

論文96-33B-8-8

# 수학적 형태학에 기반한 클러스터링을 이용한 칼라영상의 영역화

## (Color Image Segmentation Using Clustering Based on Mathematical Morphology)

朴 祥 鎬 \*, 尹 逸 東 \*, 李 商 郁 \*

(Sang Ho Park, Il Dong Yun, and Sang Uk Lee)

### 요 약

본 논문에서는 3차원 칼라 공간상에서 수학적 형태학에 기반한 클러스터링을 이용한 칼라 영상 영역화 기법을 제안하였다. 제안하는 알고리듬은 칼라 영상의 화소값들이 매핑된 칼라 좌표계에서 클러스터의 모양과 연결성, 그리고 분포와 같은 성질들을 고려하므로, 클러스터링을 행할 때 가장 큰 문제점인 클러스터의 개수와 중심 부분을 영상에 대한 별도의 사전 지식 없이 자동적으로 추출하였다. 다양한 컴퓨터 모의 실험이 수행되었으며 그 결과는 본 논문에서 토의되었다. 여러 영상의 다양한 칼라 좌표계에 대한 모의 실험 결과는 사용하는 칼라 좌표계와 클러스터의 모양에 상관없이 동일한 영상에 대해서는 같은 수의 클러스터를 추출해 내며, 따라서 정확한 영상 영역화 결과를 나타내었다. 또한 문턱값 설정시 주로 사용되는 미분 연산자를 전혀 사용하지 않으므로 잡음의 영향에 강인함을 보여준다. 또한, 벡터 양자화기를 이용한 칼라 영상 영역화 결과를 제시하고, 제안하는 알고리듬의 결과와 비교하였다.

### Abstract

In this paper, we propose a novel color image segmentation algorithm based on clustering in 3-dimensional color space employing the mathematical morphology. More specifically, since we take into account the topological properties such as the shape, connectivity and distribution of clusters in the clustering process, the number of clusters in the color cube, as well as their centers, can be easily obtained, without *a priori* knowledge on the input images. Intensive computer simulation has been performed and the results are discussed in this paper. The results of the simulation on the images in various color coordinates show that the segmentation is independent of the choice of color coordinates and the shape of clusters. Segmentation results of the vector quantizer are also presented for the comparison purpose.

### I. 서 론

인간의 시각 능력은 조도가 5승 이상에 걸치는 범위에서 사물을 구분할 수 있으며 1 nm의 좌장 변화에 의한 색상의 차이를 감지할 수 있다<sup>[1]</sup>. 또한, 공간적 주파수에 따라 광도 변화와 색상 변화에 반응하는 민

감도(sensitivity)가 달라지지만 실세계의 물체를 인식 함에 있어서 물체의 밝기값보다는 색상 차이를 이용함을 쉽게 알 수 있다<sup>[2]</sup>. 인간의 시각 능력을 모델로 삼는 컴퓨터를 이용한 시각 인식에 있어서도 칼라 영상은 점차 중요한 위치를 차지해 가고 있으며 이를 이용한 경계의 검출, 영상의 영역화, 물체의 정합 및 인식에 대한 연구가 더욱 활성화되고 있다<sup>[3, 4, 5, 6, 7, 8, 9, 10, 11, 12]</sup>.

일반적으로 영상으로부터 물체를 인식해내기 위해서는 우선 물체의 특징을 추출할 필요가 있으며, 그 전처

\* 正會員, 서울大學校 電氣工學部

(School of Electrical Eng., Seoul National University.)

接受日字: 1995年8月28日, 수정완료일: 1996年7月25日

리 과정으로서 물체를 비슷한 특성을 지닌 몇개의 면으로 분류하는 작업, 곧 영역화(segmentation)가 필수적으로 요구된다. 물체에 대한 정확한 영역화를 통해 대상 물체의 특징들을 올바로 추출해 내고, 이로부터 물체의 기술(description) 및 인식(recognition)을 수행할 수 있다<sup>[3]</sup>. 영상 영역화란 한 영상을 하나, 또는 그 이상의 특징에 따라 균일한 부분들로 나누는 과정이며 영상 분석 및 처리에 있어서 필수적으로 요구되는 중요한 일이지만 지금까지는 주로 밝기 영상에 대한 영상 영역화 연구가 수행되어 왔다<sup>[5, 6]</sup>. 그러나 밝기 영상만을 가지고 영상 영역화를 수행하는 경우 다른 색상을 가지는 물체라도 밝기가 같은 값을 가진다면 같은 영역으로 간주된다. 그러므로, 물체가 넓은 영역의 밝기 분포를 가지면서 존재하면 제대로 된 결과를 얻을 수 없으며 이는 단색의 밝기 영상에서는 오직 밝기 정보만을 이용할 수 있기 때문이다.

이에 반해 칼라는 전자파인 빛의 스펙트럼 성질로 인해 일어나는 현상이며 가시 광선은 380nm ~ 760nm의 파장을 가지고 있다. 이는 파장이 다른 전자파에 사람의 시각계가 반응하는 정도를 나타내는 감각적인 현상이며 칼라를 수량으로 표시하기 위해 쓰이는 대표적인 것이 intensity, hue, saturation이다<sup>[2]</sup>. Intensity는 밝기를 표현하고 hue는 빨간색, 노란색, 파란색과 같은 색조를 나타내며 saturation은 같은 빨간색에서도 흰색이 섞여있는 정도를 나타낸다. 이와 같은 기본이 되는 3가지 칼라를 적절히 배합하여 모든 칼라를 만들 수 있다는 사실이 알려져 있다. 이때 기본이 되는 3가지 칼라는 일정하게 정해진 것은 아니지만 간단한 좌표변환에 의해 다른 좌표계에 대한 값들을 구할 수 있다. 기본이 되는 좌표계는 R-G-B, X-Y-Z, Y-I-Q, U-V-W, II-I2-I3 등의 여러가지가 있다<sup>[4, 12]</sup>.

이와 같이 칼라 영상은 밝기 정보와 색상 정보를 동시에 내포하고 있으므로 색상 차이만으로 영상을 구분하는 것이 가능하다. 따라서 칼라 영상을 영역화하는 연구가 어느 정도 진행되어 왔지만 지금까지의 연구들은 밝기 영상에 적용되는 기법들을 단순히 3 매의 영상에 대하여 확장하는 것이 대부분이었다<sup>[8, 10, 15, 16]</sup>. 그러나 한 물체가 지니고 있는 동일한 색상이 칼라 공간상에서 한 점을 중심으로 구 모양으로 매핑되는 것이 아니라 각각의 성분 비율이 일정하므로 일반적으로 칼라 공간 상에서 원점을 향하는 원통형의 모양을 가

지게 된다. 이 때, 저차원으로 사영하여 각각의 성분 요소에 대해서 히스토그램을 구하여 피크와 밸리를 구하는 것은 무의미해진다.

한편으로 칼라 공간상에서 히스토그램의 특성을 이용하여 영역화를 하고자 하는 시도가 있었으나<sup>[7, 13]</sup> 칼라 영상의 특징 공간(feature space)인 칼라 공간에서 특정 모양을 가질 것을 요구하기 때문에 적용시킬 수 있는 영상이 제한적이었다. 또한 칼라 공간상에서 클러스터링하는 기법들은 계산량이 많은 단점이 있었다<sup>[7, 17]</sup>. 본 논문에서는 이러한 문제점을 해결하기 위하여 칼라 공간상에서 수학적 형태학(mathematical morphology) 기법을 이용한 클러스터링을 행하여 영상 영역화를 수행하였다. 수학적 형태학 기법은 원래의 데이터와 구조요소(structuring element) 간의 연산을 통하여 칼라 공간상에서 클러스터들의 모양과 연결성, 그리고 분포를 고려할 수 있다<sup>[14, 18]</sup>. 그러므로 일단 적절한 구조 요소가 결정되면 영상에 대한 사전 정보가 전혀 없어도 자동으로 클러스터의 개수를 결정할 수 있으며 영상 영역화 과정에서 별도로 값을 조정해 주어야 하는 인자(parameter)를 사용하지 않는다. 즉, 수학적 형태학을 이용하여 주어진 영상의 칼라 공간상에서 일정치 않은 모양을 형성하고 있는 클러스터 모양에 가장 적합한 클러스터를 찾아내므로 기존의 방법에 비해서 보다 효율적인 영상 영역화를 수행할 수 있다.

