

TMS320C80(MVP) 과 Markov Random Field를 이용한 영상해석

Image Analysis using a markov random field and TMS320C80(MVP)

* 백 경 석*, 정 진 현**

*광운대학교 제어계측공학과(Tel : 02-940-5156; E-mail: odin@ral.kwangwoon.ac.kr)

**광운대학교 제어계측공학과(Tel : 02-940-5156; E-mail: chung@ral.kwangwoon.ac.kr)

Abstract This paper presents image analysis method using a Markov random field (MRF) model. Particularly, image segmentation is to partition the given image into regions. This scheme is first segmented into regions, and the obtained domain knowledge is used to obtain the improved segmented image by a Markov random field model. The method is a maximum a posteriori (MAP) estimation with the MRF model and its associated Gibbs distribution. MAP estimation method is applied to capture the natural image by TMS320C80(MVP) and to realize the segmented image by a MRF model.

Keywords Markov random field, MAP estimation, TMS320C80(MVP), Gibbs random field, segmentation

는 시도를 하였다. Gibbs Random Field (GRF)가 MRF와 동등함을 이용해 MRF 모델링을 GRF를 적용하여 image restoration을 구현한 논문이다.

1. 서론

최근에, 영상 해석의 필요성이 증가하고 있다. Image segmentation은 주어진 영상을 어떤 규칙이나 방법에 근거하여 영상내의 존재하는 여러 영역으로 분류하는 것이다. Segmentation은 각각의 화소들을 화소의 이웃들과 local processing이나 global processing을 통하여 어떤 영역에 포함 시키는 작업을 통해 수행 된다. 현존하고 있는 segmentation algorithms은 크게 두 가지로 구분하는데 통계적 부류와 구조적 부류이다. 이 논문에서 사용하는 algorithm은 통계적 부류로써, Markov random field (MRF)을 이용하여 모델링을 하고 maximum a posteriori (MAP) estimation 방법을 사용한다. 이 방법들은 주로 image segmentation이나, image restoration에 최적의 결과를 얻기 위해 사용했다.

이 에 본 논문에서도 모델링 방법으로 GRF를 이용하여 MAP estimation에 적용 한다. 본론에서는 MRF와 GRF. MAP estimation을 소개하고 주어진 영상을 간단히 여러 영역으로 분류한 후 위의 방법들을 이용하여 향상된 segmented image를 획득한다.

결론으로 TMS320C80(MVP) DSP모드를 이용하여 nature image를 얻은 후 segmentation을 한다. 하지만 MRF를 이용한 모델링을 적용 할 경우 여러 가지 문제점이 제시되어 구현의 어려움이 있었다. 이 문제를 S.Geman and D.Geman의 논문에서[1] 극복하

2. 본론

본론에서는 Markov random field (MRF) 와 Gibbs random field (GRF), Maximum a posteriori (MAP) estimation 방법을 소개하고, 본 논문에서의 실제 적용한 방법에 대해 서술한다.

2.1 Markov Random Field

$N_1 \times N_2$ 으로 샘플링 된 영상을

$$L = (i, j) : 1 \leq i \leq N_1, 1 \leq j \leq N_2$$

로 정의한다. 그리고, neighborhood system을

$$\eta = \eta_{ij} : (i, j) \in L, \eta_{ij} \subseteq L \quad (1)$$

로 표시하며, 만약 화소 (i, j) 의 neighborhood η_{ij} 가

1) $(i, j) \in \eta_{ij}$ and

2) if $(k, l) \in \eta_{ij}$, then $(i, j) \in \eta_{kl}$ for any $(i, j) \in L$.

이라면 neighborhood system 으로 나타낸다.

영상 모델링에서 사용하는 neighborhood system η^1, η^2, \dots 에서 $\eta^1 = \eta_{ij}^1$ 는 각각의 화소에 대해 4개의 이웃 화소들을 가지며, $\eta^2 = \eta_{ij}^2$ 는 8개의 화소를 가진다. Neighborhood system에 대한 clique는 c로 표시하며, 다음 조건을 만족하는 영상의 부분집

합 이다.

