

논문 2007-44SP-1-5

다중 퍼셉트론과 마코프 랜덤 필드 모델을 이용한 베이지안 결 분할

(Bayesian Texture Segmentation Using Multi-layer Perceptron and
Markov Random Field Model)

김 태 형*, 엄 일 규*, 김 유 신**

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

요 약

이 논문은 다중 스케일 베이지안 관점에서 다중 퍼셉트론과 마코프 랜덤 필드를 사용한 새로운 결 분할 방법을 제안한다. 다중 퍼셉트론의 출력은 사후 확률을 모델링하므로 본 논문에서는 다중 스케일 웨이블릿 계수들을 다중 퍼셉트론의 입력으로 사용한다. 다중 퍼셉트론으로부터 구한 사후 확률과 MAP (maximum *a posterior*) 분류를 이용하여 각 스케일에서 결 분류를 수행한다. 또한 가장 섬세한 스케일에서 더 개선된 분할 결과를 얻기 위하여 모든 스케일에서 MAP 분류 결과들을 거친 스케일에서 섬세한 스케일까지 차례로 융합한다. 이런 과정은 한 스케일에서의 분류 정보와 그 인접한 보다 거친 스케일에서 얻어지는 문맥과 관련한 연역적 정보를 이용하여 MAP 분류를 행함으로써 이루어진다. 이 융합 과정에서, MRF (Markov random fields) 사전 모델이 평탄화 제한자로서 동작하고, 깁스 샘플러 (Gibbs sampler)는 MAP 분류기로서 동작한다. 제안한 분할 방법은 HMT (Hidden Markov Trees) 모델과 HMTseg 알고리즘을 이용한 결 분할 방법보다 더 좋은 성능을 보인다.

Abstract

This paper presents a novel texture segmentation method using multilayer perceptron (MLP) networks and Markov random fields in multiscale Bayesian framework. Multiscale wavelet coefficients are used as input for the neural networks. The output of the neural network is modeled as *a posterior* probability. Texture classification at each scale is performed by the posterior probabilities from MLP networks and MAP (maximum *a posterior*) classification. Then, in order to obtain the more improved segmentation result at the finest scale, our proposed method fuses the multiscale MAP classifications sequentially from coarse to fine scales. This process is done by computing the MAP classification given the classification at one scale and *a priori* knowledge regarding contextual information which is extracted from the adjacent coarser scale classification. In this fusion process, the MRF (Markov random field) prior distribution and Gibbs sampler are used, where the MRF model serves as the smoothness constraint and the Gibbs sampler acts as the MAP classifier. The proposed segmentation method shows better performance than texture segmentation using the HMT (Hidden Markov trees) model and HMTseg.

Keywords : Texture segmentation, Multiscale Bayesian framework, Neural Networks,
Markov random fields, Gibbs sampler

I. 서 론

* 학생회원, 부산대학교 전자공학과

(Dept. of Electronics Eng., Pusan Univ.)

** 정회원, 부산대학교 컴퓨터및정보통신연구소

(Dept. of Electronics Eng., Pusan Univ.)

※ 이 논문은 부산대학교 자유과제 학술연구비(2년)에 의하여 연구되었음.

접수일자: 2006년4월19일, 수정완료일: 2006년12월28일

영상 분할에서 베이지안 접근 방법은 영상 특징의 통계적 모델과 사전 문맥 정보를 결합하는 자연적인 틀을 제공한다^[10]. 사람이 영상을 분할하여 인식할 때, 먼저 넓은 영역의 정보를 이용하여 넓고 균질한 영역을 분할

하고, 그 다음 분할의 경계지 영역에서 좁은 영역의 정보를 이용하여 세밀하게 경계를 구분한다. 이러한 이유로 다중 스케일에서 영상의 처리 방법이 사용되고 있다^[11,12]. 또한 위의 두 가지 방법을 결합한 다중 스케일 베이저안 접근 방법이 결 분할에 많이 이용되고 있다^[5,10,12].

인간이 다중스케일로 영상을 분할한다는 것과 인간의 뇌가 영상을 주파수별로 분석한다는 정신 물리학의 연구 결과에 부합하는 결 영상의 특징 추출 방법은 다중 스케일 이산 웨이블릿 변환에 의한 것이 있다^[11]. 다중 스케일에서의 영상 영역 변환을 이용한 영상 특징은 영상의 전역적 정보와 지역적 정보를 동시에 이용할 수 있게 한다. 거친(coarse) 스케일에서 영상 분할은 넓은 동종의 결이 있는 영역에서 분할 결과가 좋고, 섬세한(fine) 스케일에서 영상 분할은 결들의 경계 영역에서 분할 결과가 좋다. 그러므로 각 스케일에서의 영상 분할의 특성을 융합하여 좋은 결 분할 결과를 얻을 수 있다. 따라서 다중 스케일 웨이블릿 영역에서의 영상 특징을 사용하는 HMT(hidden Markov trees) 모델과 함께 HMTseg라고 불리는 다중 스케일 베이저안 영상 분할 기술을 결 분할에 이용하기도 했다^[5]. 이 외에도 이산 웨이블릿 변환에 의한 영상의 특징 추출은 결 영상의 다양한 응용 분야에 많이 이용되고 있다^[5,6,13,14,15,16]. 웨이블릿 기반에서 신경회로망과 HMTseg 알고리즘을 이용한 결 분할 방법이 제시되기도 하였으며^[6] Kohonen 신경회로망이나 퍼지 c-means 알고리즘을 웨이블릿 변환으로부터 추출한 특징들과 함께 결 분할에 이용하기도 하였다^[17,18]. 또한 결 분할에 서포터 벡터 머신(support vector machines)과 신경회로망을 이용하는 접근 방법이 연구되기도 하였다^[4]. 신경회로망은 복잡한 방법의 모델링 없이도 입력 특징들의 임의 분포를 표현할 수 있기 때문에^[1,2] 지도자 훈련 모드(supervised training mode)에서 훈련한 신경회로망의 출력이 사후 확률을 나타내도록 망을 구성할 수 있으며^[1,2,3], 그 신경회로망 출력 값으로 MAP 분류를 행할 수가 있다.

