

論文99-36C-9~7

유전자 알고리즘을 이용한 MRF 모델 기반의 영상분할

(MRF Model based Image Segmentation using Genetic Algorithm)

金恩伊*, 朴世鉉*, 鄭基哲*, 金恒俊*

(Eun Yi Kim, Se Hyun Park, Keechul Jung, and Hang Joon Kim)

요약

영상분할은 입력된 영상을 처리하여 유사한 화소들의 집합인 영역들로 화소들을 구분하는 작업이다. 영상 분할의 결과는 영상인식의 정확성에 큰 영향을 미친다. 본 논문에서는 유전자 알고리즘을 이용하여 마르코프 랜덤 필드(Markov random field)에 기반한 영상분할 방법을 제안한다. 제안한 방법에서는 잡음과 흐름(blurring)에 강한 MRF를 이용하여 영상을 모델링 한다. MRF기반 영상분할 방법은 왜곡에 강한 반면, 정확한 파라미터의 추정이 요구된다. 그래서, 추정 방법으로 많은 파라미터를 포함하는 문제를 다루는데 효율적인 유전자 알고리즘을 사용한다. 실제 영상을 가지고 수행된 실험 결과와 자동 차량 추출 시스템에의 응용 결과는 제안된 방법의 효율성을 보여준다.

Abstract

Image segmentation is the process where an image is segmented into regions that are set of homogeneous pixels. The result has a critical effect on accuracy of image understanding. In this paper, an Markov random field (MRF) image segmentation is proposed using genetic algorithm (GA). We model an image using MRF which is resistant to noise and blurring. While MRF based methods are robust to degradation, these require accurate parameter estimation. So, GA is used as a segmentation algorithm which is effective at dealing with combinatorial problems. The efficiency of the proposed method is shown by experimental results with real images and application to automatic vehicle extraction system.

I. 서론

영상분할은 입력된 영상을 유사한 화소들의 영역들로 구분하는 작업이다. 영상분할은 영상처리 시스템의 초기 단계의 잡음 제거와 같은 영상 복원과 마지막 단계인 영상인식의 중간 부분에 위치하는 단계로, 영상분할의 결과는 영상인식의 정확성에 크게 영향을 미친다.

컴퓨터 비전 기반의 자동 로보트, 상품의 질 검사, 의학에서의 진단과 분석과 같은 하위 레벨 비전 문제뿐만 아니라, 움직임 분석 및 추적과 같은 연속된 영상처리, 물체 인식 및 장면 해석과 같은 문제들의 수행 결과 또한 고도의 영상분할 기법에 의존한다.

지금까지 영상분할을 위한 여러 가지 모델과 알고리즘이 제안되어 왔다^[1,2,3]. 영상분할 방법은 물체와 물체 또는 물체와 배경 사이의 경계를 검출하는 경계선 기반 알고리즘(boundary based algorithm)과 물체 내의 화소 값의 유사성을 이용하는 영역 기반 알고리즘(region based algorithm)으로 구분할 수 있다^[1]. 경계선 기반 알고리즘은 각 화소의 위치에서 경사도(gradi-

* 正會員, 慶北大學校 컴퓨터工學科

(Department of Computer Engineering)

接受日字 : 1999年6月28日, 수정완료일 : 1999年8月5日

를 사용하여 경계선을 검출한 후에 그래프 탐색, 동적 프로그래밍(dynamic programming), 하프 변환^[4] 등의 방법을 사용하여 인접한 경계선을 연결하는 방법을 사용한다. 또한 영역 기반 알고리즘은 영상 내의 히스토그램한 임계치 방법, 화소 분류, 영역 내의 유사성 및 연결성을 이용하여 영역을 확장시켜 가는 영역 성장(region growing) 기법 등이 있다.

최근에 영상분할에서 MRF를 이용하는 방법이 많이 연구되고 있다^[3,5]. MRF는 어떤 사건의 확률 값이 주변에 의존하는 국소적인 성질을 가지는 랜덤 필드이다. MRF는 영상 내의 화소들과 같이 환경 의존적인 실체들을 모델화 할 때 편리하고 일반된 방법을 제공한다. 이것은 그러한 환경 의존적인 개체들간의 상호 영향성을 MRF 확률을 사용하여 표현함으로써 이루어진다. MRF의 실질적인 사용은 MRF와 Gibbs 분포간의 동등성을 증명한 Hamersley and Clifford^[5]와 이를 발전시킨 Besag^[6]에 의해 이루어졌다. MRF와 Gibbs 분포 사이에 동등 성은 많은 영상 문제들을 Bayesian rule^[3]내에서 수학적으로 다루기 쉬운 방법으로 모델화 할 수 있게 한다. 또한, 계산적인 측면에서 바라볼 때, MRF의 국소적인 성질은 알고리즘을 국소적이고 병렬화된 방법으로 만들어 준다.

