

論文 95-5-23

MRF 모델과 갑스 샘플러를 이용한 영상분할

正會員 元致善*

Image Segmentation Using MRF Models and Gibbs Sampler

Chee Sun Won* Regular Members

要 約

본 논문에서는 갑스 샘플러를 이용한 새로운 영상분할 알고리즘을 제안한다. 제안된 알고리즘의 자율적 (unsupervised) 버전은 갑스 샘플러와 가치기준의 최대화 (GSM: Gibbs Sampler and Maximizer)를 번갈아 가며 실행하는 것이다. 즉, 현재까지의 영역라벨 예측값을 이용하여 모델 파라미터를 예측하고, 또 예측된 모델 파라미터를 이용하여 갑스 샘플러에 의해 새로운 영역라벨 실현을 얻는 것이다. 제안된 GSM 알고리즘은 영역라벨이 “확률적 (probabilistic)”으로 생성된다는 점이 기존의 자율적 영상분할 알고리즘의 “결정적 (deterministic)” 영역라벨 생성과 다른 점이다. 따라서 GSM 알고리즘은 근처의 국부최대치를 벗어나 더 많은 영역라벨의 실현중에서 국부최대치를 찾을 가능성이 높다. 실험결과도 GSM 알고리즘이 기존의 자율적 영상분할 알고리즘보다 똑같은 반복횟수에 더 낮은 에러율을 나타냄을 확인하였다.

ABSTRACT

In this paper, we propose a new image segmentation algorithm based on the Gibbs sampler. The unsupervised version of the proposed algorithm is an alternate Gibbs Sampler and Maximizer (GSM), which estimates model parameters based on the current region label estimates and then, using the estimated model parameters, obtains a sample of the region label realization by the Gibbs sampler. The proposed GSM algorithm is different from the conventional unsupervised segmentation algorithms in that the region label is updated “probabilistically”, whereas the conventional unsupervised segmentation algorithm updates region label “deterministically”. Therefore the GSM algorithm has a higher possibility to escape from the nearby local maximum. Experimental results consistently show that the proposed GSM algorithm yields lower error rates with the same number of iterations than the conventional deterministic unsupervised segmentation algorithms.

* 동국대학교 전자공학과

Dongguk Univ., Dept. of Electronics
Engineering

論文番號: 9573-0218

接受日字: 1995年 2月 18日

I. 서론

영상분할 (image segmentation)은 컴퓨터의 영상 인식이나 영상압축 등을 위한 전처리 단계로 주어진 영상을 의미있는 몇개의 영역으로 분할하는 과정이다. 이와 같은 영상분할 문제의 정의는 구체적으로 잘 정의된 것은 아니다. 예를 들어, “의미있는 영역”은 어떤 척도로 판정한 의미있는 영역이며, “몇개”는 어떤 척도로 결정할 것인가 하는 문제가 분명하게 정의되어 있지 않다. 따라서 그 해결책도 특정한 종류의 영상에만 적용된다거나 자동적이 아닌 다소 경험적인 방법들이 제안될 수 밖에 없다. 그러나 영상에 MRF (Markov Random Field)와 같은 추정통계적 (stochastic) 모델을 도입하면 영상분할의 문제를 예측-이론적 (estimation-theoretic)인 가치기준 (criterion)을 이용하여 새롭게 정의할 수 있다. 그러므로 영상분할의 해결책도 분명한 의미에서 최적인 해를 구할 수 있게 되었다⁽¹⁾⁻⁽⁵⁾.

추정통계적 모델을 이용한 영상분할이 실제의 자연적인 동영상에 적용되어 활용되기 위해 아직도 해결되어야 할 문제들이 있다. 그 중에 가장 중요한 두 가지 문제는 다음과 같다. 첫째, 영상분할이 동영상의 영상인식이나 영상압축을 위한 전처리 단계로 사용되기 위해서는 우선 그 처리 시간이 짧아야 한다는 것이다. 즉, 실시간 처리가 가능해야 한다. 물론 처리시간과 영상분할의 성능 사이에는 서로 대립적인 관계가 있으므로 어느 정도의 영상분할 성능을 유지하면서 처리 시간을 감축시키는 것이 관건이 된다. 두번째 문제는 광범위한 종류의 자연영상의 분할에 추정통계적 방법을 적용하기 위해 모델의 파라미터나 특징적인 영역의 갯수를 주어진 영상으로부터 예측하여 영상분할에 사용할 수 있는 자율적 (unsupervised) 영상분할 알고리즘이 개발되어야 한다는 것이다.

본 논문에서는 추정통계적 모델의 파라미터들을 주어진 영상에서 예측하고, 예측된 모델 파라미터를 이용하여 영상을 분할하는 기존의 자율적 영상분할 알고리즘⁽³⁾⁽⁴⁾⁽⁵⁾들과 비슷한 처리속도를 유지하면서 최종 분할 성능을 향상시킬 수 있는 새로운 영상분할 알고리즘을 제안한다. 제안된 영상분할 알고리즘은 갑스 샘플러 (Gibbs Sampler)⁽⁶⁾를 이용하며, 자율적 버전은 갑스 샘플러와 가치기준의 최대화 과정을 번갈아가며 수행하므로 본 논문에서는 GSM (Gibbs Sampler and

Maximizer) 알고리즘으로 부른다.

