

유전자적 완화법에 의한 자기이항모형의 파라미터 추정과 질감 영상분할

(Parameter Estimation of Auto-Binomial Model using Selectionist Relaxation for Segmentation of Texture Images)

이 승 우 [†] 김 황 수 ^{**} 박 영 철 ^{**}

(Seung-Woo Lee)(Hwang-Soo Kim)(Young-Chul Park)

요 약 Markov 랜덤 필드(MRF)를 이용한 질감 영상의 영역분할은 각 영역을 기술해줄 수 있는 제대로 된 파라미터들을 찾는 것이 가장 중요하다. 종래에는 입력영상의 질감 영역의 수와 그 형태 등을 초기에 적당히 가정하여 파라미터를 찾는 방법을 써왔는데 실제 영상에는 잘 맞지 않았다. 최근에 완화법(Relaxation)을 이용하여 MRF의 파라미터를 찾는 방법이 제안[8]되었는데 오직 일반화된 Ising 모형에서만 사용가능 하였다. 본 논문에서는 비교적 자연영상에 적합한 자기이항 모형(Auto-binomial Model)에 변형된 완화법을 적용시켜 파라미터를 추정하고 질감 영상을 분할해 보았다. 그 결과 이전의 Ising 모형으로는 어려웠던 자연영상의 분할에서 좋은 결과를 얻을 수 있었다.

Abstract The use of MRF in unsupervised mode is hampered by the parameter estimation problem. Conventional solutions proposed to overcome this difficulty rely on assumptions about the shapes of the textured regions or about the number of textures in the input images that may not be satisfied in practice. Recently, a new evolutionary approach, selectionist relaxation, is proposed to solve the problem of segmenting GRF modeled textures in unsupervised mode. However, a weakness of the method is that it is applicable only to the generalized Ising Model. In this paper, a revised selectionist relaxation method is applied to the auto-binomial model. The new relaxation method is tested for a variety of textured images, such as synthesized textures and natural textures. Experimental results show that the proposed method has the potential to work well in segmenting natural textures.

1. 서 론

영상을 특성이 비슷한 다수의 영역으로 분할하는 영상분할은 영상 분석의 기본적 단계이다. 따라서 의료 영상처리, 원격탐사(remote sensing), 로봇 비전 등의 분야에서 많은 분할 기법들이 제시되고 이용되어 왔다[1]. 근래에는 영상분할에 대한 연구들이 주로 질감 영상 분할쪽에 주로 그 초점이 맞춰져 있는데 질감의 특징을 기술하는 문제로 인해 아직 어려운 문제로 남아있다.

MRF(Markov Random Field)를 이용한 질감 영상 분할의 일반적인 방법은 영상이 가지는 화소들을 랜덤 변수로 보고 그것에 근거하여 사후(a posteriori) 확률이 최대(MAP)가 되도록 레이블을 붙이는 것이다[1]. 이때 사후 확률이 최적화 되는 해를 찾는 방법으로 모의 담금질(simulated annealing) 등을 쓰기도 한다[2, 3]. 그러나 이러한 MAP의 계산이 제대로 되기 위해서는 먼저 그 영역을 기술하는 MRF의 파라미터들이 가급적 정확하게 알려져 있어야 한다. 따라서 미리 각 영역을 기술하는 MRF의 파라미터와 영역의 수 등이 알려져 있는 경우(Supervised mode)에 위의 방법이 좋은 해를 찾아 줄 수 있다. 그러나 대부분의 자연 영상은 그 영상을 기술하는 파라미터를 모를뿐더러 영역의 수 또한 알 수 없다. 이러한 경우(unsupervised mode) 영역의 파라미터를 추정하기 위해 분할된 영상이 필요하고 또 영상

[†] 비 회 원 : 경북대학교 전자계산학과
swlo53@kornet.net

^{**} 종신회원 : 경북대학교 컴퓨터과학과 교수
hsk@knu.ac.kr
ycpark@knu.ac.kr

논문접수 : 2000년 7월 1일
심사완료 : 2001년 1월 4일

을 분할하기 위해 영역의 수와 각 영역을 기술하는 파라미터를 알아야 하기 때문에 닭이 먼저냐 달걀이 먼저냐 하는 식의 문제에 빠지게 된다.

