

논문 2005-42SP-6-6

# SOM의 통계적 특성과 다중 스케일 Bayesian 영상 분할 기법을 이용한 텍스쳐 분할

(Texture Segmentation Using Statistical Characteristics of SOM and Multiscale Bayesian Image Segmentation Technique)

김 태 형\*, 엄 일 규\*\*, 김 유 신\*\*\*

(Tae-Hyung Kim, Il-Kyu Eom, and Yoo-Shin Kim)

## 요 약

이본 논문에서는 Bayesian 영상 분할법과 SOM(Self Organization feature Map)을 이용한 텍스쳐(Texture) 분할 방법을 제안한다. SOM의 입력으로 다중 스케일에서의 웨이블릿 계수를 사용하고, 훈련된 SOM으로부터 관측 데이터에 대한 우도(尤度, likelihood)와 사후확률을 구하는 방법을 제시한다. 훈련된 SOM들로부터 구한 사후확률과 MAP(Maximum A Posterior) 분류법을 이용하여 텍스쳐 분할을 얻는다. 그리고 문맥 정보를 이용하여 텍스쳐 분할 결과를 개선하였다. 제안 방법은 HMT(Hidden Markov Tree)을 이용한 텍스쳐 분할보다 더 우수한 결과를 보여준다. 또한 SOM과 HMTseg라고 불리는 다중 스케일 Bayesian 영상 분할 기법을 이용한 텍스쳐 분할 결과는 HMT와 HMTseg을 이용한 결과보다 더 우수한 성능을 보여준다.

## Abstract

This paper proposes a novel texture segmentation method using Bayesian image segmentation method and SOM(Self Organization feature Map). Multi-scale wavelet coefficients are used as the input of SOM, and likelihood and a posterior probability for observations are obtained from trained SOMs. Texture segmentation is performed by a posterior probability from trained SOMs and MAP(Maximum A Posterior) classification. And the result of texture segmentation is improved by context information. This proposed segmentation method shows better performance than segmentation method by HMT(Hidden Markov Tree) model. The texture segmentation results by SOM and multi-sclae Bayesian image segmentation technique called HMTseg also show better performance than by HMT and HMTseg.

**Keywords :** Texture segmentation, SOM, Wavelets, Multi-scale Bayesian image segmentation, HMT

## I. 서 론

텍스쳐 분할은 텍스쳐를 가진 영상을 동종의 텍스쳐를 가진 영역별로 분할하는 것이다. 영상들은 텍스쳐를 포함하므로 텍스쳐 분할은 여러 응용 분야의 영상 처리에서 중요한 분야로 간주된다. 텍스쳐 분할은 감독 분

할(supervised segmentation)과 비감독 분할(unsupervised segmentation)로 분류해 볼 수 있다. 감독 분할은 영상에 포함된 텍스쳐 부류와 그 개수를 알고, 알려진 텍스쳐 부류별로 영상을 분할하는 것이다. 비감독 분할은 영상에 포함된 텍스쳐 부류와 그 개수에 대하여 분할 이전에 알려진 지식 없이 동종의 텍스쳐 영역별로 영상 분할을 하는 것이다. 감독과 비감독의 분할 문제는 각기 다른 분할 방법들이 고려되어야 한다. 텍스쳐 분할 방법을 결정하는 또 하나의 사항은 텍스쳐의 묘사 방법 즉, 특정 추출 방법이다. 영상에서 시각상의 텍스쳐는 영상 화소들의 공간적인 배열들 또는 동종의 패턴으로 나타난다. 텍스쳐는 텍스쳐를 이루는

\* 학생회원, \*\* 정회원, 부산대학교 전자공학과  
(Dept. of Electronics Eng., Pusan Univ.)

\*\* 정회원, 밀양대학교 정보통신공학과  
(Dept. of Information and Communication Eng., Miryang Univ.)

접수일자: 2005년6월9일, 수정완료일: 2005년9월22일

근본 요소의 크기와 구조, 배치 형태에 따라 통계적인 텍스쳐와 구조적인 텍스쳐로 나눌 수가 있고<sup>[1,2]</sup>, 그에 따라 다른 분할 방법을 사용할 수 있다. 텍스쳐의 근본 요소가 작으며 그 구조와 배치가 고정형태를 가지지 않은 통계적인 텍스쳐의 경우는 텍스쳐 영상의 분류 창 내에 영상 화소 값의 평균, 분산 등의 통계적인 모멘트들과 엔트로피를 이용하여 분류 창 내에 영상을 분류한다<sup>[1,3,4,5]</sup>. 텍스쳐의 근본 요소가 크며 그 구조와 배치가 고정된 구조의 반복적 배치로 나타나는 구조적인 텍스쳐는 텍스쳐의 근본 요소의 추출과 그것들의 배치 규칙을 결정함으로써 분석할 수 있다<sup>[1,2,4]</sup>. 이와 같은 텍스쳐의 묘사 방법에 따른 텍스쳐 분할 방법들은 영상 분할 방법들과 유사하다. 그래서 텍스쳐 분할 방법을 영상 모델 기반의 분할 방법처럼 유사하게 분류한다. 영상 모델 기반의 분할 방법은 영역 기반<sup>[4,6]</sup>과 경계 기반 방법<sup>[4,6,7,8,9,10]</sup> 등이 있다. 모델 기반의 방법에 있어서 MRF(Markov Random Field)을 텍스쳐 모델로 이용하는 접근 방법이 가장 흔하다<sup>[11,12,13]</sup>. 텍스쳐 특징 추출에 있어서 영상 화소의 값을 이용하는 것 이외에도 영상의 푸리에 영역 변환<sup>[14]</sup>이나 웨이블릿 영역 변환<sup>[15]</sup> 등을 이용한 영상 특징을 이용할 수 있는데, 다중 스케일에서의 영상 영역 변환을 이용한 영상 특징은 텍스쳐 분할에 아주 효과적이다. 거친(coarse) 스케일에서 영상 분할은 넓은 동종의 텍스쳐가 있는 영역에서는 분할 결과가 좋고, 섬세한(fine) 스케일에서 영상 분할은 텍스쳐들의 경계 영역에서 분할 결과가 좋다. 각 스케일에서의 영상 분할의 특성을 융합하여 좋은 텍스쳐 분할 결과를 얻을 수 있다. 이런 이유로 텍스쳐 분할에 다중 스케일 웨이블릿 영역에서의 영상 특징을 사용하는 HMT 모델을 이용하는 방법이 있다<sup>[15]</sup>.

HMT의 출력은 입력 특징의 우도 확률을 나타내므로, ML(Maximum Likelihood) 분류를 이용하여 감독 텍스쳐 분할을 행한다. HMT의 출력을 이용한 ML 분할은 HMT 모델이 정교하지 못하여 그다지 좋은 결과를 보여주지 못하며, 훈련에 있어서도 초기에 설정하는 파라메타의 영향이 크다. HMT 모델을 정교하게 하기 위한 확장된 형태의 HMT 모델은 모델이 복잡하고 많은 파라메타를 가지게 되어 훈련에 어려움이 생긴다. 그래서 HMT와 함께 다중 스케일 Bayesian 영상 분할 기법을 텍스쳐 분할에 이용하고 있다. 이 방법은 웨이블릿 영역의 거친 스케일에서 섬세한 스케일까지의 ML 분할 정보를 융합하여 최종의 가장 섬세한 스케일에서 영상 분할 결과를 개선한다. 그러나 다중 스케일

Bayesian 영상 분할 기법에 의한 영상 분할은 다중 스케일에서 ML 분할에 의존하여 영상 분할을 개선하므로, HMT 모델이 정교하지 못하여 다중 스케일에서의 ML 분할 결과가 좋지 못하면 좋은 텍스쳐 분할 결과를 보여주지 못한다.

신경회로망은 복잡한 방법의 모델링 없이도 입력 특징들의 임의 분포를 표현할 수 있다<sup>[16]</sup>. 다중 스케일 웨이블릿 영역에서의 영상 특징을 이용하여 신경회로망으로 텍스쳐 분할을 행하면 HMT처럼 초기 파라메타의 영향을 받는 현상 없이 정교한 모델링이 가능하여 우수한 성능을 보여 줄 수 있다. 여러 신경회로망들 중에서 SOM(Self Organization feature Map)은 비감독 훈련 모드(unsupervised training mode)에서 훈련을 한다. 한 텍스쳐 부류에 대하여 훈련된 SOM은 훈련 데이터의 대표 데이터(prototypes)를 형성한다. 한 부류의 SOM이 형성한 대표 데이터로부터 입력 데이터의 우도를 구할 수 있다.

