

논문 2005-42SP-4-5

신경회로망과 다중스케일 Bayesian 영상 분할 기법을 이용한 결 분할

(Texture segmentation using Neural Networks and multi-scale 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

본 논문에서는 Bayesian 추정법과 신경회로망을 이용한 새로운 결 분할 방법을 제안한다. 신경회로망의 입력으로는 다중 스케일을 가지는 웨이블릿 계수와 인접한 이웃 웨이블릿 계수들의 문맥정보를 사용하고, 신경회로망의 출력을 사후 확률로 모델링한다. 문맥정보는 HMT(Hidden Markov Tree) 모델을 이용하여 구한다. 제안 방법은 HMT를 이용한 ML(Maximum Likelihood) 분할 보다 더 우수한 결과를 보여준다. 또한 HMT를 이용한 결 분할 방법과 제안 방법을 이용한 결 분할 각각에 HMTseg라고 불리는 다중 스케일 Bayesian 영상 분할 기술을 이용하여 후처리를 행한 결 분할 또한 제안 방법이 우수함을 보여준다.

Abstract

This paper proposes novel texture segmentation method using Bayesian estimation method and neural networks. We use multi-scale wavelet coefficients and the context information of neighboring wavelets coefficients as the input of networks. The output of neural networks is modeled as a posterior probability. The context information is obtained by HMT(Hidden Markov Tree) model. This proposed segmentation method shows better performance than ML(Maximum Likelihood) segmentation using HMT model. And post-processed texture segmentation results as using multi-scale Bayesian image segmentation technique called HMTseg in each segmentation by HMT and the proposed method also show that the proposed method is superior to the method using HMT.

Keywords : Texture segmentation, Neural Networks, Wavelets, Multi-scale Bayesian image segmentation,
Hidden Markov Trees

I. 서 론

물체의 명도 변화가 어떤 반복적인 구조와 패턴을 가지기 때문에 시각상의 결은 영상 화소들의 공간적인 배열들 또는 동종의 패턴으로 나타난다. 실제 영상들은 결을 포함하므로 결을 가지는 영상의 분할은 여러 응용 분야의 영상 처리에서 중요한 분야로 간주된다. 문서

저장에서 문자 영역과 그림 영역을 분할하여, 영역별로 문서를 분석, 압축, 표현하는데 이용할 수 있다. 또 비디오 압축, 비디오 내용 기반 검색 등을 위한 첫 단계로서 결을 가진 영상 분할은 중요하다.

결의 묘사 방법은 결 분할에 있어서 중요한 문제이며, 결의 묘사 방법에 따라 결 분할 방법이 달라진다. 결은 결을 이루는 근본 요소의 크기와 구조, 배치 형태에 따라 통계적인 결과 구조적인 결로 나눌 수가 있고 [1,2], 그에 따라 다른 분할 방법을 사용할 수 있다. 결의 근본 요소가 작으며 그 구조와 배치가 고정형태를 가지지 않은 통계적인 결의 경우는 결 영상의 분류 창 내에 영상 화소 값의 평균, 분산 등의 통계적인 모멘트들과 엔트로피를 이용하여 분류 창 내에 영상을 분류한다

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

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

접수일자: 2005년2월18일, 수정완료일: 2005년4월26일

^[1,3,4,5]. 결의 근본 요소가 크며 그 구조와 배치가 고정된 구조의 반복적 배치로 나타나는 구조적인 결은 결의 근본 요소의 추출과 그것들의 배치 규칙을 결정함으로써 분석할 수 있다^[1,2,4]. 이와 같은 분할 방법 외에 모델 기반의 분할 방법이 있다. 모델 기반의 분할 방법은 영역 기반^[4,6]과 경계 기반 방법^[4,6,7,8,9,10] 등이 있다. 이외에도 MRF(Markov Random Field)가 결 모델로서 널리 연구되었다^[11,12,13]. MRF는 한 화소값을 그 주변의 이웃 화소들의 값들과 잡음값의 합으로 모델링한다.

결 영상의 특징을 추출하는 방법에 따라 결 분할 방법을 분류해 볼 수도 있다. 영상 화소의 값을 이용하는 것 이외에도 영상의 푸리에 영역 변환^[14]이나 웨이블릿 영역 변환^[15] 등을 이용한 영상 특징을 이용할 수 있는데, 다중 스케일에서의 영상 영역 변환을 이용한 영상 특징은 결 분할에 아주 효과적이다. 거친(coarse) 스케일에서 영상 분할은 넓은 동종의 결이 있는 영역에서는 분할 결과가 좋고, 섬세한(fine) 스케일에서 영상 분할은 결들의 경계 영역에서 분할 결과가 좋다. 각 스케일에서의 영상 분할의 특성을 융합하여 좋은 결 분할 결과를 얻을 수 있다. 이런 이유로 결 분할에 다중 스케일 웨이블릿 영역에서의 영상 특징을 사용하는 HMT 모델을 이용하는 방법이 있다^[15].

HMT의 출력은 입력 특징의 likelihood 확률을 나타내므로, ML(Maximum Likelihood) 분류를 이용하여 결 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 기술을 결 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 기술에 의한 영상 분할은 다중 스케일에서 ML 분할에 의존하여 영상 분할을 개선하므로, HMT 모델이 정교하지 못하여 다중 스케일에서의 ML 분할 결과가 좋지 못하면 좋은 결 분할 결과를 보여주지 못한다.