최근에 Andrey등에 의해 제시된 유전자적 완화(SR) 알고리즘은[8] 질감 영상이 몇 개의 영역으로 구분되어 있는가에 관한 사전지식 없이 또한 영역의 넓이에 관계 없이 영상을 비교적 잘 분할 시켜주는 알고리즘이다. Andrey등은 특별히, 일반화된 Ising 모형(generalized Ising Model 또는 Multi-Level Logistic:MLL Model)을 이용하였는데 일반화된 Ising 모형은 화소간의 화소값이 같든가 다른가에 의해서만 에너지 함수를 계산하므로 너무 단순화되어 실제 자연 영상을 나타내기에는 적합하지 않은 MRF 모형이다. 또한 그들이 우도 함수에서 사용한 분배 함수의 근사식은 일반화된 Ising 모형에서만 사용하기에 적합할 뿐 다른 모형에서는 사용이 어렵고 고온영역에서 잘 맞는 고온 근사라는 단점이 있다. 이러한 이유로 우리는 좀더 자연영상에 적합한 모형을 SR알고리즘에 적용해 보기로 하였다.

자기이항 모형(Auto-binomial Model)은 화소값이 같은가 다른가 뿐 아니라 어느 정도 같고 어느 정도 다른가 정도를 고려하여 에너지 함수를 계산하므로 자연 영상을 나타내기에는 적합한 MRF모형이다. 그래서 우리는 SR알고리즘에 자기이항모형을 적용시켰다. 자기이항모형을 이용한 수정된 완화 알고리즘을 적용시킨 질감 영상분할 결과를 일반화된 Ising 모형에 적용한 SR알고리즘과 비교하여 보았다. 그 결과 자연영상에서 보다 좋은 분할영상을 얻을 수 있었다.

2. 질감모형(Texture Model)

이 장에서는 영역, 질감 같은 영상의 특성을 모형화하기 위해 실험에서 이용한 MRF 모형을 소개하고 우도 함수의 계산을 위해 필요한 클리크(clique)의 정의 등에 대해 소개한다.

2.1 이웃 계(Neighborhood System)와 클리크

영상의 각 화소(pixel)가 차지하는 공간을 자리(site)라 할 때, 자리(s)들의 집합 S를 $S = \{s_1, s_2, \dots, s_Q\}$ ($Q=q \times q$; 영상의 크기)라 하고 $N = \{N_i, i \in S\}$ 가 두 가지 조건, 즉 i) $i \notin N_i$, ii) $i \in N_i \Leftrightarrow j \in N_i$ 를 만족시키면 N을 이웃 계라 한다. 여기서 N_i 는 자리 i의 이웃들의 집합이다. S의 부분집합 c의 모든 서로 다른 두 개의 자리가 서로 이웃일 때 우리는 그러한 집합 c를 클리크라고 부른다. (그림 1)에서 모형의 차수에 따른 이웃 구조와 몇 가지 클리크 형태를 나타내었다[9].




그림 1 이웃 계와 클리크

여기서 차수가 n인 자리 s의 이웃은 n과 작거나 같은 수로 표시되었다. 우측은 2차 모형의 10가지 클리크 형태들. 포텐셜계산의 편의성을 위해 실험에서는 X표시된 한 쌍으로 된(pair-wise) 클리크들 이외는 파라미터를 모두 0으로 둔다. $\alpha, \beta_1, \beta_2, \beta_3, \beta_4$ 는 각 클리크의 형태에 해당하는 파라미터를 나타낸다.

2.2 Markov 랜덤 필드

집합 S상에서 정의되는 랜덤변수들의 모임 $F = (F_1, F_2, \dots, F_m)$ 를 가정하자. 여기서 각 랜덤변수 F_i 는 이산적 레이블값들의 집합 $L = \{1, 2, \dots, M\}$ 내의 값 f_i 를 취한다. 이 때 이 랜덤변수들의 모임 F를 랜덤 필드라 한다. F_i 가 값 f_i 를 취하는 사건을 $F_i = f_i$ 로 나타내고 $(F_1 = f_1, F_2 = f_2, \dots, F_m = f_m)$ 는 joint 사건을 표시한다. 또한 간략화 시켜 랜덤 필드의 실현(realization)을 나타내는 F의 configuration $f = (f_1, f_2, \dots, f_m)$ 를 $F = f$ 로 나타내자. 그리고 집합 L에서 랜덤변수 F_i 가 f_i 를 취할 확률 $P(F_i = f_i)$ 를 $P(f_i)$ 로 결합 확률(joint probability) $P(F_1 = f_1, F_2 = f_2, \dots, F_m = f_m)$ 를 $P(f)$ 로 표현한다.