본 논문에서는 다중 스케일 웨이블릿 영역에서의 영상 특징을 이용하여 SOM과 다중 스케일 Bayesian 영상 분할 기법에 의한 감독 텍스쳐 분할 방법을 제안한다. 본 논문에서는 첫 번째로 SOM을 이용하여 관측 데이터에 대한 우도와 사후확률(a posterior probability)을 구하는 방법을 제시하고, 이로부터 구한 사후확률과 MAP 분류법을 이용하여 텍스쳐 분할을 행하였다. SOM에 의한 MAP 분할은 HMT를 이용한 ML 분할보다 더 우수한 결과를 보여준다. 두 번째로 SOM에 의한 텍스쳐 분할의 개선을 위하여 문맥 정보를 이용하는 방법을 제시하고 그 효과를 보였다. 세 번째로 SOM의 출력을 이용한 다중 스케일에서의 MAP 분할에 HMTseg라고 불리는 다중 스케일 Bayesian 영상 분할 기법을 이용하여 최종의 가장 섬세한 스케일에서 영상 분할을 개선시켰고, 그 분할 성능은 HMT를 사용한 다중 스케일에서의 ML 분할에 HMTseg 알고리즘으로 최종의 가장 섬세한 스케일에서 영상 분할을 개선시킨 결과보다 더 우수하다.

II장에서는 영상의 웨이블릿 변환과 HMT 모델을 이용한 다중 스케일에서의 영상 분할에 대해 간단히 설명한다. III장에서는 SOM의 통계적 특성을 설명하고 본 논문에서 제시한 SOM으로부터의 우도와 사후확률을 구하는 방법을 설명하였다. IV장에서는 본 논문에서 제안한 SOM을 이용한 텍스쳐 분할에 대해 설명한다. V장은 분할 실험 및 결과에 대해 평가한다.

## II. Harr 웨이블릿 변환

Harr 웨이블릿 변환은 한 영상에 대하여 피라미드 형태를 가지는 다중 스케일 구조를 구성한다. Harr 웨이블릿 계수들은 4개의 웨이블릿 필터를 이용하여 구할 수 있는데, 그 4개의 웨이블릿 필터는 각각 국부 평탄화기( $h_{LL}$ ), 수평 에지 검출기( $g_{LH}$ ), 수직 에지 검출기( $g_{HL}$ ) 그리고 대각에지 검출기( $g_{HH}$ )의 역할을 한다. 입력 영상  $x$  ( $= u_J$ )를 Harr 웨이블릿 변환하면 근사화된 부영상  $u_{J-1}$ , 수평 에지 영상  $w_{J-1}^{LH}$ , 수직 에지 영상  $w_{J-1}^{HL}$ , 그리고 대각 에지 영상  $w_{J-1}^{HH}$  얻을 수 있고,  $u_{J-1}$  부영상에 대하여 동일한 과정을 반복함으로써 다단계의 Harr 웨이블릿 변환을 수행할 수 있다. 그림 1은 3단계의 Harr 웨이블릿 변환된 결과를 보이고 있다. 그림 1에서 볼 수 있듯이 거친 스케일에서의 웨이블릿 계수  $w_{J-3}^{HH}$ 는 섬세한 스케일에서 웨이블릿 계수 4개와 대응되며 이들 계수들과의 의존관계는 쿼드트리(quad tree; 4진 트리) 구조를 보인다.

영상의 같은 부 영역을 분석하는 다중 스케일 웨이블릿 계수들은 스케일 사이에 영속성을 가지고 있고, 그 상관관계는 쿼드트리의 부모와 자식간의 상호관계로 나타난다. 한 웨이블릿 부밴드의 웨이블릿 계수들의 상관관계를 그림 2에 나타내었는데, 그림에서 검은 점은 웨이블릿 계수를 나타내고 화살표는 웨이블릿 계수들의 영속성을 나타낸다.  $T_i$ 는  $i$ 번째 노드를 루트로 하는 부트리의 웨이블릿 계수들을 요소로 하는 벡터이다.

웨이블릿 계수들의 분포를 HMT라는 모델을 이용하여 모델링한 연구가 있다<sup>[19]</sup>. 웨이블릿 영역에서의 HMT 모델은 HMT 모델이 가진 은닉 상태에서의 평균

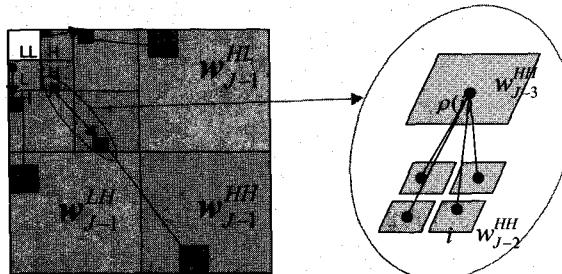


그림 1. Harr 웨이블릿 변환과 웨이블릿 계수들의 4 가지의 나무 구조

Fig. 1. Harr wavelet transform and quad tree structure of wavelet coefficients.

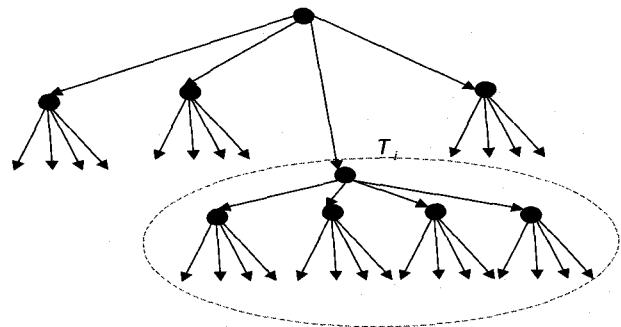


그림 2. 한 웨이블릿 부밴드에서 웨이블릿 계수들의 쿼드트리 구조와  $i$  번째 노드를 루트로 하는 부트리  $T_i$ 와 그 요소들.

Fig. 2. The quad tree structure of wavelet coefficients in a wavelet subband and subtree  $T_i$  rooted at node  $i$  and its elements.

과 분산, 그리고 은닉 상태들 사이의 상태 천이 확률로 결정이 된다. HMT 모델은 반복적인 Expectation Maximization (EM) 알고리즘을 이용하여 결정되는데, EM 알고리즘은 훈련데이터에 대하여 HMT 모델 파라메타들의 지역적인 최적 집합을 ML 관점에서 찾는다. 다중 스케일 웨이블릿 영역에서 HMT를 이용하면, 다중 스케일에서의 텍스쳐 분할을 얻을 수 있다<sup>[15]</sup>. 본 논문에서는 혼동의 여지가 없는 한 웨이블릿 스케일 ( $J, J-1, \dots$ ) 및 방향( $LH, HL, HH$ )을 나타내는 첨자를 생략한다.

## III. SOM의 통계적 특성과 사후학률

### 1. SOM의 훈련과 통계적 특성<sup>[17]</sup>

SOM은 자율(비감독 훈련)과 경쟁학습을 하는 신경회로망이다. SOM은 단일 층을 가지며 그 단일 층에 있는 뉴런 노드들은 2차원 배열 구조로 배치되어 있다. 단일 층위의 뉴런에는 입력 벡터와 차원이 같은 가중치 벡터가 연결되어 있다. SOM에 입력 벡터가 입력되면 입력 벡터와 어떤 기준(e.g. Euclidean distance)에서 가장 비슷한 가중치 벡터를 가지는 뉴런 노드가 반응하여 1의 출력을 내놓게 된다. 1의 출력을 내는 노드를 승자(wining) 노드라고 부른다. SOM의 2차원 배열 구조인 출력 층에서 승자 노드의 순서와 위치(승자 노드의 위치(topology))는 중요한 의미를 가진다. SOM의 학습은 훈련 벡터  $P(t)$ 에 대한 승자 노드  $i^*$ 와 이웃 노드(출력 층에서 위치상 승자 노드에 이웃하는 노드)들  $N_i(d)$ 에 대하여 다음 식과 구성된다.

$$\mathbf{W}_i(t) = \mathbf{W}_i(t-1) + \alpha(\mathbf{P}(t) - \mathbf{W}_i(t-1)) \quad (1)$$

여기서  $t$ 는 가중치의  $t$ 번째 갱신을 나타내며,  $\mathbf{W}_i$ 는  $i$  번째 뉴런에 연결된 가중치,  $\alpha$ 는 훈련비,  $\mathbf{P}(t)$ 는  $t$ 번째 훈련 벡터이다. 그리고  $i \in N_i(d)$ 이다. 이웃 노드들은  $N_i(d) = \{j, d_{ij} \leq d\}$  인데,  $d_{ij}$ 는 승자 노드  $i^*$ 와 출력 층의  $j$  노드 사이의 거리(출력 층에서 배치된 위치상의 거리)이다. 식 (1)에 의해 SOM을 반복적으로 학습하면 SOM의 가중치 벡터들은 훈련 벡터들의 대표(prototype) 벡터들이 된다. 승자 노드와 몇몇의 이웃 노드들의 가중치 벡터들은 동시에 훈련 벡터  $\mathbf{P}(t)$  방향으로 갱신되므로 식(1)에 의해 출력 층의 이웃 뉴런 노드들의 가중치 벡터들은 벡터 공간상에서 서로의 거리가 가까워진다. 즉, 출력 층에서 노드들의 위상은 벡터 공간에서 훈련 벡터들의 위상을 반영한다.