따라서 본 논문에서는 다중 스케일 베이저안 관점에서 다중 스케일 웨이블릿 영역에서의 영상 특징을 기반으로, 다중 퍼셉트론과 MRF (Markov random fields)를 사용한 결 분할 방법을 제안한다. 다중 퍼셉트론의 입력으로는 쿼드 트리(quad tree) 구조를 가지는 다중 스케일 웨이블릿 계수들을 사용하고, 다중 퍼셉트론의 출력값으로 결의 MAP 분할을 행한다. 다중 퍼셉트론에 의한 MAP 분할은 HMT를 이용한 ML 분할보다 더

우수한 결과를 보여준다^[6]. 그러나 분류 오류에 의한 노이즈는 분명히 분할 결과에 나쁜 영향을 미친다. 본 논문에서 제안한 방법은 지역적) 평탄화 제한자(smoothness constraint)로서 MRF 사전(prior) 모델을 사용하여, 분류 오류에 의한 노이즈를 감소시킨다. 그리고 다중 퍼셉트론으로부터 각 스케일의 MAP 분할들을 거친 스케일에서 섬세한 스케일까지 차례로 융합한다. 그리하여 최종의 가장 섬세한 스케일에서 가장 개선된 분할 결과를 얻는다.

이러한 융합 과정은 한 스케일에서의 분류 정보와 그 인접한 보다 거친 스케일에서 얻어지는 문맥과 관련된 연역적 정보(a priori knowledge)를 이용하여 MAP 분류를 행함으로써 이루어진다. 여기서 Gibbs 샘플러는 MRF 평탄화 사전 모델과 신경 회로망으로부터의 각 스케일의 MAP 분할, 그리고 인접한 보다 거친 스케일에서 얻어지는 문맥 정보를 통합하는 역할을 하며, 하나의 MAP 분류기로서 동작한다. 제안한 방법에 의한 결 분할은 HMT 모델과 HMTseg 알고리즘^[5]을 이용한 결 분할보다 더 뛰어난 성능을 보여준다. 또한 제안한 다중 스케일의 분할을 융합하는 방법은 HMTseg 보다 더 좋은 성능을 보인다.

본 논문의 구성은 다음과 같다. II장에서는 다중 퍼셉트론의 구조 및 입출력 관계를 설명하고, MRF 모델과 Gibbs 샘플러를 이용한 다중 스케일 결 분할에 대하여 III장에서 논의한다. IV장에서 실험 결과를 살펴보고, V장에서 결론을 맺는다.

II. 다중 퍼셉트론의 구조 및 입력과 출력

1. Haar 웨이블릿 계수와 다중 퍼셉트론의 입력

본 논문에서 사용될 다중 퍼셉트론의 입력 벡터는 다단계 Haar 웨이블릿 변환으로부터 구하여진 다중 스케일 웨이블릿 계수들로 구성된다. Haar 웨이블릿 변환의 각 단계에서, 즉 각 스케일에서, 각기 다른 해상도의 영상들이 형성되는데, $s=0$ 스케일을 실험 영상에 웨이블릿 변환이 적용하기 전이라고 하면, 스케일 $s=0$ 은 실험 영상의 화소 단위 해상도를 갖는다. 그리고 1단계의 웨이블릿 변환을 적용하면, 스케일 $s=1$ 에서 실험 영상의 해상도에 비해 2×2 블록의 해상도($1/2$ 의 해상도)를 갖는 영상이 형성된다. 다단계의 웨이블릿 변환을 적용하면서 스케일 $s=(0, 1, \dots, S-1)$ 에 따라 순서대로 화소 단위, 2×2 블록, $2^2 \times 2^2$ 블록, $2^{S-1} \times 2^{S-1}$ 블록의 해상도 영상이 형성된다.




그림 1. (a) 3단계 Harr 웨이블릿 변환과 웨이블릿 계수들의 쿼드 트리 구조, (b) 한 웨이블릿 부 밴드에서 웨이블릿 계수들의 쿼드 트리 구조와 i 번째 노드를 루트로 하는 부 트리 T_i 와 그 요소들

Fig. 1. (a) The three-level Harr wavelet transform and the quad-tree structure of the wavelet coefficients, (b) The quad-tree structure of the wavelet coefficients in a wavelet sub-band and sub-tree T_i rooted at node i and its elements.

그림 1-(a)는 3단계의 Haar 웨이블릿 변환의 경우를 보여준다. 한 영상의 공통 부 영역을 분석하는 다중 스케일 웨이블릿 계수들은 스케일 간에 연속성을 가진다. 그림 3-(b)에서처럼, 이들 계수들 간의 의존성은 웨이블릿 쿼드 트리(quad tree)의 자식과 부모 노드 사이의 의존성으로 표현될 수 있다. 그림 3-(b)에서 하나의 검정 노드는 하나의 웨이블릿 계수를 나타내고, T_i 는 위치 i (노드 i)를 뿌리로 하는 하나의 부 트리(subtree)이다. 본 논문에서 혼동을 일으키지 않는다면, 스케일 인덱스 s 와 웨이블릿 부 밴드의 방향 표시 (LH, HL, HH)를 생략할 것이다.