## II. 칼라 영상 영역화 알고리듬 고찰

밝기 영상 및 칼라 영상의 영역화를 위하여 여러가지 방법들이 제안되어 왔다<sup>[5, 6, 7, 8, 9, 10, 12, 15, 16, 17]</sup>. 밝기 영상의 경우에는 영상에 대한 히스토그램을 먼저 구한 후, 극점을 찾아서 임계치를 구하는 방법들이 제안되었다. 이 경우 영상의 히스토그램에서 피크와 밸리를 어떠한 방식으로 추출하는가 하는 방법에 따라 알고리듬의 성능이 좌우된다. 이에 반해 칼라 영역화의 경우 3 매의 영상을 가지고 영상 영역화를 수행하므로 히스토그램을 이용한 방법 이외에도 다양한 기법들이 제안되었다. 지금까지 제안된 칼라 영상 영역화 알고리듬들을 간단히 살펴보면 다음과 같다.

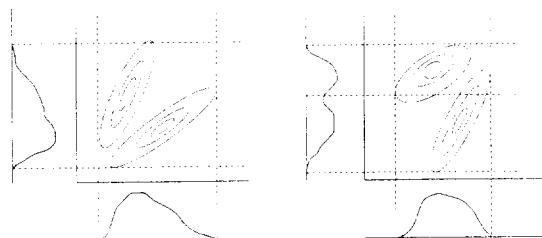
Ohlander<sup>[18]</sup> 등은 반복적 영상 영역화 방법을 제안하였는데 이 방법은 R-G-B, Y-I-Q, H-S-I 9매의 칼라 좌표계 영상을 사용하여 각 영상의 히스토그램에

서 가장 좋은 극대점(peak)을 찾은 후 영상을 분할하고 분할된 영상에서 다시 9개의 히스토그램을 구해 영상을 분할하는 기법을 반복적으로 적용하였다. 그래서 모든 히스토그램에 더 이상의 극점이 존재하지 않으면 영상 영역화를 끝내게 된다. 이 방식은 가장 좋은 극대점을 대한 우선 순위가 미리 결정되어야 하며, 유효한 극대점을 찾을 때 사용되는 몇 가지 인자들을 영상의 히스토그램에 따라 적절히 조정해 주어야만 좋은 결과를 얻을 수 있으므로 자동으로 영상 영역화를 수행하지는 못하며 칼라 영상의 특징을 전혀 살리지 못한다는 문제점이 존재한다.

Bezdek<sup>[91]</sup> 등은 fuzzy c-means(FCM) 알고리듬을 사용한 클러스터링 기법을 제안하여 칼라 영상 영역화를 수행하였다. 이 방법은 사전에 클러스터의 개수인 c, 회원 등급 가중 지수(membership weighting exponent) m, positive definite 행렬 A, 행렬의 norm, 관측 벡터의 개수 n, 관측 벡터의 차원 d와 계층적 영상에서 초기 계층, 영역의 균일성을 판별하는 기준으로서 회원 등급 합수값에 대한 문턱값 T를 미리 정해 주어야 하므로 역시 영상이나 영상의 히스토그램에 대한 사전 정보를 필요로 한다. 이와 같이 미리 지정해 주어야 할 인자들의 개수가 너무 많고 수행시간이 길며 영상 영역화 결과에 불리한 현상이 발생하게 된다.

Lim<sup>[101]</sup> 등은 Witkin이 제안한 scale space filtering 기법<sup>[111]</sup>을 사용하여 클러스터의 개수를 미리 정하고 대략적인 영역 분할을 한 후 나머지 분류되지 않은 화소들은 FCM 알고리듬을 이용하여 가장 가까운 클러스터에 속하게 하는 coarse-fine 칼라 영상 영역화 기법을 제안하였다. 이 방법은 scale space filter (SSF)를 사용하여 영상의 히스토그램에서 가장 좋은 피크를 찾을 수 있고 클래스가 지정된 후, FCM 알고리듬을 적용하므로 클러스터링 시간을 상당히 단축시킬 수 있으며 메모리 사용량도 훨씬 적다. 그리고 Bezdek의 알고리듬에서 생기는 불리한 현상을 제거할 수 있다. 하지만 영상에 따라 scale을 미리 정해주어야 하고 저차원으로 사영된 칼라 좌표계를 따로따로 사용함으로써, 그림 1(a)와 같이 클러스터를 구분하지 못하는 경우가 있다. 또한, 칼라 공간에서 초기 클러스터의 모양이 저차원 히스토그램의 밸리에 의해 구분되고 그림 1(b)에 나타난 바와 같이 실제의 클러스터 모양과 상관없이 항상 좌표축에 평행한 직육면체 모양을

가지게 된다. 따라서 사용하는 칼라 좌표계에 대한 의존도가 높고 결국은 대상 영상에 따라서 영상 영역화의 성공 여부가 좌우되게 된다.



(a) 분리되지 않는 경우 (b) 직사각형 모양의 구분

그림 1. 저차원 공간으로의 사영

Fig. 1. Projection onto a Lower Dimensional Space.

Huang<sup>[151]</sup>과 Liu<sup>[161]</sup>는 Lim과 마찬가지로 scale space filter를 사용하고 후처리 과정으로서 Markov Random Field를 이용하여 MAP(maximum a posteriori) estimate로 수렴하는 relaxation 과정을 제안하였다. 하지만 초기 과정의 히스토그램을 분석하는 단계에서 R G B에 대하여 따로따로 처리를 하므로 칼라 공간의 좌표축에 수직이 아닌 클러스터의 개수와 중심을 제대로 찾아내지 못하며 그 이후의 과정은 상당한 오류를 내포할 수 있다.

위의 방법들은 밝기 영상을 영역화할 때 사용되는 기법을 단순히 3차원으로 확장한 것에 불과하다. 즉, 칼라 영상 형성 과정상의 특성이나 칼라 공간에서의 클러스터 모양은 전혀 고려하지 않은 알고리듬들이다. 이에 반하여 Klinker<sup>[131]</sup> 등은 영상 형성 과정을 모델링하여 칼라 영상 형성 모델링에 기반한 영상 영역화 기법을 제시하였다. 이 모델에 의하면 물체의 표면에서 전반사 성분인 surface reflection과 난반사 성분인 body reflection이 동시에 일어나게 된다. 이와 같은 dichromatic reflection 모델<sup>[131]</sup>에 근거하면 영상 내에서 한 물체의 칼라 히스토그램이 T 모양을 가지게 되므로 영상의 3 × 3 크기의 부영역(subblock)에서 히스토그램이 가지는 모양을 이용한 칼라 영상 영역화 기법을 제안하였다. 그러나 어떤 물체의 칼라 히스토그램은 3차원 칼라 공간 상에서 T 모양의 평면상에 존재한다. 가장은 사용하였으므로 조명 조건과 대상 물체의 종류에 대한 세부적으로 인해 실외에서 취득한 일반적인 칼라 영상에 대해서 적용하기에는 부적합하며 칼

라 공간을 기반으로 한 영상 영역화가 아닌 영상 내의 부영역을 기반으로 한 영역화 기법이기 때문에 국부적인 잡음의 영향에 민감하며 별도의 부블러 통합(merging) 알고리듬을 필요로 한다.

### III. 수학적 형태학을 이용한 3차원 칼라 공간에서의 클러스터링

기존의 알고리듬들을 살펴보면 입력 영상 및 칼라 좌표계에 알고리듬의 성능이 좌우되기 쉽고 설정해 주어야 할 인자(parameter)가 많으며 영상에 따라 인자 값들의 할당이 달라야 한다. 또한 미분을 이용하여 터값을 설정하고 있기 때문에 잡음의 영향에 민감한 문제점이 있다. 본 논문에서는 이러한 문제점을 해결하기 위하여 직접 칼라 공간상에서 클러스터링을 수행하는 접근 방법을 제시하였다.

먼저 입력된 칼라 영상의 특성을 살펴보면 화소값은 화소당 8bit를 사용하므로 256계조를 가지게 되며 이에 대응하는 칼라 공간은  $256 \times 256 \times 256$  개의 bin을 가진 3차원 칼라 공간이 되는데 이를 R-G-B Color Cube라고도 부른다<sup>[13]</sup>. 각각의 화소값에 따라서 칼라 공간에 대응시키면 같은 영역에 속하는 화소들은 서로 가까운 거리의 bin에 존재하므로, 가까운 거리에 존재하는 화소들의 덩어리들을 각각의 클러스터로 구분하여 번호를 붙여주면 클러스터의 개수와 이에 따른 영상 영역화 결과를 얻을 수 있다.