## 2. 훈련데이터로부터 분포 추정<sup>[16]</sup>

여기서는 훈련 데이터 또는 대표들로부터 데이터의 분포를 추정하는 방법을 보이고 이로부터 SOM을 이용한 분포 추정방법을 3.3절에서 제안하고자 한다.

샘플 벡터  $\mathbf{x}$ 가 벡터공간상의 영역  $R$ 에 존재할 확률  $P$ 는 다음과 같다.

$$P = \int_R p(\mathbf{x}') d\mathbf{x}' \quad (2)$$

$n$ 개의 샘플들  $\mathbf{x}_1, \dots, \mathbf{x}_n$ 을 독립적이고 중복되지 않게 분포하도록 (independently and identically distributed) 추출하였고 이들이 확률법칙  $p(\mathbf{x})$ 을 따른다고 가정하자. 그러면 이들  $n$ 개중에서  $k$ 개가 영역  $R$ 에 있을 확률은  $P$ 이다. 그리고 비  $k/n$ 은 확률  $P$ 을 위한 추정치가 된다. 만약  $p(\mathbf{x})$ 가 연속적인 값을 가지고 영역  $R$ 이 아주 작다면 다음과 같이 볼 수 있다.

$$P = \int_R p(\mathbf{x}') d\mathbf{x}' \approx p(\mathbf{x}) V \quad (3)$$

여기서  $\mathbf{x}$ 는 영역  $R$ 에 있는 한 샘플이며  $V$ 는 영역  $R$ 의 크기이다. 확률  $P$ 에 대한 추정치와 식 (2), (3)을 이용하여 확률법칙  $p(\mathbf{x})$ 는 다음과 같이 추정할 수 있다.

$$p(\mathbf{x}) \approx \frac{k/n}{V} \quad (4)$$

그러면 식 (4)를 이용하여 벡터  $\mathbf{x}$ 에서 확률밀도를 추정하기 위하여, 벡터  $\mathbf{x}$ 을 포함하는 영역들  $R_1, R_2, \dots,$

$R_n, \dots$ 을 형성할 수 있다. 첫 번째 영역  $R_1$ 은 샘플 하나를 포함하고 두 번째 영역  $R_2$ 은 샘플 두개를 포함하도록 설정하는 등의 작업을 계속하여 영역을 형성한다. 즉 벡터  $\mathbf{x}$ 를 중심으로 하나의 셀(cell)을 형성하고 그 셀이 샘플들을 하나씩 포함해 나가도록 확장할 수 있다. 셀에 포함된 샘플들은 벡터  $\mathbf{x}$ 에 가장 가까운 이웃 샘플들이다. 만약 벡터  $\mathbf{x}$  주위에 샘플들의 밀도가 높으면 셀의 크기는 상대적으로 작을 것이고, 벡터  $\mathbf{x}$  주위에 샘플들의 밀도가 낮으면 셀의 크기는 상대적으로 클 것이다.  $V_n$ 을 영역  $R_n$ 의 크기라고 하고  $k_n$ 은 영역  $R_n$  안에 있는 샘플들의 수라고 하면,  $p(\mathbf{x})$ 에 대한  $n$ 번째 추정치  $p_n(\mathbf{x})$ 는 다음과 같다.

$$p_n(\mathbf{x}) \approx \frac{k_n/n}{V_n} \quad (5)$$

추정치  $p_n(\mathbf{x})$ 이 확률밀도  $p(\mathbf{x})$ 에 수렴하려면, 다음의 3가지 조건이 요구된다.

$$\lim_{n \rightarrow \infty} V_n = 0, \quad \lim_{n \rightarrow \infty} k_n = \infty, \quad \lim_{n \rightarrow \infty} k_n/n = 0 \quad (6)$$

## 3. SOM을 이용한 사후확률의 추정

SOM의 학습을 다시 살펴보면 SOM은 훈련벡터공간에서 많은 훈련벡터들이 분포하는 영역을 인식하기 위해 많은 뉴런 노드들을 할당하고 훈련벡터들이 적게 분포하는 영역을 위해서는 적은 뉴런 노드들을 할당한다. 즉 SOM은 훈련벡터들의 분포를 학습하는 것이다. 또한 SOM은 훈련벡터들의 대표들을 형성하고 훈련데이터의 위상을 반영한다. SOM은 높은 차원의 훈련벡터를 2차원의 평면에 배열된 노드들 위로 투영하는 작용을 한다고 볼 수 있다.

$c$ 부류에 속하는 훈련벡터들만 이용하여 학습한 SOM으로부터 입력벡터  $\mathbf{x}$ 에 대한 우도를 다음과 같이 추정하는 것을 제안한다.

$$f(\mathbf{x}|c) \approx \frac{K/N}{V_N} = \frac{K/N}{\pi r_c(\mathbf{x})^2} \quad (7)$$

여기서  $c \in \{1, 2, \dots, N_c\}$ ,  $K$ 는 입력  $\mathbf{x}$ 에 가장 가까운 이웃 가중치벡터들의 개수,  $N$ 은 SOM의 출력층에 있는 모든 노드들의 개수,  $V_N$ 은 입력  $\mathbf{x}$ 와  $K$ 개의 노드들에 연결된 가중치들 사이에서 가장 먼 거리  $r_c(\mathbf{x})$ 을 반지름으로 하는 원이다.  $K$ 의 값은  $N$ 의 함수로써 결정되도록 할 수 있을 것이지만, 본 연구에서는 상수로

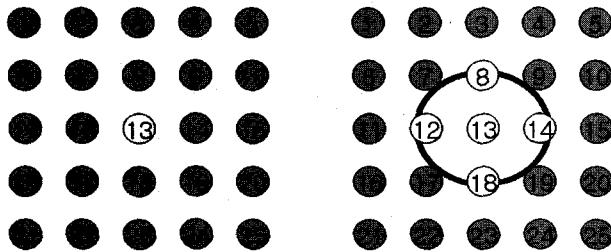


그림 3.  $d$ 의 값에 따른  $N_i(d)$ 의 요소들, (a) $N_i(0)$  (b)  $N_i(1)$

Fig. 3. Elements in  $N_i(d)$  according to the value of  $d$ , (a) $N_i(0)$  (b)  $N_i(1)$ .

설정하였다. 상수로 설정한  $K$ 의 값을 입력  $\mathbf{x}$ 에 대한 SOM의 승자 노드와 그 이웃 노드들  $N_i(d)$ 의 개수를 의미한다. 즉  $d = 0$ 이면  $K = 1$ ,  $d = 1$ 이면  $K = 5$  인 것을 그림 3을 보면 알 수 있다. 그리고  $K$ 의 값이 주어지면 입력  $\mathbf{x}$ 와  $N_i(d)$ 의 노드들로부터  $r_c(\mathbf{x})$ 을 구할 수가 있다. SOM으로부터 우도를 보다 정확하게 추정하는데 있어서, SOM의 규모와 훈련데이터 개수 등에 의존하는 적절한  $K$ 가 존재한다고 볼 수 있다. 또한, 본 논문에서는 SOM으로부터 사후확률을 추정하는 방법을 다음 식과 같이 제안한다.

$$f(c|\mathbf{x}) = \frac{f(x|c)p(c)}{\sum_{c=1}^{N_c} f(x|c)p(c)} \approx \frac{1/r_c(\mathbf{x})^2}{\sum_{c=1}^{N_c} 1/r_c(\mathbf{x})^2} \quad (8)$$

여기서 모든 부류들의 발생빈도  $p(c)$ 는 동일하다고 가정하였다. 식 (8)에 의한 MAP 분류법은 다음과 같다.

$$\begin{aligned} \hat{c}^{MAP} &\equiv \arg \max_{c \in \{1, 2, \dots, N_c\}} \frac{1/r_c(\mathbf{x})^2}{\sum_{c=1}^{N_c} 1/r_c(\mathbf{x})^2} \\ &= \arg \max_{c \in \{1, 2, \dots, N_c\}} 1/r_c(\mathbf{x})^2 \\ &= \arg \min_{c \in \{1, 2, \dots, N_c\}} r_c(\mathbf{x}) \end{aligned} \quad (9)$$

식 (9)을 살펴보면,  $K = 1$ 로 설정했을 때, SOM으로부터 구한 사후확률을 사용하는 MAP 분류에 의한 부류는 입력  $\mathbf{x}$ 와 입력  $\mathbf{x}$ 에 대한 각 부류 SOM의 승자 노드에 연결된 가중치벡터사이의 거리들 중에서 최소 거리를 나타내는 SOM이 속하는 부류를 의미한다.

#### IV. SOM을 이용한 텍스쳐 분할

SOM에 의한 다중 스케일 웨이블릿 영역에서의 사후

확률을 텍스쳐 영상 분할에 이용하는 방법을 제안한다. 제안한 시스템에서는 다중 스케일 웨이블릿 영역에서의 사후 확률을 구하기 위하여, 웨이블릿의 각 스케일 당 하나씩의 SOM을 구성하였다. 그리고 각 텍스쳐 부류 당 하나씩의 SOM을 구성하였다.