본 논문은 다음과 같이 구성되어 있다. 제II장에서는 영상의 추정통계적 모델과 기존의 자율적 영상분할 알고리즘들을 소개하고, 제III장에서는 갑스 샘플러를 이용한 의존적 (supervised) 영상분할 알고리즘과 모델의 파라미터 값도 주어진 영상으로부터 예측하는 자율적 영상분할 (GSM) 알고리즘을 제안한다. 제안된 GSM 알고리즘의 성능 평가를 위해 제IV장에서 합성된 영상과 자연영상에 적용하여 비교하였다. 마지막으로 제V장의 결론으로 본 논문을 마감한다.

II. 기존의 자율적 영상분할 알고리즘

디지털 영상의 2차원 공간을 구성하는 격자점들의 집합을 $\Omega = \{(i, j) \mid 1 \leq i \leq N_1, 1 \leq j \leq N_2\}$ 로 나타낼 때 각 격자점에 존재하는 랜덤변수는 직접 관찰 가능한 주어진 영상의 밝기세기에 대한 랜덤변수의 집합 $Y = \{Y_t, t \in \Omega\}$ 과 그것의 한 실현 (realization)인 $y = \{y_t, t \in \Omega\}$, 그리고 분할된 영상의 각 영역의 라벨링에 관한 랜덤변수의 집합 $X = \{X_t, t \in \Omega\}$ 과 어떤 특정의 분할된 영역을 나타내는 라벨값의 집합 $x = \{x_t, t \in \Omega\}$ 로 나타낸다. 이때, 어떤 픽셀 t 에서의 영역라벨 $X_t = x_t$ 는 $\{1, \dots, G\}$ 중에 한 개의 값을 갖는다. 따라서 주어진 영상에 존재하는 서로 다른 특성의 분할된 영역의 갯수는 G 개이며, 모든 가능한 영역라벨 실현 x 의 갯수는 $G^{N_1 N_2}$ 개다. 각 영역을 특징짓는 것은 각 영역 고유의 질감특성이나 잡음특성이다. 본 논문에서는 각 영역의 특징을 일정밝기의 세기에 독립적인 가우시안 잡음이 가산된 형태를 가정한다⁽¹⁾⁻⁽⁵⁾. 즉, 픽셀 t 에서의 밝기의 세기 $Y_t = y_t$ 는 $x_t = g \in \{1, \dots, G\}$ 로 할당되어 있을 때 g 영역의 원래의 밝기의 세기 r_g 에 평균값이 0이고 분산이 σ^2 인 독립적 가우시안 잡음이 더해진 형태로 모델링된다. 따라서

$$P(Y|X) = \prod_{t \in \Omega} P(Y_t | \theta_Y, X_t) \quad (1)$$

$$P(Y_t = y_t | \theta_Y, X_t = g) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_t - r_g)^2}{2\sigma^2}} \quad (2)$$

이며 Y 와 관련된 모델의 파라미터 θ_Y 는 $\theta_Y = \{\sigma^2, r_1, \dots, r_G\}$ 로 주어진다. 랜덤필드 X 는 이웃시스템 (neighborhood system) $\eta = \{\eta_t : t \in \Omega\}$ 에 대한 MRF

(Markov Random Field) 모델을 사용한다⁽¹⁾⁻⁽⁶⁾. 즉, 국부조건부확률 (local conditional probability)이 다음의 등식을 만족한다.

$$\begin{aligned} P(X_t = x_t | X_{q-t} = x_q, q \in Q, q \neq t) \\ = P(X_t = x_t | X_{q-t} = x_{q-t}) \end{aligned} \quad (3)$$

여기서 q 는 $t \in Q$ 에 대한 이웃 픽셀들의 집합으로 $t \in \eta_t$ 이며, $q \in \theta_t$ 는 곧 $t \in \eta_q$ 를 의미한다⁽¹⁾⁻⁽⁶⁾. MRF 모델의 특성은 다른 모든 픽셀에서의 영역라벨 값이 주어진 상황에서 어떤 특정점 t 의 영역라벨에 대한 조건부확률은 그 중에 t 와 이웃인 집합 t 내에 있는 영역라벨의 값에만 의존하는 특성으로, 영상의 밝기의 세기가 2차원적으로 연속적이라는 점에서 합리적이며 계산의 복잡성을 훨씬 줄일 수 있는 유용한 특성이다. 또한 MRF와 GRF (Gibbs Random Field)의 동등성 (equivalence)⁽⁶⁾에 의해 영역라벨의 모델 X 를 깁스 분포를 갖는 조인트 확률의 형태로도 나타낼 수 있다. 본 논문에서 사용한 X 의 깁스 분포는 영상분할의 문제에 많이 사용되어온 MLL (Multi-level Logistic) 분포⁽¹⁾⁻⁽⁵⁾을 채택한다. 특히, 각 픽셀의 8방향 8개의 이웃 픽셀로 이루어진 2차 이웃시스템에서 중심 픽셀과 각 8방의 픽셀로 이루어진 8개의 쌍-클릭 포텐셜 (Pair-Clique Potential)에 대해 모두 같은 포텐셜을 갖도록 하였다. 이때 X 의 조인트 분포는 다음과 같이 나타낼 수 있다.

$$P(X = x) = \frac{e^{\beta v(x)}}{\sum_x e^{\beta v(x)}} \quad (4)$$

여기서 $v(x)$ 는 특정 실현 x 에 대해 모든 픽셀에 대한 2차 이웃시스템 중 쌍-클릭이 서로 같은 영역라벨을 갖는 쌍-클릭의 갯수에서 서로 다른 영역라벨을 갖는 쌍-클릭의 갯수를 뺀 값을 나타내고 는 쌍-클릭의 포텐셜로 X 의 파라미터가 되어 $\theta_x = \beta = \gamma$ 된다. 영상분할의 문제에 적용된 경우 값은 비교적 넓은 범위 (0.5-1.2)에서 영상분할의 결과에 민감하지 않고 좋은 결과를 내므로 보통 값은 아는 것으로 가정하고 고정하여 사용한다.