본 논문에서는 다중 스케일 웨이블릿 영역에서의 영상 특징을 이용하여 신경회로망과 HMTseg라고 불리는 다중 스케일 Bayesian 영상 분할 기술에 의한 결 분할 방법을 제안한다. 신경회로망은 복잡한 방법의 모델

링 없이도 입력 특징들의 임의 분포를 표현할 수 있다^[16]. 다중 스케일 웨이블릿 영역에서의 영상 특징을 이용하여 신경회로망으로 결 분할을 행하면 HMT처럼 초기 파라메타의 영향을 받는 현상 없이 정교하고 일반화 능력이 뛰어난 모델링이 가능하여 우수한 성능을 보여줄 수 있다. 지도자 훈련 모드(supervised training mode)에서 훈련한 신경회로망의 출력이 사후 확률을 나타내도록 망을 구성할 수 있으며^[16,17,18], 그 신경회로망 출력 값으로 MAP(Maximum A Posterior) 분류를 행할 수가 있다. 제안한 결 분할 방법은 신경회로망의 입력으로 quad tree 구조를 가지는 다중 스케일에서의 웨이블릿 계수들과 한 스케일 안에서 웨이블릿 계수의 의존 관계의 정보(문맥 정보)를 이용하기 위하여 HMT 모델을 이용하여 구한 이웃 웨이블릿 계수들의 likelihood 값을 사용한다. 그리고 신경회로망의 출력값으로 결의 MAP 분할을 행한다. 신경회로망에 의한 MAP 분할은 HMT를 이용한 ML 분할보다 더 우수한 결과를 보여준다. 신경회로망의 출력을 이용한 다중 스케일에서의 MAP 분할에 HMTseg라고 불리는 다중 스케일 Bayesian 영상 분할 기술을 이용하여 최종의 가장 섬세한 스케일에서 영상 분할을 개선시킨 결과 또한 HMT를 사용한 다중 스케일에서의 ML 분할에 HMTseg 알고리즘으로 최종의 가장 섬세한 스케일에서 영상 분할을 개선시킨 결과보다 더 우수하다.

II장에서는 영상의 웨이블릿 변환과 웨이블릿 계수로부터 2-D HMT 모델의 구성에 대해 설명하고 HMT 모델을 이용한 다중 스케일에서의 영상 분할과 HMTseg 알고리즘을 이용한 후처리에 대해 설명한다. III장에서는 제안한 신경회로망을 이용한 결 분할에 대해 설명한다. IV장은 분할 실험 및 결과에 대해 평가한다.

II. 은닉 마코프 트리 모델을 이용한 결 분할

1. Harr 웨이블릿 변환

웨이블릿 변환은 한 영상에 대하여 피라미드 형태를 가지는 다중 스케일 구조를 구성한다. Harr 웨이블릿 계수들은 다음과 같은 4개의 웨이블릿 필터를 이용하여 구할 수 있다.

$$\begin{aligned} h_{LL} &= \frac{1}{2} \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}, g_{LH} = \frac{1}{2} \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix}, \\ g_{HL} &= \frac{1}{2} \begin{pmatrix} 1 & -1 \\ 1 & -1 \end{pmatrix}, g_{HH} = \frac{1}{2} \begin{pmatrix} -1 & -1 \\ -1 & 1 \end{pmatrix} \quad (1) \end{aligned}$$

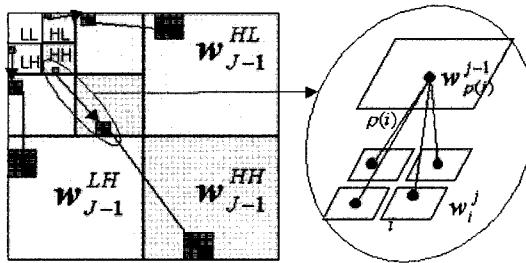


그림 1. Harr 웨이블릿 변환과 웨이블릿 계수들의 4 나뭇가지의 나무 구조
Fig. 1. The Harr wavelet transform and The quad tree structure of wavelet coefficients.

여기서 h_{LL} 는 국부 평탄화기, g_{LH} 는 수평에지 검출기, g_{HL} 는 수직에지 검출기 그리고 g_{HH} 는 대각에지 검출기의 역할을 한다. 입력 영상 \mathbf{x} ($= \mathbf{u}_J$)를 Harr 웨이블릿 변환하면 근사화된 부영상 \mathbf{u}_{J-1} , 수평 에지 영상 \mathbf{w}_{J-1}^{LH} , 수직 에지 영상 \mathbf{w}_{J-1}^{HL} , 그리고 대각 에지 영상 \mathbf{w}_{J-1}^{HH} 얻을 수 있고, \mathbf{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 quad tree 구조를 보인다.

2. Hidden Markov Tree 모델

웨이블릿 계수들의 분포는 HMT를 이용하여 모델링 할 수 있다^[21]. 한 웨이블릿 부밴드에서 그림 1과 같은 다중 스케일 웨이블릿 계수들의 quad tree 구조는 그림 2와 같이 HMT 모델로 표현할 수 있다. 그림 2에서 검은 노드는 웨이블릿 계수를 나타내고, 흰색 노드는 두 개의 은닉 상태를 가지는 상태를 나타낸다. 웨이블릿 계수들은 적은 수의 큰 값을 가지는 계수와 많은 수의 작은 값을 가지는 계수들로 구성된다. 그러므로 큰 값을 가지는 계수의 분포는 큰 분산 값을 가지는 가우스 확률 밀도 함수로 표현할 수 있다. 마찬가지로 작은 값을 가지는 계수의 분포는 작은 분산 값을 가지는 가우스 확률 밀도 함수로 표현할 수 있다. 따라서 웨이블릿 계수의 분포는 두개의 은닉 상태를 가우스 혼합 모델로 설정될 수 있다. i번째 위치의 웨이블릿 계수 w_i 의 확률 밀도함수는 다음과 같다.

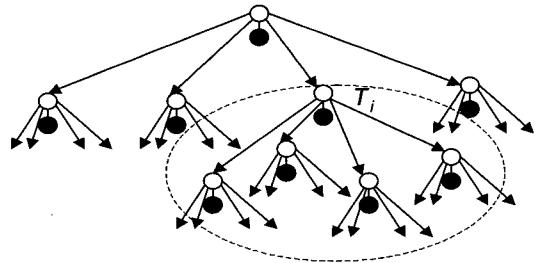


그림 2. HMT 모델의 구조.
Fig. 2. The HMT model structure.

$$f(w_i) = \sum_{m=S,L} p_{S_i}(m) f(w_i|S_i = m) \quad (2)$$

여기서 숨겨진 상태 S_i 는 작은 분산과 큰 분산을 나타내는 $m = S, L$ 의 값을 가지며, $p_{S_i}(m)$ 은 i번째 계수의 숨겨진 상태 $S_i = m$ 일 확률 함수, $f(w_i|S_i = m)$ 은 i번째 계수의 숨겨진 상태가 $S_i = m$ 일 때 가우스 확률 밀도 함수 $N(\mu_{i,m}, \sigma_{i,m}^2)$ 이다. 그리고 $p_{S_i}(S) + p_{S_i}(L) = 1$ 이다. 본 논문에서는 혼동의 여지가 없는 한 웨이블릿 스케일($J, J-1, \dots$) 및 방향(LH, HL, HH)을 나타내는 첨자를 생략한다.