- 1) c 는 하나의 화소만으로 구성되거나,
- 2) $(i, j) \neq (k, l), (i, j) \in c$ and $(k, l) \in c$ 는 $(i, j) \in \eta_{kl}$ 이다.




Fig.1. Neighborhood system and clique type

모든 clique의 집합을 C 로 표시하고, 영상 L 에 대한 random field를 Z 라고 정의한다. $Z = z(x), x \in L$ 인 random field가 neighborhood system에 대해 MRF이라면, 다음 조건을 만족해야 한다. 모든 z 에 대해 $p(z) > 0$, $p(z(x_{ij})|z(x_{kl}), \forall x_{kl} \neq x_{ij}) =$

$$p(z(x_{ij})|z(x_{kl}), x_{kl} \in \eta_{ij}) \quad (2)$$

첫 번째 조건은 제로가 아닌 확률값을 가져야 하는 것을 의미하며, 두 번째는 한 특정 화소의 local conditional pdfs는 그 화소의 neighborhood system의 값에 의존해야 한다. 실제로 위의 조건을 가지고 영상에 적용하는 것은 여러 가지 문제점을 유발시킨다. 그로 인해 영상에 대한 MRF의 응용이 어려운 시점에 이를 수 있음으로 이에 대한 해결책을 Hammersley-Clifford theorem에 의한 MRF와 GRF의 동등성원리를 많은 영상 해석 방법 [3],[5],[6],[7],[8]에서 이용해 왔다.

2.2 Gibbs Random Field

Neighborhood system과 clique 집합 C 에 대해서

$$p(z) = \frac{1}{Q} \exp(-U(z)) \quad (3)$$

이며, $U(z)$ 는 energy function으로 clique potentials로 표현 할 수 있다.

$$U(z) = \sum_c V_c(z) \quad (4)$$

$V_c(z)$ 는 clique c 에 대한 potential function이다. Potential function은 clique에 있는 화소의 값과 clique type에 영향을 받는다. 식 (3)에서 Q 는 정규화 상수로서 partition function이다. Second-order neighborhood system의 potential function은 식 (5), (6) 그리고 식 (7), (8)로 정의한다. 하나의 화소로 이루어진 clique에 대해

$$V_c(z) = a_k \text{ for } (x_{ij} = q_k) \quad (5)$$

정의 하며, 여러개의 화소로 이루어진 clique에 대

해

$$\begin{aligned} & [** , \beta_1], [* , \beta_2], [* , \beta_3], [* , \beta_4] \\ & [* , \delta_1], [* , \delta_2], [* , \delta_3] \\ & [* , \delta_4], [* , \zeta_1] \end{aligned} \quad (6)$$

만약 c 안에 있는 모든 x_{ij} 가 동일하면

$$V_c(z) = -\zeta \quad (7)$$

동일하지 않으면

$$V_c(z) = \zeta \quad (8)$$

으로 정의한다.

2.3 Maximum a posteriori estimation

MAP estimation은 Bayesian theorem의 한 부류로써, 주로 노이즈가 존재하는 영상에서의 효과적인 영상 분류나 복원 등에 많이 사용하였다. 크게 두 부분으로 MAP estimation이 구성 되는데, 주어진 영상의 segmentation과 관련된 conditional probability distribution 과 segmentation결과로 미리 예상할 수 있는 model인 a priori probability distribution으로 구성된다. 특히, a priori probability model로 2.2 에서 언급한 GRF를 사용하며, 이로 인해 segmentation의 추정은 영상의 명암 뿐만 아니라 GRF에 의해 나타나는 여러 공간적인 속성들에 의존한다. Original source image를 g 라고 표시한다. 원하는 추정 랜덤 필드(z)는 a posteriori pdf $p(z|g)$ 가 최대값을 가지는 것으로 정의한다.

$$p(z|g) \propto p(g|z)p(z) \quad (9)$$

위식에서 $p(g|z)$ 는 conditional probability distribution 이며, $p(z)$ 는 a priori probability distribution이며, GRF 이용하여 식 (10)과 같이 나타낸다.