##### 1. SOM의 입력 벡터

다중 스케일 웨이블릿 계수들의 각 스케일 간의 의존 관계 특징을 이용하여 입력벡터를 결정하였다. 즉, 스케일간의 의존관계가 그림 1과 같은 큐드트리 구조임을 이용하여 입력 벡터를 결정하였다. 한 웨이블릿 부밴드의  $i$ 번째 위치에 대한 SOM의 입력으로 그림 2에서 나타낸 웨이블릿 부나무  $T_i$ 에 있는 모든 계수들을 사용한다. 또한  $i$ 번째 노드가 분석하는 부 영상 영역의 픽셀들의 밝기 값들도 SOM의 입력으로 사용한다. 웨이블릿 부밴드들의 계수들을 모두 고려하여 다음 식처럼 SOM의 입력 벡터를 정한다.

$$\mathbf{g}_i = \{T_i^{HL}, T_i^{LH}, T_i^{HH}, \mathbf{p}_i\} \quad (10)$$

여기서  $\mathbf{g}_i$ 는 웨이블릿 부나무  $T_i$ 에서 분석하는 부 영상 영역에 대한 SOM의 입력 벡터이며,  $T_i^{HL}$ ,  $T_i^{LH}$ ,  $T_i^{HH}$ 는 각 웨이블릿 부 밴드들에서 같은  $i$ 번째 노드의 위치를 루트로 하는 웨이블릿 부나무들의 웨이블릿 계수들로 구성된 벡터들이고,  $\mathbf{p}_i$ 는  $i$ 번째 노드가 분석하는 부 영상 영역의 화소들의 밝기 값들로 구성된 벡터이다.

##### 2. SOM을 이용한 다중 스케일에서의 텍스쳐 분할

웨이블릿 변환의  $j$ 스케일에서 입력 벡터  $\mathbf{g}_i$ 의 분류법은 다음과 같다.

$$\begin{aligned} \hat{c} &= \arg \max_{c \in \{1, 2, \dots, N_c\}} f(c|\mathbf{g}_i) \\ &= \arg \max_{c \in \{1, 2, \dots, N_c\}} \frac{1/r_c^j(\mathbf{g}_i)^2}{\sum_{c=1}^{N_c} 1/r_c^j(\mathbf{g}_i)^2} \end{aligned} \quad (11)$$

여기서  $r_c^j(\mathbf{g}_i)$ 는  $c$ 부류에 대한 스케일  $j$ 의 SOM으로부터 입력  $\mathbf{g}_i$ 에 대해 식(7)에서처럼 구한 거리이다. 본 연구에서는 거리의 척도는 유clidean 거리를 사용하였다. 보다 정확한 사후확률을 추정하는  $K$ 의 값을 훈련 데이터의 개수와 SOM의 규모에 따라 적절하게 설정됨이 필요하다. 최적의  $K$ 값을 설정하고

SOM으로 텍스쳐 분할을 행하면, 최상의 텍스쳐 분할 성능을 보일 것이다. 본 연구에서는  $K$ 의 값에 따라 SOM을 이용한 텍스쳐 분할의 성능 변화를 실험하였다. 식 (11)을 이용하여 다중 스케일에서의 영상 분할을 얻는다.

### 3. 문맥 정보 이용한 SOM에 의한 텍스쳐 분할 개선

웨이블릿 큐드트리의 한 노드에 대한 텍스쳐 분류를 위하여 영상의 문맥 정보를 이용하면 다중 스케일에서의 분할 결과들을 더 개선시킬 수 있다. 문맥 정보로 써는 한 노드 주위의 이웃 노드들의 정보를 이용하거나, 부모 노드와 그 이웃 노드들의 정보까지도 이용할 수 있다. 문맥 정보는 그림 4에서 보인 것처럼 웨이블릿 큐드트리의 노드  $i$ 에 대한 문맥을 노드  $i$  주위의 8개의 이웃들과 노드  $i$ 의 부모 노드  $\rho(i)$ 와 부모 노드 주위의 8개의 이웃들을 고려할 수 있다. 문맥 요소를 고려한 사후확률을 다음 식과 같이 구한다.

$$f(c_i|\mathcal{D}_i) = \frac{f(\mathcal{D}_i|c_i)}{f(\mathcal{D}_i)} p(c_i) \quad (12)$$

여기서  $c_i$ 는 웨이블릿 큐드트리의  $i$ 번째 노드의 부류,  $\mathcal{D}_i = \{\mathbf{g}_i, \mathcal{D}_{N_i}, \mathbf{g}_{\rho(i)}, \mathcal{D}_{N_{\rho(i)}}\}$ 는 웨이블릿 큐드트리의 노드  $i$ 에서 문맥을 고려한 관측 테이터이다. 그리고  $\mathcal{D}_{N_i} = \{\mathbf{g}_{N_{i,1}}, \mathbf{g}_{N_{i,2}}, \dots, \mathbf{g}_{N_{i,8}}\}$ 는 노드  $i$  주위의 8개의 이웃 노드들에서 관측 테이터이다. 또한  $\mathcal{D}_{N_{\rho(i)}} = \{\mathbf{g}_{N_{\rho(i),1}}, \mathbf{g}_{N_{\rho(i),2}}, \dots, \mathbf{g}_{N_{\rho(i),8}}\}$ 는 부모 노드  $\rho(i)$  주위의 8개의 이웃 노드들에서 관측 테이터이다. 한 스케일내의 웨이블릿 계수가 독립적이고 모든 부류들의 발생빈도가 동일하다고 가정하면, 식 (12)는 다음과 같이 전개할 수 있다.

$$\begin{aligned} f(c_i|\mathcal{D}_i) &= \frac{f(\mathbf{g}_i|c_i)}{f(\mathbf{g}_i)} \frac{f(\mathcal{D}_{N_i}|c_i)}{f(\mathcal{D}_{N_i})} \frac{f(\mathbf{g}_{\rho(i)}|c_i)}{f(\mathbf{g}_{\rho(i)})} \frac{f(\mathcal{D}_{N_{\rho(i)}}|c_i)}{f(\mathcal{D}_{N_{\rho(i)}})} p(c_i) \\ &\propto \frac{f(\mathbf{g}_i|c_i)}{f(\mathbf{g}_i)} \frac{f(\mathcal{D}_{N_i}|c_i)}{f(\mathcal{D}_{N_i})} \frac{f(\mathbf{g}_{\rho(i)}|c_{\rho(i)})}{f(\mathbf{g}_{\rho(i)})} \frac{f(\mathcal{D}_{N_{\rho(i)}}|c_{\rho(i)})}{f(\mathcal{D}_{N_{\rho(i)}})} \end{aligned} \quad (13)$$

$$(즉, \frac{f(\mathcal{D}_{N_i}|c_i)}{f(\mathcal{D}_{N_i})} = \prod_{l=1}^8 \frac{f(\mathbf{g}_{N_{i,l}}|c_i)}{f(\mathbf{g}_{N_{i,l}})} \propto \prod_{l=1}^8 \frac{1/r_{c_i}(\mathbf{g}_{N_{i,l}})^2}{\sum_{c_i=1}^{N_c} 1/r_{c_i}(\mathbf{g}_{N_{i,l}})^2})$$

$$\frac{f(\mathcal{D}_{N_{\rho(i)}}|c_{\rho(i)})}{f(\mathcal{D}_{N_{\rho(i)}})} = \prod_{l=1}^8 \frac{f(\mathbf{g}_{N_{\rho(i),l}}|c_{\rho(i)})}{f(\mathbf{g}_{N_{\rho(i),l}})} \propto \prod_{l=1}^8 \frac{1/r_{c_{\rho(i)}}(\mathbf{g}_{N_{\rho(i),l}})^2}{\sum_{c_{\rho(i)}=1}^{N_c} 1/r_{c_{\rho(i)}}(\mathbf{g}_{N_{\rho(i),l}})^2})$$

문맥 정보를 위해 부모 노드를 사용하지 않고 한 스케일 내에서만 고려한다면(즉,  $\mathcal{D}_i = \{\mathbf{g}_i, \mathcal{D}_{N_i}\}$ ), 식 (12)를 다시 식 (14)와 같이 전개할 수 있다.