본 논문에서 다층 퍼셉트론의 입력 벡터는 스케일 간 웨이블릿 계수들의 의존성(연속성)을 고려하여 결정된다. 다층 퍼셉트론 입력을 위한 웨이블릿 부 트리 계수들(그림 1-(b) 참고)은 웨이블릿 부 밴드의 통계적 의존성을 고려하여 수평, 수직 및 대각 방향 부트리 T_i^{LH} , T_i^{HL} 및 T_i^{HH} 로 구성된다. 즉, $T_i = \{T_i^{LH}, T_i^{HL}, T_i^{HH}\}$ 로 구성된다. 그리고 노드 i 에 대응하는 영상 화소들의 밝기 값(그레이 값)들을 웨이블릿 쿼드 트리의 노드 i 에 대한 신경 회로망의 입력으로 사용하였다. 3개의 웨이블릿 부 밴드 쿼드 트리들의 노드 i 에 위치한 모든 트리를 고려하여, 신경 회로망의 입력 벡터 g_i 는 다음과 같이 정의된다.

$$g_i = \{T_i, p_i\} \quad (1)$$

여기서 p_i 는 노드 i 에 대응되는 부 영상 화소들의 밝기 값이다. 트리 T_i 를 구성하는 각 부 밴드의 부 트리들은

영상의 공통된 영역을 분석하는 웨이블릿 계수들을 담고 있다. g_i 의 구성 요소들 중에서 웨이블릿 계수들은 단지 2×2 블록 해상도 영상에서 까지만, 즉 스케일 $s=1$ 까지만 존재한다. 스케일 $s=0$ 에서 입력 벡터 g_i 는 단지 p_i 만 가지고 T_i 는 가지지 않는다.

2. 다층 퍼셉트론의 훈련 및 출력

다층 퍼셉트론은 사후 확률을 추정하도록 출력과 입력 구조를 구성할 수 있다^[1,2,3]. 본 논문에서는 각 스케일 당 한 그룹의 다층 퍼셉트론을 구성한다. 그리고 각 스케일에서 각 결 부류 당 하나의 다층 퍼셉트론을 할당한다. 만약 웨이블릿 변환을 L 단계까지 수행하고 결 부류의 수가 C 라면, 다층 퍼셉트론의 수는 $(L+1) \times C$ 개가 된다. 결 부류 c ($c \in \{1, 2, \dots, C\}$)의 다층 퍼셉트론에 대하여, 노드 i 에 대응하는 입력 벡터의 훈련을 위한 목표 출력 값 t_i 은 다음과 같이 설정한다. 즉,

$$t_i = \begin{cases} 1, & g_i \in c \\ 0, & g_i \notin c \end{cases} \quad (2)$$

본 논문에서는 다층 퍼셉트론의 훈련을 위하여 resilient 역전파 방법^[19]을 사용하였다. Resilient 역전파 알고리즘은 패턴 인식 문제에서 다른 여러 훈련 알고리즘에 비해 가장 빠른 훈련 속도를 가지며, 알고리즘을 위한 메모리 요구도 상대적으로 적다^[20].

3. 다층 퍼셉트론에 의한 각 스케일에서의 결 분할

다층 퍼셉트론의 훈련 후 각 스케일에서의 분할 결과를 얻기 위해서 본 논문에서는 다음과 같은 분류법을 사용한다. 다층 퍼셉트론에 의한 결의 부류 \hat{c} 은 입력 벡터 및 가중치 벡터로 구성되는 다층 퍼셉트론의 출력으로 구할 수 있다.

$$\hat{c} = \arg \max_{c \in \{1, 2, \dots, C\}} \frac{N(g_i, w_c)}{\sum_{k=1}^C N(g_i, w_k)} \quad (3)$$

여기서 $N(g_i, w_c)$ 는 노드 i 에 대한 입력 g_i 와 각 부류 c 에 대한 가중치 벡터 w_c 로 구성되는 다층 퍼셉트론의 출력을 나타낸다. 식 (3)을 이용하여 다중 스케일에서 결 분할 결과들을 얻을 수 있다. 식 (3)에 의한 결 분할은 스케일에 따라서 신뢰도와 정밀도 사이의 모순 관계가 존재한다. 따라서 본 논문에서는 식 (3)에 의한 결 분할들을 인접한 보다 거친 스케일에서 얻어지는 문맥

과 관련한 연역적 정보와 Gibbs 샘플러를 이용하여 융합하고, 최종의 가장 섬세한 스케일에서 가장 개선된 분할 결과를 얻을 수 있는 방법을 제안하고자 한다.

III. MRF 모델과 Gibbs 샘플러를 사용한 다중 스케일 베이저안 결 분할

영상 화소들의 부류 레이블들이 MRF 또는, 등가적으로, Gibbs 분포로 모델링 되어왔다^[7,8,9]. Gibbs 샘플러는 MRF 모델의 파라미터를 추정하거나 MRF 결 모델로부터 결을 합성해내는 결 합성기로 이용되고 있다^[8].

본 논문의 다중 퍼셉트론에 의한 초기의 결 분할 결과들은 분류 오류에 의한 잡음을 가진다. 이 장에서는 MRF 평탄화 사전 모델에 의한 잡음의 감소 방법을 제안한다. 또한 인접한 보다 거친 스케일에서 얻어지는 문맥 정보를 담은 문맥 벡터 v 를 정의하고 스케일 간의 결 분할 융합 과정 및 Gibbs 샘플러에 의한 MAP 분류 방법을 제안한다.