$$p(z) = \frac{1}{Q} \exp(-U(z)) \quad (10)$$

$$p(g|z) \propto \exp(-\sum_x [g(x) - \mu_{z(x)}]^2) \quad (11)$$

2.4 적용한 방법

본 논문에서는 주어진 원 영상을 먼저 여러개의 영역들로 분리 시킴으로써 우리가 원하는 segmented image에 대한 영역의 개수등 MAP estimation에 적용하기 전에 예측 정보를 구한다. 이 과정을 거친 후에 여러 가지의 clique type 중 적절한 type을 선택하여 2.3에서 언급한 방법에 적용한다. 그림 2는 본 논문에서 적용한 방법의 블록 다이어그램을 보여주고 있다.

2.4.1 Potential function 설계

A priori probability distribution을 얻기 위해 clique

type을 정해 potential function을 식(12)와 (13) 그리고 (14)로 정한다.

$$\sum_c V_c(z) =$$

$$\beta_1 \sum_c I(z) + \beta_2 \sum_c I(z) + \beta_3 \sum_c I(z) + \beta_4 \sum_c I(z) \quad (12)$$

$$I(z) = -1, \text{ 안에 있는 모든 } X_{ij} \text{가 동일} \quad (13)$$

$$I(z) = 1, \text{ 나머지 경우} \quad (14)$$

위 식에서 처럼 영상이 같은 gray values를 가진다면 potential function의 값은 점점 감소하게 된다.

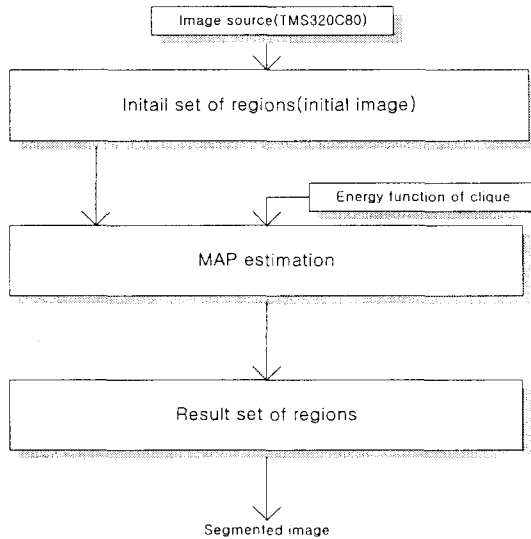


Fig 2. The segmentation procedure

2.4.2 MAP estimation 에 적용

앞서 언급한 방법으로 a priori probability distribution을 구한 것을 가지고 식(9)에 대입한다. Conditional probability distribution은 식(11)을 이용하여 구한다. 식(11)이 최대값을 가질 때 추정 랜덤 필드를 얻으므로 $(-\sum_x [g(x) - \mu_{z(x)}]^2)$ 이 최소값을 가지는 경우를 이용하면 식(11)의 최대값을 구할 수 있다. 여기서, g 는 원 영상을 나타내고 $\mu_{z(x)}$ 는 initial set of regions의 영상이다. A priori probability distribution과 conditional probability distribution을 식(9)처럼 표현하면 식(15)와 같이 나타낼 수 있다.

$$p(z|g) \propto \exp(-\sum_x [g(x) - \mu_{z(x)}]^2 - U(z)) \quad (15)$$

식(10)에서의 $\frac{1}{Q}$ 은 고정된 상수이므로 최소값을 얻는 과정에서 특별한 고려를 하지 않아도 된다.

2.4.3 Tms320c80(MVP)

논문에서 사용한 TMS320C80은 floating-point RISC unit인 MP(Master Processor)와 4개의 PP(Parallel processor)라 불리는 integer DSP와 200MHz RAMDAC등 다양한 controller를 가지고 있다. Natural image를 얻기 위해 CCTV camera로 입

력을 받아 RAMDAC을 통하여 모니터에 입력 받은 영상을 보여줌 과 동시에 저장미디어에 데이터로 저장할 수가 있다. 데이터를 이용하여 segmentation에 적용한다.