이 때 다음의 두 조건이 만족되는 필드 F를 이웃 계(neighborhood system) N에 대한 집합 S에서의 Markov 랜덤 필드(MRF)라 한다.

$$P(f) > 0, \quad \forall f \in \mathbb{J} \quad (\text{positivity}) \quad (1)$$

$$P(f_i | f_{S-(i)}) = P(f_i | f_N) \quad (\text{Markovianity}) \quad (2)$$

여기서 \mathbb{J} 는 집합 S의 가능한 모든 configuration을 나타내고

$$f_N = \{f_j | j \in N_i\} \quad (3)$$

이고 N_i 는 자리 i의 이웃 자리들의 집합을 나타낸다.

2.3 Gibbs 랜덤 필드

Configuration들이 다음의 Gibbs 분포를 따르는 랜덤 필드 F를 이웃 N에 대한 집합 S에서의 Gibbs 랜덤 필드(GRF)라 한다.

$$P(f) = Z^{-1} \times e^{-\frac{1}{T} U(f)} \quad (4)$$

여기서 규격화 상수

$$Z = \sum_{\{f \in \mathcal{C}\}} e^{-\frac{1}{T} U(f)} \quad (5)$$

를 분배함수(partition function)라 한다. T는 온도를 나타내는 상수이고 보통 1로 둔다. 그리고 $U(f)$ 는 에너지 함수이다. 에너지 함수의 계산에서는 특별히 클리크의 크기가 2인 경우가 많이 이용되고 그 경우 configuration f 의 에너지는

$$U(f) = \sum_{i \in S} V_1(f_i) + \sum_{i, j \in N_i} V_2(f_i, f_j) \quad (6)$$

로 나타낼 수 있다. 여기서 V_1, V_2 는 각 1차, 2차의 클리크 포텐셜을 의미하고 그 형태는 모형에 따라 여러 가지가 가능하다[9]. 이제 $P(f)$ 가 Gibbs 분포를 따른다면 조건부 확률은 다음과 같이 주어진다.

$$P(f_i | f_N) = \frac{\exp\{-[V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j)]\}}{\sum_{f_i \in S} \exp\{-[V_1(f_i) + \sum_{j \in N_i} V_2(f_i, f_j)]\}} \quad (7)$$

2.4 일반화된 Ising 모형

일반화된 Ising 모형(혹은 multi-level logistic:MLL 모형)은 이산상태 MRF중의 하나로 단일화소(single-pixel) 포텐셜의 경우는

$$V_1(f_i) = a_I \quad \text{if } f_i = I \in L \quad (8)$$

로 주어지고 여기서 a_I 는 레이블값 I 에 대한 포텐셜이다. 단일화소 이외의 클리크의 포텐셜은

$$V_c(f) = \begin{cases} -\beta_c & \text{클리크 } c \text{의 모든 } f_i \text{가 같은 밝기등급을 가지는 경우} \\ \beta_c & \text{그 이외의 경우} \end{cases} \quad (9)$$

의 형태로 주어진다. 여기서 β_c 는 c 형태(c -type)의 클리크에 대한 파라미터를 의미한다. 대개의 경우 그렇듯이 모형을 단순화하기 위해 우리는 2차의 일반화된 Ising 모형에서 2개 자리들간의 상호작용만을 고려할 것이므로 파라미터는 자리쌍(pair-site)들의 상호작용을 나타내는 $\beta_1, \beta_2, \beta_3, \beta_4$ 만 0이 아니고 나머지 파라미터는 모두 0으로 둔다. 따라서 일반화된 Ising 모형을 이용하는 실험에서 추정해야 하는 파라미터는 $\beta_1, \beta_2, \beta_3, \beta_4$ 의 네 개가 된다.

정의에서 볼 수 있듯이 MLL 모형은 클리크 포텐셜 함수가 한 클리크내의 화소값들의 동일여부에 의해서만 결정된다. 따라서 실제 자연영상을 표현하기에는 적합하지 않은 모형이다.

2.5 자기이항 모형(Auto-Binomial Model)

이항 모형(binomial model)은 [4]에서 처음으로 절감을 모형화 하기 위해 이용되었다. 만약 f_i 가 $\{0, 1, \dots, M-1\}$ 중의 한 값을 취한다면, f_i 는 다음과 같은, 1회 시행에서의 성공확률이 q 인 M 회의 독립시행에서의 조건부 이항분포를 따른다. 이항모형의 조건부 확률은 다음과 같이 주어진다.

$$P(f_i | f_N) = \binom{M-1}{f_i} q^{f_i} (1-q)^{M-1-f_i} \quad (10)$$

여기서

$$q = \frac{\exp\{a_i + \sum_{j \in N_i} \beta_{i,j} f_j\}}{1 + \exp\{a_i + \sum_{j \in N_i} \beta_{i,j} f_j\}} \quad (11)$$