칼라 공간에서의 클러스터링을 수행하기 위해서는 일반적인 클러스터링 알고리듬과 달리 다음과 같은 점들을 고려하여야 한다. 첫째, 영상에서 추림(decimation)을 행하지 않으면 칼라 공간에서 영상의 크기 만큼 빈도가 발생한다. 즉,  $256 \times 256$ 크기의 영상일 경우 65536번의 빈도가 발생하게 되는데 같은 bin에 여러번 대응이 되더라도 일반적인 영상의 경우 상당히 많은 bin을 차지하게 된다. 따라서 많은 양의 데이터를 클러스터링해야 하므로 계산에 의한 부담이 적어야 한다. 둘째, 영상의 종류에 따라서 클러스터의 크기나 모양 등에 변이가 매우 심하다. 실내에서 단일 조명하에서 취득한 영상은 조명의 영향을 직접적으로 받으므로 클러스터의 모양이 Klinker가 제안한 T 모양을 형성하거나 실외에서 취득한 영상은 주변광의 영향을 받으므로 조명에 의한 클러스터의 모양 변화가 적으며 칼라 공간상에서 넓은 범위에 걸쳐서 존재하게 된다. 그러므로

로 클러스터의 모양에 전혀 영향을 받지 않아야 한다.

#### 1. 수학적 형태학

위와 같은 점을 고려할 때, 데이터의 형태학적인 측면을 고려하는 수학적 형태학을 이용하면 계산량에 의한 부담이나 클러스터의 모양에 상관없이 원 데이터를 가장 잘 보존하는 모양의 클러스터링을 수행할 수 있다<sup>[14]</sup>. 먼저 수학적 형태학 연산에 대해서 간단히 살펴보면 기본이 되는 형태학 연산으로 팽창(dilation)과 침식(erossion)이 있다. A와 B가 n 차원 공간에서의 집합일 때, B에 의한 A의 팽창은  $A \oplus B$ , B에 의한 A의 침식은  $A \ominus B$ 로 나타내며 다음과 같이 정의된다.

$$A \oplus B = \{c \in E^N | c = a + b \text{ for some } a \in A \text{ and } b \in B\} \quad (1)$$

$$A \ominus B = \{x \in E^N | x + b \in A \text{ for every } b \in B\} \quad (2)$$

여기서 A는 집합 또는 영상이라 부르고 B는 구조 요소(structuring element)라고 부른다.  $A \oplus B$ 는 A를 B에 의해 팽창시킨 집합이 되며 따라서  $A \oplus B$ 는 A를 포함하게 된다. 팽창에 대한 쌍대(dual) 개념이 침식이며,  $A \ominus B$ 라는 집합은 A에서 B를 완전히 포함하고 있는 원소들을 나타낸다고 볼 수 있다. 팽창과 침식을 쌍으로 사용하면 전체적인 모양의 왜곡 없이 영상 A에서 구조 요소보다 작은 특정 부분들을 제거할 수 있다.

이같은 연산 중 대표적인 것이 침식 후 팽창을 행하는 열기(open)와 팽창 후 침식을 행하는 닫기(close) 연산이다. 구조 요소 K에 의한 영상 A의 열기 연산은  $A \cdot K$ , 구조 요소 K에 의한 영상 A의 닫기 연산은  $A \cdot K$ 와 같이 나타내며 다음식과 같이 정의된다.

$$A \cdot K = (A \ominus K) \oplus K \quad (3)$$

$$A \cdot K = (A \oplus K) \ominus K \quad (4)$$

열기 연산은 영상에서 연결이 되어 있으면서 뭉쳐있는 데이터들을 자연스럽게 몇개의 클러스터로 구분하는 역할을 수행하며 닫기 연산은 산재한 데이터들을 구조 요소로 연결시켜 묶어 주는 역할을 한다.

#### 2. 제안하는 클러스터링 알고리듬

위와 같은 수학적 형태학을 바탕으로 한 칼라 영상 영역화 알고리듬은 먼저 칼라 공간상에서 클러스터의 중심 부분을 찾아 번호 매기기(labeling)를 하고 자동적으로 클러스터의 개수를 결정한다. 그리고 나서 이

클러스터들을 확장시키면서 대부분의 bin들을 가까운 클러스터에 속하게 한다. 이를 단계별로 그림 2에 나타내었으며, 이를 자세히 살펴보면 다음과 같다.

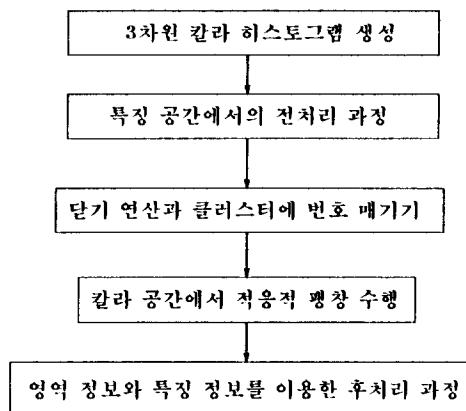


그림 2. 제안하는 알고리듬의 흐름도  
Fig. 2. Flowchart of the Proposed Algorithm.

#### A. 전처리 과정 (Pre-processing)

칼라 공간상에서 클러스터링을 행하기 위하여 먼저 3 차의 칼라 영상으로부터 3차원 칼라 공간으로 매핑과정이 필요하다. 칼라 영상에서 각 화소당 8bit를 가지므로 칼라 공간은  $256 \times 256 \times 256$  의 bin을 가지지만 계산상의 효율을 위하여 전체 성능을 저하시키지 않는 크기로 축소하여  $128 \times 128 \times 128$  bin을 가지는 특징 공간으로 설정한다. 칼라 공간의 각각의 bin에는 칼라 영상에서 칼라 공간으로의 매핑 회수(mapping index)가 기록되어 있다. 칼라 공간 내에서 클러스터의 중심 부분끼리는 일정 거리 이상을 유지해야 다른 클러스터로 분류할 수 있으며, 이웃하는 클러스터끼리는 공간적으로 연결되지 않아야 한다. 그러나 실제 영상의 경우 다른 영역이 비슷한 색상을 가질 경우 클러스터 사이가 매우 가까울 수도 있고, 잡음의 영향으로 다른 클러스터 사이가 연결되어 있을 수도 있다. 따라서 칼라 공간에서 유효한 클러스터를 형성하는 매핑 회수가 큰 밀집된 bin들의 중심을 찾고 인접한 클러스터끼리는 분리하기 위하여 다음과 같은 전처리 과정을 거친다.

구하고자 하는 클러스터의 후보가 될 만한 곳은 히스토그램의 피크에 해당되므로 먼저 피크 부분만을 정확히 찾아내는 과정이 필요하다. 먼저, 원래의 히스토그램과 표준 편차  $\sigma_1$ 과  $\sigma_2$ 를 가진 가우스 함수와의 3 차원 컨볼루션을 통해 평활화된 히스토그램  $H_1$ 과  $H_2$ 를 생성한다. 여기서  $\sigma_1$ 은  $\sigma_2$ 보다 큰 값을 가지도록

한다. 그림 3에 1차원에서의 예를 나타내었는데, ORG는 원래의 히스토그램,  $H_1$ 은  $\sigma_1$ 으로 평활화된 히스토그램,  $H_2$ 는  $\sigma_2$ 로 평활화된 히스토그램을 나타낸다. 가우스 함수와의 컨볼루션은 low-pass filtering에 해당하므로,  $H_1$ ,  $H_2$ 를 살펴보면 원래의 히스토그램에서 올 통통통한 부분은 사라지게 된다. 가우스 함수의 표준 편차가 클수록 컨볼루션된 히스토그램은 더욱 더 평활해지므로, 컨볼루션된 히스토그램의 피크는 낮아지고, 밸리는 높아진 형태가 된다. 이 두 히스토그램의 차이인  $(H_2 - H_1)$ 을 구한 후, 문턱값보다 작으면 0으로 설정한다. 이같은 과정을 통하여 클러스터의 후보들을 찾아낼 수 있다. 원 영상에 잡음이 거의 없는 경우에는  $\sigma_2$ 를 0으로 설정하여 원래의 히스토그램과  $H_1$ 의 차이를 구할 수 있지만 대부분의 영상은 영상 형상 과정에서 잡음이 자연적으로 첨가되므로  $\sigma_2$ 의 값을 0 보다 약간 큰 값으로 설정해 주는 것이 좋다.

