 및 고찰

실험에 사용한 영상은 그림4-1의 COLOR IMAGE와 그림4-5의 HOUSE IMAGE로 256×256 의 크기를 가지고, 칼라 요소는 R(Red), G(Green), B(Blue)로 구성되어 있다. IBM PC호환용 펜티엄 586(133MHz)에서 실험을 하였다.

실험 용 영상에 대해서 먼저 스케일 공간 필터링을 하여 적당한 스케일 상수 σ 를 구하였다. COLOR IMAGE의 R, G, B 각각에 대한 적당한 스케일 상수 σ 는 표4-1과 같다. 앞서 구한 스케일 상수 σ 를 이용하여 R, G, B 각각의 히스토그램에 적용하여 각각의 히스토그램에서 두드러진 골과 마루 영역을 찾는다. 골 영역은 선택된 골을 중심으로 인접한 마루까지의 거리에 비례하도록 허용범위를 구하였다.

이렇게 구한 히스토그램의 두드러진 골과 마루 영역을 3차원 칼라 공간 상에 교차시킨다. 이때, 마루 영역들이 교차하는 영역이 타당한 클러스터가 될 수 있는 후보 영역이 된다. 이를 후보 영역들 가운데 화소의 개수가 1,000 이상이 되는 후보 영역들을 타당한 클러스터 영역으로 선택했다. COLOR IMAGE에서 타당한 클러스터로 7개의 클러스터가 선택되었고, HOUSE IMAGE에서는 4개가 선택되었다.

이렇게 얻은 클러스터에 대한 정보를 이용하여 기존의 PCM 알고리듬과 제안한 PCM 알고리듬 그리고, 기존의 FCM 알고리듬에 대해 각각 실험하고 성능 평가를 위해 연산 시간과 영상 분할 결과를 시각적으로 평가한다.

기존의 PCM 알고리듬은 다음과 같다. 먼저, 스케일 공간 필터링을 하여 구한 타당한 클러스터로부터 초기 중심값을 구하였다. 표4-2는 COLOR IMAGE에 대한 초기 중심값을 나타내고 있다. 초기 중심값을 이용하여 FCM 알고리듬을 실행하여 영상을 분할하고, 그 결과를 이용하여 기존의 PCM 파라미터를 추정한다. 본 논문에서는 식(3-8)을 이용하여 η_i 를 구하였다. 추정된 η_i 를 이용하여 영상을 분할하였다. 제안한 PCM 알고리듬은 스케일 공간 필터링 과정에서 구한 타당한 클러스터에 속하는 데이터들을 이용하여 식(3-9)로 η_i 를 추정하였다. 따라서, 제안한 PCM 알고리듬에서는

FCM 알고리듬 과정을 생략하여 상당한 연산 시간을 줄일 수 있었다. 표4-4는 FCM 알고리듬과 기존의 PCM 알고리듬 그리고, 제안한 PCM 알고리듬의 연산시간을 나타내고 있다.

영상 분할 결과를 평가하기 위한 정해진 평가 기준이 없기 때문에, 대부분의 영상 분할 결과는 사람의 시각에 의해 평가되어 진다. 표4-3은 기존의 PCM 알고리듬과 제안한 PCM 알고리듬에서 추정한 클러스터의 대역폭 η_i 를 나타내고 있으며, 그림4-1과 그림4-5는 실험에 사용된 COLOR IMAGE와 HOUSE IMAGE이고, 그림4-2와 그림4-6은 FCM 알고리듬을 이용하여 영상을 분할한 결과이다. 그림4-4 와 그림4-8은 제안한 PCM 알고리듬으로 영상을 분할한 결과이다. 기존의 PCM 알고리듬에서 구한 η_i 값과 제안한 PCM 알고리듬에서 구한 η_i 가 약간은 차이가 있으나 비슷한 결과를 얻을 수 있었으며, FCM 알고리듬과도 비슷한 영상 분할 결과를 얻을 수 있었다.

<표 4-1> R, G, B 히스토그램에 대한 적당한 σ (COLOR IMAGE)

스케일	칼 라	R	G	B
σ		13	12	11

<표 4-2> 타당한 클러스터로 부터 초기 중심값 추정 (COLOR IMAGE)

칼라	클러스터	1	2	3	4	5	6	7
R	82	41	70	129	190	185	218	
G	50	118	176	79	51	198	189	
B	70	78	160	160	48	103	171	

<표 4-3> η_i 의 추정값 (COLOR IMAGE)

방법	클러스터	1	2	3	4	5	6	7
기존의 방법	115	89	326	250	204	149	103	
제안한 방법	99	97	318	209	243	163	143	

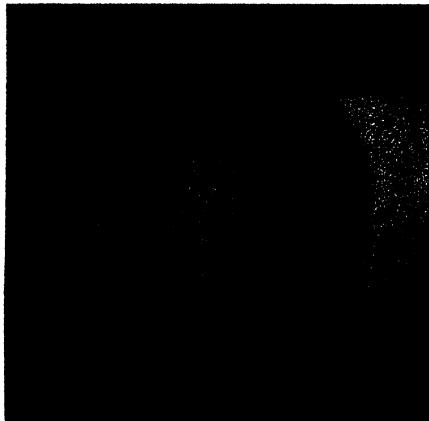
<표 4-4> 각 알고리듬의 연산시간 (단위 : 초)