이다. 이때 configuration f 의 에너지는 다음과 같은 형태를 가진다.

$$U(f) = - \sum_i \ln \binom{M-1}{f_i} - \sum_i a_i f_i - \sum_{(i,j)} \beta_{i,j} f_i f_j \quad (12)$$

여기서 $a_i, \beta_{i,j}$ 은 이항 모형의 파라미터들이다. 실험에서는 $a_i=0, \beta_{i,j} \in \{\beta_1, \beta_2, \beta_3, \beta_4\}$ 이다.

MLL 모형은 클리크 포텐셜 함수의 정의에 의해 한 클리크내의 화소들이 서로 다른 경우의 상호의존성과 서로 같은 경우의 상호의존성만을 고려한다. 그러나 이항 모형은 같은가 다른가에만 의존하지 않고 밝기등급이 비슷한 경우와 아주 다른 경우 등에 따라 상호 의존성을 고려한다. 즉, 얼마나 같고 얼마나 다른가에 대한 고려가 있다. 흔히 질감 모형으로 이용되는 가우시안(Gaussian) 모형은 근본적으로 연속적 랜덤변수에 적용되는 모형이므로 디지털 영상의 밝기등급처럼 이산적인 랜덤변수의 경우에는 오히려 이항모형이 더 적합할 것이다. 그렇기 때문에 본 논문에서는 GRF를 이용하는 질감영상분할모형으로 자기이항모형을 이용한다.

3. 우도 함수의 근사

우도 함수의 계산을 위하여 집합 S 를 코딩(coding)이라 불리는 몇 개의 집합 $s^{(k)}$ 로 분리한다.[그림 2] 이때 각 집합 $s^{(k)}$ 에 포함된 자리들은 자기들끼리 서로 이웃이 되지 않게 한다. 즉 서로에 대해 독립적이므로 우도 함수를 다음과 같이 쓸 수 있다.

$$P^{(k)}(f | \theta) = \prod_{i \in S^{(k)}} P(f_i | f_N, \theta) \quad (13)$$

여기서 우도를 최대로 하는 파라미터 $\theta^{(k)}$ 를 얻을 수 있다. 위의 식은 근사식이 아니다. 그러나 이 방법의 약점은 각 코딩에 대해서는 정확한 $\theta^{(k)}$ 를 얻을 수 있지만 그것이 우리가 원하는 θ 가 아니라는 것이다. 각 코딩에 대해 얻어낸 $\theta^{(k)}$ 를 이용하여 역시 근사의 θ 를 얻을 수 있다.

앞의 식(10)에서 보았던 자기이항모형의 조건부 확률에 의해 k 번째 코딩의 우도 함수는 다음과 같이 주어진다.

$$P^{(k)}(f) = \prod_{i \in S^{(k)}} P^{(k)}(f_i | f_N) = \prod_{i \in S^{(k)}} \binom{M-1}{f_i} q^{f_i} (1-q)^{M-1-f_i} \quad (14)$$

M 은 밝기등급의 개수이고 f_i 는 $\{0, 1, \dots, M-1\}$ 중의 한 값을 가진다. q 는 (11)식에서 주어졌다. 이제 f_i 를 영상

1	2	1	2	1
2	1	2	1	2
1	2	1	2	1
2	1	2	1	2
1	2	1	2	1

1	2	1	2	1
3	4	3	4	3
1	2	1	2	1
3	4	3	4	3
1	2	1	2	1

그림 2 4-neighbor에 대한 코딩(좌측)과 8-neighbor에 대한 코딩(우측). 표시된 수는 코딩 $s^{(k)}$ 에 속함을 나타낸다.

의 m 번째 행, n 번째 열의 화소라 하면(즉, $i=(m,n)$) 2차 모형에서

$$T = \alpha + \beta_1(f_{m,n-1} + f_{m,n+1}) + \beta_2(f_{m-1,n} + f_{m+1,n}) + \beta_3(f_{m-1,n-1} + f_{m+1,n+1}) + \beta_4(f_{m-1,n+1} + f_{m+1,n-1}) \quad (15)$$

이고 α 와 β_k 들은 이항 모형의 파라미터들이다. 이제 로그코딩우도(log coding likelihood) 함수는

$$\log P^{(k)}(f) = \sum_{i \in S} w_i \left\{ \log \binom{M-1}{f_i} + f_i T - (M-1) \log(1 + e^T) \right\} \quad (16)$$