X 와 Y 에 대한 확률적 모델이 확정되면 자율적 잡음 영상 분할의 문제는 Y 의 실현 y 로부터 x 와 θ_y 의 최적 예측치 (x^*, θ_y^*) 를 얻는 것이다. 이를 위해 Besag⁽³⁾은

ICM (Iterative Conditional Mode)을 자율적 알고리즘으로 확장한 UICM (Unsupervised ICM)을 제안하였다. UICM은 최근의 반복주기까지 생성된 영역라벨로 부터 모델의 파라미터를 예측하고, 또한 새롭게 예측된 모델의 파라미터를 이용하여 영역라벨을 번갈아가면서 생성하는 알고리즘이다. UICM과는 달리 참고문헌(4) (본 논문에서는 Won-Derin 알고리즘으로 부름)에서는 모델 파라미터의 ML (Maximum Likelihood) 예측값이 영역라벨과 주어진 데이터의 단한표현 (closed-form)을 갖는 경우 ML 표현식을 원래 최적화하려는 가치기준에 대입하여 해당 모델 파라미터 변수를 영역라벨만의 함수로 바꾸어 영역라벨만을 반복적으로 생성하는 알고리즈다. 즉, UICM 알고리즘에서 영역라벨에 대한 추정 \hat{x} 이 주어졌을 때 θ_y 은 조건부확률 $P(Y | \theta_y, \hat{x})$ 를 최대로하는 ML 예측값이고, 주어진 θ_y 에 대해 $t \in Q$ 에서의 영역라벨 x_t 의 생성은 주어진 영상 데이터 y 와 픽셀 t 에서의 영역라벨을 제외한 이전의 반복과정 (iteration)에서의 예측값의 집합 $\hat{x}_{t-1} = \{\hat{x}_s : s \in Q, s \neq t\}$ 가 주어진 상태에서 국부조건부확률을 최대로하여 얻는다. 즉, \hat{x} 는 $P(x_t | y, \hat{x}_{t-1}, \theta_x, \theta_y)$ 를 모든 가능한 x_t 에 대해 최대로 하는 값 \hat{x}_t 의 모든 $t \in Q$ 의 집합이다. 이와 같이 \hat{x} 와 θ 가 번갈아가며 반복적으로 생성된다. 반면에 Won-Derin 알고리즘에서 영역라벨 x_t 의 생성은, $\theta_y(x_t, \hat{x}_{t-1})$ 을 $P(Y | \theta_y, x_t, \hat{x}_{t-1})$ 에 대한 θ_y 의 ML 예측값이라고 할 때, 조건부확률 $P(x_t | y, \hat{x}_{t-1}, \theta_y(Y(x_t, \hat{x}_{t-1}))$ 를 x_t 에 대해 최대로 하는 값이다.

Won-Derin 알고리즘은 각 픽셀의 영역라벨 생성시에 모델 파라미터가 항상 ML 예측값을 유지하도록 하므로써 영역라벨의 변화로부터 발생하는 파라미터 값의 변화를 바로 영역라벨의 생성에 반영한다. 즉, Won-Derin 알고리즘은 가치기준을 영역라벨과 모델 파라미터에 대해 동시에 최대화하므로 UICM의 경우보다 초기 수렴속도는 빠르나 훨씬 쉽게 국부최대치에 수렴한다. 즉 주어진 영역라벨 값이 국부최대치의 근처에 있을 때 Won-Derin 알고리즘은 의한 영역라벨 생성은 항상 모델 파라미터의 ML 예측치를 반영하므로 쉽게 근처의 국부최대치에 수렴할 가능성이 높으나, UICM의 경우 모델 파라미터가 ML값을 유지하지 않더라도 우선 영역라벨 값들을 이전의 모델 파라미터의 예측값에 따라 모든 픽셀을 방문하여 생성하므로 모델 파라미터와 영역라

별 모두에 대해 동시에 최대화하려는 Won-Derin 알고리즘 보다 근처의 국부최대치를 벗어날 가능성이 높다⁽⁵⁾.

III. 김스 샘플러를 이용한 영상분할

UICM⁽³⁾과 Won-Derin⁽⁴⁾의 자율적 영상분할 알고리즘들의 공통적인 한계는 이들 알고리즘들이 결정적(deterministic)인 영역라벨 갱신 규칙에 의해 영상분할의 결과를 얻으므로 채택한 가치기준의 국부 최대치의 수렴만 보장하는 것이다. 물론 SA (Simulated Annealing)(α)와 같은 추정 통계적 이완(stochastic relaxation)알고리즘을 적용하여 전체 최대치(global maximum)의 수렴을 얻을 수 있지만 이론적인 SA 과정이 너무 많은 계산량(즉, 계산 시간)을 필요로 하므로 실시간 적용에 어려움이 있다. 따라서 기존의 결정적 이완 알고리즘(즉, Won-Derin, UICM 및 열 단위 영상분할)과 SA의 중간적인 특성을 갖는, 즉 국부 최대치를 찾되 넓은 범위의 국부 최대치를 가능한 많이 수렴하여 좀 더 향상된 국부 최대치에 접근하는 방법이 요구된다.