그림 2의 HMT 모델에서 각 스케일에 있는 흰색 노드 사이의 연결 가지는 영상의 같은 부 영역을 분석하는 웨이블릿 계수들의 스케일 사이의 영속성을 나타낸 것이다. 웨이블릿 계수의 크기값이 스케일 사이에 영속성을 가지기 때문에 웨이블릿 계수들 사이의 가장 중요한 상관관계는 웨이블릿 quad tree의 부모와 자식간의 상호관계이다. 계수 크기들의 스케일 영속성을 그림 3에서 보듯이 HMT 모델에서 흰색 노드의 은닉 상태들 사이의 상태 천이 확률로 표현한다. 그러면 각 흰색 노드에 대하여 다음과 같은 상태 천이 확률 행렬을 얻을 수 있다.

$$\begin{bmatrix} \epsilon_{i,S}^{\rho(i),S} & \epsilon_{i,L}^{\rho(i),S} \\ \epsilon_{i,S}^{\rho(i),L} & \epsilon_{i,L}^{\rho(i),L} \end{bmatrix} = \begin{bmatrix} \epsilon_{i,S}^{\rho(i),S} & 1 - \epsilon_{i,S}^{\rho(i),S} \\ 1 - \epsilon_{i,L}^{\rho(i),L} & \epsilon_{i,L}^{\rho(i),L} \end{bmatrix} \quad (3)$$

여기서 부모와 자식 노드의 상태를 $\{S_{\rho(i)}, S_i\}$ 에 대하여 상태 천이 확률은 $\epsilon_{i,m}^{\rho(i),m}, m, m' = S, L$ 이다. 또한 $\rho(i)$ 는 i번째 웨이블릿 계수의 부모 계수를 나타낸다. 웨이블릿 영역에서의 HMT 모델은 각 은닉 상태에서의 평균과 분산, 그리고 은닉 상태들 사이의 상태 천이 확률로 결정이 된다.

3. HMT 모델을 이용한 결 분할

결 분할에 HMT 모델을 이용하기 위해서는 먼저 각 결의 훈련 데이터를 준비하고 각 결에 대해 훈련된 HMT 모델이 있어야 한다. HMT 모델은 각 결의 C 개의 부류 중 $c \in \{1, 2, \dots, C\}$ 에 대하여 하나의 결에 대한 HMT 모델을 반복적인 EM(Expectation Maximization) 알고리즘을 사용하여 생성한다. EM 알고리즘은 훈련 데이터에 대하여 HMT 모델 파라메터들의 지역적인 최적 집합을 ML 관점에서 찾는다. 반복적인 EM 알고리즘에서 각 반복에서 E step은 현재 결정된 파라메터들에 기초하여 likelihood를 구한다. M step에서는 훈련데이터에 대하여 모델로부터의 likelihood가 최대가 되도록 파라메터를 변경한다.

그림 2의 T_i 에 대응하는 HMT의 likelihood는 다음과 같이 구할 수 있다. 즉,

$$\begin{aligned} f(\mathbf{d}_i|M) \\ = f(T_i^{LH}|\Theta^{LH})f(T_i^{HL}|\Theta^{HL})f(T_i^{HH}|\Theta^{HH}) \end{aligned} \quad (4)$$

여기서 T_i 를 구성하는 웨이블릿 계수는 $\mathbf{d}_i = \{T_i^{LH}, T_i^{HL}, T_i^{HH}\}$ 이고 HMT 파라메터의 집합은 $M = \{\Theta^{LH}, \Theta^{HL}, \Theta^{HH}\}$ 이다. T_i 의 계수들에 대한 likelihood는 다음 식과 같다.

$$f(T_i|\Theta) = \sum_{m=S,L} \beta_i(m)p(S_i = m|\Theta) \quad (5)$$

여기서 EM 알고리즘의 E step의 $\beta_i(m) \equiv f(T_i|S_i = m, \Theta)$ 로서 일사귀로부터 노드 i 까지 HMT quad tree를 올라가며 계산한다. 식 (4)를 이용하여 다중 스케일에서 웨이블릿 계수들의 likelihood를 구할 수가 있으며, 다중 스케일 likelihood로부터 ML 분류를 이용하여 분할 결과를 얻을 수 있다. 웨이블릿 quad tree의 i번째 노드의 ML에 의한 분류 \hat{c}_i^{ML} 은 다음과 같다.

$$\hat{c}_i^{ML} \equiv \arg \max_{c \in \{1, 2, \dots, C\}} f(\mathbf{d}_i|M_c) \quad (6)$$

여기서 M_c 는 $c \in \{1, 2, \dots, C\}$ 부류에 대한 웨이블릿 HMT 모델이다.

4. HMTseg를 이용한 후처리

다중 스케일에서 영상의 ML 분할은 스케일에 따라

서 신뢰도와 정밀도 사이에 다음과 같은 모순 관계가 존재한다. 거친 스케일에서 영상 분할은 넓은 동종의 결이 있는 영역에서는 결과가 좋지만 결들의 경계 영역에서의 분할 결과는 좋지 못하며, 섬세한 스케일에서 영상 분할은 결들의 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 likelihood들과 영상 분할을 결합하는 HMTseg라는 다중 스케일 Bayesian 분할 알고리즘을 사용하여 가장 섬세한 스케일의 결 분할을 개선시킨 연구가 있다^[15]. HMTseg 알고리즘은 다음과 같이 문맥요소를 고려한 사후확률을 다음과 같이 구한다.

$$\begin{aligned} f(c_i|\mathbf{d}_i, \mathbf{v}_i) &= \frac{f(\mathbf{d}_i|c_i)p(c_i|\mathbf{v}_i)}{f(\mathbf{d}_i|\mathbf{v}_i)} \\ &= \frac{f(\mathbf{d}_i|c_i)p(c_i|\mathbf{v}_i)}{\sum_{l=1}^{N_c} f(\mathbf{d}_i|c_i = l)p(c_i = l|\mathbf{v}_i)} \end{aligned} \quad (7)$$

여기서 N_c 는 총 결 부류의 개수이며 c_i 는 웨이블릿 quad tree의 i번째 노드의 부류를 나타내고, \mathbf{v}_i 는 i번째 노드 주위의 문맥을 표현한 문맥 벡터이다. 식 (4)에서 와 마찬가지로 $\mathbf{d}_i = \{T_i^{LH}, T_i^{HL}, T_i^{HH}\}$ 이다.