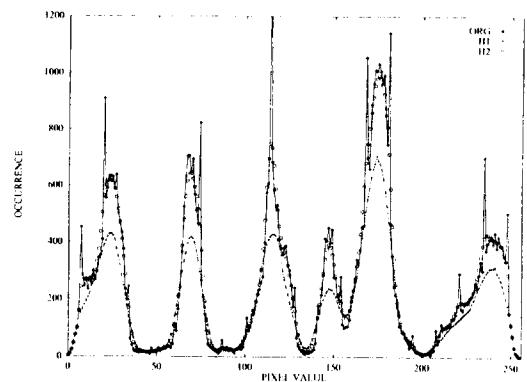


그림 3. 가우스 함수로 평활화된 히스토그램 : 1차원 경우

Fig. 3. Gaussian Smoothed Histogram : 1-D case.

#### B. 단기 연산의 수행 및 번호 매기기

모든 입력 영상에 대해서 클러스터들의 중심 부분을 찾고 다른 클러스터와는 구분되는 최적의  $\sigma_1$ 과  $\sigma_2$ 를 분석적으로 찾을 수는 없다. 그러므로 모든 영상에 대해서 히스토그램의 중심 부분을 찾아낼 수 있도록 고정된  $\sigma_1$ 과  $\sigma_2$ 를 사용하고 이를 thresholding하면 유효한 bin들의 수는 급격하게 줄어들고 공간적 연결성이 유지되지 않는다. 이 bin들을 의미있는 덩어리들로 묶어서 하나의 클러스터로 성립시키기 위해선 적절한 연산작용이 필요한데 이와 같이 직접 연결되어 있지 않으면서 뭉쳐져 있는 데이터들을 구분하기 위해

서는 닫기 연산이 적절하다. 닫기 연산은 다음과 같은 특징을 가지는 공간적 클러스터들을 찾는데 유용하게 사용될 수 있다<sup>[14]</sup>.

공간적인 점들의 집합  $A$ 가  $2\rho_0$  이상의 거리를 가진 클러스터들로 구성되어 있고 각각의 클러스터  $C$ 는 다음과 같은 거리  $\rho$ 의 분할 특성(partition property)을 가진다. 공간적 클러스터  $C$ 의 어떠한 두 셀에 의한 분할  $\{P_1, P_2\}$ 에 대하여 다음 조건을 만족시키는 세 점  $p_1, p_2, p_3 \in C$  가 존재한다.

1. 각각의 점들 사이의 거리는  $\frac{1}{2}\rho_0$  보다 크고  $\rho_0$  보다 작다.

2.  $P_1 \cap \{p_1, p_2, p_3\} \neq \emptyset$  and  $P_2 \cap \{p_1, p_2, p_3\} \neq \emptyset$ .

이러한 경우에 반경  $2\rho_0$  이상을 가지는 구에 의한 닫기 연산은 공간적 점들의 클러스터를 연결된 집합으로 바꾸어 주는 역할을 한다. 따라서 전처리 과정에 의해서 남아있는 bin들이 위와 같은 거리  $\rho_0$  분할 특성을 가지고 있고 각각의 클러스터들은  $2\rho_0$  이상의 거리를 가지고 존재한다면, 닫기 연산을 행한 후 칼라 공간에는 구분된 클러스터들이 존재하게 된다. 이들을  $N \times N \times N$  윈도우 내의 연결성을 조사하여 연결된 bin끼리 동일한 값을 부여하는 번호 매기기(labeling)를 수행한다. 그러면 클러스터별로 번호가 부여되는데 이 단계에서 한 클러스터 내에 있는 bin의 매핑 회수를 모두 더하여 클러스터의 크기를 구한후 이 값이 영상 크기의 1%이하이면 의미 없는 클러스터로 간주하여 제외한다. 이 단계에서 영상을 몇개의 영역으로 나누게 될 것인가를 결정하는 클러스터의 개수와 각 클러스터의 중심 부분이 정해지게 된다.

### C. 적응적 팽창 연산의 수행

윗 단계에서 다수의 화소들이 클러스터에 속하게 되지만 전처리 과정에서 제외된 bin에 속하는 화소들은 대부분 영역화 되지 않은 채 남아있게 된다. 이들을 가장 가까운 클러스터에 속하게 하기 위해서는 칼라 공간 내에서 클러스터들을 확장시켜 포함되게 하면 된다. 기존의 방법들<sup>[9, 10, 15, 16]</sup>은 클러스터의 개수와 중심 부분을 결정한 후, 분류되지 않은 bin들을 각각의 클러스터의 중심과 거리를 계산하여 가장 가까운 거리를 가지는 클러스터에 속하게 하였다. 이러한 방법들은 사용하는 칼라 좌표 시스템에 따라 거리 기준이 달라지기 때문에 동일한 화소가 다른 클러스터로 분류될 수 있으며 잡음의 영향에 민감한 결과를 낳게 된다. 클러-

스터의 모양을 고려하여 클러스터의 가장자리에서 확장하기 위해서는 수학적 형태학 기법 중에서 팽창 연산을 행하면 되지만 원래의 팽창 연산은 클러스터의 크기만 크게 할 뿐 분류되지 않은 bin들이 확장되는 클러스터에 속하게 하기가 힘들다. 즉, 기존 클러스터의 원형을 유지하면서 미분류된 bin들을 포함시키기 위하여 원래의 매핑 회수가 기록된 bin의 값을 이용하면 효율적인 팽창 연산을 수행할 수 있다. 즉, 어떤 번호가 매겨진 클러스터를 팽창 연산에 의해서 확대시킬 때, 클러스터를 확장시킬 부분인 클러스터의 가장자리에서 구조 요소에 포함되는 매핑 회수의 합을 고려하여 기준값 이상의 매핑 회수를 가지면 팽창 연산을 수행하고 그렇지 않을 경우에는 팽창 연산을 수행하지 않는다. 그러면 매핑 회수가 적은 bin쪽으로는 클러스터가 확장되지 않는다.

또한 클러스터를 계속 팽창시켜 주변의 bin들을 모두 포함하기 위해서 이와 같은 적응적 팽창 연산을 반복적으로 수행한다. 즉, 반복적 팽창 연산의 초기 단계에서는 기준값을 크게 하고 반복 회수에 따라 점차적으로 기준값을 작게 하여 팽창 연산을 수행하면 기존의 클러스터를 중심으로 밀도가 높은 부분부터 작은 부분까지 점진적으로 모두 이 클러스터에 포함되게 된다. 이웃 클러스터의 경계 부분과 만나지 않을 때까지 여러 클러스터를 동시에 확장시키면 반복적 팽창 연산에 의해 거의 모든 bin들이 분류되게 되며 두 클러스터 사이의 벌리에서 경계가 결정되게 된다. 하지만 원래부터 전혀 연결 요소 없이 동떨어져 있었던 bin들은 이와 같은 과정에 의해서도 분류되지 않는다.