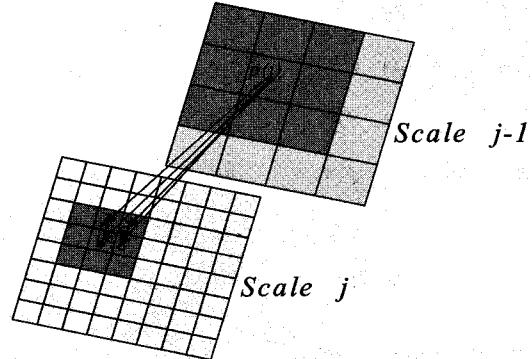


그림 4. 웨이블릿 큐드트리의 스케일  $j$ 에서 노드  $i$ 에 대한 문맥 고려

Fig. 4. The consideration of contexts for node  $i$  in scale  $j$  of a subband wavelet quad tree.

$$f(c_i|\mathcal{D}_i) = \frac{f(\mathbf{g}_i|c_i)}{f(\mathbf{g}_i)} \frac{f(\mathcal{D}_{N_i}|c_i)}{f(\mathcal{D}_{N_i})} \quad (14)$$

식 (12)과 다음 식을 이용하여 다중 스케일에서의 영상 분할을 얻는다.

$$\hat{c}_i \equiv \arg \max_{c_i \in \{1, 2, \dots, N_c\}} f(c_i|\mathcal{D}_i) \quad (15)$$

### 4. 다중 스케일에서 SOM과 다중 스케일 Bayesian 영상 분할 기법을 이용한 텍스쳐 분할

다중 스케일에서의 영상 분할은 스케일에 따라서 신뢰도와 정밀도 사이의 모순 관계가 존재한다. 거친 스케일에서 영상 분할은 넓은 동종의 텍스쳐가 있는 영역에서는 결과가 좋지만 텍스쳐들의 경계 영역에서의 분할 결과는 좋지 못하며, 섬세한 스케일에서 영상 분할은 텍스쳐들의 경계 영역에서 세밀한 분할 결과를 보이지만 대체로 분할 결과가 좋지 못하다. 따라서 다중 스케일에서 분할 결과들을 융합하여 최종의 섬세한 스케일에서 좋은 분할 결과를 얻을 수 있다. HMT에 의한 다중 스케일에서 우도들과 영상 분할을 결합하는 HMTseg라는 다중 스케일 Bayesian 분할 알고리즘을 사용하여 가장 섬세한 스케일의 텍스쳐 분할을 개선시킨 연구가 있다<sup>[15]</sup>. [15]에서 HMTseg 알고리즘은 각 스케일 간에 분할 정보를 융합하기 위하여 웨이블릿 큐드트리의  $i$ 번째 노드의 부모 노드와 부모의 이웃 노드들에서의 부류 정보를 담은 벡터  $\mathbf{v}_i$ 를 정의하고 다음 식과 같이 벡터  $\mathbf{v}_i$ 를 고려한 사후확률  $f(c_i|\mathbf{d}_i, \mathbf{v}_i)$ 을 구하여, MAP 분류법에 의해 분할을 행한다.

$$f(c_i|\mathbf{d}_i, \mathbf{v}_i) \propto f(\mathbf{d}_i|c_i)p(c_i|\mathbf{v}_i) \quad (16)$$

여기서  $c_i$ 는 웨이블릿 큐드트리의  $i$ 번째 노드의 부류를 나타내며,  $\mathbf{d}_i$ 는  $i$ 번째 노드에서의 관측 데이터이다.

따라서 본 논문에서는 SOM을 이용한 다중 스케일에서의 분할 결과들을 융합하여 최종의 섬세한 스케일에서의 개선된 분할 결과를 얻기 위하여, 다중 스케일 영상 분할 기법 중에 하나인 HMTseg 알고리즘을 사용한다. HMTseg 알고리즘을 적용하기 위하여 식 (16)을 다음과 같이 변형하여 적용한다.

$$\begin{aligned} f(c_i|\mathbf{d}_i, \mathbf{v}_i) &\propto f(\mathbf{d}_i|c_i)p(c_i|\mathbf{v}_i) \\ &= \frac{f(c_i|\mathbf{d}_i)f(\mathbf{d}_i)}{p(c_i)}p(c_i|\mathbf{v}_i) \quad (17) \\ &\propto f(c_i|\mathbf{d}_i)p(c_i|\mathbf{v}_i) \end{aligned}$$

식 (17)을 SOM으로부터의 사후확률을 이용하여 다시 쓰면 식 (18)과 같이 된다.

$$\begin{aligned} f(c_i|\mathbf{g}_i, \mathbf{v}_i) &\propto f(c_i|\mathbf{g}_i)p(c_i|\mathbf{v}_i) \\ (\text{또는}, f(c_i|\mathbf{D}_i, \mathbf{v}_i) &\propto f(c_i|\mathbf{D}_i)p(c_i|\mathbf{v}_i)) \quad (18) \end{aligned}$$

식 (18)으로부터 다음 식과 같이 Bayes 분류를 적용하여 MAP 분할을 얻는다.

$$\begin{aligned} \hat{c}_i^{MAP} &\equiv \arg \max_{c_i \in \{1, 2, \dots, N_c\}} f(c_i|\mathbf{g}_i, \mathbf{v}_i) \\ (\text{또는}, \hat{c}_i^{MAP} &\equiv \arg \max_{c_i \in \{1, 2, \dots, N_c\}} f(c_i|\mathbf{D}_i, \mathbf{v}_i)) \quad (19) \end{aligned}$$

HMTseg 알고리즘은 거친 스케일에서부터 시작하여 각 스케일에서의 MAP 분할 결과들을 차례로 융합하여 최종의 섬세한 스케일에서의 개선된 분할을 구한다.

## V. 텍스쳐 분할 실험 및 결과

본 논문에서는 16개의 Brodatz 텍스쳐 영상을 실험에 사용하였다. 16개의 텍스쳐 영상에서 훈련 데이터를 얻기 위하여, 하나의  $512 \times 512$  텍스쳐 영상에서 임의 위치 선택을 10번하여 얻은 10개의  $64 \times 64$  크기의 텍스쳐 영상들을 다중 웨이블릿 변환(3단계의 웨이블릿 변환)하여 텍스쳐 영상의 특징을 추출하였다. HMT를 이용한 시스템 및 제안한 시스템들의 텍스쳐 분할 능력을 비교하기 위하여 위의 방법으로 확보한 훈련 데이터를 각 시스템들의 훈련에 똑같이 사용하였다. HMT 훈련은 지능적인 초기 파라메타 설정 방법<sup>[18]</sup>을 이용한 EM 알고리즘을 사용하였다. 그리고 SOM의 단일 출력층에

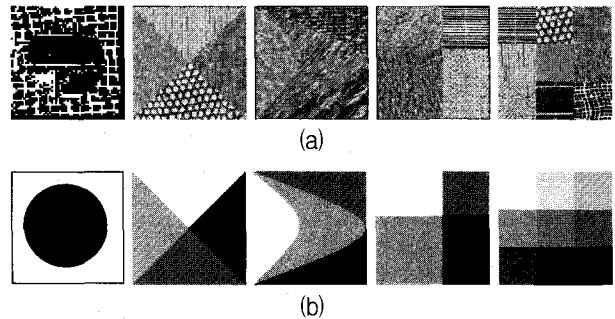


그림 5. (a) 테스트 텍스쳐 영상들과 (b) 이상적인 텍스쳐 분할

Fig. 5. (a) test texture images and (b)ideal texture segmentation.

있는 뉴런들을  $7 \times 7$  평면 사각 구조로 배열하였으며, 입력 벡터와 뉴런 가중치사이의 거리는 유clidean의 거리를 사용하였다. 실험에 쓰인 테스트 영상들은 그림 5에 나타내었다.

$K$ 의 값에 따른 SOM에 의한 텍스쳐 분할 성능의 비교를 위하여 그림 6에서 (b)는  $K=1$ , (c)는  $K=5$ 인 SOM을 이용한 텍스쳐 분할 결과를 보인다. 비교를 위하여 (a)는 HMT에 의한 텍스쳐 분할 결과를 보였다. 그림 6의 (a), (b), (c), 그리고 (d)에 각각 두 행의 그림들 중에서 첫 행은 HMTseg 알고리즘을 적용하기 전의 각 텍스쳐 분할 방법에 의한 다중 스케일에서의 텍스쳐 분할을 나타내고, 두 번째 행은 첫 행의 결과에 HMTseg 알고리즘을 적용한 결과이다. 또한 (a), (b), (c), 그리고 (d)의 각각에 있는 두 행의 그림들은 좌측부터 우측까지 거친 스케일에서 섬세한 스케일까지의 다중 스케일에서의 텍스쳐 분할을 나타낸다. 최 좌측 거친 스케일에서의 스케일을  $j=3$ 이라고 하면, 차례로 섬세한 스케일로 갈수록 스케일이 하나씩 증가한다. 스케일  $j=3$ 에서  $j=5$ 까지는 웨이블릿 영역의 각 스케일에서 구한 텍스쳐 분할이고, 최 우측의 스케일( $j=6$ )은 웨이블릿 계수가 아닌, 화소의 밝기(그레이 스케일)를 영상의 특징으로 사용하여 구한 텍스쳐 분할이다. HMT 모델은 웨이블릿 영역에서만 사용이 가능하므로 그림 6의 (a)의 경우, 첫 행의 가장 오른쪽 텍스쳐 분할은 HMT 모델이 아닌 가우스 혼합 모델<sup>[15]</sup>을 이용하여 ML 분할이 행하여 졌고, 그 결과를 보였다.