1. 랜덤 필드와 부류 라벨의 배열

결 영상의 화소들 또는 블록들은 하나의 이차원 격자를 형성한다. 크기 $n \times n$ 의 이차원 격자위의 위치들의 집합을 $M = \{i | 1 \leq i \leq m, m = n \times n\}$ 이라 하고, 부류 라벨의 집합을 $L = \{1, 2, \dots, C\}$ 이라고 하자. 만약 위치 $i \in M$ 에 라벨 f_i 가 할당된다고 한다면, 집합 $f = \{f_1, \dots, f_m\}$ 는 라벨 집합 L 에 의한 M 안의 위치들의 라벨링이라고 부를 수 있다. 결 분할은 격자 M 위의 각 위치들에 부류 라벨을 할당하는 라벨링 문제이다. 이것은 다시 각 위치에 유일한 한 가지 부류 라벨만 할당하는 매핑 문제이다. 결국 결 분할은 영상 격자 M 위에 최적의 부류 라벨의 배열을 구하는 것이다.

2. 문맥 벡터 v 와 스케일 간의 결 분할 융합

그림 1에서 보았듯이, 웨이블릿 영역에서 부모 노드와 4개의 자식 노드사이에는 의존성이 존재한다. 따라서 부모 노드의 부류 정보가 자식 노드의 부류 결정을 인도해 줄 수 있다. 부모 노드에 부가하여 부모 노드의 이웃 노드의 부류 정보도 자식 노드의 부류 결정에 이용할 수 있다. 한 스케일에 있는 영상 블록들이 형성한 격자 위에 위치 i 는 웨이블릿 쿼드 트리의 노드 i 에 해당한다. 스케일 s 의 위치 i 를 위한 문맥 벡터 v_i^s 를 다음과 같이 정의할 수 있다.

$$v_i^s \equiv [c_{\rho(i)}^{s+1}, c_{N1_{\rho(i)}}^{s+1}, c_{N2_{\rho(i)}}^{s+1}, \dots, c_{N7_{\rho(i)}}^{s+1}, c_{N8_{\rho(i)}}^{s+1}] \quad (4)$$

여기서 $c_{\rho(i)}^{s+1}$ 는 위치 i 에 대한 부모 위치 $\rho(i)$ 의 부류 라벨, $[c_{N1_{\rho(i)}}^{s+1}, c_{N2_{\rho(i)}}^{s+1}, \dots, c_{N7_{\rho(i)}}^{s+1}, c_{N8_{\rho(i)}}^{s+1}]$ 는 부모 위치 $\rho(i)$ 의 8개의 이웃 위치들의 부류 라벨들이다. 그러면, 스케일 s 에서 문맥 벡터의 배열은 $v^s = \{v_i^s | i \in M^s\}$ 로 표현된다. 여기서 v^s 는 그 전의 거친 스케일 $s+1$ 에서의 MAP 분류 정보를 담고 있다. c^s 를 스케일 s 의 격자 위에 부류 라벨들의 배열이라 하고, $G^s = \{g_i^s | i \in M^s\}$ 라 할 때 사후 확률 $p(c^s | G^s, v^s)$ 를 고려해 보자. 배열 c^s 가 주어진 조건에서 G^s 와 v^s 가 통계적으로 독립적이라고 가정하면, 사후 확률 $p(c^s | G^s, v^s)$ 은 나이브 베이저안 규칙(naive Bayes rule)^[21]을 이용하여 $p(c^s | G^s, v^s) = p(c^s | G^s)p(c^s | v^s)$ 로 표현할 수 있다. 나이브 베이저안 규칙은 단순함에도 불구하고 실제적인 문제에 잘 동작한다. 따라서 결 분할은 다음과 같이 최적의 배열 c^* 를 다음과 같이 구함으로써 수행된다.

$$\begin{aligned} c^* &= \arg \max_{c^s \in \Theta^s} p(c^s | G^s, v^s) \\ &= \arg \max_{c^s \in \Theta^s} \{p(c^s | G^s)p(c^s | v^s)\} \end{aligned} \quad (5)$$

여기서 Θ^s 는 스케일 s 에서 배열 공간(스케일 s 의 격자 위의 위치들에 할당 가능한 모든 배열들의 집합)이다. 확률 $p(c^s | G^s)$ 는 분할을 위하여 스케일 s 의 모든 g_i^s 로부터 획득할 수 있는 정보를 가진다. 그리고 확률 $p(c^s | v^s)$ 는 그 전 거친 스케일 $s+1$ 로부터 추출한 모든 문맥 벡터들로부터 획득할 수 있는 정보를 가진다. 식 (5)를 이용함으로써 스케일 s 에서 스케일간의 분할 결정 융합을 행할 수가 있다.

3. 다중 스케일 결 분할 융합을 위한 각 인자들과 Gibbs 샘플러에 의한 MAP 분류

식 (5)는 베이저안 법칙을 이용하여 다음과 같이 표현 될 수 있다. 즉,

$$\begin{aligned} c^* &= \arg \max_{c^s \in \Theta^s} \{p(c^s | G^s)p(c^s | v^s)\} \\ &= \arg \max_{c^s \in \Theta^s} \{p(c^s | G^s)p(v^s | c^s)p(c^s)\} \end{aligned} \quad (6)$$

식 (6)에서 $p(c^s | v^s)$ 는 부류 라벨들의 스케일 사이의

Begin

Step 1 : 다층 퍼셉트론으로부터 모든 $i \in M^s$ 과 $c_i^s \in L$ 에 대하여 $p(c_i^s | \mathbf{g}^s)$ 를 구함;

Step 2 : $p(c_i^s | \mathbf{g}^s)$ 와 MAP 분류식 (3)를 이용하여 배열 c^s 를 초기화;

Step 3 : 모든 $i \in M^s$ 에 대하여

3.1 만약 스케일 s 가 가장 초기의 거친 스케일이면, 모든 $l \in L$ 에 대하여

$$p_l = p(c_i^s = l | \mathbf{g}^s) p(v_i^s | c_i^s = l) p(c_i^s = l | c_{N_i}^s) \text{ 계산};$$

3.2 만약 스케일 s 가 가장 초기의 거친 스케일이 아니면, 모든 $l \in L$ 에 대하여

$$p_l = p(c_i^s = l | \mathbf{g}^s) p(c_i^s = l | c_{N_i}^s) \text{ 을 계산};$$

3.3 가장 최대의 값을 가지는 p_l 에 따라 c_i^s 를 부류 라벨 l 로 설정하라;

Step 4 : N 번 동안 또는 수렴할 때까지 Step 3을 반복;

End

그림 2. 스케일 s 에서 Gibbs 샘플러를 사용한 MAP 결 분할

Fig. 2. MAP segmentation at scale s using Gibbs sampler.