본 논문에서는 유전자 알고리즘을 이용하여 마르코프 랜덤 필드(Markov random field)에 기반한 영상분할 방법을 제안한다. 본 논문에서 제안된 알고리즘은 영역 기반 알고리즘으로, 정교한 분할을 위해서 칼라 정보를 이용한다. 그리고, 실 영상에의 적용을 위해서 관측 영상에서 노이즈와 블러링의 특징 값을 고려한다. 블러링, 칼라와 노이즈를 모두 고려하여 영상을 분할하는 것은 복잡한 문제일 뿐만이 아니라, 많은 시간을 필요로 한다. 이러한 이유로, 오염된 영상을 처리하는 데 효율적인 마코프 랜덤 필드를 사용하여 영상을 모델링 한다. 주어진 관측 영상에 대해 영상 레이블의 조건부 확률 분포(conditional probability distribution)를 최대로 하는 레이블을 최적의 레이블로 추정한다. Bayesian 추정에서 이러한 형태는 사후 확률을 최대화 추정(Maximum a posteriori or MAP estimation)으로 알려져 있다. 사후 확률 최대화하는 레이블은 정의되는 사후 에너지 함수를 최소화하는 레이블의 탐색으로 얻어진다. 제안된 사후 에너지 함수에는 칼라 값, 블러링 행렬, 노이즈와 같은 많은 파라미터들이 포함되어 있다. 사후 에너지 함수를 최소화하기 위해서는 칼라 값, 블

러링 행렬, 노이즈와 같은 많은 파라미터들의 탐색이 이루어져야 한다. 탐색 알고리즘으로는 유전자 알고리즘이 사용된다. 이 유전자 알고리즘은 결과적으로 선역적인 최적해에 수렴될 수 있는 해를 보상하는 부분집합에 주안점을 두는 휴리스틱한 탐색 알고리즘으로써 현재의 부분해가 상대적으로 덜 영향을 주는 방법이다^[2, 9,10,11,12,13]. 제안된 분할 알고리즘의 수행은 계층적이고 분산적이다. 분할 방법은 3단계로 구성되어 있고, 각 단계에서는 분산 유전자 알고리즘을 사용하여 파라미터를 탐색한다^[2]. 하위 단계에서 탐색된 파라미터 결과는 또 다른 파라미터를 탐색하는 상위단계로 보내어진다. 이러한 계층간의 상호작용은 전체적인 파라미터를 탐색할 필요가 없도록 한다.

본 논문의 구성은 다음과 같다. II장에서는 최적화 함수를 정의하고 III장에서는 제안된 사후 에너지 함수를 최적화 하는 유전자 알고리즘에 대해서 알아본다. IV장에서는 제안한 시스템의 실험 결과를 분석 검토한다. 마지막으로 V장에서는 결론과 앞으로의 연구 방향에 대해 제시한다.

II. 최적화 함수

본 장에서는 먼저 관측된 영상의 특성과 영상 모델링에 대해 알아본 후, 최적화 함수로 사용되는 사후 에너지 함수를 정의한다.

1. 관측 영상 특성

일반적으로 관측 영상은 다음과 같이 노이즈, 블러링과 비선형 변환에 의해 오염되어 있다^[3].

$$G = \psi(F) \odot N$$

여기에서 G 는 관측된 영상, F 는 속성에 따라 추정된 원래 영상의 칼라 벡터를 말한다. 일반적으로 ψ 는 비선형 연산을, N 은 노이즈, 그리고 \odot 은 역함수 가능한 비선형 연산을 말한다.

본 논문에서는 비선형 변환은 선형 변환으로 \odot 는 덧셈 연산으로 간주한다. 따라서 관측 영상 G 는 다음과 같이 정의된다.

$$G = H(F) + N \quad (1)$$

여기에서 H 는 블러링 행렬을 수행하는 연산자, N 은 원 영상에 독립적인 확률 모델로 평균값과 분산값

으로 구성된 가우시안 변수들(Gaussian variables)로 가정한다.