그림 6의 (a)와 (b)를 비교해보면,  $K=1$ 을 사용한 SOM에 의한 분할 결과가 HMT에 의한 분할 결과보다 웨이블릿의 전 스케일에 걸쳐 더 좋다. 이것은 SOM이 HMT에 비해 보다 정교하게 웨이블릿 계수들의 분포를 나타냄을 보여 주는 것이다. 그러나 화소 단위 영역에

서 가우스 혼합 모델을 이용한 텍스쳐 분할은  $K=1$ 을 사용한 SOM에 의한 텍스쳐 분할보다 좀 더 좋은 듯하다. 비록 HMTseg 알고리즘에 의해 HMT에 의한 ML 분할이 개선되었지만, HMTseg에 의한 영상 분할은 HMT에 의한 다중 스케일에서의 우도값에 의존한다. 그러므로 HMT에 의한 다중 스케일에서의 ML 분할이 좋지 못하면 HMTseg에 의한 영상 분할도 우수한 결과를 기대할 수 없다. 실제로 HMT 모델은 섬세한 스케일에서 웨이블릿 계수의 분포를 아주 정교하게는 표현하지 못하고 훈련 시에 초기 파라미터 값에 의존하는 경향이 크다. 또한 HMT의 모델을 정교하게 하는 것은 HMT 모델의 구조를 복잡하게 만들고 모델의 파라미터를 증가시킨다. 증가한 파라미터는 많은 훈련 데이터를 요구하게 되며 훈련 데이터가 충분하지 못하면 분류의 능력이 떨어지게 된다. SOM을 이용한 다중 스케일에서의 텍스쳐 분할에 HMTseg 알고리즘을 적용한 텍스쳐 분할 결과는 HMT에 의한 텍스쳐 분할에 HMTseg를 적용한 텍스쳐 분할 결과에 비해 훨씬 뛰어나다. 이는 HMTseg를 적용하기 전의 SOM에 의한 다중 스케일에서의 분할 결과가 화소 단위 영역을 제외한 모든 스케일 영역에서 HMT 보다 뛰어나므로, 각 스케일의 분할 정보를 융합한 후에 최종 화소 단위 영역에서의 분할 결과가 우수한 것이다.

SOM에서 적절한  $K$ 값은 최상의 분할 성능을 보일 것이다. 그림 6의 (b)와 (c)에서  $K=1$ 과  $K=5$ 인 경우에 첫 행의 텍스쳐 분할을 비교해 보면,  $K=1$ 인 경우가 웨이블릿 영역에서(스케일  $j=3, 4, 5$ )의 텍스쳐 분할 성능이 뛰어나고,  $K=5$ 인 경우는 화소 단위 영역에서(스케일  $j=6$ )의 텍스쳐 분할 성능이 뛰어나다. 그리고  $K=5$ 인 경우는 (a)의 첫 행에 가우스 혼합 모델에 의한 결과보다 텍스쳐 분할 성능이 뛰어나다. 섬세한 스케일의 화소 단위 영역에서는 거친 스케일의 웨이블릿 영역에서 보다 훈련데이터의 개수가 많고 잡음의 영향을 많이 받는다. 훈련데이터의 개수가 많을 때  $K$ 의 값을 증가시키면 분포 추정의 신뢰성을 증가시켜 잡음의 영향을 줄이는 효과가 있으므로, 화소 단위 영역에서는  $K=5$ 인 경우가 분할 성능이 좋다. 그러나 훈련데이터의 개수가 적은 웨이블릿 영역에서는  $K$ 값의 증가는 오히려 분포 추정에 있어서 신뢰성을 떨어뜨리는 것을 볼 수 있다.  $K$ 의 값의 증가는 데이터가 분포하는 공간상에서 분포 추정을 위한 영역  $R$ 을 증가시키는 결과를 가져오는데, 데이터의 개수가 적을 때는 영역  $R$ 의 증가가 크므로 분포 추정의 정확성을 떨어뜨린다(식 (4), (5), 그리고 (6)을

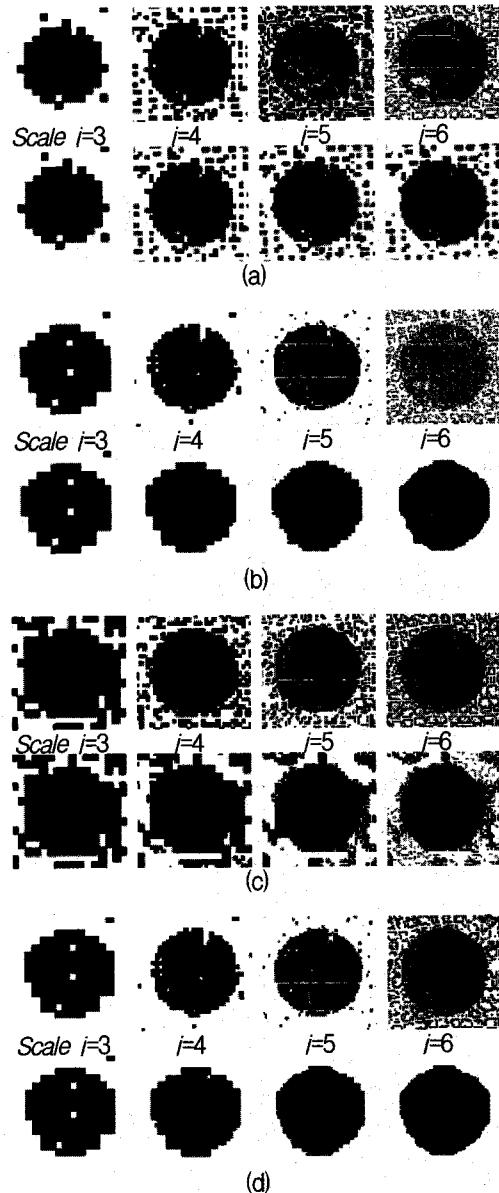


그림 6. 각 텍스쳐 분할 방법에 의한 다중 스케일에서의 텍스쳐 영상 분할과, HMTseg 알고리즘을 적용한 결과들, (a)첫 행: HMT 이용, 둘째 행: HMTseg를 적용, (b)첫 행:  $K=1$ 인 SOM 이용, 둘째 행: HMTseg를 적용, (c)첫 행:  $K=5$ 인 SOM 이용, 둘째 행: HMTseg를 적용, (d)첫 행: 스케일마다 다른  $K$ 값을 가진 SOM 이용(왼쪽부터 차례로  $K$ 는 1, 1, 1, 그리고 5의 값을 가진다.), 둘째 행: HMTseg를 적용.

Fig. 6. Multi-scale texture segmentations by each method, and post-processed results by HMTseg, (a)first row: by HMT, second row: by HMTseg, (b)first row: by SOM with  $K=1$ , second row: by HMTseg, (c)first row: by SOM with  $K=5$ , second row: by HMTseg, (d)first row: by SOM with different values of  $K$  according to each scale ( $K=1, 1, 1$ , and  $5$  from the left to the right of figures), second row: by HMTseg.

참고하라).

그러므로 스케일마다 다른 적절한  $K$ 값을 사용한 SOM을 이용하면 좋은 분할 성능을 얻을 수 있다. 참고로, 그림 6의 (c)에서 HMTseg를 적용한 후인 두 번째 행의 텍스쳐 분할 결과가 좋지 않은 것은 HMTseg를 적용하기 전인 첫 번째 행에서 보듯이 거친 스케일에서 부적절한  $K$ 값을 설정한 SOM에 의한 텍스쳐 분할들이 좋지 않아 HMTseg를 적용한 후에도 결과가 나쁜 것이다. 그림 6의 (d)는 스케일에 따라 다른  $K$ 값을 설정한 SOM을 이용한 텍스쳐 분할을 보였다. (d)에 첫 행의 그림들은 왼쪽부터 차례로  $K=1, 1, 1$ , 그리고 5의 값을 설정한 SOM으로부터 구한 각 스케일에서의 텍스쳐 분할들이다. (d)의 화소 영역에서의 텍스쳐 분할은 (b)의  $K=1$ 로만 설정한 SOM에 비해 결과가 좋으므로, HMTseg를 적용한 후에 (d)의 텍스쳐 분할이 (b)보다 조금 더 좋은 것을 볼 수 있다.