로 정리할 수 있다. 각 코딩에 대해 얻은 우도 함수를 평균하여 configuration f 의 로그-우도(log-likelihood) 함수로 정한다.

$$\log P(f) = \frac{\sum_k \log P^{(k)}(f)}{K}, \quad (17)$$

$K =$ 코딩의 수(8-neighbor의 경우는 4)

4. 완화 알고리즘

사용한 완화법은 분산 유전자 알고리즘(distributed genetic algorithm)을 이용하여 점차적으로 분할된 영상을 찾아내는 무감독(unsupervised) 분할 방법이다. 먼저 각 화소에 대한 정보(파라미터와 레이블)를 저장하기 위해, 입력 영상을 읽어들이고 그것과 크기가 같은 2차원 배열을 만든다. 이때 배열의 각 성분을 유닛(unit)이라 하고 각 유닛은 한 세트의 파라미터로 이루어지는 파라미터 벡터(B)와 레이블(L)을 가진다. i 번째 유닛 U_i 의 적합성(fitness)은 파라미터 벡터 B_i 가 i 번째 자리를 중심으로 하는 적당한 크기의 질감 영상의 창 W_i 에 얼마나 잘 맞는가를 나타낸다. 전체 유닛들의 집합을 유전자 알고리즘에서의 population으로 두고 알고리즘을 적용시키면 적합성이 큰 유닛들이 점차적으로 적합성이 작은 것들을 대신해 가면서 완화가 진행되어 간다. 이 과정에서 유닛 U_i 는 주로 그것의 이웃 N_i 에 있는 유닛들과 작용한다.

4.1 적합성과 유닛

위에서 기술한대로 입력 영상의 각 자리 i 는 유닛 U_i

와 연관되어 있다. 유닛 U_i 는 질감 모형 파라미터들의 벡터($B_i = \beta_{i,1}, \beta_{i,2}, \dots, \beta_{i,k}$)와 레이블 L_i 로 이루어지며 L_i 는 자리 i 에 할당된 레이블이다. 유닛 전체의 집합을 $U = \{U_i, i \in S\}$ 을 population이라고 부른다. 완화가 만들어 내는 최종적인 출력 영상은 $L(\infty) = \{L_i(\infty), i \in S\}$ 이다. 여기서 ∞ 는 완화가 멈추는 시간을 의미한다. 각 유닛 U_i 에는 적합성 $F(U_i)$ 가 할당된다. 이것은 자리 i 를 중심으로 하는 $w \times w$ 크기의 질감 창 W_i 에 U_i 가 가지고 있는 파라미터들이 질감 모형에 얼마나 잘 맞는가 하는 정도를 나타낸다. 이 적합성의 척도가 우도 함수 $P(f_{W_i}; B_i)$ 이다. 그러나 일반적인 경우 정확한 우도 함수를 계산할 수 없으므로 (17)식의 결과를 적합성의 함수로 이용한다. 또한 각 유닛 U_i 는 레이블 L_i 가 이웃에 있는 모든 유닛들의 레이블과 같은가 다른가에 따라 상태(state)가 정해진다. 유닛 U_i 의 상태 S_i 는 다음과 같이 정해진다.

$$S_i = 0 \quad \text{if } L_r = L_i, \quad \forall r \in N_i$$

$$S_i = 1 \quad \text{그 외}$$

4.2 초기화

완화법의 초기단계는 초기 population $U(0)$ 를 다음과 같이 설정하는 것이다. 먼저 각 유닛 U_i 의 파라미터 벡터 B_i 의 각 성분 $\beta_{i,k}$ 에 적당한 간격 $[-\delta, \delta]$ 에서 랜덤 추출한 값을 할당한다. 그리고 초기의 유닛 레이블 L_i 는 자리 i 의 일련번호를 준다. 그래서 초기단계에는 영상내의 화소의 수만큼의 레이블들이 있고 모든 자리들의 상태는 1이다.