의존 정도를 나타낸다. 배열 c^s 가 주어진 조건에서, 모든 v_i^s 가 독립적이고 각 v_i^s 는 $k \neq i$ 인 모든 다른 c_k^s 와 v_k^s 에 독립적으로 분포 $p(v_i^s | c_i^s)$ 에 따라 분포한다고 가정하면, 식 (6)의 $p(\mathbf{v}^s | \mathbf{c}^s)$ 은 다음과 같이 다시 표현할 수 있다.

$$p(\mathbf{v}^s | \mathbf{c}^s) = \prod_{i \in M^s} p(v_i^s | c_i^s) \quad (7)$$

본 논문에서 $p(v_i^s | c_i^s)$ 는 다음과 같이 결정한다.

$$p(v_i^s | c_i^s) \equiv \frac{\delta_{c_i^s, c_{p(i)}^{s+1}} + \delta_{c_i^s, c_{N1_{p(i)}}^{s+1}} + \delta_{c_i^s, c_{N2_{p(i)}}^{s+1}} + \dots + \delta_{c_i^s, c_{N8_{p(i)}}^{s+1}}}{9} \quad (8)$$

여기서 $\delta_{m,n}$ 은 Kronecker delta 함수이다. 식 (6)의 $p(\mathbf{c}^s)$ 는 MRF 모델로서 다음과 같이 모델링한다.

$$p(\mathbf{c}^s) = \prod_{i \in M^s} p(c_i^s | c_{N_i}^s) \quad (9)$$

여기서 $c_{N_i}^s$ 은 위치 i 의 이웃 위치들의 부류 라벨 배치 (배열)를 나타낸다. 이 MRF 사전 모델은 지역적 평탄화 제한자 역할을 위하여 MLL(multi-level logistic)

Begin

Step 1 : 초기 거친 스케일 $s = S$ 에서 그림 2의 알고리즘을 이용하여 결 분할을 행하라;

Step 2 : $s = s - 1$, 그리고 스케일 $s + 1$ 의 결 분할로부터 스케일 s 의 모든 위치 $i \in M^s$ 과 $l \in L$ 에 대하여 $p(v_i^s | c_i^s = l)$ 를 결정하라;

Step 3 : 스케일 s 에서 그림 2의 알고리즘을 이용하여 결 분할을 행하라;

Step 4 : s 가 가장 섬세한 스케일이 될 때까지 Step 3과 4를 반복하라;

End

그림 3. 거친 스케일부터 섬세한 스케일까지 연속적인 결 분할에 의한 다중스케일 결 분할 결정 융합

Fig. 3. The multi-scale decision fusion by sequential texture segmentation from coarse to fine scales.

모델로 특징짓는다^[8].

위와 같은 방식으로 배열 \mathbf{G}^s 가 주어진 조건에서 모든 c_k^s 가 독립적이고 각 c_i^s 는 $k \neq i$ 인 모든 다른 c_k^s 와 \mathbf{g}_k^s 에 독립적으로 $p(c_i^s | \mathbf{g}^s)$ 에 따라 분포한다고 가정하면, 식(6)의 $p(\mathbf{c}^s | \mathbf{G}^s)$ 은 다음과 같이 다시 표현할 수 있다.

$$p(\mathbf{c}^s | \mathbf{G}^s) = \prod_{i \in M^s} p(c_i^s | \mathbf{g}^s) \quad (10)$$

여기서 $p(c_i^s | \mathbf{g}^s)$ 는 다층 신경회로망으로부터 다음과 같이 획득 한다.

$$p(c_i^s | \mathbf{g}^s) = \frac{N(\mathbf{g}_i^s, \mathbf{w}_c^s)}{\sum_{k=1}^C N(\mathbf{g}_i^s, \mathbf{w}_k^s)} \quad (11)$$

여기서 \mathbf{w}_c^s 는 스케일 s 에서 부류 c 를 위한 다층 신경회로망의 가중치 벡터이다. 식 (7)-(10)으로부터 식 (5)를 다음과 같이 다시 나타낼 수 있다. 즉,

$$\begin{aligned} \mathbf{c}^* &= \arg \max_{\mathbf{c}^s \in \Theta^s} \{p(\mathbf{c}^s | \mathbf{G}^s) p(\mathbf{c}^s | \mathbf{v}^s)\} \\ &= \arg \max_{\mathbf{c}^s \in \Theta^s} \left\{ \prod_{i \in M^s} p(c_i^s | \mathbf{g}_i^s) p(v_i^s | c_i^s) p(c_i^s | c_{N_i}^s) \right\} \end{aligned} \quad (12)$$

앞의 식들을 이용하여 스케일 s 에서 결 분할 과정을 그림 2에 보였다.