본 논문에서는 기존의 Won-Derin, UICM 및 열 단위 영상분할 알고리즘의 한계점을 극복하여 더 좋은 국부 최대치를 얻을 수 있는 방법을 제안한다. 즉, 기존의 영상분할 알고리즘들이 가치기준을 계속 증가시키는 방향으로만 영역라벨값의 갱신을 유도하므로 초기의 영상분할 결과에 상당히 의존적이며 쉽게 근처의 국부최대치에 수렴한다. 이와 같은 문제를 극복하기 위해 본 장에서는 Posterior Gibbs 분포로부터 얻은 샘플을 분할된 영상으로 간주하는 새로운 영상 분할 개념을 소개한다. 즉, Won-Derin 알고리즘이나 UICM 및 열 단위 영상분할 알고리즘과는 달리 국부 특성을 계속 증가하는 방향으로 영역라벨을 갱신시키는 것이 아니라, 국부 특성을 갖는 분포로 부터 얻은 샘플을 영역라벨의 갱신 값으로 결정하므로써 영상분할 알고리즘이 쉽게 국부 최대치에 수렴하는 것을 방지하였다.

1. Gibbs Sampler를 이용한 의존적 영상분할

II장의 X 및 Y의 모델 정의로부터 Posterior 분포 $P(X | Y)$ 는 다음과 같은 에너지 함수를 갖는 Gibbs 분포를 갖는다⁽²⁾.

$$P(X | Y) \triangleq \pi(x) = \frac{1}{Z} e^{U^p(x)} \quad (5)$$

여기서

$$U^p(x) = \beta v(x) - \frac{\sum_{t \in Q} (y_t - \gamma_{xt})^2}{2\sigma^2} \quad (6)$$

$$Z = \sum_x e^{U^p(x)} \quad (7)$$

이때 주어진 초기 영역라벨의 실현 $X(0)$ 로부터 시작하여 $t=1, 2, 3, \dots$ 에서 각 픽셀을 순차적으로 하나씩 방문하면서 해당 픽셀의 영역라벨만 김스 샘플러⁽²⁾를 사용하여 갱신 한다. 즉, 어떤 시간 t 에서 $N_1 N_2$ 픽셀 중의 한 픽셀 $s \in Q$ 의 해당 영역라벨 x_s 만 갱신하고 나머지 영역라벨은 변하지 않는다. 이때 각 픽셀의 영역라벨을 나타내는 랜덤변수를 $x_s(t)$ 로 나타내면 이를 랜덤변수의 집합 $x(t)$ 는

$$X(t) \triangleq (X_{s_1}(t), X_{s_2}(t), \dots, X_{s_{N_N}}(t)) \quad (8)$$

로 나타낼 수 있다. 각 불연속 시간 t 가 1씩 증가함에 따라 단지 한 픽셀의 영역라벨 값만 갱신되므로 전체 영역라벨의 실현 $X(t-1)$ 과 $X(t)$ 는 기껏해야 한 픽셀에서의 영역라벨 값만 다르고, 다른 모든 픽셀에서의 영역라벨 값은 같다. 즉, n_1, n_2, \dots 의 순서로 영역라벨의 갱신을 위해 픽셀들을 방문한다면 $s_n \in Q$ 이며 $x_{s_i}(t) = (t-1), i \neq n$ 이다. 이때 시간 t 에서 해당 픽셀 s_n 의 영역라벨 값은 이웃픽셀의 영역라벨 $x_r(t-1), r \in \eta_{s_n}$ 주어진 상태에서 x_{s_n} 의 조건부 확률분포로부터 (즉, 국부특성(local characteristics)) 얻을 수 있다.

주어진 초기 영역라벨의 실현 $X(0)$ 로 각 픽셀을 방문하면서 얻은 (즉, $t=1, 2, \dots$) 영역라벨의 실현 $X(1), X(2), X(3), \dots$ 의 관계는 다음의 이론으로 설명될 수 있다⁽²⁾.

이론 (Relaxation)

각 픽셀 $s \in Q$ 에 대해 픽셀방문순서 $\{n_t, t \geq 1\}$ 에 따라 각 픽셀을 무한대번 방문하면 주어진 임의의 초기 영역라벨의 실현 $X(0)=x^0$ 에 대해

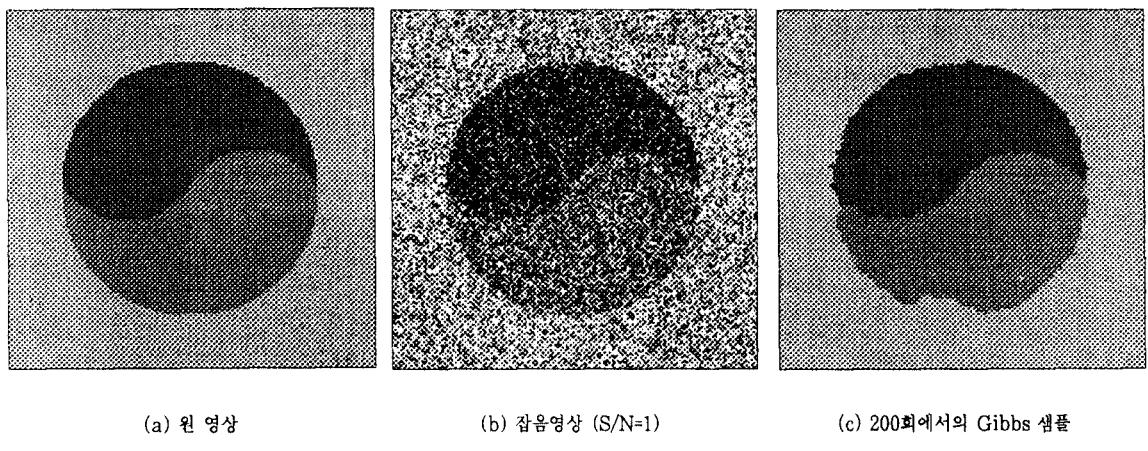
$$\lim_{t \rightarrow \infty} P(X(t) = \omega | X(0) = x^0) = \pi(\omega) \quad (9)$$

이 성립한다. 여기서 ω 는 X 의 한 실현이고 $\pi(\omega)$ 는 식 (5)의 갑스 분포다.