4.3 완화법

유닛들의 population이 초기화되고 난 이후의 완화 과정은 다음과 같이 진행되어 간다. 먼저 시간 t 에서의 population $U(t)$ 에 선택(selection) 연산자를 적용한다. 그 다음으로 교차(crossover)와 변이(mutation)를 거쳐 population $U(t+1)$ 이 결정된다. 연산자들은 유닛의 상태에 따라 다르게 적용된다. 선택 연산자를 적용할 때, 상태가 0인 자리는 오직 자기의 neighbor에 있는 유닛들과 경쟁하지만 상태가 1인 유닛의 경우는 거기에 임의의 거리만큼 떨어져 있는 하나의 자리가 더 추가된다. 이렇게 함으로써 서로 떨어져 있어도 같은 질감일 경우는 같은 레이블이 할당되도록 해준다. 만일 이렇게 해주지 않는다면 항상 서로 분리되어 있는 영역의 수만큼 레이블 값이 할당될 것이다. 그래서 실제로는 같은 질감을 가지는데 서로 떨어져 있기 때문에 다른 질감을 가지는 영역으로 분할될 것이다. 다음 단계에서의 교차와 변이 연산자는 상태가 0인 자리에만 적용된다. 이것은

영상 분할에서 상대적으로 중요한, 경계를 이루는 자리가 교차와 변이에 의해 갑작스럽게 그 적합성이 변하게 되는 것을 방지해 준다.

(1) 선택(Selection) : 완화 과정에서 적용되는 선택연산자는 토너먼트 선택의 변형인 로컬 토너먼트 선택연산자이다. population U 의 부분 집합인 U_i 에서 적합성이 가장 큰 유닛이 선택되어 자리 i 의 유닛을 대체한다. 이때 부분 집합 U_i 는 다음과 같이 결정된다.

if $S_i = 0$ then $U_i = \{U_r, t \in N_i\}$
 if $S_i = 1$ then $U_i = \{U_r, t \in N_i \cup \{r\}\}$

여기서 r 은 무작위로 선택된 자리이다.

(2) 교차(Crossover) : 상태가 0인 경우에만 적용된다. 교차 확률 P_c 에 따라 neighbor에 있는 유닛 $U_r, r \in N_i$ 이 무작위로 선택되고, U_i 의 파라미터 벡터 B_i 의 성분 중에서 무작위로 선택된 한 성분을 유닛 U_r 의 파라미터 벡터 B_r 의 대응 성분으로 대체 시킨다.

(3) 변이(Mutation) : 상태가 0인 경우에만 적용된다. 변이 확률 P_m 에 따라 U_i 의 파라미터 벡터 B_i 의 한 성분을 무작위로 선택하여 $[-\delta, \delta]$ 에서 무작위로 선택한 값으로 대체시킨다.

```

· 초기화
유닛 U의 초기화{
    각 유닛에
        i) 임의의 파라미터값 할당
        ii) 일련번호를 레이블로 할당
}
· relaxation
반복{ //영상내의 모든 화소에 대해
1. 선택{ //모든 i(유닛)에 대해
    ①  $B_i$ (파라미터 벡터)의 질감 창  $W_i$ 에 대한
    적합성(우도 함수)계산 - (17식)
    ② if not boundary{
        이웃들과 우도 함수를 비교
    }
    if boundary{
        이웃 + 임의의 거리에 자리와
        우도 함수를 비교
    }
    값이 최대가 되는 유닛으로 갱신
    - 파라미터와 레이블을 갱신
}
2. if not boundary{
    교차와 변이
    (유닛이 가지는 파라미터들만 변화)
}
}
· return U.
    
```

그림 3 알고리즘

5. 실험결과

합성된 영상과 자연영상에 대해 일반화된 Ising 모형을 적용시킨 SR 알고리즘과 자기이항 모형을 적용시킨 SR 알고리즘을 이용하여 영상을 분할하였다. MRF 모형을 이용하여 합성된 영상은 8개의 밝기등급을 가지는 128×128 의 크기를 가지는 영상이다. 질감은 Metropolis Sampler[2]를 이용하여 50스텝을 반복시킨 영상이다. 완화 과정에서 각 유닛은 8-neighbor를 가지고 ($N_i = 3 \times 3$) 적합성을 계산하기 위한 창 크기 (w)는 질감의 조밀성에 따라 조절하여야 하는데 크게 잡아줄수록 질감의 적합성이 정확해 지겠지만 그만큼 경계부근에서 오차가 커지게 되고 계산 시간도 많이 걸린다. 영상내의 질감의 종류의 수는 완화 과정을 통해 자동으로 결정된다. 분할의 정확도를 보기 위한 오차율을 전체 영상의 자리의 개수에 대한 잘못 분할된 자리의 개수의 비로 정의하였다.