식 (12)에 의한 MAP 분류를 위하여 Gibbs 샘플러를

사용할 수 있다. 만약 식 (12)를 사용하여 거친 스케일에서부터 섬세한 스케일까지 차례로 결 분할이 수행된다면, 각 스케일의 결 분할 결과들이 거친 스케일에서부터 섬세한 스케일까지 차례로 융합된다. 결국, 가장 섬세한 스케일, 화소 단위의 해상도 영상에서 더 개선된 결 분할 결과를 획득할 수 있다. 이는 다중스케일의 결 분할들의 융합과 MRF 평탄화 사전 확률 모델의 분류 오류에 의한 잡음을 줄이는 능력에 의한 것이다. 식 (12)를 가장 초기의 거친 스케일에 적용하고자 할 때, 문맥 벡터는 존재하지 않는다. 그러나 배열 c^s 가 초기 스케일에서 문맥 벡터들에 통계적으로 독립적이라고 생각할 수가 있다. 따라서 초기 스케일에서 $p(c^s | v^s) = p(c^s)$ 로 볼 수 있다. 그림 2의 제안된 분할 과정에서 Gibbs 샘플러를 MAP 분류기로 사용함을 알 수 있다. 거친 스케일에서부터 섬세한 스케일까지의 연속적인 결 분할 과정을 그림 3에 보였다. 가장 섬세한 스케일에서 최종의 결 분할 결과를 그림 3의 제안된 방법을 사용하여 획득할 수 있다.

IV. 실험 및 결과

본 논문에 제안한 결 분할 방법을 결 영상들에 대해 실험하였다. 그리고 이 방법의 유용성과 성능을 보이기 위하여, HMT와 HMTseg 알고리즘^[5]에 의한 결 분할 결과들과 비교하였다. 본 논문에서는 훈련 데이터를 얻기 위하여 22개의 Brodatz 결 영상을 실험에 사용하였다. 훈련 데이터를 위하여, 하나의 512×512 결 영상에서 임의의 위치 선택을 10번하여 얻은 10개의 64×64 크기의 결 영상들을 3단계 웨이블릿 변환하여 결 영상의 특징을 추출하였다. 모든 다층 퍼셉트론은 하나의 은닉층을 가지며, 은닉층은 20개의 뉴런들을 가진다. 그리고 다층 퍼셉트론의 입력 벡터는 각 스케일 s 에 따라 $((4^s - 4)/3 + 1) \times 2 + ((4^{s+1} - 4)/3 + 1)$ 차원을 가진다(II.1절을 참고). HMT 모델도 위의 방법으로 확보한 훈련 데이터를 훈련에 똑같이 사용하였다. 다만 HMT를 이용한 시스템과 다층 신경회로망을 이용한 시스템의 다른 점은 다층 신경회로망이 하나의 결 모델을 만들기 위해 동종의 결과 이종의 결에 대한 훈련 데이터를 모두 사용하는 반면, HMT는 하나의 결 모델을 만들기 위해 동종의 결에 대한 훈련 데이터만 이용한다. 다층 퍼셉트론의 훈련은 resilient 역전파 훈련 알고리즘^[19]을 사용하였고, HMT 훈련은 지능적인 초기 파




그림 4. 모자이크 테스트 결 영상들과 그에 대한 이상적인 결 분할; (a) 2개의 결을 가지고 크기 64×64 인 diagonals2 모자이크의 영상; (b) 3개의 결을 가지고 크기 64×64 인 blocks3 모자이크의 영상; (c) 4개의 결을 가지고 크기 64×64 인 cross4 모자이크의 영상; (d) 9개의 결을 가지고 크기 128×128 인 squares9 모자이크의 영상; (e) diagonals2에 대한 이상적인 결 분할; (f) blocks3에 대한 이상적인 결 분할; (g) cross4에 대한 이상적인 결 분할; (h) squares9에 대한 이상적인 결 분할

Fig. 4. Mosaic test texture images and ideal texture segmentation for the mosaic test images; (a) The 64×64 diagonals2 mosaic, a 2-textures image (D24/D84); (b) The 64×64 blocks3 mosaic, a 3-textures image (D24/D68/D84); (c) The 64×64 cross4 mosaic, a 4-textures image (D22/D24/D68/D84); (d) The 128×128 squares9 mosaic, a 9-textures image (D15/D19/D22/D24/D26/D38/D49/D68/D103); (e) Ideal texture segmentation for diagonals2; (f) Ideal texture segmentation for blocks3; (g) Ideal texture segmentation for cross4; (h) Ideal texture segmentation for squares9.

라메타 설정 방법^[22]을 이용한 EM 알고리즘을 사용하였다. 그림 4는 4개의 테스트 영상과 이상적인 분할 결과를 나타낸다.

다중 스케일에서 결 분할 융합을 하기 전의 각 스케일에서의 결 분할 결과가 좋으면, 융합 후의 결 분할 결과도 좋다. 따라서 다층 퍼셉트론에 의한 각 스케일에서의 융합 전의 결 분할 결과가 HMT에 의한 결과보다 좋다는 것을 보여준 연구도 있다^[6]. 본 논문은 다층 퍼셉트론에 의한 각 스케일에서의 결 분할을 융합하고 분류 오류를 줄이는 방법에 대한 것이다. 그림 5는 다층 신경 회로망에 의한 각 스케일에서의 결 분할을 HMTseg 알고리즘을 이용하여 융합하는 과정과 본 논문에서 제안한 그림 3의 방법으로 융합하는 과정의 그림을 비교하여 나타내고 있다. 다중 스케일 분할 결정 융합을 위한 초기 시작 스케일을 $s = 3$ 으로 설정하였