### D. 후처리 과정

윗 단계까지 칼라 공간 내의 대부분의 bin들이 가까운 클러스터로 분류가 되지만, 분류가 안된 bin들은 클러스터와 전혀 연결되어 있지 않은 것들이다. 이에 대응하는 화소들은 잡음의 영향이거나 영역화된 영상 내에서 작은 구멍(hole)을 형성하고 있는 것들이다. 기존의 방법들은 이러한 분류되지 않은 bin들을 클러스터의 중심으로부터 거리를 계산하여 가장 가까운 거리의 클러스터로 속하게 하였는데<sup>[9, 10]</sup> 이런 방법은 잡음의 영향이 강하면 잘못 분류하기 쉽고 칼라 공간의 특성에 맞는 적당한 거리 measure를 찾기가 쉽지 않기 때문에 다른 클러스터로 분류되기 쉽다. 따라서 분류되지 않은 화소들은 칼라 공간에서의 관계보다 영역 내에서 주변 화소의 관계를 이용하여 분류하는 것이 효

과적이다<sup>[15, 16]</sup>. 대표적인 예가 영상 영역화 초기 단계에서는 scale space filter를 사용하여 클러스터의 개수를 구하고 분류되지 않은 화소들은 영상 내에서의 주변 화소들 값으로부터 Markov Random Field를 이용하여 분류하는 방법이 제안되었으나 과도한 계산량 때문에 데이터량이 방대한 영상 처리에는 적합하지 않다<sup>[15, 16]</sup>. 본 논문에서는 주변 화소와의 관계를 이용하여 분류하기 위하여 먼저 분류되지 않은 화소가 속하게 될 후보 영역을 구한다. 즉, 영상 내에서 분류되지 않은 화소를 중심으로 하는 일정한 거리의 유클리디안 거리 내에 이미 특정 클러스터에 속하도록 분류된 화소들을 찾는다. 주변의 화소들이 모두 동일한 영역에 속하면 분류되지 않은 화소는 주변의 화소와 같은 영역으로 분류한다. 그러나, 주변의 화소들이 여러 영역에 속하는 화소들로 나누어질 경우에는 분류되지 않은 화소와 주변 영역의 대표값과의 거리를 특징 공간인 칼라 공간 상에서 계산하여 가장 가까운 경우의 대표값으로 분류함으로써 모든 화소들의 영역화가 끝나게 된다. 이와 같은 후처리 기법은 영상 내의 거리 정보와 특징 공간상의 정보를 동시에 이용할 수 있으므로 효율적이다.

#### IV. 벡터 양자화기를 이용한 칼라 영상의 영역화

다차원 상의 공간에 존재하는 데이터들을 이를 대표하는 몇 개의 벡터로 나타내는 문제는 깊이 연구되어 왔으며, 이중에서 그 실제적인 유용성이 인정되어 널리 사용되는 것이 벡터 양자화기이다<sup>[19, 20, 21]</sup>. 칼라 영상의 경우 3차원 공간 상에서의 히스토그램은 영역별로 어느 정도 클러스터링되어 존재하므로, 벡터 양자화기법을 이용하여 히스토그램을 대표하는 몇 개의 벡터를 찾아낼 수 있다. 이와 같이 찾은 각각의 대표 벡터들은 각각의 영역을 나타낼 수 있으므로, 손쉽게 영역화된 결과를 얻을 수 있다. 본 논문에서는 벡터 양자화기를 이용하여 칼라 영상을 영역화하고, 그 결과를 제안하는 기법과 비교하였다. 먼저, 벡터 양자화기에 대해 간단히 살펴보면 다음과 같다<sup>[21]</sup>.  $D$  차원의 유클리디안 공간에서  $N$ 개의 점의 집합  $X = \{x_i, i = 1, \dots, N\}$  가 주어졌을 경우,  $X$ 를  $M$  개의 대표 벡터  $\{m_1, \dots, m_M\}$ ,  $m_k \in R^D$ ,  $k = 1, \dots, M$ , 에 의해서 나타내지는  $M$ 개의 집합  $\{S_1, \dots, S_M\}$  으로 구분할

수 있으며, 각각의 집합  $S_k$ 는 다음과 같이  $m_k$ 를 중심으로 하는 Voronoi 영역을 형성한다.

$$S_k = \{x_i : \|x_i - m_k\| < \|x_i - m_j\|, j \neq k\}$$

$$\|x_i - m_k\| = \sum_{l=1}^D (x_{il} - m_{kl})^2$$

여기서  $\|\cdot\|$  는 유클리디안 norm을 나타내며, 배터 양자화기에서 가장 널리 사용되는 measure이다. 이 대표 벡터들은 식 (5)와 같은 error measure를 최소화시키는데 최적으로 알려져 있으며 다음 식에서  $1_S(\cdot)$ 은 집합  $S$ 에 속하는지를 나타내는 indicator 함수이다.

$$\begin{aligned} \epsilon(m) &= \frac{1}{2} \sum_{k=1}^M \sum_{x_i \in S_k} \|x_i - m_k\|^2 \\ &= \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^M \|x_i - m_k\|^2 1_{S_k}(x_i) \end{aligned} \quad (5)$$

이와 같은 중심 벡터를 찾기 위하여 처음에는 임의의 중심 벡터  $m^{(0)}$ 에서 시작하여 다음과 같은 식을 통해 중심 벡터를 생성하게 된다. 여기서 위 첨자는 이러한 과정의 반복 회수를 나타낸다.

$$m_k^{(t+1)} = \frac{\sum_{i=1}^N x_i 1_{S_k^{(t)}}(x_i)}{\sum_{i=1}^N 1_{S_k^{(t)}}(x_i)} \quad (6)$$

$$S_k^{(t)} = \{x_i : \|x_i - m_k^{(t)}\| < \|x_i - m_j^{(t)}\|, j \neq k\}$$

이 알고리듬은 식 (5)에 국부적으로 수렴함이 알려져 있으나, 클러스터의 개수인  $M$ 은 미리 적당히 결정되어야 한다는 문제점이 존재한다. 이와 같은 벡터 양자화기를 칼라 영상 영역화에 적용시키기 위하여 다음의 식 (7)와 같은 measure를 사용하였다.

$$\begin{aligned} \|p - q\| &= (r_1 - r_2)^2 + (g_1 - g_2)^2 + (b_1 - b_2)^2 \\ &\quad + W[(x_1 - x_2)^2 + (y_1 - y_2)^2] \\ p &= (r_1, g_1, b_1, x_1, y_1)^t \\ q &= (r_2, g_2, b_2, x_2, y_2)^t \end{aligned} \quad (7)$$

식 (7)에서  $(r_1, g_1, b_1)$ 은 영상 좌표가  $(x_1, y_1)$ 인 점에서의 칼라 좌표를 나타내며,  $W$ 는 칼라 차이와 영상 좌표간의 차이에 대한 비율을 나타낸다. 이 값은 분석적으로는 결정할 수 없으며, 경험적으로 적당한 값을 설정해야만 한다.  $W$ 가 0이 아니면 5차원 클러스터링이며, 0으로 설정하면 칼라 공간상의 3차원 클러스터

링이 된다.

## V. 실험 및 성능 평가

본 논문에서는 합성 영상인 BALL 영상과 실제 영상인 WOMAN 영상, 그리고 COLOR 영상과 HOUSE 영상에 대하여 영상 영역화 알고리듬을 실험하였다. 또한, 제안한 영역화 기법과 벡터 양자화기를 적용한 결과를 제시하였으며 일반적으로 사용되는 다양한 컬라 좌표계에서의 결과를 제시하여 제안하는 기법이 특정 컬라 좌표계에 의존하지 않음을 보였다. 클러스터링을 수행하기 위한 첫단계로서 유효한 bin을 판정하는 기준값인  $\sigma_1$ 과  $\sigma_2$ 를 설정해야 하는데, 실험적으로  $\sigma_1 = 1.5$ ,  $\sigma_2 = 0.5$ 가 모든 영상에 대해서 적당함을 알 수 있었다.

닫기 연산을 위한 구조 요소는 임의의 모양을 설정할 수 있지만 특정 클러스터의 모양에 독립적이기 위해서는 구 모양의 구조 요소를 가지는 것이 바람직하다. 구조 요소의 크기가 너무 크면 닫기 연산 수행시 생성되는 클러스터의 개수와 중심 부분이 너무 줄어들게 되며, 구조 요소의 크기가 너무 작으면 그 반대의 결과가 나타난다. 본 연구에서 사용한 구조 요소로서는 3차원  $5 \times 5 \times 5$  크기의 구 모양을 가진 구조 요소를 사용하였는데 이때 구조 요소의 반지름인  $\rho_0$ 는 2가 된다. 이것을 이용하여 닫기 연산을 하고 번호 매기기를 수행하면 클러스터의 개수가 자동으로 나오게 된다. 하지만 이중에서도 매핑 회수의 합이 너무 작은 클러스터들은 하나의 클러스터로서 의미가 없으므로 제외시킨다. 전체 영상의 1% 미만의 크기를 가지는 클러스터들은 하나의 영역을 형성한다고 볼 수 없으므로 제외시켰다.