2. 영상 모델링

유한한 $M_1 \times M_2$ 의 공간 $S = \{(i, j) | 1 \leq i \leq M_1, 1 \leq j \leq M_2\}$ 상에서 정의되는 $X = \{X_{i,j} | 1 \leq i \leq M_1, 1 \leq j \leq M_2\}$ 는 원 영상을 나타낸다. 원 영상 X 는 관측 가능한 화소(pixel)의 컬러값들의 벡터인 F 와 관측 불가능한 레이블들의 벡터인 L 의 쌍으로 이루어져 있다고 정의한다. 각 화소의 컬러값 $F_{i,j}$ 는 HSI(Hue, Saturation, Intensity) 모델로 표현되는 랜덤 변수(random variable)이고, 레이블 값 $L_{i,j}$ 은 집합 $\Lambda = \{\lambda_1, \lambda_2, \dots\}$ 에서 하나의 값을 가진다. f 와 l 는 각각 F 와 L 의 실현(realization)이다. $\Gamma = \{\eta_{i,j} | 1 \leq i \leq M_1, 1 \leq j \leq M_2\}$ 을 공간 S 에 대한 주변 시스템(neighborhood system)이라고 정의할 때, $\eta_{i,j}$ 는 (i, j) 번째 화소에 이웃한 화소들의 집합이다. 가능한 모든 배열(configuration)의 집합을 $\Omega = \{\omega = (x_{1,1}, x_{1,2}, \dots, x_{M_1, M_2}) | x_{i,j} = (f_{i,j}, l_{i,j}), f_{i,j} \in F, l_{i,j} \in L\}$ 이라고 할 때, 주변 시스템, Γ 에 대해 X 가 다음의 두 성질을 만족하기 때문에 MRF로 모델링된다.

$$P(X = \omega) > 0 \quad \forall \omega \in \Omega$$

$$\begin{aligned} P(X_{i,j} = x_{i,j} | X_{k,l} = x_{k,l}, (k, l) \neq (i, j)) \\ = P(X_{i,j} = x_{i,j} | X_{k,l} = x_{k,l}, (k, l) \in \eta_{i,j}) \end{aligned}$$

3. 사후 에너지 함수

본 논문에서는 주어진 관측 영상 g 에 대해 원 영상 ω 의 조건부 확률 분포(conditional probability distribution), $P(X = \omega | G = g)$ 를 최대로 하는 레이블을 최적의 레이블로 추정한다. Bayesian 추정에서 이러한 형태는 사후 확률 최대화 추정(Maximum a posteriori or MAP estimation)으로 알려져 있다. Bayesian 규칙에 의해 사후 확률은 다음과 같이 계산되어진다.

$$\begin{aligned} P(X = \omega | G = g) \\ = \frac{P(G = g | X = \omega) \times P(X = \omega)}{P(G = g)} \end{aligned}$$

$P(G = g)$ 는 상수이기 때문에 생략되어지고, 중요한 항은 $P(G = g | X = \omega)$ 과 $P(X = \omega)$ 가 된다. 따라서, l^* 을 최적의 영상 레이블 벡터라 할 때, MAP 추정은

다음과 같이 나타내어진다.

$$\begin{aligned} l^* = \arg \max_{l \in L} P(G = g | X = \omega) \times P(X = \omega) \\ \omega = (f, l) \end{aligned} \quad (2)$$

$P(G = g | X = \omega)$ 는 관측된 영상 g 와 추정된 원 영상의 유사도를 고려하는 것으로, 식(1)에 의해 다음과 같이 표현된다.

$$\begin{aligned} P(G = g | X = \omega) \\ = P(H(F) + N = g | X = \omega) \end{aligned} \quad (3)$$

$$\begin{aligned} = P(N = g - H(f) | X = \omega) \\ = (2\pi\sigma^2)^{-\frac{M_1 M_2}{2}} \exp\left(-\frac{\|E - (g - H(f))\|^2}{2\sigma^2}\right) \end{aligned} \quad (4)$$