	FCM 방법	기존의 PCM 방법	제안한 PCM 방법
COLOR IMAGE	56	68	8
HOUSE IMAGE	21	27	5

5장 결 론

본 논문에서는 클러스터의 개수와 초기 중심값을 추정하기 위해 사용되었던 타당한 클러스터에 속하는 데이터를 이용하여 PCM알고리듬에서 필요한 클러스터의 대역폭을 추정하여 기존의 PCM 알고리듬 보다 클러스터링 시간을 상당히 줄일 수 있었다. 제안된 방법은 먼저 스케일 공간 필터링을 이용하여 타당한 클러스터를 구하고, 이들 타당한 클러스터를 사용하여 클러스터의 개수와 초기 중

PCM 알고리듬을 이용한 칼라 영상 분할



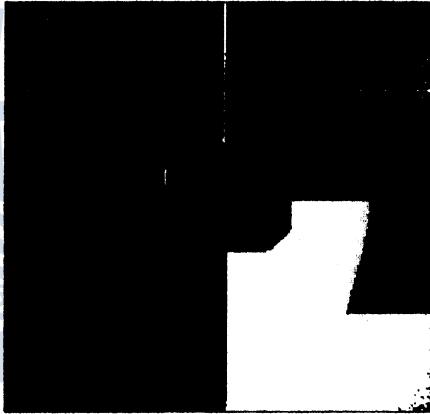
<그림 4-1> COLOR IMAGE 원영상



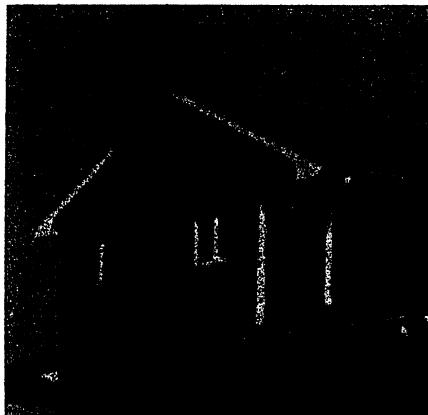
<그림 4-2> FCM 처리 결과 영상



<그림 4-3> 기존의 PCM
처리 결과 영상



<그림 4-4> 제안한 PCM
처리 결과 영상



<그림 4-5> HOUSE IMAGE 원영상



<그림 4-6> FCM 처리 결과 영상



그림4-7 기존의 PCM
처리 결과 영상



그림4-8 제안한 PCM
처리 결과 영상

심값 그리고 클러스터의 대역폭 η_i 를 추정하여 PCM 알고리듬을 이용하여 영상을 분할한다. 이렇게 하므로서 기존의 PCM 방법에서 클러스터의 대역폭 η_i 를 추정하기 위해 수행되었던 FCM 과정을 생략하여 연산량을 상당히 감소시킬 수 있었으며, 영상의 분할 결과는 비슷하였다. 따라서, 본 논문에서 제안한 칼라 영상 분할 방법은 연산량을 상당히 줄이면서 비슷한 분할 결과를 얻을 수 있었다.

클러스터링에 의한 방법만으로는 영상을 깔끔하게 분할하기 어렵다. 클러스터링에 의한 방법은 화소들이 가지는 특징 정보만을 이용하여 특정 공간상에서 클러스터링을 하기 때문에 영역 내부에 많은 구멍(Hole)들을 포함하게 된다. 이들은 영역 확장법 등의 후처리 과정을 통해 제거될 수 있다.

참 고 문 헌

- [1] R. Ohlander, K. Price, and D.R. Reddy, "Picture segmentation using a recursive region splitting method," CGIP, Vol. 8, pp.313 – 333, 1978.
- [2] Y. Otha, T. Kanade and T. Sakai, "Color information for region segmentation," CGIP, Vol. 13, pp. 224 – 241, 1980.
- [3] 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.
- [4] C. L. Huang, T. Y. Cheng and C. C. Chen, "Color images segmentation using scale space filter and Markov Random Field," Pattern Recognition, pp.1217 – 1229, 1992.
- [5] J. Liu and Y. H. Yang, "Multiresolution Color Image Segmentation," IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 16, No. 7, pp.689 – 700, 1994.
- [6] K. B. Eun and J. W. Lee, "Possibilistic C – Mean 클러스터링과 영역 확장을 이용한 칼라 영상 분할," 대한 전자공학회논문지, Vol. 34, No. 3, pp.97 – 107, 1997.
- [7] S. A. Shafer and T. Kanade, *Color vision*, Encyclopedia of Artificial Intelligence, pp.124 – 131, Wiley, New York, 1987.
- [8] J. O. Eklundh, H. Yamamoto, and A. Rosenfeld, "A relaxation method for multispectral pixel classification," IEEE Trans. PAMI, Vol. PAMI – 2, No. 1, pp.72 – 75, 1980.

- [9] R. C. Gonzalez and R. E. Woods, Digital Image Processing, pp.443 – 457.
- [10] G. B. COLEMAN, and H. C. ANDREWS, "Image Segmentation by Clustering," Proceedings of the IEEE, Vol.67, No.5, 1979.
- [11] M. Ali, W. N. Martin, and J. K. Aggarwal, "Color – based computer analysis of aerial photographs," CGIP, Vol. 9, pp.282 – 293, 1979.
- [12] J. C. Bezdek and M. M. Trivedi, "Low level segmentation of aerial images with Fuzzy clustering," IEEE Trans. Syst., Man, Cybert., Vol. SMC – 16, No. 4, pp.589 – 598, 1986.
- [13] R. Krishnapuram, J. M. Keller, "A possibilistic approach to clustering," IEEE Trans. on Fuzzy Systems, Vol. 1, No. 2, pp.98 – 110, 1993.
- [14] 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.
- [15] A. P. Witkin, "Scale – space filtering," Proc. IJCAI – 83, pp.1019 – 1022, 1983.