위 이론으로부터 각 픽셀을 순차적으로 수없이 방문하면서 각 픽셀의 영역라벨을 해당 국부 특성으로부터 개선하면 결과적으로 얻는 영역 라벨의 실현은 초기의 영역라벨의 실현과는 무관하게 갑스 분포 $\pi(x)$ 로부터의 샘플이 됨을 알 수 있다. 위 이론에 덧붙여 국부 특성으

로부터 영역라벨을 개선할 때 적당한 감온계획 (cooling schedule) T 를 적용하여 담금과정 (annealing processing)을 부가하면 최종적인 영역라벨의 실현은 $\pi(x)$ 의 에너지 함수를 최대로 하는 실현값을 얻으며 이것이 SA 알고리즘이 된다¹²⁾. 그러나 SA를 위한 감온계획은 너무 느려 실시간 적용이 불가능하고 본 연구에서는 감온계획 없이 위 이론의 갑스샘플러로 부터 얻은 샘플값을 영상분할의 결과로 취급하는 과정을 제안한다.

SA와 갑스샘플러의 차이는 SA는 에너지 함수를 최대로 하는 실현을 확률 1로 얻으므로 MAP



(a) 원 영상

(b) 잡음영상 ($S/N=1$)

(c) 200회에서의 Gibbs 샘플

그림 1. 3-영역 영상의 Gibbs 샘플 (임의의 초기 영역라벨)
 Fig. 1. A Gibbs sample of the 3-region image
 (starting from an arbitrary initial region label realization)

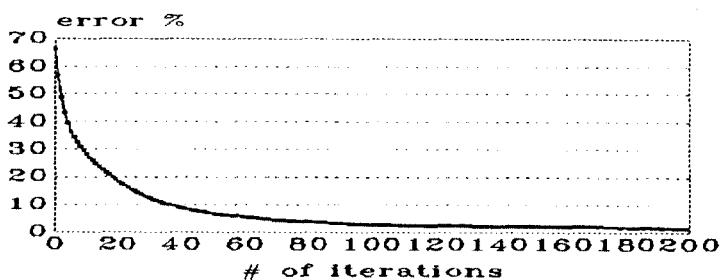


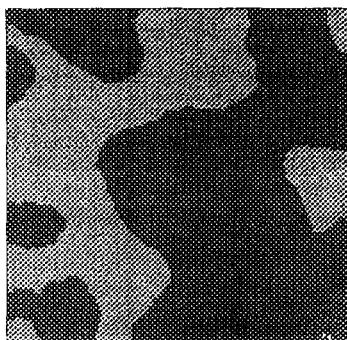
그림 2. 갑스 샘플러의 에러율 (그림 1)
 Fig. 2. Error rate of the Gibbs sampler (Fig. 1)

(Maximum A Posteriori)을 실현하는 것이고, 깁스 샘플러는 에너지 함수를 갖는 깁스 분포로부터 영상분할의 결과를 얻으므로 MAP 가치기준을 깁스 분포를 갖는 확률로 얻는 과정이다. 실제로 모델의 모든 파라미터 값을 알고 있을 때 MAP 가치기준을 최대로 하는 영역 라벨의 실현을 SA 과정을 통해 확률 1로 얻을 수 있고 깁스샘플러를 이용하면 단지 “높은” 확률 값으로 얻을 수 있다. 그러나 깁스샘플러는 SA의 감온계획을 사용하지 않아 빠른 시간에 수렴할 수 있는 장점이 있다. 실제로 모든 모델 파라미터를 알고 있을 때 그림1과 2에 깁스 샘플러로 얻은 샘플 값을 나타내었다. 임의의 초기 영역 라벨 실현으로 시작했음에도 불구하고 비교적 빠른 속도로 예리율이 감소함을 알 수 있다. 이것은 원 영상을 나타내는 영역라벨이 깁스샘플러를 통해 “높은” 확률로 선

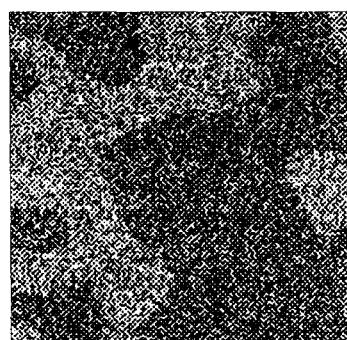
택될 수 있기 때문이다.

2. Gibbs Sampler를 이용한 자율적 영상분할깁스샘플러를 이용한 영상분할의 자율적 버전은 모든 모델 파라미터값을 알고 있지 않을 때 모델 파라미터의 측정과 영역라벨 생성을 동시에 진행하는 것이다. 즉, 주어진 영역라벨로부터 모델 파라미터의 ML 측정을 구하고, 구한 ML 모델 파라미터를 이용하여 깁스샘플러의 1회전 (iteration)을 진행하는 것이다. 따라서 깁스샘플러 - 최대화를 번갈아 가며 실행하므로 제안된 자율적 영상분할 알고리즘을 GSM (Gibbs Sampler and Maximizer) 알고리즘으로 명명한다.