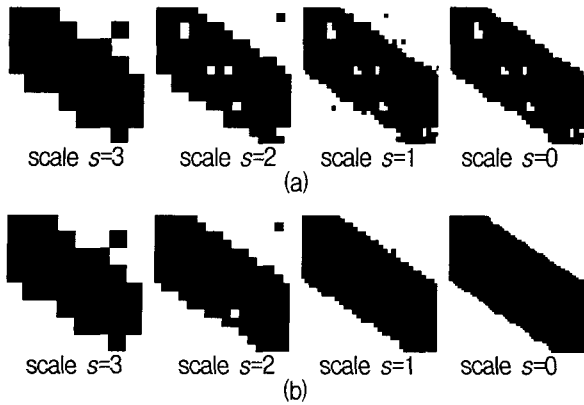


그림 5. Diagonals2 영상에 대한, 거친 스케일에서부터 섬세한 스케일까지 결 분할 융합 과정에서의 결 분할들의 비교; (a) 다중 신경 회로망과 HMTseg 알고리즘을 이용한 결 분할; (b) 제안한 방법을 이용한 결 분할

Fig. 5. The comparison of texture segmentation results at each scale for diagonals2 image; (a) by MLP and HMTseg; (b) by the proposed method.

표 1. 실험 영상들에 대한 분할 오류율; 오류율 = (실험 영상의 오류 분류된 화소수) / (실험 영상의 총 화소수) × 100 %

Table 1. The Segmentation error rate for test images; Segmentation error rate = (the number of misclassified pixels of test image) / (the number of all pixels of test image) × 100 %.

분할 방법 실험 영상	HMT and HMTseg	MLP and HMTseg	The proposed method
Diagonals2	6.81%	3.86%	1.20%
Blocks3	13.72%	9.11%	2.56%
Cross4	11.62%	5.32%	1.56%
Squares9	8.07%	5.16%	0.98%

다. 이 초기 시작 스케일은 초기 거친 스케일의 분할이 충분히 신뢰성을 가지는 스케일로 설정된 것이다(아주 거친 스케일에서 블록 입력의 영역이 아주 넓어서 그 블록 안에 몇 개의 다른 결 영역을 포함하고 있을 가능성이 있다). 그림 5의 거친 스케일에서부터 섬세한 스케일까지, 융합 과정에서의 분할 그림들에서 볼 수 있듯이, 다중스케일 결 분할 융합과 분류 오류에 의한 노이즈를 줄이는 능력의 면에서 그림 3의 제안된 방법이 HMTseg보다 더 뛰어난 성능을 나타낸다.

그림 6은 그림 4의 실험 영상들에 대하여, 가장 섬세한 스케일에서 최종의 결 분할 결과들을 비교하여 보여 준다. 그리고 표 1은 그림 4의 실험 영상들에 대하여, 그림 6의 분할과 그림 4-(b)의 이상적인 분할 사이의




그림 6. 그림 4의 실험 영상들에 대한 각 결 분할 방법에 의한 결 분할 결과들(각 실험 영상의 결과들인 (a), (b), (c), 그리고 (d)에서 첫 번째 열을 HMT와 HMTseg에 의한 결 분할, 두 번째 열은 다중 신경회로망과 HMTseg에 의한 결 분할, 그리고 세 번째 열은 제안된 방법에 의한 결 분할을 나타낸다.); (a) diagonals2에 대한 결과; (b) blocks3에 대한 결과; (c) cross4에 대한 결과; (d) squares9에 대한 결과

Fig. 6. Texture segmentation results, for test images of Fig. 4, by each segmentation method (In (a), (b), (c), and (d) of Fig 6, the first column shows results by HMT and HMTseg, the second column by MLP and HMTseg, and the third column by the proposed method.); (a) For diagonals2; (b) For blocks3; (c) For cross4; (d) For squares9.

오류율을 보여준다. 이 오류율은 영상의 총 화소수에 대한 오류 분류된 화소수의 비율이다. 그림 6과 표 1에서 그림 3의 제안한 다중스케일 결 분할 융합 방법이 뛰어난 것을 볼 수 있을 뿐만 아니라, 다중 신경 회로망을 이용한 제안한 결 분할 방법이 HMT와 HMTseg 알고리즘을 이용하는 방법보다 훨씬 뛰어난 결 분할 성능을 보임을 알 수 있다.

V. 결론

본 논문은 다중 스케일 베이지안 관점에서 다중 퍼

샐트론과 MRF 모델, 그리고 Gibbs 샘플러를 이용한 결 분할 방법을 제안하였다. 다중 스케일 처리에 유용한 다단계 웨이블릿 변환에 의한 다중 스케일 웨이블릿 계수들을 결 영상의 특징으로 사용하였다. 분류 오류에 의한 잡음을 줄이기 위하여 MRF 평탄화 사전 모델을 이용하였는데, MRF 평탄화 모델로 MLL 모델을 사용하였다. 그리고 다중스케일 분할 결정 융합을 위하여 문맥 벡터를 정의하고, 스케일간의 의존성을 모델링하였다. Gibbs 샘플러는 MAP 분류기로서의 역할을 하였는데, 다층 신경 퍼셉트론으로부터의 사후 확률과 MRF 평탄화 사전 모델, 그리고 스케일간의 융합을 위한 문맥 모델을 전체로 합치는데 Gibbs 샘플러를 이용하였다.

스케일간의 결 분할 융합 방법의 비교를 위한 실험에서 제안한 그림 3의 방법이 다중스케일 베이지안 영상 분할 방법 중 하나인 HMTseg보다 더 뛰어난 성능을 보임을 확인하였다. 그리고 제안한 방법과 다른 결 분할 방법들(HMT와 HMTseg^[5], 또는 다층 신경회로망과 HMTseg^[6])과의 결 분할 성능 실험에서 제안한 방법이 다른 방법들보다 훨씬 뛰어난 결 분할 성능을 보임을 확인 하였다.