지금까지 구분된 클러스터는 클러스터의 대략적인 중심 부분이 되며 대부분의 화소가 속하게 되지만 아직 분류되지 않은 화소를 특정 클러스터에 속하게 하기 위해서 다음 단계로 적응적 팽창 연산을 수행하였다. 이를 위한 구조 요소로는 가장자리에서의 밀집도를 쉽게 평가할 수 있는 3차원  $3 \times 3 \times 3$  크기의 구조 요소를 사용하였는데 27 개의 bin 중에서 꼭지점에 해당하는 가장자리 8개의 bin만 0인 값을 가지고 나머지 19개의 bin은 1의 값을 가지고도록 하였다. 이와 같은 과정을 통하여 매핑 회수가 작아서 처음에는 클러스터에 속하지는 못했지만 원래 연결된 bin들은 기존의 클

러스터에 포함되도록 하였다.

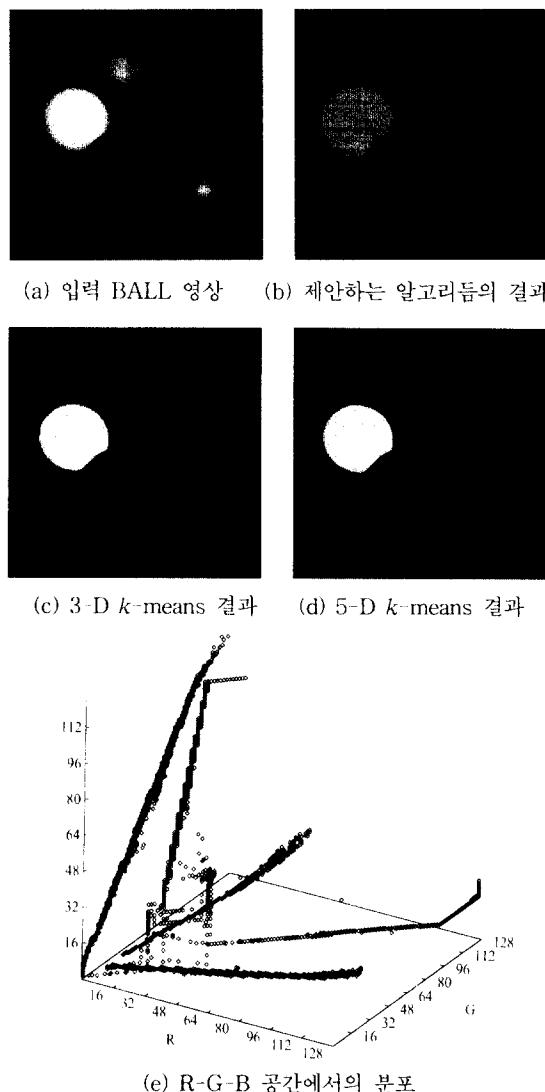


그림 4. 합성 영상과 영역화 결과

Fig. 4. Synthetic Image and Segmentation Results.

그러나 팽창된 클러스터의 가장자리에서  $3 \times 3 \times 3$  구조 요소 내에서 연결되지 않은 bin에 해당하는 화소들은 영역화된 영상에서 분류가 안된 채로 남아 있게 된다. 이와 같이 기존의 클러스터에 포함되지 않은 bin들은 접음의 영향이거나 어느 클러스터에 속하는지 판별하기 어려운 것들이다. 본 논문에서는 최종적으로 분류되지 않은 화소들은 그 화소 주변의 반지름이 2인 유클리디안 거리 내에서의 영역화된 값들을 참조하여 이중에서 컬라 공간상에서 가장 가까운 화소값으로 지

정하는 영역 확장 기법을 이용하여 분류되도록 하였다.



그림 5. 실제 영상과 영역화 결과  
Fig. 5. Real Image and Segmentation Results.

먼저, 합성 영상은 Klinker가 제안한 영상 형성 모델에 부합하는 surface reflection과 body reflection을 가지도록 그림 4(a)와 같은 BALL 영상을 생성하였다. 그림 4(e)에서 R-G-B 공간에서의 히스토그램을 살펴보면, 각각의 공에 해당하는 히스토그램이 T 또는 L 모양으로 형성되어 있음을 알 수 있다. 아래쪽의 몸체 부분이 물체의 색을 반영하는 body reflection이며 위쪽의 꺽어진 부분이 조명의 영향을 주로 받는 surface reflection이 된다. 영상내에서의 각 공의 색은 주로 body reflection에 의해서 좌우되고 하일라이트 부

분은 surface reflection에 의해서 결정된다. 제안하는 알고리듬에 의한 결과를 살펴보면, 그림 4(b)와 같이 칼라 공간상에서 6개의 클러스터를 자동으로 추출하여 L 모양으로 연결된 클러스터를 하나로 취급하므로 각 공과 배경이 각각 하나의 영역으로 나누어짐을 알 수 있다. 그러나 벡터 양자화기를 이용하여 영역화를 할 경우에는 미리 클러스터의 개수를 지정해주어야 하며, 6개로 클러스터의 개수를 지정하면 여러개의 공이 하나의 영역으로 영역화되고 그림자 부분만을 다른 영역으로 구분하므로 각 공을 분리시키기 위하여 전체 클러스터의 개수를 8개 또는 9개의 클러스터로 지정해 주어야 한다.

그 결과를 살펴보면 하나의 공이라도 밝기 정도에 따라 여러개의 영역으로 잘못 구분함을 알 수 있다. 칼라 공간상에서만 클러스터링을 하는 그림 4(c)의 3차원 벡터 양자화기의 결과에 비해 그림 4(d)의 5차원 벡터 양자화기의 결과는 영상내에서의 인접성을 고려하여 영역화를 수행하지만 3차원 벡터 양자화기에 비해 거의 차이가 없음을 알 수 있다.

실제 영상인 그림 4(a)의 경우에도 제안하는 알고리듬은 그림 4(b)와 같이 밝기 변화가 심한 머리카락 부분과 얼굴, 옷, 배경 등을 하나의 영역으로 구분하고 있으나 그림 4(c)와 같이 3차원 벡터 양자화기를 이용하면 여러개의 영역으로 잘못 구분하고 있다. 특히 그림 4(d)와 같이 5차원 벡터 양자화기의 경우에는 영상 전체에 걸쳐 있는 배경 부분을 두개로 나누므로 영상내에서 넓게 분포되어 있는 영역의 경우에 큰 오차를 발생시킨다. 제안하는 알고리듬의 각 칼라 좌표계에서의 영향을 살펴보기 위하여 R-G-B 뿐만이 아니라 X-Y-Z, Y-I-Q, U-V-W, I1-I2-I3 좌표계에 대하여 영역화를 수행하였다.

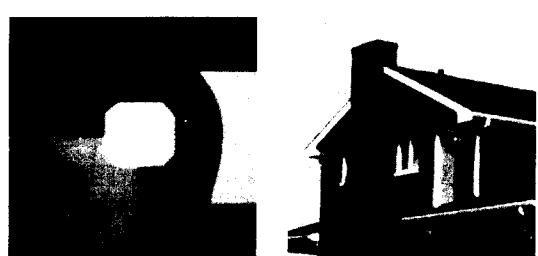


그림 6. 입력 영상  
Fig. 6. Input Image.