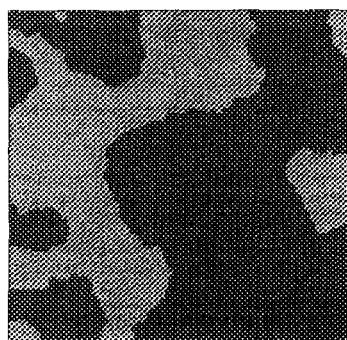
GSM 알고리즘



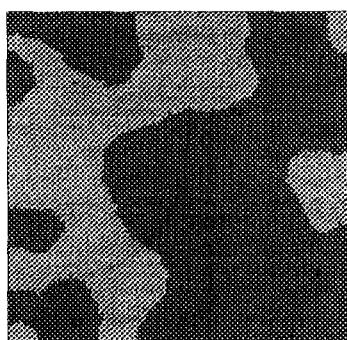
(a) original image



(b) noisy image ($S/N=1$)



(c) segmented by UICM



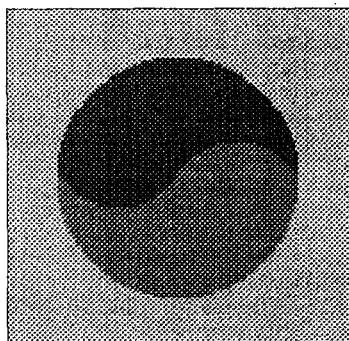
(d) segmented by GSM

그림 3. 2-영역 합성 영상의 분할
Fig. 3. segmentations of a 2-region synthesized image

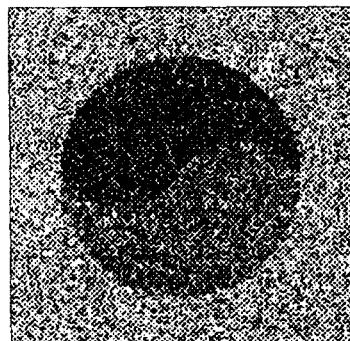
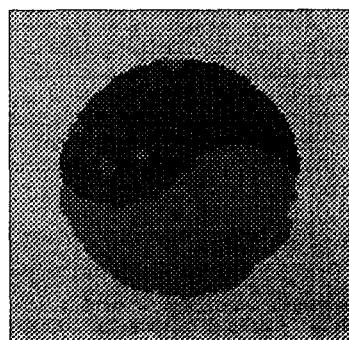
1. x 의 초기 추정치 \hat{x} 을 결정 한다.
2. $P(Y | \theta_Y, \hat{x})$ 을 θ_Y 에 대해 최대로 하는 $\hat{\theta}_Y$ 을 구 한다.
3. 영상공간내의 모든 픽셀 $t \in \Omega$ 에 대해
 - i) $\{1, \dots, G\}$ 사이의 영역라벨값 g 를 랜덤하게 선택 한다.
 - ii) x_t 을 g 로 $\pi(x_t=g | x_{\eta_t}, \theta_x, \theta_Y)$ 의 확률값에 따라 갱신한다.
4. 과정 3에서 얻은 갱신된 열의 영역라벨을 포함시켜 새로운 x 을 형성한다.
5. 과정 3에서 새롭게 갱신된 픽셀의 수가 미리 정해 놓은 숫자보다 작거나, 반복횟수가 미리 정해 놓은 값에 도달하면 알고리즘의 실행이 끝나고 그렇지 않으면 과정 2로 돌아간다.

GSM 알고리즘은 UICM 알고리즘과 가장 가깝다. GSM은 각 픽셀에서의 영역라벨을 국부 특성분포로부터 선택하고 UICM은 국부 특성 분포를 최대로 하는 영역라벨 값을 선택한다는 점이 다르다. 따라서 UICM 알고리즘에 의한 결과가 더욱 빠른 속도로 수렴하되 근처의 국부 최대치에 수렴할 확률이 높고 GSM은 천천히 수렴하되 좀 더 넓은 영역에서 국부 최대치를 찾는다. 따라서 최종 수렴 결과는 GSM이 더 작은 수렴오차를 나타낼 것으로 기대된다.

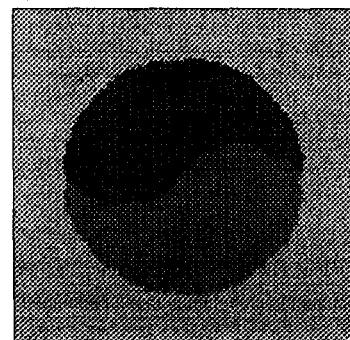
GSM 알고리즘은 Won-Derin 및 UICM과 같은 결정적이거나 알고리즘이나 영역라벨의 갱신이 결정적 (deterministic) 이지 못하고 확률적 (probabilistic) 이므로 국부최대치에 확실하게 수렴하지 않는다. 따라서 GSM의 수렴상태 (과정5)는 Won-Derin과 UICM의



(a) original image

(b) noisy image ($S/N=1$)