참 고 문 헌

- [1] M. D. Richard, R. P. Lippmann, "Neural Network Classifiers Estimate Bayesian a posteriori Probabilities," *Neural Computation*, vol. 3, pp. 461-483, 1991.
- [2] H. Gish, "A probabilistic approach to the understanding and training of neural network classifiers," in *Proc. IEEE Intl. Conf. on Acoustics, Speech and Signal Processing (Albuquerque, NM)*, pp. 1361-1364, 1990.
- [3] R. Rojas, "Short proof of the posterior probability property of classifier neural networks," *Neural Computation* 8, pp. 41-43, 1996.
- [4] Kwang In Kim, Keechul Jung, Se Hyun Park, and Hang Joon Kim, "Support Vector Machine for Texture Classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 11, pp. 1542-1550, November 2002.
- [5] Hyeokho Choi and Richard G. Baraniuk, "Multiscale Image Segmentation Using Wavelet-Domain Hidden Markov Models," *IEEE Transaction on image processong*, vol. 10, no. 9, pp. 1309-1321, September 2001.
- [6] Kim Tae Hyung, Eom Il Kyu, and Kim Yoo Shin, "Texture segmentation Using Neural Networks and Multi-scale Wavelet Feature," *Lecture Note in Computer Science* 3611, pp. 395-404, Springer-Verlag Berlin Heidelberg, 2001.
- [7] S. Z. Li, *Markov Random Field Modeling in Computer Vision*, Springer-Verlag, New York, 1995.
- [8] S. Z. Li, *Markov Random Field Modeling in Image Analysis*, 2nd ed., Computer Science Workbench, T. L. Kunii eds. Springer-Verlag, 2001.
- [9] H. Derin and H. Elliot, "Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 9, no. 1, pp. 39-55, January 1987.
- [10] Guoliang Fan and Xiang-Gen Xia, "A Joint Multicontext and Multiscale Approach to Bayesian Image Segmentation," *IEEE Transaction on Geoscience and Remote Sensing*, vol. 39, no. 12, pp. 2680-2688, December 2001.
- [11] Y. Meyer, *Wavelets Algorithm and Application*, SIAM, Philadelphia, PA, 1993.
- [12] Jia Li, R.M. Gray, and R.A. Olshen, "Multiresolution Image Classification by Hierarchical Modeling with Two-Dimensional Hidden Markov Models," *IEEE Transaction on Information Theory*, vol. 46, no. 5, pp. 1826-1841, August 2000.
- [13] Guoliang Fan and Xiang-Gen Xia, "Wavelet-Based Texture Analysis and Synthesis Using Hidden Markov Models," *IEEE Transaction on Circuits and Systems I: Fundamental Theory and Applications*, vol. 50, no. 1, pp. 106-120, January 2003.
- [14] Guoliang Fan and Xiang-Gen Xia, "Image Denosing Using a Local Contextual Hidden Markov Model in the Wavelet Domain," *IEEE Signal Processing Letters*, vol. 8, no. 5, pp. 125-128, May 2001.
- [15] E. P. Simoncelli, "Statistical Models for Images: Compression, Restoration and Synthesis," in *Proc. 31st Asilomar Conf. Signals, Systems and Computers*, pp. 673-678, Pacific Grove, CA, November 1997.
- [16] J.M. Shapiro, "Embedded Image Coding Using Zerotrees of Wavelet Coefficients," *IEEE Transaction on Signal Processing*, vol. 41, no. 12, pp. 3445-3462, December 1993.
- [17] Z. Chen, T.J. Houkes, and Z. Houkes, "Texture

Segmentation Based on Wavelet and Kohonen Network for Remotely Sensed Images," *IEEE International Conf. on Systems, Man, and Cybernetics*, pp. 816-821, Tokyo, Japan, 1999.

[18] Xiaoyue Jiang and Rongchun Zhao, "A New Method of Texture Segmentation," *IEEE International Conf. on Neural Networks and Signal Processing*, pp. 1083-1086, Nanjing, China, December 14-17, 2003.

[19] Martin Reidmiller and Heinrich Braun, "A direct adaptive method for faster backpropagation learning: the Rprop algorithm", *Proceedings of the ICNN*, San Francisco, 1993.


[20] Howard Demuth and Mark Beale, "*Neural Network Toolbox For Use with MATLAB*," The MathWorks, Inc., User's Guide Version 4, pp.164-182.

[21] Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*, 2nd Edition, revised chapter section 2.11, A Wiley Interscience publication, 2002.

[22] Guoliang Fan and Xiang-Gen Xia, "Improved Hidden Markov Models in the Wavelet-Domain", *IEEE Transaction on*


signal processong, vol. 49, NO. 1, January 2001.

저 자 소 개



김 태 형(학생회원)
 1997년 부산대학교 전자공학과 학사.
 1999년 부산대학교 전자공학과 석사.
 2001 부산대학교 전자공학과 박사과정 수료.

1999년~현재 부산대학교 전자공학과 박사과정
 <주관심분야 : 영상처리, 음성처리, 신호처리, 신경회로망>



엄 일 규(정회원)
 1990년 부산대학교 전자공학과 학사.
 1992년 부산대학교 전자공학과 석사.
 1998 부산대학교 전자공학과 박사.

현재 부산대학교 전자공학과 부교수
 <주관심분야 : 통계신호처리, 영상처리, 웨이블릿 변환 신호처리, 신경회로망>



김 유 신(정회원)
 1974년 서울대학교 전자공학과 학사.
 1980년 U.C. Berkeley 전자공학과 석사.
 1983년 Stanford University 전자재료 박사과정 수학.

1995년 Cornell University Ph.D
 1983년~현재 부산대학교 전자공학과 교수
 2005년 현재 한국 과학철학회 회장
 <주관심분야 : 영상처리, 신경회로망, 공학윤리, 과학기술철학>