HMTseg 알고리즘은 식 (7)을 다음과 같이 단순화하여 사후확률 $f(c_i|\mathbf{d}_i, \mathbf{v}_i)$ 을 구하고 MAP 분류법에 의해 분할을 행한다.

$$f(c_i|\mathbf{d}_i, \mathbf{v}_i) \propto f(\mathbf{d}_i|c_i)p(c_i|\mathbf{v}_i) \quad (8)$$

식 (9)에서 $f(\mathbf{d}_i|c_i)$ 는 HMT 모델로부터 구하고 $p(c_i|\mathbf{v}_i)$ 는 바로 구하지 않고 다음과 같이 Bayes 규칙을 적용하여 $p(\mathbf{v}_i|c_i)$ 로부터 구한다.

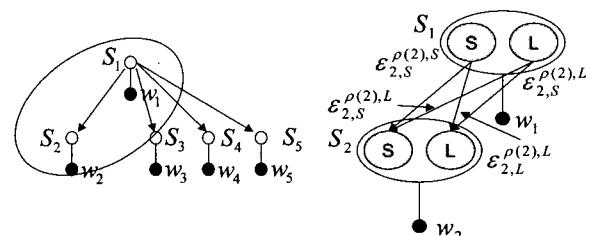


그림 3. 상태 천이 확률은 계수 크기의 스케일간 영속성을 포착한다.

Fig. 3. State transition probabilities capture the scale persistence of coefficient magnitude.

$$p(c_i|\mathbf{v}_i) = \frac{p(\mathbf{v}_i|c_i)p(c_i)}{p(\mathbf{v}_i)} \quad (9)$$

최종적으로 후처리된 결 부류 \hat{c}_i^{MAP} 는 다음과 같다.

$$\hat{c}_i^{MAP} \equiv \arg \max_{c \in \{1, 2, \dots, C\}} f(c_i|\mathbf{d}_i, \mathbf{v}_i) \quad (10)$$

HMTseg 알고리즘은 거친 스케일에서부터 시작하여 각 스케일에서의 MAP 분할 결과들을 차례로 융합하여 최종의 섬세한 스케일에서의 개선된 분할을 구한다. 비록 HMTseg 알고리즘이 HMT에 의한 ML 분할보다 개선된 분할 결과를 보이지만, HMTseg에 의한 영상 분할은 HMT에 의한 다중 스케일에서의 likelihood값에 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 파라메타 값에 의존하는 경향이 크다. 또한 HMT의 모델을 정교하게 하는 것은 HMT 모델의 구조를 복잡하게 만들고 모델의 파라메타를 증가시킨다. 증가한 파라메타는 많은 훈련 데이터를 요구하게 되며 훈련 데이터가 충분하지 못하면 분류의 능력이 떨어지게 된다.

III. 신경회로망을 이용한 결 분할

신경회로망은 사후 확률을 추정하도록 출력과 입력 구조를 구성할 수 있다^[16,17,18]. 웨이블릿 계수들을 신경회로망의 입력으로 사용하려면, 웨이블릿 계수들의 특징을 잘 이용하여야 한다. HMT 모델에서처럼 각 스케일 간에 웨이블릿 계수들의 의존관계를 고려하여 입력 벡터의 수를 결정하는 것이 중요하다. 한 웨이블릿 부밴드의 j 번째 스케일의 i 번째 위치에 대한 신경회로망 입력으로 i 번째 노드와 그 자손들의 노드에 해당하는 웨이블릿 계수들을 모두 사용한다. 또한 i 번째 노드가 분석하는 부 영상 영역의 화소의 밝기 값도 신경회로망의 입력으로 사용한다. 웨이블릿 부밴드들의 웨이블릿 계수들을 모두 고려한다면, 신경회로망의 입력 벡터, \mathbf{g}_i 는 다음과 같다.

$$\mathbf{g}_i \equiv \{\mathbf{T}_i^{HL}, \mathbf{T}_i^{LH}, \mathbf{T}_i^{HH}, \mathbf{p}_i\} \quad (11)$$

여기서 \mathbf{p}_i 는 i 번째 노드에 대응되는 부 영상의 화소 값이다. 각 부류에 대하여 신경회로망의 K 개의 출력

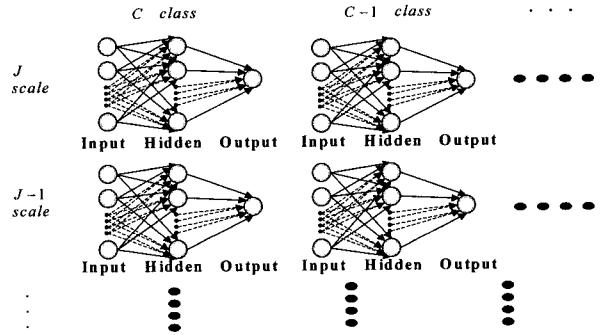


그림 4. 제안 신경회로망의 입출력 구조

Fig. 4. The structure of input and output layer of proposed neural networks.