앞에서 노이즈 N 은 평균이 μ 이고 표준 편차가 σ 인 가우시안 변수들로 가정했다. 그리고 E 를 모든 요소의 값이 μ 인 크기가 $M_1 \times M_2$ 인 벡터라고 할 때, $P(G = g | X = \omega)$ 는 식 (4)와 같이 얻어진다. 본 논문에서는 X 를 MRF로 모델링 한다. $P(X = \omega)$ 항은 사전 확률을 나타내는 것으로, Gibbs 확률 분포를 갖는다. $P(X = \omega)$ 에 대해서 식 (5)와 같은 Z_1 과 $U(\omega)$ 이 존재한다.

$$P(X = \omega) = \frac{1}{Z_1} \exp(-U(\omega)) \quad (5)$$

식 (5)에서 partition 함수 Z_1 는 정규화 상수이고, $U(\omega)$ 는 사전 에너지 함수이다.

$$\begin{aligned} U(\omega) = U(f, l) = U_1(f | l) + U_2(l) \\ = \sum_{c \in C} V_c(f | l) + \sum_{c \in C} Q_c(l) \end{aligned} \quad (6)$$

$U_1(f | l)$ 과 $U_2(l)$ 은 각각 모든 가능한 클릭들의 집합 C 에 대한 클릭^[3] potential V_c 와 Q_c 의 합이다. V_c 과 Q_c 는 클릭 c 상에 있는 배열들에만 영향을 받고, 다음과 같이 표현된다.

$$V_c(f | l) = \begin{cases} \frac{m_c^2}{4^2}, & \text{만약 } c\text{안에 있는} \\ & \text{화소들의 레이블이} \\ & \text{모두 같으면} \\ 0, & \text{만약 } c\text{안에 있는} \\ & \text{화소들의 레이블이} \\ & \text{모두 같지 않다면} \end{cases}$$

$$Q_c(l) = \begin{cases} -\frac{1}{|A|}, & \text{만약 } c\text{안에 있는} \\ & \text{화소들의 레이블이} \\ & \text{모두 같으면} \\ \frac{1}{|A|}, & \text{만약 } c\text{안에 있는} \\ & \text{화소들의 레이블이} \\ & \text{모두 같지 않다면} \end{cases}$$

m_c^2 은 클릭 c 의 화소들의 칼라 값들의 분산을 뜻하

고, Δ^2 은 전체 영상의 추정된 칼라 값들의 분산을 말한다. 클릭 potential V_c 의 값을 최소화하기 위해서는 m_c^2 의 값을 최소화 시켜야 한다. 이는 한 영역에 있는 화소들의 칼라는 서로 유사해야 한다는 생각을 반영한다. 클릭 c 의 화소들이 여러 영역에 속할 때, 클릭 potential은 0이 되어 클릭 c 안의 화소들은 서로간에 영향을 미치지 않게 된다. 이는 서로 다른 영역들간의 칼라는 서로에게 상관없이 정해지기 때문에, 서로 다른 영역간에 칼라 값 관계에 대해 어떠한 예측을 할 수 없다는 생각을 반영한다. 클릭 potential Q_c 는 |시|의 값에 의존한다. |시|는 가능한 레이블의 수를 나타내는 것으로, 이 값은 분할되는 영역의 크기에 영향을 준다. $P(X = \omega | G = g)$ 의 최대값을 얻기 위한 식 (2)는 식 (4)와 (6)에 의해 식 (7)과 같이 나타내어지고, log를 취하면 (8)과 같이 나타내어지게 된다.

$$\arg \max_l \left\{ (2\pi\sigma^2)^{-\frac{M_1 M_2}{2}} \exp\left(-\frac{\|\Xi - (g - H(f))\|^2}{2\sigma^2}\right) \times \exp\left(-\sum_{c \in C} (V_c(f|l) + Q_c(l))\right)\right\} \quad (7)$$

$$\log P(X = \omega | G = g) = \left\{ \frac{M_1 M_2}{2} \log(2\pi\sigma^2) + \frac{\|\Xi - (g - H(f))\|^2}{2\sigma^2} + \sum_{c \in C} (V_c(f|l) + Q_c(l)) \right\} \quad (8)$$

식(8)을 사후 에너지 함수라고 정의하자. 전체 영상의 크기를 $M_1 \times M_2$ 이라고 할 때, 전체 영상에 대해서 사후 에너지 함수를 계산하는 것은 복잡하다. 노이즈 필드는 각 화소에서 독립적인 확률 변수들로 이루어져 있기 때문에 $P(N = g - H(f) | X = \omega)$ 는 다음과 같이 각 화소에서의 확률 값들로 곱으로 나타낼 수 있다.