(c) segmented by UICM



(d) segmented by GSM

그림 4. 3-영역 합성 영상의 분할
Fig. 4. segmentations of a 3-region synthesized image

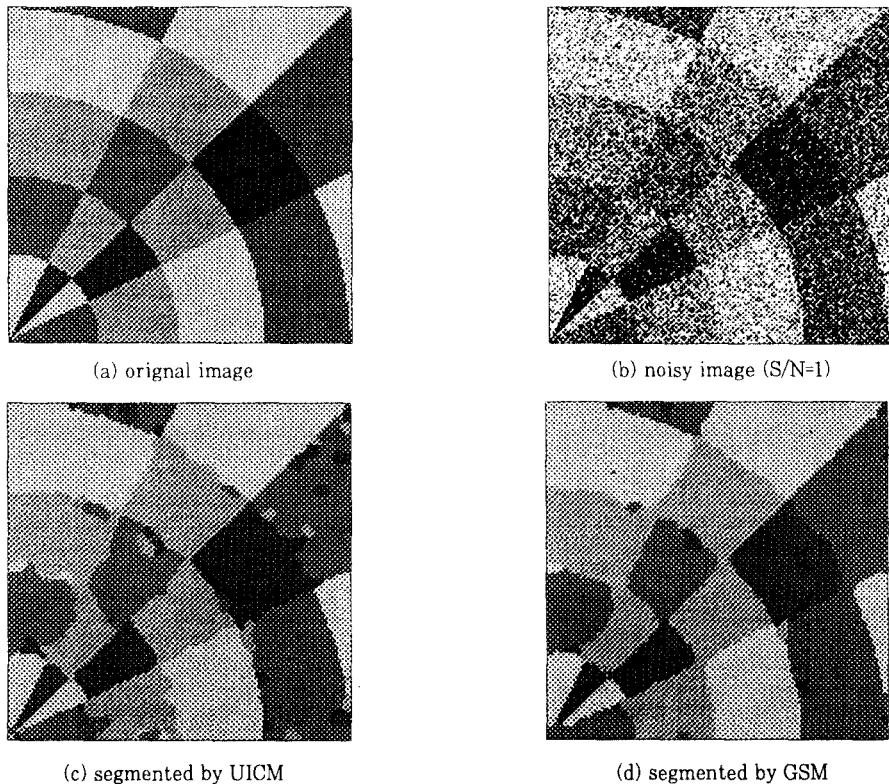


그림 5. 4-영역 합성 영상의 분할
Fig. 5. segmentations of a 4-region synthesized image

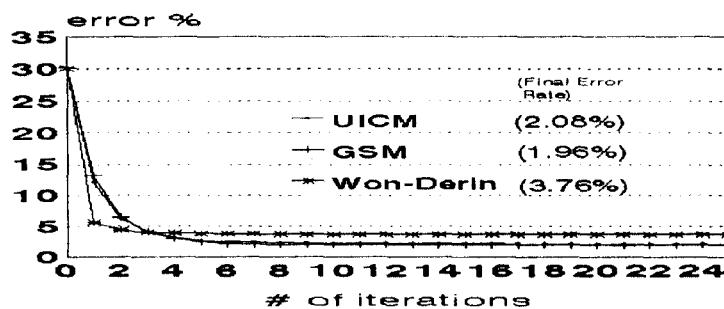


그림 6. 2-영역 영상분할의 수렴특성 비교
Fig. 6. Convergence comparison of the 2-region image segmentation

알고리즘과는 달리 새롭게 생성된 픽셀의 수나 반복횟수로 결정한다.

IV. 성능평가

제안된 GSM 알고리즘을 기준의 UICM과 Won-Derin 알고리즘과 합성된 영상으로 성능을 비교하였다. X의 모델 파라미터 $\beta=0.8$ 로 고정하여 사용하였고, 128 x 128 크기와 2, 3, 및 4 개의 영역을 갖는 영상에 S/N가 1인 잡음영상을 분할한 결과를 그림3-5에 나타

내었다. 그럼 3-5와 같은 잡음영상에 대해 UICM과 Won-Derin 그리고 GSM 알고리즘의 반복횟수와 에러율과의 비교 그래프를 그림6-8에 제시하였다. GSM의 초기 수렴 속도는 UICM과 유사하나, UICM은 Won-Derin 알고리즘보다 국부최대치에 쉽게 수렴하지 않아 최종 잔류오차가 작다는 것을 알 수 있다. 그럼9는 그림3-5에 사용된 똑 같은 영상모델과 열단위의 영상분할을 실제의 자연영상에 적용하여 2개의 영역에서 4개의 영역까지 분할한 결과다.

실험에 적용된 모든 자율적 영상분할 알고리즘의 초기

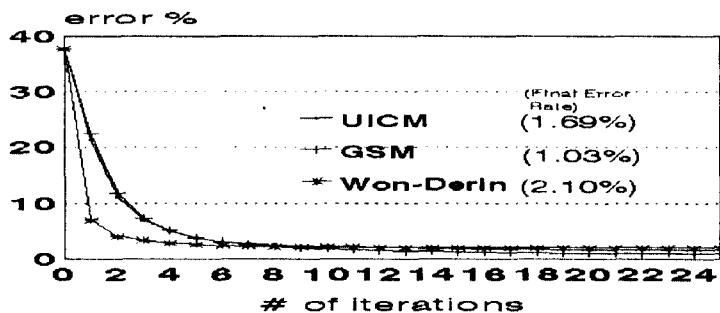


그림 7. 3-영역 영상분할의 수렴특성 비교
Fig. 7. Convergence comparison of the 3-region image segmentation

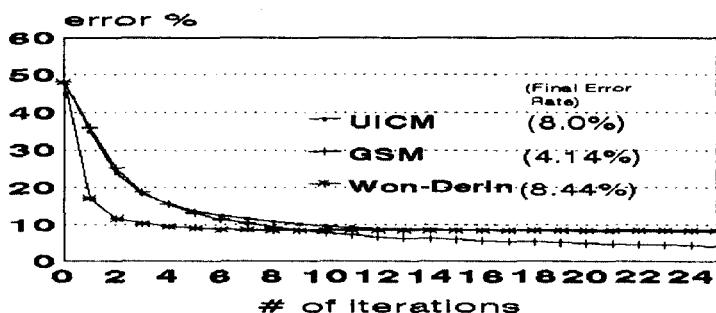


그림 8. 4-영역 영상분할의 수렴특성 비교
Fig. 8. Convergence comparison of the 4-region image segmentation