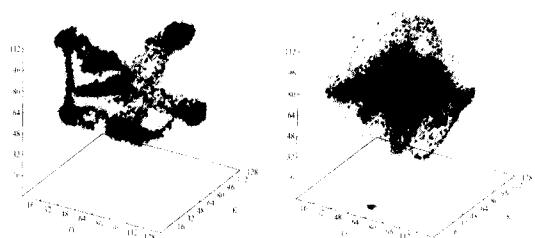
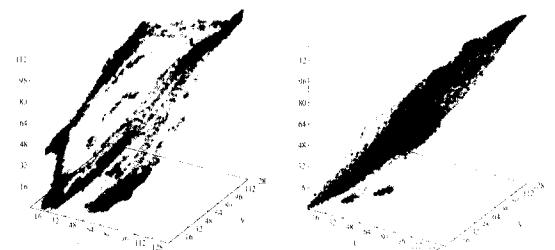
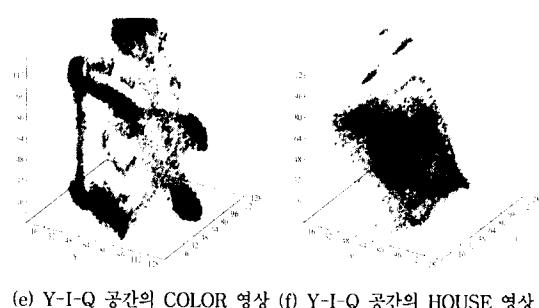
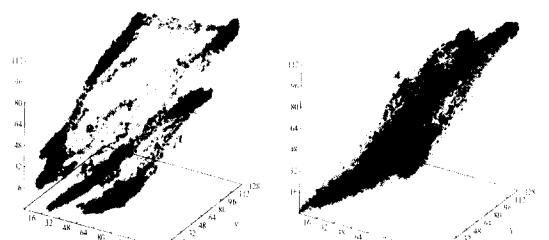
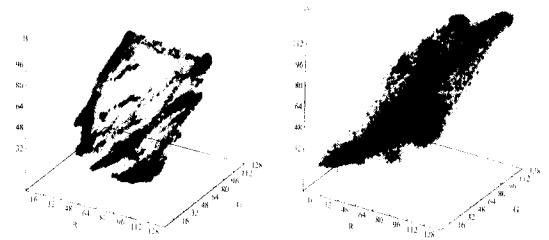
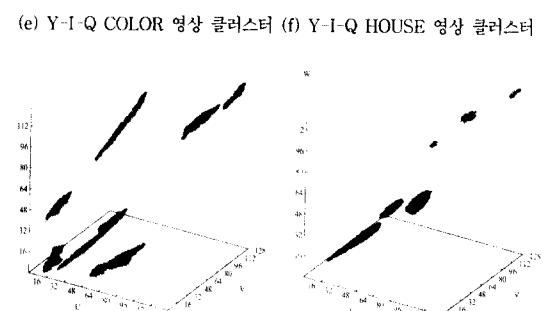
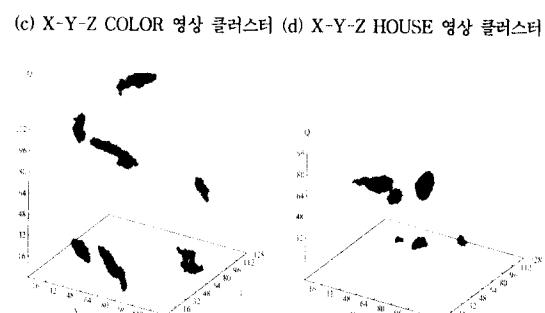
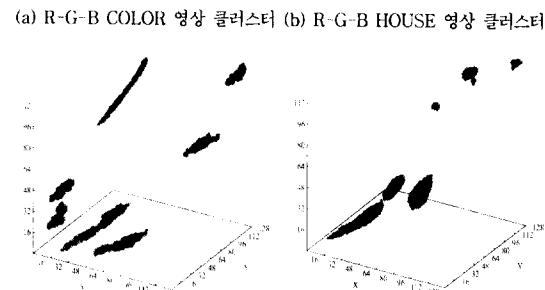
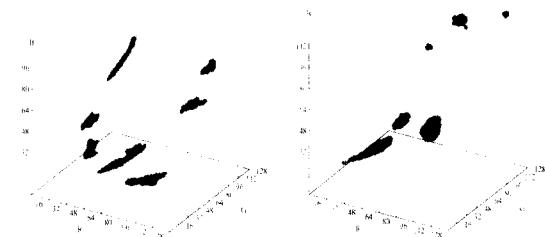
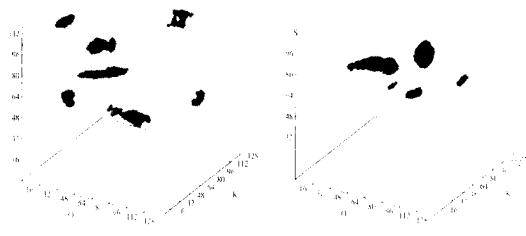


그림 7. COLOR 영상의 3차원 히스토그램  
Fig. 7. 3D Histogram of COLOR Image.

그림 6의 COLOR 영상과 HOUSE 영상을 대상으로 하였는데 먼저 COLOR 영상의 각 좌표계에서의 히스토그램을 살펴보면 그림 7과 같으며 저차원 공간으로 사영하여 문턱값을 구하는 경우에는 클러스터의 모양이 좌표축에 수직인 II-I2-I3 좌표계가 가장 유리함을 알 수 있다. 반면에 좌표축에 비스듬한 클러스터들을 가지고 있는 U-V-W 좌표계의 경우에는 상당한 성능 저하가 있을 것으로 예측할 수 있다.



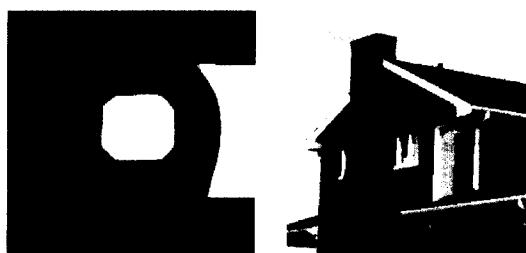


(i) II-I2-I3 COLOR 영상 클러스터 (j) II-I2-I3 HOUSE 영상 클러스터

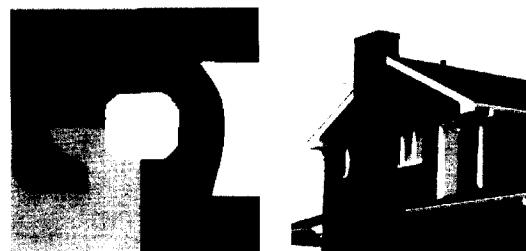
그림 8. 3차원 COLOR 공간에서 닫기 연산 결과

Fig. 8. Results of Closing Operation in 3-D Color Space.

그림 8은 3차원 좌표계에서 닫기 연산을 수행한 후의 결과를 나타내며 클러스터의 모양과 분포에 상관없이 COLOR 영상의 경우 모두 7개의 클러스터로, HOUSE 영상의 경우는 6개로 구분함을 알 수 있다. 그림 9에서는 제안한 알고리듬에 의하여 COLOR 영상과 HOUSE 영상을 영역화한 결과를 나타내었다.



(a) R-G-B COLOR 영상 영역화 (b) R-G-B HOUSE 영상 영역화



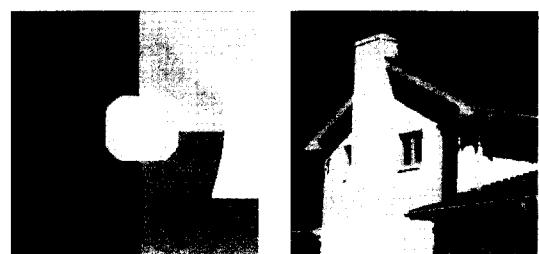
(c) X-Y-Z COLOR 영상 영역화 (d) X-Y-Z HOUSE 영상 영역화



(e) Y-I-Q COLOR 영상 영역화 (f) Y-I-Q HOUSE 영상 영역화



(g) U-V-W COLOR 영상 영역화 (h) U-V-W HOUSE 영상 영역화

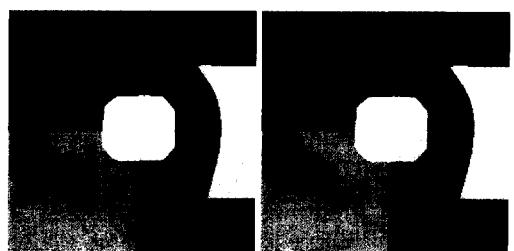


(i) II-I2-I3 COLOR 영상 영역화 (j) II-I2-I3 HOUSE 영상 영역화

그림 9. COLOR 영상 영역화 결과

Fig. 9. Results of color image segmentation.

COLOR 영상에 대하여 벡터 양자화기를 적용하여 영역화한 결과는 그림 10과 같다. 그림 10(a)는 7개의 클러스터를 지정하고 3차원 벡터 양자화기를 적용한 결과인데 오른쪽 아래부분 영상에 잘못 나누어졌음을 알 수 있으며 이것은 SSF를 사용한 [10]의 결과와 비슷한 오류를 보여준다. 이러한 문제점은 그림 10(b)와 같이 영상 좌표를 포함하는 5차원 벡터 양자화기를 적용하여 극복할 수 있으나 여전히 클러스터의 개수를 미리 지정해야 한다는 문제점이 존재한다.