$$\log P(G = g | X = \omega) = \sum_{(i,j) \in S} \left\{ -\frac{\log 2\pi\sigma^2}{2} - \frac{1}{2\sigma^2} (\mu - (g_{i,j} - H(f_{i,j}))) \right\} \quad (9)$$

$P(X = \omega)$ 를 계산하기 위해서는 근사 계산할 수 있는 방법이 필요하다. $P(X = \omega)$ 대신에 국소 조건부 확률들의 곱인 pseudolikelihood(PL)를 사용하여 potential은 다음과 같이 나타내어진다.

$$V_c(f|l) + Q_c(l) = \sum_{c \in \rho_{i,j}} (V_c(f|l) + Q_c(l))$$

$\rho_{i,j}$ 는 화소 (i, j) 를 포함하는 클릭의 집합을 말한다. 식 MAP 추정은 다음과 같이 표현된다.

$$\begin{aligned} \arg \min_l \sum_{(i,j) \in S} & \left\{ \frac{\log(2\pi\sigma^2)}{2} + \frac{\|\mu - (g_{i,j} - H(f_{i,j}))\|^2}{2\sigma^2} \right. \\ & \left. + \sum_{c \in \rho_{i,j}} (V_c(f|l) + Q_c(l)) \right\} \end{aligned} \quad (10)$$

III. 유전자 알고리즘을 이용한 영상의 분할

$P(X = \omega | G = g)$ 의 최대값을 얻기 위해서는 식 (10)에서 정의된 사후 에너지 함수를 최소화해야 한다. 사후 에너지 함수를 최소화하기 위해서는 칼라, 블러링, 노이즈와 같은 파라미터들을 고려해야만 한다. 정의된 사후 에너지 함수를 최적화 하기 위한 모든 파라미터를 탐색하는 데에는 많은 시간이 필요하다.

본 논문에서는 칼라, 블러링, 노이즈와 같은 파라미터들이 서로 독립적이라고 가정한다. 또한 영상은 국소적인 성질을 가진다. 따라서 한 화소의 칼라 값은 주위 화소들의 칼라 값에만 영향을 받으므로, 그 화소의 칼라 값을 결정하기 위해서는 자신과 주위 화소들만을 탐색하면 된다. 그리고 II장에서 언급하였듯이 같은 영역에 속하는 모든 화소들은 같은 블러링 행렬을 가진다고 가정하였다. 그래서, 한 영역의 블러링 행렬을 결정하기 위해서는 자신과 그 이웃한 영역만을 탐색 공간으로 한다. 마지막으로 노이즈는 전체 영상에 대해서 탐색되어진다. 본 논문에서 사용되는 분할 알고리즘은 이러한 파라미터들간의 독립성과 탐색 공간의 계층적 구조를 이용하여 사후 에너지 함수를 최적화 한다.

1. 분할 알고리즘의 구조

본 논문에서 사용되는 분할 알고리즘은 그림 1에서 보여지듯이 다 단계 탐색 구조를 가진다. 상위 단계의 클러스터(cluster)에서는 더 넓은 탐색 공간을 조사한다. 하위 단계에서 탐색된 결과들은 상위 단계로 보내지고,

이 상위 단계는 남아 있는 또 다른 파라미터의 탐색 결과를 덧붙여서 다시 상위 단계로 보낸다. 이렇게 상위 단계에서는 하위 단계들로부터 탐색된 파라미터의 결과를 이용하고자 전체적으로 모든 파라미터 집합을 탐색할 필요가 없다.

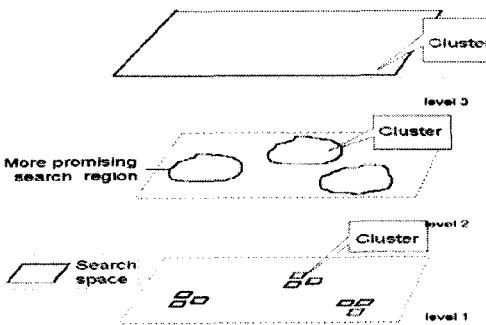


그림 1. 분할 알고리즘의 다단계 탐색 구조
Fig. 1. The structure of multilevel search strategy in segmentation algorithm.