5.1 자연영상으로 합성된 영상의 분할

위에서와 같은 분할영역을 Brodatz의 질감 영상으로 합성시킨 영상을 분할해 보았다. 합성된 영상은 전처리를 거쳐 8개의 밝기등급을 갖도록 하여 분할 영상으로 사용하였다. MRF 모형을 자연영상에 적용할 경우 적합성 테스트를 위한 창 크기가 충분히 커야 비교적 율




그림 4 (a)합성된 영상 (b)실제 분할영상 (c)수정된 SR알고리즘을 (a)에 적용한 분할영상 (d) 일반화된 Ising모형을 이용한 SR알고리즘을 (a)에 적용한 분할영상

바른 우도 함수 값을 계산할 수 있을 것이다. 실험에서는 창의 크기를 19×19로 하였다. 그림에서 볼 수 있듯 자연 영상으로 합성된 영상의 경우 일반화된 Ising 모형은 영역을 제대로 분할해 내지 못하고 있다. 반면 이항 모형을 적용한 분할의 경우는 비교적 잘 분할을 수행하고 있음을 알 수 있다. [그림 4]

5.2 자연영상

다음으로 합성된 영상이 아닌 실제 자연 영상의 분할에 두 알고리즘을 적용시켜 보았다. 같은 영상에 두 알고리즘을 적용시킨 결과는 그림5, 6에서 볼 수 있다. 두 알고리즘 모두 15×15의 창의 크기를 이용하여 600 스텝을 거쳐 분할되었다. 이항 모형을 적용한 알고리즘이 자연영상의 분할에도 비교적 잘 적용될 수 있음을 볼 수 있다. 결과에서 질감 영역이 잘 나타나지 않는 부분에서는 분할 결과가 그다지 좋지 않지만 질감의 특성이 잘 나타나는 부분(그림 5에서의 소파부분 등)은 이항 모형을 적용한 알고리즘이 영역을 잘 분할해 주고 있음을 확인할 수 있다.

우리는 이상의 결과에서 수정된 SR알고리즘이 질감 영상을 분할하는데 보다 더 좋은 결과를 보여주고 있음을 확인할 수 있었다. 위에서 예로 보았던 몇 가지 영상들에 대해 분할의 정확성을 보기 위해 분할의 오차를 계산해 보았다. 오차는 합성된 영상의 경우 영역이 확실하므로 전체 영상의 화소의 개수에 대한 잘못 분할된

화소의 개수의 비로 정의하였다. 그렇지만 자연 영상의 경우는 질감의 영역을 정확히 알 수 없기 때문에 등화(equalization)를 통하여 밝기등급을 8개로 줄인 영상을 직접 구분하여 분할한 영역과 비교하여 오차를 계산하였다.

$$\text{오차}(\%) = (\text{잘못 분할된 화소의 수}) / (\text{영상의 전체 화소 수})$$

표 1 SR 알고리즘과 수정된 SR 알고리즘의 분할 오차 비교

영상	알고리즘 일반화된 Ising 모형을 이용한 SR 알고리즘	수정된 SR 알고리즘
자연영상으로 합성된 영상(그림4)	0.5321	0.0548
자연영상(그림5)	0.4934	0.1238
자연영상(그림6)	0.3662	0.0731

6. 결 론

SR알고리즘은 영상내의 미지의 영역의 수에 대한 사전지식이 없이도 영역을 효과적으로 분할할 수 있다는 장점을 가지고 있다. 그렇지만 이 알고리즘은 제한된 모형과 제한된 가정 하에서 이용될 수 있고 그래서 실제 자연영상의 영역분할에는 효과적이지 못한 결과를 보여주었다. 그런 단점을 극복하기 위해 우리는 확장된 에너지 모형과 우도 함수를 이용하고 다듬어 개선된 알고리즘을 만들 수 있었다.

자연영상으로 합성된 영상과 자연영상에 대해 각각 일반화된 Ising 모형을 적용시킨 SR 알고리즘과 자기이항모형을 적용시킨 SR 알고리즘을 이용하여 영상을 분할한 결과를 보았다. 결과에서 볼 수 있듯이 이항모형의 경우는 어떤 경우는 비교적 잘 영역을 구분해 주었다. 물론 일반화된 Ising 모형을 적용하는데 있어 적합성 테스트를 위한 창의 크기를 좀더 크게 잡아주고 우도 함수의 값을 계산하기 위한 모형의 차수(order)를 크게 하여 분할영상을 구해볼 경우 좀더 나은 결과가 나올 것이라 예측해볼 수도 있었으나 실험에서 적용한 자기이항모형의 경우는 2차의 모형만을 이용하여 위에서와 같은 비교적 좋은 분할결과를 얻을 수 있었다. 이상에서 우리는 이산화(digitize)된 질감 영상을 MRF로 모형화 하는데 있어 이산화클러스터를 이용하는 자기이항 모형이 좋은 결과를 나타내 주고 있음을 알 수 있었다.