(a) 3-D k-means 결과 (b) 5-D k-means 결과

그림 10. COLOR 영상을 벡터 양자화기로 영역화한 결과

Fig. 10. Segmentation Results of COLOR image using Vector Quantizer.

본 논문에서 제안한 방법은 클러스터링을 행할 때, 미분 요소를 사용하지 않으므로 잡음의 영향에 둔감하리라고 예상할 수 있다. 잡음의 영향을 고찰하기 위하여 앞의 실험에서 사용한 컬라 영상의 모든 좌표계에 대하여 화이트 가우시안 잡음을 증가시키면서 실험을 수행하였다. 잡음의 영향에 대한 측정 기준으로는 잡음이 없을 때 영역화된 결과와 잡음 첨가시 영역화된 결과를 비교하여 그 차이의 전체 영상 크기에 대한 비율을 사용하였다. 각 좌표계의 3매의 영상에 대하여 신호 대 잡음 비율인 SNR을 30dB 부터 16dB 까지 변화시키면서 영역화를 수행했을 때의 오차 비율을 그림 11에 나타내었다. 대부분의 경우 클러스터의 개수를 7개로 잘 찾아내고 잡음의 영향에 둔감하지만 U-V-W 좌표계의 경우 컬라 공간상에서 클러스터끼리 너무 인접해 있으므로 다른 좌표계의 오차에 비해 2배에서 3배의 오차를 나타내며 SNR이 18dB, 16dB인 경우에는 클러스터의 개수를 6개로 인식하므로 오차 비율이 급격히 증가한다. 그러므로 U-V-W 좌표계의 경우 오차 비율을 그림 11에서 생략하였으며, 다른 좌표계의 경우 상당히 적은 오차 비율을 나타내며 잡음의 증가에도 불구하고 안정적인 영역화 결과를 나타낸다.

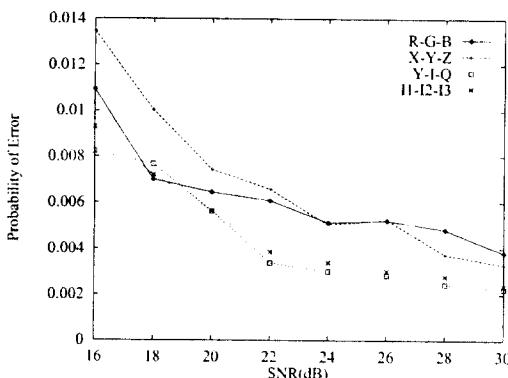


그림 11. COLOR 영상에 가우시안 잡음 첨가시 오차 비율

Fig. 11. Error rate when Gaussian noise is added to color image.

## VI. 결 론

본 논문에서는 3차원 컬라 공간에서의 클러스터링을 이용한 새로운 영상 영역화 기법을 제안하였다. 제안한 기법은 수학적 형태학 기법을 이용하여 직접 3차원 공간에서 클러스터링을 행함으로 기준의 1차원, 2차원

부분 공간에 사영하여 영상 영역화를 행하는 알고리듬 보다 성능이 우수하며 클러스터의 모양에 제약을 받지 않는다. 특히, 컬라 공간상에서 클러스터의 모양을 고려하여 의미있는 클러스터를 찾아내므로 영상에 대한 사전 정보가 전혀 없어도 자동으로 클러스터의 개수와 중심 영역을 결정할 수 있다. 클러스터의 개수를 찾아낸 후에는 중심 영역으로부터 원래의 데이터가 가장 밀한 곳으로 각각의 클러스터를 확장시켜 나가므로 밀집되어 있는 bin들을 대부분 포함하는 클러스터를 생성하게 된다. 그리고 최종적으로 분류되지 않은 화소들은 주변 화소들의 값을 참조하는 영역 확장기법을 이용하여 주변의 영역에 지정하게 된다.

본 논문에서 제안한 방법은 문턱값 설정시 주로 사용되는 미분 연산자를 사용하지 않으므로 잡음의 영향에 상당히 강인함을 보였고, 클러스터의 모양에 제약을 받지 않으므로 사용하는 컬라 좌표계와 입력 영상에 따라 성능이 좌우되지 않는 이점이 있다. 또한 특정 공간의 차원이 3 보다 더 큰 값일 때에도 적용할 수 있으므로 컬라 영상을 나타내는 차수가 4 이상이거나 Infrared, R, G, B 영상이 입력일 경우에도 다른 알고리듬과 달리 더욱 효과적인 영상 영역화를 수행할 수 있다.

## 참 고 문 현

- [1] G. A. Agoston, "Color Theory and Its Application in Art and Design," New York : Springer-Verlag, 1979.
- [2] R. D. Overheim and D. L. Wagner, "Light and Color," New York : John Wiley & Sons, Inc., 1982.
- [3] D. H. Ballard and C. M. Brown, "Computer Vision," Prentice-Hall Inc., 1982.
- [4] W. K. Pratt, "Digital Image Processing," New York : John Wiley & Sons, Inc., 1991.
- [5] K. S. Fu and J. K. Mui, "A Survey on Image Segmentation," *Pattern Recognition*, vol. 13, No. 1, pp. 3-16, 1981.
- [6] N. R. Pal and S. K. Pal, "A Review on Image Segmentation Techniques," *Pattern Recognition*, vol. 26, No. 9, pp. 1277-1294, 1993.
- [7] A. Sarabi and J. K. Aggarwal, "Segmen-

- tation of Chromatic images," *Pattern Recognition*, vol. 13, No. 6, pp. 417-427, 1981.
- [8] R. Ohlander, K. Price and D. R. Reddy, "Picture Segmentation Using A Recursive Region Splitting method," *Computer Vision, Graphics, and Image Processing*, vol. 8, pp. 313-333, 1978.
- [9] J. C. Bezdek and M. M. Trivedi, "Low Level Segmentation of Aerial Images with Fuzzy Clustering," *IEEE Trans. Syst. Man, Cybern.*, vol. 16, No. 4, pp. 589-598, 1986.
- [10] 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. 379-396, 1990.
- [11] M. J. Carlotto, "Histogram Analysis Using a Scale-Space Approach," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 9, No. 1, pp. 121-129, July 1987.
- [12] Yu-Ichi Ohta, Takeo Kanade and To shiyuki Sakai, "Color Information for Region Segmentation," *Computer Vision, Graphics, and Image Processing*, vol. 13, pp. 224-241, 1980.
- [13] G. J. Klinker, S. A. Shafer and T. Kanade, "A Physical Approach to Color Image Understanding," *Int'l Journal of Computer Vision*, vol. 4, No. 1, pp. 7-38, January 1990.
- [14] R. M. Haralick and L. G. Shapiro, "Com puter and Robot Vision : Volume I, II," Addison-Wesley, 1993.
- [15] C. L. Huang, T. Y. Cheng and C. C. Chen, "Color Images' Segmentation Using Scale Space Filter and Markov Random Field," *Pattern Recognition*, vol. 25, No. 10, pp. 1217-1229, 1992.
- [16] J. Liu and Y. H. Yang, "Multiresolution Color Image Segmentation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 16, No. 7, pp. 689-700, July 1994.
- [17] M. Celenk, "A Color Clustering Technique for Image Segmentation," *Computer Vision, Graphics and Image Process.*, vol. 52, pp. 145-170, 1990.
- [18] S. H. Park, I. D. Yun and S. U. Lee, "Color Image Segmentation based on the 3D Clustering and Morphological Operators" *Second Asian Conference on Computer Vision*, pp. 253-257, Singapore, December 1995.
- [19] A. Gersho and R. M. Gray, "Vector Quantization and Signal Processing," Boston : Kluwer Academic Publishers, 1992.
- [20] A. Gersho, "On the structure of vector quantizers," *IEEE Trans. Information Theory*, vol. 28, No. 2, pp. 157-166, 1982.
- [21] J. L. Marroquin and F. Girosi, "Some Extensions of the K-Means Algorithm for image Segmentation and Pattern Recognition," AI Memo 1390, MIT Artificial Intelligence Laboratory, January 1993.

## 저자 소개

朴祥鑄(正會員) 第33卷 B編 第2號 參照  
 현재 서울대학교 전기공학부 박사  
 과정

李商郁(正會員) 第33卷 B編 第2號 參照  
 현재 서울대학교 전기공학부 교수

尹逸東(正會員) 第33卷 B編 第2號 參照  
 현재 서울대학교 전기공학부 박사과정