중에 하나의 출력 값이 1이고 나머지는 모두 0이 되도록 구성할 수 있다. K 개의 출력 노드들의 출력 값을 합하면 1이 되도록 하고 신경회로망 훈련을 위하여 자승오차 또는 교차 엔트로피 등의 비용함수를 사용하면, 신경회로망이 Bayesian 사후확률을 추정할 수 있다. 제안한 시스템에서는 다중 스케일에서 사후 확률을 구하기 위하여, 웨이블릿의 각 스케일 당 하나씩의 다층 신경회로망을 구성하였다. 그림 4는 결 분할을 위한 제안 신경회로망의 구조를 나타낸다. 그림 4에서 볼 수 있듯이 각 결 부류 당 하나씩의 다층 신경회로망을 구성하였고, 그 다층 신경회로망의 출력 노드는 하나로 하였다. 결 부류 c_i 를 위한 다층 신경회로망의 출력 노드에 대한 훈련 시에 목표 출력값은 다음과 같다.

$$t_i = \begin{cases} 1, & \mathbf{g}_i \in c \\ 0, & \mathbf{g}_i \notin c \end{cases} \quad (12)$$

본 논문에서는 신경회로망의 훈련을 위하여 resilient 역전파 방법^[19]을 사용하였다. 이 알고리즘은 가중치 갱신에 목적함수의 미분의 크기를 사용하는 Back-propagation의 치명적 맹점을 제거한 것으로, 목적함수의 미분의 크기는 가중치 갱신에 전혀 영향을 미치지 않고 단지 미분의 부호가 가중치 갱신의 방향 결정에 사용된다. 가중치 변화의 크기는 미분의 부호와 관련한다. 반복된 훈련 알고리즘 진행 중 목적 함수의 미분의 부호가 진동하면 가중치 변화 크기는 한 점점 작아지고, 미분의 부호가 같은 방향을 계속 유지하면 가중치 변화 크기가 점점 커진다. Resilient 역전파 알고리즘은 패턴 인식 문제에서 다른 여러 훈련알고리즘에 비해 가장 빠른 훈련 속도를 가지며, 알고리즘을 위한 메모리 요구도 상대적으로 적다^[20].

신경회로망 훈련 후 분할 결과를 얻기 위해서는 다음

과 같은 분류법을 사용한다. 즉, 신경회로망에 의한 결의 부류 \hat{c}_i^N 은 신경회로망의 입력 벡터 및 가중치 벡터로 구성되는 신경회로망의 출력으로 구할 수 있다. 즉,

$$\hat{c}_i^N \equiv \arg \max_{c \in \{1, 2, \dots, C\}} \frac{N(\mathbf{g}_i, \mathbf{w}_c)}{\sum_{k=1}^C N(\mathbf{g}_i, \mathbf{w}_k)} \quad (13).$$

여기서 $N(\mathbf{g}_i, \mathbf{w}_c)$ 는 i번째 노드의 입력 \mathbf{g}_i 과 각 부류 c 에 대한 가중치 벡터 \mathbf{w}_c 로 구성되는 신경회로망 모델의 출력을 나타낸다. 식 (13)을 이용하여 다중 스케일에서 결 분할 결과를 얻을 수 있다. HMT에 의한 다중 스케일에서의 ML 분할과 마찬가지로 식 (13)에 의한 결 분할은 스케일에 따라서 신뢰도와 정밀도 사이의 모순 관계가 존재한다. 따라서 본 논문에서는 HMT 모델을 이용한 결 분할과 마찬가지로 HMTseg 알고리즘을 신경회로망에 의한 분할 결과에 후처리로 사용한다. HMTseg 알고리즘을 적용하기 위하여 식 (7)을 다음 식과 같이 변형하여 적용한다.

$$f(c_i | \mathbf{g}_i, \mathbf{v}_i) \propto \frac{N(\mathbf{g}_i, \mathbf{w}_c)}{\sum_{k=1}^C N(\mathbf{g}_i, \mathbf{w}_k)} p(c_i | \mathbf{v}_i) \quad (14)$$

식 (14)를 다시 단순화 시키면 다음과 같이 된다.

$$f(c_i | \mathbf{g}_i, \mathbf{v}_i) \propto N(\mathbf{g}_i, \mathbf{w}_c) p(c_i | \mathbf{v}_i) \quad (15)$$

즉, 식 (15)로부터 식 (10)과 같이 Bayes 분류를 적용하여 후처리된 MAP 분할을 얻을 수 있다.

웨이블릿 quad tree의 한 위치의 계수에 대한 결 분류를 위하여 영상의 문맥 정보를 이용하면 다중 스케일에서의 분할 결과들을 더 개선시킬 수 있다. 문맥 정보로써는 한 위치 주위의 이웃 계수들의 정보를 이용할 수 있다. 문맥 정보는 그림 5에서 보인 것처럼 웨이블릿 quad tree의 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. 즉, 제안 방법에서 신경회로망의 입력 벡터는 다음과 같이 구성된다.

$$\mathbf{g}_i \equiv \{\mathbf{T}_i^{HL}, \mathbf{T}_i^{LH}, \mathbf{T}_i^{HH}, \mathbf{p}_i, \mathbf{CV}_i\} \quad (16)$$

여기서 \mathbf{CV}_i 는 노드 i 의 문맥 정보에 대한 벡터이다. 본 논문에서는 신경회로망의 입력을 위한 문맥 정보를 웨이블릿 계수를 사용하지 않고 HMT로부터 구해지는 likelihood로 사용하였다.

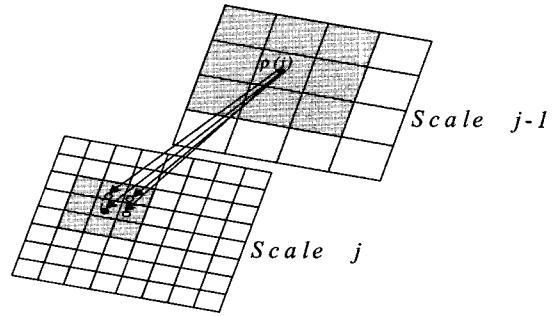


그림 5. 웨이블릿 quad tree의 스케일 j 에서 노드 i 에 대한 문맥 고려

Fig. 5. The consideration of contexts for node i in scale j of wavelet quad tree.