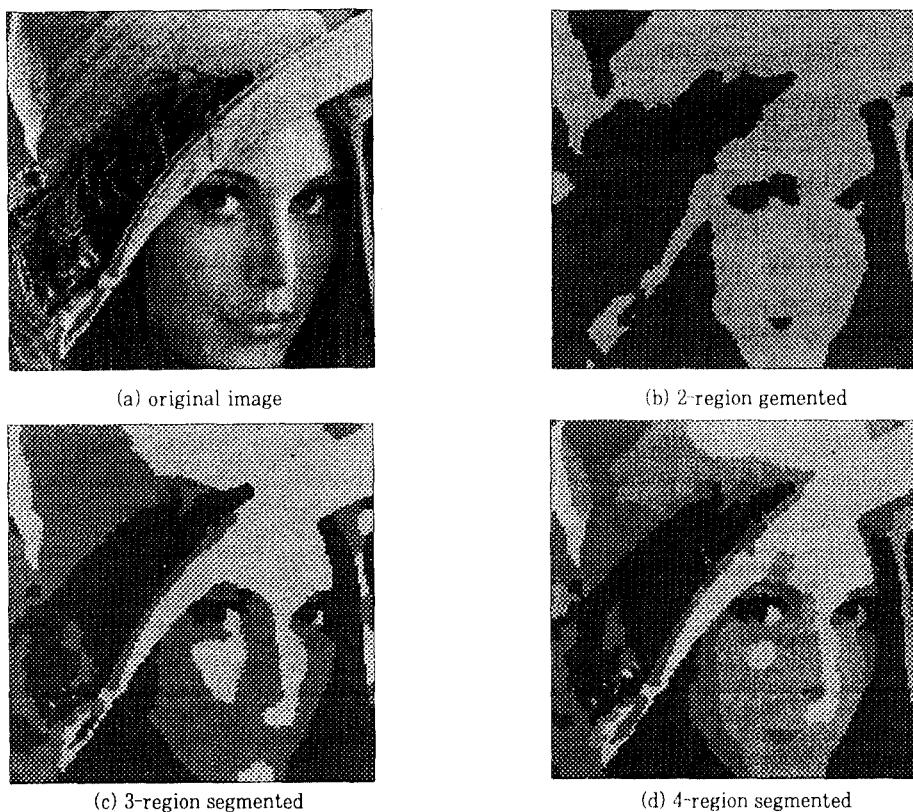


그림 9 GSM알고리즘에 의한 자연영상 분할
Fig. 9 Natural image segmented by the GSM algorithm

분할은 영상내 최대 밝기의 세기와 최소 밝기의 세기를 영역의 갯수로 균등하게 분할하여 얻었다.

V. 결론

기존의 Won-Derin 알고리즘과 UICM의 영역라벨 개선 알고리즘들의 공통점은 각 픽셀에서의 영역라벨 개선이 가치기준을 향상시키는 방향으로만 이루어 진다는 점이다. 따라서 초기수렴 상태에 상당히 의존적이고 쉽게 근처의 국부최대치에 수렴하는 단점을 갖고 있다. 이런 점을 극복하면서도 빠른 속도로 수렴할 수 있는 방안의 하나로 깁스 샘플러를 이용한 영상분할 알고리즘을 본 논문에서 제안한다. 즉, 각 픽셀에서의 영역라벨 개선을 국부특성의 확률에 따라 결정하므로 결정적

(deterministic)이 아닌 확률적 (probabilistic)으로 영역라벨을 개선한다. 그러므로 쉽게 국부최대치에 빠지지 않고 높은 확률값을 갖는 영상분할의 결과를 빠른 시간에 얻는다. 제안된 방법의 자율적 버전인 GSM (Gibbs Sampler and Maximizer) 알고리즘을 적용해 본 결과, 실험한 모든 경우에 기존의 Won-Derin 및 UICM 알고리즘들 보다 개선된 수렴특성을 보였다.

참고문헌

1. H. Derin and H. Elliott, "Modeling and segmentation of noisy and textured images using Gibbs random field," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. PAMI-

9. pp.39-55, 1987.
2. S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. PAMI-6 (6), pp.721-741, 1984.
3. J. E. Besag, "On the statistical analysis of dirty pictures," *J.R.Statist. Soc., Ser. B*, vol. 48, pp.259-302, 1986.
4. C. S. Won and H. Derin, "Unsupervised segmentation of noisy and textured images using Markov random fields," *CVGIP:Graphical Models and Image Processing*, vol. 54(4), pp.308-328, 1992.
5. 원치선, "MRF 모델을 이용한 영상분할 알고리즘의 수렴특성 개선," 제7회 영상처리 및 이해에 관한 워크샵 발표 논문집, pp.22-26, 1995.
6. J. Besag, "Spatial interaction and the statistical analysis of lattice system (with Discussion)," *J.R.Statist. Soc., Ser. B*, vol. 36, pp.192-263, 1974.



元致善(Chee Sun Won) 정회원

1959년 11월 24일생

1982년 : 고려대 전자과 졸업

1986년 : 매사추세츠 대학(앰허스트)
석사

1990년 : 매사추세츠 대학(앰허스트)
박사

1989년~1992년 : 금성사 선임연구원

1992년~현재 : 동국대학교 전자공학과 조교수

*주관심 분야: 영상처리, 디지털 방송 시스템