텍스쳐 분할에 있어서 영상의 문맥 정보를 이용하는 SOM의 효과를 보여주는 실험 결과를 그림 7에 보였다. 그림 7은 그림 6과 같은 방식으로 각 스케일별 텍스쳐 분할과 HMTseg를 적용한 후의 결과를 배치하였다. 그림 7-(a)는 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려한 경우에 SOM에 의한 텍스쳐 분할이다. 그림 6-(b)의 첫 행의 분할 그림들에서 보듯이 섬세한 스케일로 갈수록 분류 윈도우의 크기가 작아 분류에 이용할 정보량이 적고 그로 인해 분할 결과가 좋지 않으며 국소적인 노이즈에 의해 영향을 많이 받는 것을 볼 수 있다. 이해 비해 그림 7-(a)의 첫 행의 분할 그림들은 주위의 이웃 문맥 정보를 이용함으로서 섬세한 스케일에서 국소적인 노이즈에 영향을 덜 받은 분할 결과를 보인다. 그림 7-(a)에서 보면 거친 스케일에서 보다 섬세한 스케일에서의 문맥 고려 효과가 더 큼을 볼 수 있다. 특히, HMTseg를 적용하기 전 가장 섬세한 스케일인 화소 영역에서의 텍스쳐 분할 결과가 매우 좋은 것을 볼 수 있다. HMTseg를 적용하기 전의 텍스쳐 분할 결과가 좋으므로 그림 7-(a)의 두 번째 행의 텍스쳐 분할 결과가 좋다. 그림 7-(b)는 문맥 정보  $D_i = \{g_i, D_{N_i}\}$ 를 고려한 경우인데, 그림 7-(a)에서 HMTseg를 적용하기 전의 텍스쳐 분할 결과보다는 그림 7-(b)의 첫 행의 텍스쳐 분할 결과가 좋지 않지만, HMTseg를 적용한 후의 최종 화소 영역에서 텍스쳐 분할 결과에 있어서 그림 7의 (a)와 (b)가 별 차이가 없음을 볼 수 있다. 이것은 HMTseg 알고리즘이 스케일 간의 분류 정보를 융합

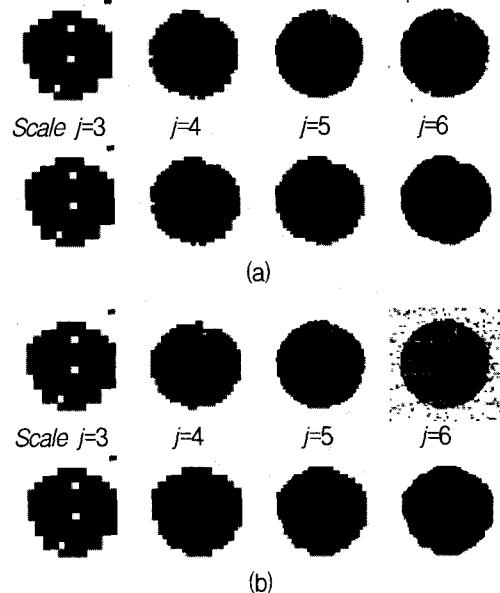


그림 7. 문맥 정보를 이용한 SOM에 의한 다중 스케일에서의 텍스쳐 분할과, HMTseg 알고리즘을 적용한 결과들, (a) 첫 행: 왼쪽부터 차례로  $K$ 가 1, 1, 1, 그리고 5인 SOM을 이용하고, 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려, 둘째 행: HMTseg를 적용, (b) 첫 행: 왼쪽부터 차례로  $K$ 가 1, 1, 1, 그리고 5인 SOM을 이용하고, 문맥 정보  $D_i = \{g_i, D_{N_i}\}$ 를 고려, 둘째 행: HMTseg 적용.

Fig. 7. Multi-scale texture segmentation by SOM with considering context information, and post-processed results by HMTseg, (a) first row: by SOM with considering context information  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$  and using  $K=1, 1, 1$ , and 5 from the left to the right of figures, second row: by HMTseg, (b) first row: by SOM with considering context information  $D_i = \{g_i, D_{N_i}\}$  and using  $K=1, 1, 1$ , and 5 from the left to the right of figures, second row: by HMTseg.

하는 방법 때문에 나타나는 현상으로 보인다. HMTseg 알고리즘은 웨이블릿 큐드트리의 한 노드의 분류를 위하여 부모 노드와 부모의 이웃 노드의 정보를 이용하는 방법으로 스케일간의 분류 정보를 융합하는데, SOM에서 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 사용하면 부모 노드에서의 문맥 정보를 고려하는 효과가 HMTseg 알고리즘과 중복된다. 그렇지만 부모 노드 주위의 이웃을 고려하는 범위에 있어서, HMTseg의 적용 전에 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려하면 HMTseg를 적용하는 과정에서는 부모 노드 주위의 24개의 이웃 노드 정보를 고려하게 되며, HMTseg를 적

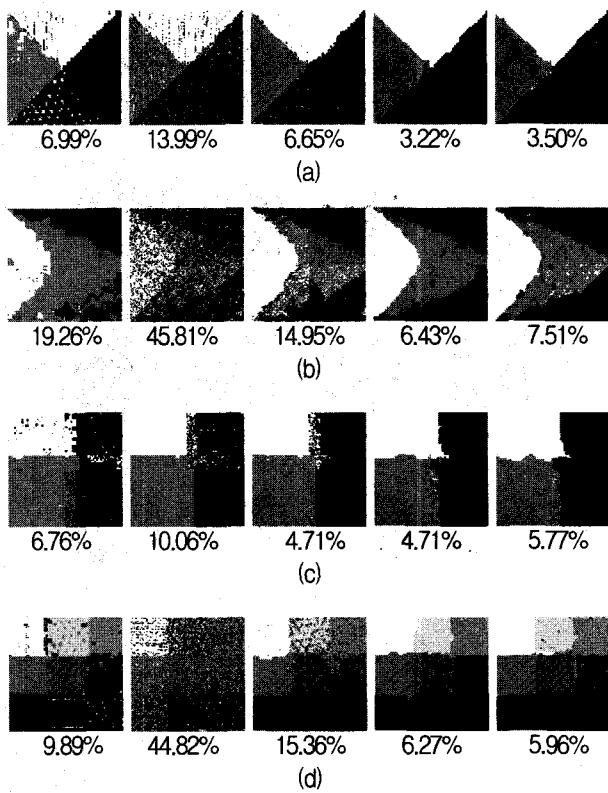


그림 8. 각 텍스쳐 분할 방법과 HMTseg에 의한 텍스쳐 분할 결과와 에러율, (a) 첫 열: HMT와 HMTseg, 둘째 열: K=1인 SOM과 HMTseg, 셋째 열: 거친 스케일에서 섬세한 스케일까지 K=1,1,1, 그리고 5인 SOM과 HMTseg, 넷째 열: 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려하고, K=1,1,1, 그리고 5인 SOM과 HMTseg, 다섯째 열: 문맥 정보  $D_i = \{g_i, D_{N_i}\}$ 를 고려하고, K=1,1,1, 그리고 5인 SOM과 HMTseg, (b) (a)와 동일, (c) (a)와 동일, (d) (a)와 동일.

Fig. 8. Texture segmentation results and error rates by each segmentation method and HMTseg, (a) first column: by HMT and HMTseg, second column: by SOM with K=1, and HMTseg, third column: by SOM with K=1,1,1, and 5 from coarse scales and fine scales, and HMTseg, fourth column: by SOM with considering context information  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$  and using K=1, 1, 1, and 5, and HMTseg, fifth column: by SOM with considering context information  $D_i = \{g_i, D_{N_i}\}$  and using K=1, 1, 1, and 5, and HMTseg, (b) the same methods as (a), (c) the same methods as (a), (d) the same methods as (a).

용하기 전에 문맥 정보  $D_i = \{g_i, D_{N_i}\}$ 를 고려하면 HMTseg를 적용하는 과정에서는 부모 노드 주위의 8개의 이웃 노드 정보를 사용하게 된다. SOM에서 문맥 정보로서 그림 7-(a)와 같이 고려하는 것이 좋은지, 그림

7-(b)와 같이 고려하는 것이 좋은지는 텍스쳐 패턴에 의존 할 것이다.

다른 테스트 텍스쳐 영상에 대한 텍스쳐 분할 결과들은 그림 8에 있다. 그림 8은 각 텍스쳐 분할 방법을 사용하여 최종의 가장 섬세한 스케일인 화소 단위에서 분할한 결과를 보인다. 그리고 각 분할 결과의 그림 아래에 그림 5-(b)의 이상적인 분할과 각 분할 결과와의 에러율을 표시하였다. 에러율은 영상의 전체 화소 개수와 텍스쳐 분류에 에러를 발생한 화소 개수와의 비를 나타낸다. 그림 8에서 사용한 텍스쳐 분할 방법을 왼쪽 열부터 오른쪽 열까지 차례로 살펴보면, 첫 번째 열은 HMT와 HMTseg를 사용한 방법, 두 번째 열은 K=1을 사용한 SOM과 HMTseg를 사용한 방법, 세 번째 열은 그림 6의 (d)에서처럼 각 스케일마다 다른 K값을 사용한 SOM(가장 거친 스케일에서부터 가장 섬세한 스케일까지 차례로 K=1,1,1, 그리고 5이다.)과 HMTseg를 사용한 방법, 네 번째 열은 그림 7-(a)에서처럼 세 번째 열에서 사용한 SOM으로 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려하여 분할을 행하고 HMTseg를 사용한 방법을 이용하였다.