HMT의 사후확률 $f(c_i | \mathbf{d}_i)$ 는 Bayes 규칙에 따라 다음 같이 전개된다. 즉,

$$f(c_i | \mathbf{d}_i) = \frac{f(\mathbf{d}_i | c_i) p(c_i)}{f(\mathbf{d}_i)} \quad (17)$$

식 (17)에서 문맥 벡터를 $\{v_{1i}, v_{2i}, \dots, v_{Mi}\}$ 라고 하면, 식 (17)은 다음과 같다.

$$\begin{aligned} & f(c_i | \mathbf{d}_i, v_{1i}, v_{2i}, \dots, v_{Mi}) \\ &= \frac{f(\mathbf{d}_i, v_{1i}, v_{2i}, \dots, v_{Mi} | c_i) p(c_i)}{f(\mathbf{d}_i, v_{1i}, v_{2i}, \dots, v_{Mi})} \\ &= \frac{f(\mathbf{d}_i | c_i) f(v_{1i} | c_i) f(v_{2i} | c_i) \dots f(v_{Mi} | c_i) p(c_i)}{f(\mathbf{d}_i, v_{1i}, v_{2i}, \dots, v_{Mi})} \end{aligned} \quad (18)$$

식 (18)에서 문맥 정보에 대한 likelihood $f(v_{1i} | c_i), \dots, f(v_{Mi} | c_i)$ 은 HMT로부터 구해 질 수 있다. 따라서 본 논문에서는 HMT로부터 구할 수 있는 문맥 정보에 대한 likelihood를 신경회로망의 입력을 위한 문맥 벡터로 설정한다. 즉,

$$\mathbf{CV}_i = \{f(v_{1i} | c_i), \dots, f(v_{Mi} | c_i)\} \quad (19)$$

문맥 정보를 이용하지 않은 경우는 섬세한 스케일로 갈수록 분류 윈도우의 크기가 작아 분류에 이용할 정보량이 적고 그로 인해 분할 결과가 좋지 않으며 국소적인 잡음에 의해 영향을 많이 받을 수 있다. 주위의 이웃 문맥 정보를 이용함으로서 섬세한 스케일에서 국소적인 잡음의 영향을 줄일 수 있다.

IV. 실험 및 결과

본 논문에서는 22개의 Brodatz 결 영상을 실험에 사용하였다. 22개의 결 영상에서 훈련 데이터를 얻기 위

하여, 하나의 640×640 결 영상에서 임의 위치 선택을 10번하여 얻은 10개의 64×64 크기의 결 영상들을 다중 웨이블릿 변환하여 결 영상의 특징을 추출하였다. HMT를 이용한 시스템 및 제안한 시스템들의 결 분할 능력을 비교하기 위하여 위의 방법으로 확보한 훈련 데이터를 각 시스템들의 훈련에 똑같이 사용하였다. 다만 HMT를 이용한 시스템과 다중 신경회로망을 이용한 시스템의 다른 점은 다중 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. 다중 신경회로망 훈련은 resilient 역전파 훈련 알고리즘을 사용하였고, HMT 훈련은 지능적인 초기 파라메타 설정 방법^[20]을 이용한 EM 알고리즘을 사용하였다. 실험에 쓰인 테스트 영상들은 그림 6에 있다.

각 테스트 영상에 대한 결 분할 결과들을 그림 7, 8, 9에 보였다. 결 분할 결과들 그림 각각에서 (a), (b), (c)의 두 행으로 나열된 영상 분할 그림들은 다중 스케일에서 결 분할을 나타내는데, 두 행 중 첫 행은 각 결 분할 시스템의 결 분할 과정 중에서 HMTseg라는 후처리 과정을 거치지 않은 결 분할을 나타내고 두 번째 행은 후처리 과정을 거친 후의 결 분할을 나타낸다. 그리고 (a), (b), (c)에 영상 분할들은 왼쪽부터 오른쪽까지 차례로 거친 스케일에서 섬세한 스케일까지의 다중 스케일에서 결 분할들을 나타낸다. 맨 왼쪽의 거친 스케일은 $j=3$ 이고 차례로 섬세한 스케일로 갈수록 스케일은 하나씩 증가한다. 스케일 $j=3$ 에서 $j=5$ 까지는 웨이블릿 영역의 각 스케일에서 구한 결 분할이고, $j=6$ 의 가장 섬세한 스케일에서의 분할 그림은 웨이블릿 영역이 아닌 픽셀 영역에서 구한 최종의 결 분할 결과를 나타낸다. 그림 7에서 그림 9까지 그림들에서 (a)의 첫 행의 그림

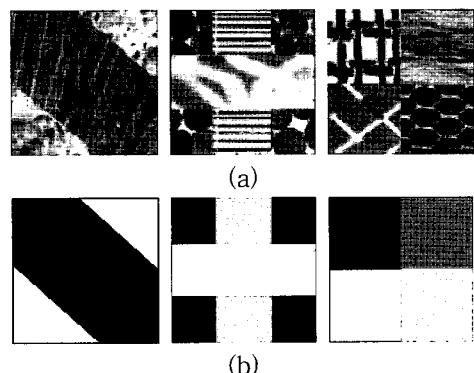


그림 6. (a) 테스트 결 영상들과 (b) 이상적인 결 분할
Fig. 6. (a) test texture images and (b)ideal texture segmentation.

들은 HMT와 가우스 혼합 모델에 의한 다중 스케일 likelihood값들과 식 (6)의 ML 분류법에 의한 다중 스케일 ML 분할을 보였다. 그리고 (a)의 두 번째 행은 (a)의 첫 행에 ML 분할과 다중 스케일 likelihood값들에