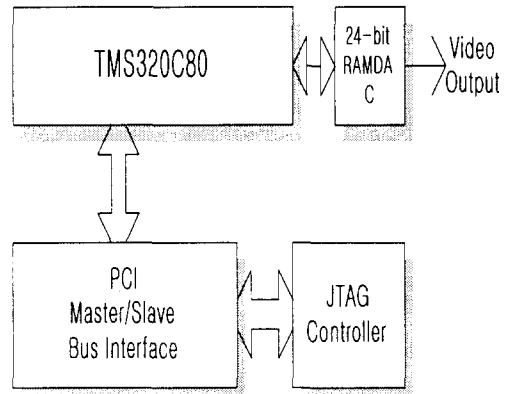


Fig 3.TMS320C80(MVP) block diagram

2.5 실험 및 고찰

2.4.3에서 언급한 DSP 보드를 통해 얻은 natural image를 256gray level을 가지는 Fig 4.의 영상을 이용하였다.식 (12)에서의 potential function실계는 $\beta = \beta_1 = \beta_2 = \beta_3 = \beta_4 = 0.5$ 로 정했다. 이와 같은 수치는 segmented image에서 물체간에 윤곽선을 뚜렷하게 보여주는 역할을 한다. Fig 5.가 원 영상을 간단히 여러 영역으로 clustering 기법을 이용하여 5 gray level로 표현한 영상이다. 그리고, Fig 6.영상이 MAP estimation을 적용한 결과 영상이다.

Fig 5.의 영상과 같은 5 gray level로 영상이 표현되었고, 물체간 smooth한 윤곽을 보여주는 영상에 비해 Fig 6. segmented image내의 물체간 윤곽선이 뚜렷하다.




Fig 4. Original image

3. 결론

TMS320C80(MVP) DSP 보드를 이용하여 natural

image를 얻고 직접 image segmentation을 구현했다. MRF(Markov random field)를 이용하여 영상 모델링을 얻기 위해 실제 적용이 쉬운 GRF(Gibbs random field)를 통하여 potential function을 설계함으로써 영상을 모델링 하였다. 주어진 원 영상을 먼저 여러개의 영역으로 간단한 clustering 기법으로 구하고, 앞서 구한 모델링을 이용하여 MAP(Maximum a posteriori) estimation에 적용하여 initial set of regions image에 비해 영상내에 존재하는 물체간의 윤곽선을 살리면서 분류하여 향상된 segmentation method임을 입증했다.



Fig 5. Initial set of regions image



Fig 6. Segmented image

참고 문헌

[1] David W. Murray and Bernard F. Buxton. "Scene Segmentation from Visual Motion Using Global Optimization ", *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-9*. PP220-228. 1987.

[2] Emanuel Levitan and Michael Chan and Gabor T. Herman. "Image-Modeling Gibbs priors", *CVGIP: Graphical Models and Image Processing* Vol. 57, NO. 2 PP117-130 1995.

[3] H. Derin and H. Elliott. "Modeling and Segmentation of Noisy and Textured images using Gibbs random fields", *IEEE Trans. Pattern Anal.*

Mach. Intell. PAMI-9, PP39-55, 1987.

[4] Il Y. KIM and Hyun S. Yang. "An integration Scheme for image segmentation and labeling based on Markov random field model". *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-18*, PP69-73, 1996.

[5] J. W. Modestino and Jun Z. "A Markov random field model based Approach to Image interpretation". *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-14*, PP606-615, 1992.

[6] M. R. Bhatt and U. B. Desai. "Robust image Restoration Algorithm Using Markov Random Field Model", *CVGIP: Graphical Models and Image Processing* Vol. 56, NO. 1 PP61-74 1994.

[7] S. Geman and D. Geman. "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images". *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-6*, PP721-741, 1984.

[8] S. Lakshmanan and H. Derin. "Simultaneous parameter estimation and Segmentation of Gibbs random fields using Simulated annealing", *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-11*. PP799-813, 1989.