우도함수의 계산에서는 Andrey등이 사용한 고은 근사의 계산이 시간상으로는 상당히 빠르다는 장점이 있




그림 5 (a) 자연영상 (b) 수정된 SR알고리즘을 적용한 분할영상 (c) 일반화된 Ising 모형을 이용한 SR알고리즘을 적용한 분할영상




그림 6 (a)자연영상 (b)수정된 SR알고리즘을 (a)에 적용한 분할영상 (c) 일반화된 Ising 모형을 이용한 SR알고리즘을 (a)에 적용한 분할영상

다. 그렇지만 역시 계(system)의 온도가 높다는 가정 하에서만 적용할 수 있는 고온 근사라는 약점을 가지고 있고 모형의 차수를 크게 잡아줄수록(3차 이상) 포텐셜 계산을 위한 클리크의 형태가 많아지므로 에너지 계산이 아주 복잡해진다는 단점을 가지고 있다. 그리고 일반화된 Ising 모형이 아닌 다른 에너지 모형에 대해서는 그 근사식이 수학적으로 계산이 너무 난해하기 때문에 다른 모형에서는 근사식을 이용할 수 없다는 단점이 있다. 이에 반해 본 논문에서 이용한 코딩 방법을 통한 우도함수의 계산은 계산속도가 조금 느린 단점을 가지고는 있으나 여타의 다른 에너지 모형에도 또 고차의 모형에서도 쉽게 적용될 수 있어 실험에서 이용하였다.

참 고 문 헌

- [1] F. S. Cohen and D. B. Cooper. Simple parallel hierarchical and relaxation algorithms for segmenting noncausal Markovian random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(2), 195-219, 1987.
- [2] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6), 721-741, 1984.
- [3] R. Hu and M. M. Fahmy. Texture segmentation based on a hierarchical Markov random field model. *Signal Processing*, 26, 285-305, 1992.
- [4] S. Lakshmanan and H. Derin. Simultaneous parameter estimation and segmentation of Gibbs random fields using simulated annealing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(8), 799-813, 1989.
- [5] B. S. Manjunath, R. Chellappa. Unsupervised texture segmentation using Markov random field models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(5), 478-482, 1991.
- [6] H. H. Nguyen and P. Cohen. Gibbs random fields, fuzzy clustering, and the unsupervised segmentation of textured images. *CVGIP: Graphical Models and Image Processing*, 55(1), 1-19, 1993.
- [7] C. S. Won and H. Derin. Unsupervised segmentation of noisy and textured images using Markov random fields. *CVGIP: Graphical Models and Image Processing*, 54(4), 308-328, 1992.
- [8] P. Andrey and P. Tarroux. Unsupervised segmentation of Markov random field modeled textured images using selectionist relaxation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3), 252-262, 1998.
- [9] S. Z. Li *Markov Random Field Modeling in*

Computer Vision. Springer-Verlag, Tokyo, 1995.

- [10] G. R. Cross and A. K. Jain. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9, 25-39, 1983.



이 승 우

1991년 경북대 물리학과 졸(학사). 1994년 경북대 물리학과 석사. 1996년 경북대 물리학과 박사수료. 1999년 경북대 전자계산학과 석사. 관심분야는 컴퓨터 비전, 신경망, 영상처리 등임



김 황 수

1975년 서울대학교 공과대학 전기공학과 졸업(학사). 1988년 미국 미시간 대학원 EECS과 졸업(석사,박사). 1989년 ~ 현재 경북대학교 자연대 컴퓨터과학과 부교수. 관심분야는 컴퓨터 비전, 신경망, 영상처리, 컴퓨터그래픽 등임



박 영 철

1977년 서울대학교 전기공학과 졸업(학사). 1981년 서울대학교 전기공학과 졸업(석사). 1986년 Northwestern University(전산학, 석사). 1989년 Northwestern University(전산학, 박사). 1981년 ~ 1993년 울산대학교 전자계산학과 부교수. 1990년 ~ 1992년 울산대학교 중앙전자계산소 소장. 1991년 ~ 1992년 한국전자통신연구원 초빙연구원. 1992년 ~ 1994년 한국정보과학회 데이터베이스연구회 운영위원. 1993년 ~ 현재 경북대학교 컴퓨터과학과 부교수. 관심분야는 데이터베이스 시스템, 객체관계형 데이터베이스, 질의 처리, 트랜잭션 처리 등임.