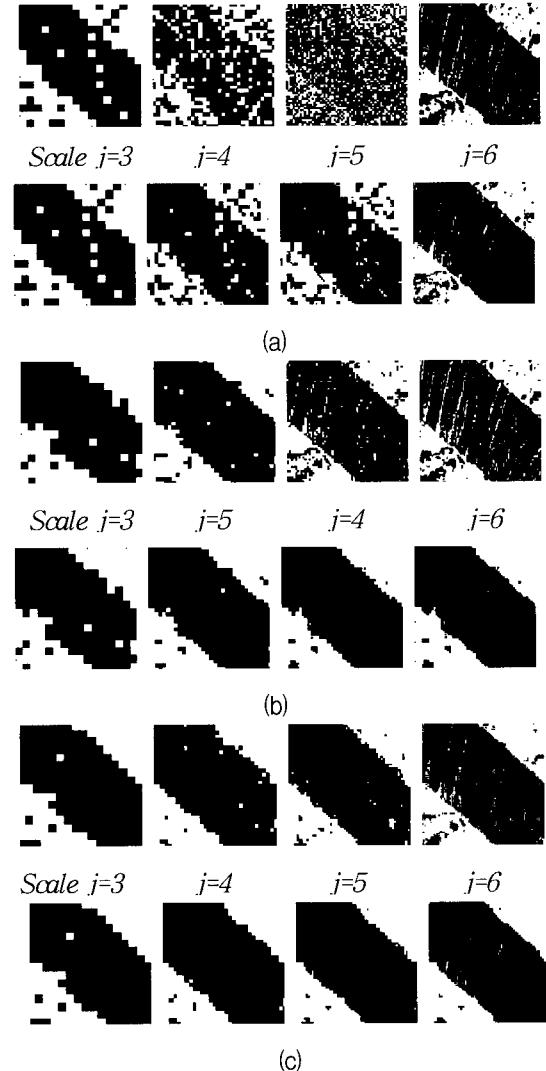


그림 7. 각 시스템에 의한 다중 스케일에서의 결 영상 분할 결과들, (a)첫 행: HMT 이용, 둘째 행: HMT와 HMTseg 이용, (b)첫 행: 문맥 정보를 사용치 않는 제안한 방법, 둘째 행: 문맥 정보를 사용치 않는 제안한 방법과 HMTseg 이용, (c)첫 행: 문맥 정보를 사용하는 제안한 방법, 둘째 행: 문맥 정보를 사용하는 제안한 방법과 HMTseg 이용

Fig. 7. Multiscale texture image segmentation results by each system, (a)first row: by HMT, second row: by HMT and HMTseg, (b)first row: by the proposed method without contexts, second row: by the proposed method without contexts and HMTseg, (c)first row: by the proposed method with contexts, second row: by the proposed method with contexts and HMTseg.

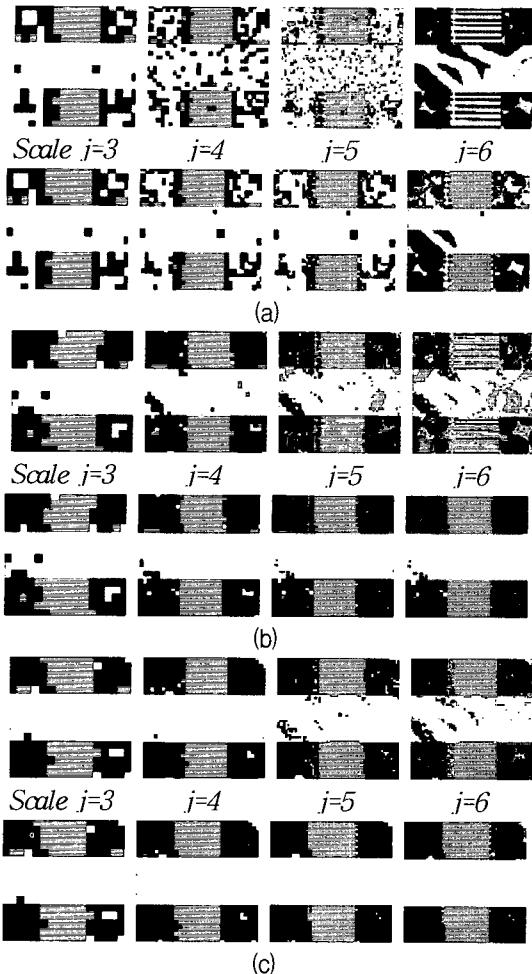


그림 8. 각 시스템에 의한 다중 스케일에서의 결 영상 분할 결과들, (a)첫 행: HMT 이용, 둘째 행: HMT와 HMTseg 이용, (b)첫 행: 문맥 정보를 사용치 않는 제안한 방법, 둘째 행: 문맥 정보를 사용치 않는 제안한 방법과 HMTseg 이용, (c)첫 행: 문맥 정보를 사용하는 제안한 방법, 둘째 행: 문맥 정보를 사용하는 제안한 방법과 HMTseg 이용

Fig. 8. Multiscale texture image segmentation results by each system, (a)first row: by HMT, second row: by HMT and HMTseg, (b)first row: by the proposed method without contexts, second row: by the proposed method without contexts and HMTseg, (c)first row: by the proposed method with contexts, second row: by the proposed method with contexts and HMTseg.

HMTseg 알고리즘을 적용하여 구한 MAP 분할 결과를 보였다. 또한 (b)의 첫 행의 그림들은 다중 스케일 웨이블릿 계수와 픽셀 밝기 값의 입력에 대한 신경회로망 출력으로 구한 다중 스케일 사후확률 값들과 식 (13)에 의한 다중 스케일 MAP 분할을 보였다. (b)의 두 번째 행은 (b)의 첫 행에 MAP 분할과 다중 스케일 사후확률 값들에 HMTseg 알고리즘을 적용하여 구한 MAP

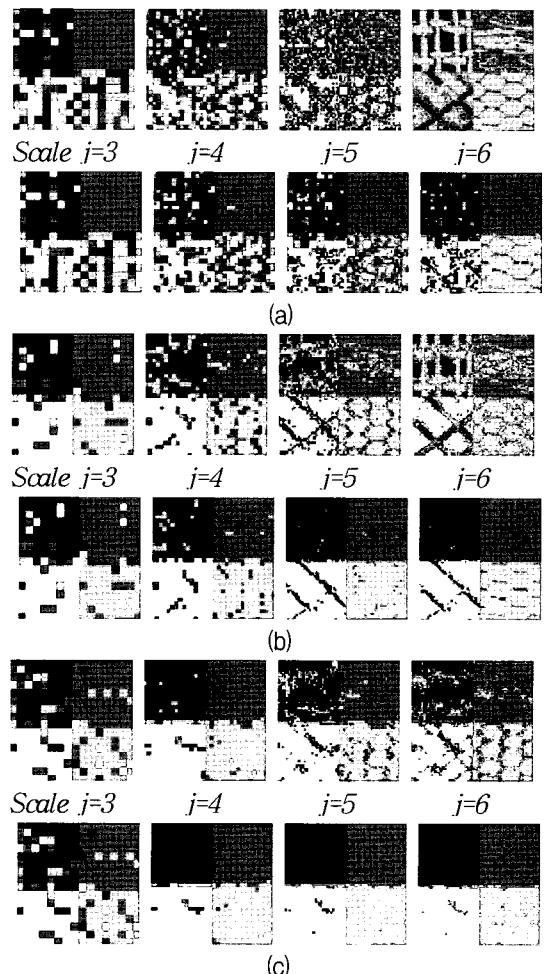


그림 9. 각 시스템에 의한 다중 스케일에서의 결 영상 분할 결과들, (a)첫 행: HMT 이용, 둘째 행: HMT와 HMTseg 이용, (b)첫 행: 문맥 정보를 사용치 않는 제안한 방법, 둘째 행: 문맥 정보를 사용치 않는 제안한 방법과 HMTseg 이용, (c)첫 행: 문맥 정보를 사용하는 제안한 방법, 둘째 행: 문맥 정보를 사용하는 제안한 방법과 HMTseg 이용