그림 8의 결과에서 4가지의 텍스쳐를 분할하는 그림 (a), (b)와 (c)의 경우를 보자. 각 스케일에 동일한 K=1을 사용한 SOM(두 번째 열의 결과)에 의한 결과를 제외하면, 제안한 방법으로 SOM을 이용한 것이 HMT보다 성능이 좋은 것을 볼 수 있다. 그런데, 그림 8-(d)의 경우는 각 스케일마다 다른 K값을 사용한 SOM(세 번째 열의 결과)에 의한 결과가 HMT보다 성능이 좋지 않게 나타났다. 이는 텍스쳐의 부류가 많아지면 7x7 크기의 SOM이 화소 단위(가장 섬세한 스케일)에서 가우스 혼합 모델에 비해 잡음의 영향을 다소 많이 받기 때문으로 보인다. 그러나 문맥을 고려하여 잡음의 영향을 줄인 SOM의 경우는 여전히 HMT보다 성능이 좋다. 그림 8의 두 번째 열과 세 번째 열의 그림들을 비교해 보면 각 스케일마다 적당한 K값을 사용한 SOM에 의한 텍스쳐 분할 결과가 동일한 K=1을 사용한 SOM에 비해 뛰어남을 볼 수 있다. 그리고 제안한 방법으로 문맥 정보를 고려하여 보다 섬세한 영역에서 잡음의 영향을 줄이면 상당한 텍스쳐 분할 성능 개선을 보인다. 그런데 그림 8-(c)와 같이 문맥 정보를 고려하지 않은 SOM

에 의한 결과가 뛰어난 텍스트 영상의 경우 오히려 문맥 정보를 고려하는 것이 텍스쳐 분할 성능을 감소한다. 이는 문맥 정보를 고려하면 텍스쳐 분할 경계치에서 예리가 심해지기 때문으로 보인다. 문맥 정보  $D_i = \{g_i, D_{N_i}, g_{\rho(i)}, D_{N_{\rho(i)}}\}$ 를 고려한 것이 문맥 정보  $D_i = \{g_i, D_{N_i}\}$ 를 고려한 것보다 논문에 사용한 테스트 영상에서 성능이 좋게 나타났다.

## VI. 결 론

다중 스케일 웨이블릿 계수를 텍스쳐 영상의 특징으로 이용하여 SOM과 다중 스케일 Bayesian 영상 분할 기법을 사용한 텍스쳐 분할 방법을 제안하였다. 또한 SOM으로부터 사후확률을 획득하는 방법을 제안하였다. SOM에서  $K=1$ 로서 MAP 분류를 행할 경우는 입력벡터와 입력벡터에 대한 각 부류 SOM의 승자 노드에 연결된 가중치벡터사이의 거리를 중에서 최소 거리를 나타내는 SOM이 속하는 부류로 분류하는 것이다. 이는 사후확률의 개념을 생각하지 않은 일반적인 SOM의 사용방법과 같은 것이다. 제안한 방법에 의한 텍스쳐 분할은 같은 텍스쳐 영상을 이용하여 HMT 모델과 HMTseg 알고리즘을 사용한 텍스쳐 분할에 비해 뛰어난 텍스쳐 분할 결과를 보였다. 이것은 HMT 모델에 비해 SOM이 웨이블릿 계수들의 특징 분류에 있어서 일반화 능력이 뛰어나고 텍스쳐 영상의 웨이블릿 계수들의 분포를 잘 표현함을 보여준다. 즉, 다중 스케일 Bayesian 영상 분할 기법으로써 사용한 HMTseg 알고리즘의 성능은 이 알고리즘을 적용하기 전의 다중 스케일에서의 분할 결과에 의존하는데, 시뮬레이션 결과에서 보면 다중 스케일에서 SOM에 의한 텍스쳐 분할 결과가 뛰어나므로 SOM을 사용한 텍스쳐 분할에 대해 HMTseg를 적용한 결과는 HMT를 사용한 텍스쳐 분할에 대해 HMTseg를 적용한 결과에 비해 월등히 뛰어나다.

SOM으로부터 사후확률을 추정함에 있어서, 훈련 데이터 공간상에 분포 추정 영역을 증가시키는  $K$ 값 증가는 훈련 데이터의 개수가 많을수록 사후 확률의 추정을 보다 정확하게 하는 효과를 보인다. 그러므로 다중 스케일의 각 SOM 모듈에 대하여, 훈련데이터의 개수를 고려하여 각 스케일마다 다른  $K$ 값을 설정함으로써 텍스쳐 분할 성능의 개선 효과를 얻었다.

SOM에서 사후확률을 추정할 때 문맥 정보를 이용하

는 방법을 제안하였으며, 제안한 방법으로 문맥 정보를 이용한 것이 보다 개선된 영상 분할 성능을 나타내었다.

## 참 고 문 헌

- [1] R. M. Haralick., "Statistical and Structural Approaches to Texture," *Proc. IEEE* 67, no. 5, pp. 786-809, May 1979.
- [2] T. R. Reed and H.J.M. du Buf, "A Review of Recent Texture segmentation and Feature Extraction Techniques," *CVGIP: Image Understanding*, vol. 57, no. 3, pp. 359-372, 1993.
- [3] P. C. Chen and T. Pavlidis, "Segmentation by Texture Using a Co-Occurrence Matrix and a Split-and-Merge Algorithm," *Computer Graphics and Image Processing*, vol. 10, pp. 172-182, 1979.
- [4] C. H. Chen and L. F. Pau, P. S. P. Wang(eds.), "The Handbook of Pattern Recognition and Computer Vision (2nd Edition)," World Scientific Publishing Co., pp. 207-248, 1998.
- [5] Tuceryan, M., "Moment Based Texture Segmentation," in *Proc. of 11th international Conf. on Pattern Recognition*, The Hague, Netherlands, August 1992.
- [6] Jain, A. K. and F. Farrokhnia, "Unsupervised Texture Segmentation Using Gabor Filters," *Pattern Recognition*, 24, pp. 1167-1186, 1991.
- [7] Tuceryan, M. and A. K. Jain, "Texture Segmentation Using Voronoi Polygons," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-12, pp. 211-216, 1990.
- [8] Voorhees, H. and T. Poggio, "Detecting textons and texture boundaries in natural images," In *Proc. of the first international Conf. on Computer Vision*, pp. 250-258, London, 1987.
- [9] Eom, Kie-Bum and R. L. Kashyap, "Texture and Intensity Edge Detection with Random Field Models," In *Proc. of the Workshop on Computer Vision*, pp. 29-34, Miami Beach, FL, 1987.
- [10] Du Buf, J. M. H. Kardan and M. Spann, "Texture Feature Performance for Image Segmentation," *Pattern Recognition*, 23, pp. 291-309, 1990.
- [11] Besag, J., "Spatial Interaction and the Statistical Analysis of Lattice Systems," *Journal of Royal Statistical Society*, B-36, pp. 344-348, 1974.
- [12] H. Derin and W. S. Cole, "Segmentation of Textured Images Using Gibbs Random Fields," *Computer Vision, Graphics, and Image*

- Processing*, vol. 35, pp. 72-98, 1986.
- [13] R. Hu and M. M. Fahmy, "Texture Segmentation Based on a Hierarchical Markov Random Field Model," *Signal Processing*, vol. 26, pp. 285-305, 1992.
- [14] Jain, A. K. and F. Farrokhnia, "Unsupervised Texture Segmentation Using Gabor Filters," *Pattern Recognition*, 24, pp. 1167-1186, 1991.
- [15] Hyeokho Choi and Richard G. Baraniuk, "Multiscale Image Segmentation Using Wavelet-Domain Hidden Markov Models," *IEEE Transaction on image processing*, vol. 10, NO. 9, September 2001.
- [16] Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification," A Wiley Interscience publication, second edition, pp.161-192.
- [17] Howard Demuth, Mark Beale, "Neural Network Toolbox For Use with MATLAB," The MathWorks, Inc., User's Guide Version 4, pp.277-298
- [18] Guoliang Fan and Xiang-Gen Xia, "Improved Hidden Markov Models in the Wavelet-Domain", *IEEE Transaction on signal processsing*, vol. 49, NO. 1, January 2001.
- [19] Guoliang Fan and Xiang-Gen Xia, "Wavelet-Based Texture Analysis and Synthesis Using Hidden Markov Models", *IEEE Transaction on circuits and systems*, vol. 50, NO. 1, January 2003.

## 저자 소개



김 태 형(학생회원)  
 1997년 부산대학교 전자공학과  
 학사.  
 1999년 부산대학교 전자공학과  
 석사.  
 2001년 부산대학교 전자공학과  
 박사과정 수료.  
 1999년~현재 부산대학교 전자공학과 박사과정  
 <주관심분야 : 영상처리, 음성처리, 신호처리, 신  
 경회로망>



이 일 규(정회원)  
 1990년 부산대학교 전자공학과  
 학사.  
 1992년 부산대학교 전자공학과  
 석사.  
 1998년 부산대학교 전자공학과  
 박사.  
 1997년~현재 밀양대학교 정보통신학과 부교수  
 <주관심분야 : 통계신호처리, 영상처리, 웨이블릿  
 변환 신호처리, 신경회로망>



김 유 신(정회원)  
 1974년 서울대학교 전자공학과  
 학사.  
 1980년 U.C. Berkeley 전자공학과  
 석사.  
 1983년 Standford University  
 전자재료 박사과정 수학.  
 1995년 Cornell University Ph.D  
 1983년~현재 부산대학교 전자공학과 교수  
 2005년 현재 한국 과학철학회 회장  
 <주관심분야 : 영상처리, 신경회로망, 공학윤리,  
 과학기술철학>