Fig. 9. Multiscale texture image segmentation results by each system, (a)first row: by HMT, second row: by HMT and HMTseg, (b)first row: by the proposed method without contexts, second row: by the proposed method without contexts and HMTseg, (c)first row: by the proposed method with contexts, second row: by the proposed method with contexts and HMTseg.

분할 결과를 보였다. 마찬가지로 (c)의 첫 행의 그림들은 다중 스케일 웨이블릿 계수와 픽셀 밝기 값, 그리고 HMT에 의한 likelihood를 문맥 정보로 고려한 입력에 대한 신경회로망 출력으로 구한 다중 스케일 사후확률 값들과 식 (13)에 의한 다중 스케일 MAP 분할을 보였다. (c)의 두 번째 행은 (c)의 첫 행에 MAP 분할과 다중 스케일 사후확률 값들에 HMTseg 알고리즘을 적용하여 구한 MAP

하여 구한 MAP 분할 결과를 보였다.

그림 7부터 그림 9까지에서 (a)와 (b)의 첫 행 그림들에서 보듯이 다중 신경회로망에 의한 분할 결과가 HMT에 의한 분할 결과 보다 전 스케일에 걸쳐 모두 좋으며, 특히 섬세한 스케일로 갈수록 HMT에 의한 것보다 더 분할 결과가 나이지는 것을 볼 수 있다. 이것은 신경회로망이 HMT에 비해 보다 정교하게 웨이블릿 계수들의 분포를 나타냄을 보여 주는 것이다. 그리고 HMT 알고리즘으로 후처리한 결과들인 (a)와 (b)의 두 번째 행에서 보듯이 HMT와 HMTseg에 의한 결과보다 다중 신경회로망과 HMTseg에 의한 결과가 훨씬 뛰어남을 볼 수가 있다. 이는 후처리 전의 다중 신경회로망에 의한 다중 스케일 분할 결과가 뛰어나므로 후처리 후의 최종화소 단위 영역에서의 분할 결과가 우수한 것이다.

그림 7부터 그림 9까지에 (c)의 첫 행의 분할 그림은 제안한 방법에 의해서 문맥을 고려한 효과를 보여 준다. (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 (c)의 첫 행의 분할 그림들은 주위의 이웃 문맥 정보를 이용함으로서 섬세한 스케일에서 국소적인 노이즈에 영향을 덜 받은 분할 결과를 보인다. (c)에서 보면 거친 스케일에서 보다 섬세한 스케일에서의 문맥 고려 효과가 더 큼을 볼 수 있다. 테스트 결 영상에 대하여 거친 스케일에서 문맥을 고려한 것이 문맥을 고려하지 않은 것보다 조금 좋거나 대부분이 거의 같은 분할 결과를 보인다. 그러므로 거친 영역에서는 문맥을 고려하지 않아도 될 것으로 보인다. 적당히 섬세한 영역들에서만 문맥을 고려하는 것이 HMTseg로 후처리로 했을 때의 분할 결과가 좋을 수가 있다. (c)의 두 번째 행의 HMTseg 후처리 후 결과는 (c)의 첫 행의 다중 스케일에서의 분할 결과가 좋으므로 (d)의 두 번째 행의 분할에 비해 대부분의 분할 결과가 좋다.

V. 결 론

본 논문에서는 다중 스케일 웨이블릿 계수를 결 영상의 특징으로 이용하여 다중 신경회로망 모델과 HMT 모델 및 HMTseg 알고리즘을 사용한 결 분할 방법을 제안하였다. 신경회로망의 입력을 구성하는데 있어서 웨이블릿 계수와 영상의 문맥 정보로서 HMT로부터 구한 likelihood값을 사용하였는데, 문맥 정보를 이용하는

것이 문맥 정보를 이용하지 않고 웨이블릿 계수만을 사용한 경우보다 섬세한 스케일에서 보다 개선된 영상 분할을 보였다. 제안 방법에 의한 결 분할은 같은 결 영상 특징을 이용하여 HMT 모델과 HMTseg 알고리즘을 사용한 결 분할에 비해 우수한 결 분할 결과를 보였다. 후처리로 사용한 HMTseg 알고리즘의 성능은 후처리 전의 분할 결과에 의존하는데, 실험 결과에서 보면 다중 신경회로망에 의한 결 분할 결과가 우수하므로 후처리 결과 또한 HMT를 사용한 방법보다 우수함을 보였다.

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] Hyekho Choi and Richard G. Baraniuk, "Multiscale Image Segmentation Using Wavelet-Domain Hidden Markov Models," *IEEE Transaction on image processsing*, vol. 10, NO. 9, September 2001.
- [16] M. D. Richard,, R. P. Lippmann,, "Neural Network Classifiers Estimate Bayesian à posteriori Probabilities," *Neural Computation*, vol. 3, pp. 461-483, 1991.
- [17] 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.
- [18] R. Rojas, "Short proof of the posterior probability property of classifier neural networks," *Neural Computation* 8, pp. 41-43, 1996.
- [19] Martin Reitmiller and Heinrich Braun, "A direct adaptive method for faster backpropagation learning: the Rprop algorithm", *Proceedings of the ICNN*, San Francisco, 1993.
- [20] 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.
- [21] 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.
- [22] Howard Demuth, Mark Beale, "Neural Network Toolbox For Use with MATLAB," The MathWorks, Inc., User's Guide Version 4, pp.164-182.

저자 소개



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

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



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>



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

1997년~현재 밀양대학교 정보통신학과 부교수
<주관심분야 : 통계신호처리, 영상처리, 웨이블릿
변환 신호처리, 신경회로망>