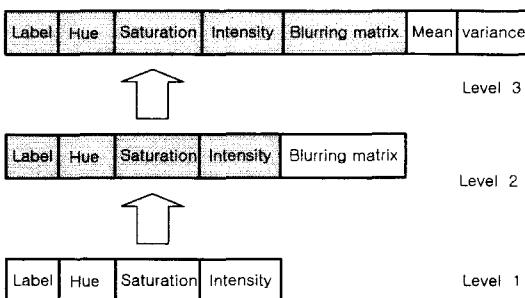


그림 2. 파라미터 탐색 구조
Fig. 2. The structure of parameter search.

그림 2는 본 논문의 파라미터 탐색 구조를 설명한다. 첫 번째 단계는 단지 레이블과 컬러 특징 벡터 값만을 탐색하고 그 결과를 각 영역의 블러링 행렬만을 탐색하는 두 번째 단계에 옮겨 준다. 마지막으로 이러한 파라미터들은 노이즈 파라미터 값을 탐색하는 세 번째 단계에 보내진다. 분할 알고리즘은 정의된 종료 조건에 도달할 때까지 계속해서 파라미터를 탐색한다. 본 논문에서는 각 파라미터의 탐색 알고리즘으로 유전자 알고리즘을 사용한다. 특히 MRF로 모델링 된 영상을 다루기 때문에, 첫 번째와 두 번째 단계에서는 탐색 알고리즘으로 분산 유전자 알고리즘을 사용한다. 그림 3은 각

화소당 염색체의 구조를 보여준다. 각 염색체는 3단계로 초기화된다. 제일 먼저 각 화소의 레이블 값이 가능한 임의의 레이블 집합에서 균일하게 선택되어진다. 두 번째로, 각 레이블 1의 염색체들은 Gaussian 분포에 따라 컬러 값들이 할당된다. 그 다음 각 블러링 행렬을 초기화한다. 블러링 행렬의 5번째 유전자는 1로 하고 나머지는 0으로 주어지는데, 이는 블러링이 일어나지 않았음을 의미한다. 마지막으로, 노이즈의 평균과 분산을 초기화한다.

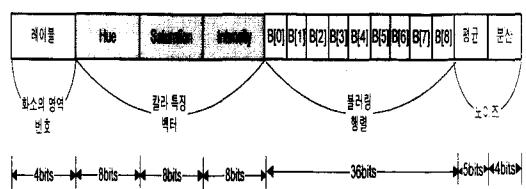


그림 3. 각 화소의 염색체 구조
Fig. 3. The structure of chromosome at a pixel.

2. 유전자 알고리즘의 동작

분산 알고리즘의 첫 번째 단계는 분산 유전자 알고리즘을 사용하여 컬러 특징과 레이블 값을 탐색한다. 이 단계에서 수행되는 연산은 다음 3가지로 구성된다.

- (1) 평가. 각 염색체에 대해서 적합도를 계산한다. 적합도 평가 함수로는 식 (10)에서 정의된 국소적인 사후 에너지 함수를 사용한다.
- (2) 선택. 이웃한 염색체들과의 적합도에 따라 각 염색체를 이웃한 염색체와 바꾼다. 본 논문에서는 선택 기법으로 최적 선택 기법(Elitist Selection Scheme)을 사용한다.
- (3) 교배. 이 단계에서는 교접과 돌연변이가 일어난다. 먼저 교접 과정에서 각 염색체는 같은 레이블을 가지는 이웃을 하나 임의적으로 선택한다. 그리고 현재의 염색체를 이 이웃과 재구성을 한 후, 현재의 염색체를 생성된 두 자손 중의 하나와 바꾼다. 돌연변이 과정에서는 임의로 선택된 염색체의 일부 비트 값을 바꾸어 준다.

두 번째 단계에서는 각 영역의 블러링 행렬을 탐색한다. 블러링 행렬의 각 요소들의 합이 1이라고 가정하였기 때문에 교접과 돌연변이 후에 휴리스틱한 후처리가 요구된다. 이 단계에서 사용되는 탐색 알고리즘 또한 첫 번째 단계와 같이 분산 유전자 알고리즘

(Distributed Genetic Algorithm)을 사용하고 그 연산은 위와 같다. 세 번째 단계에서는 영상의 노이즈 파라미터 값들이 탐색되어진다. 이 단계에서는 일반적인 유전자 알고리즘을 사용하고 연산자는 다음과 같다.

- (1) 평가. 각 염색체에 대해서 적합도를 계산한다. 적합도 평가 함수로는 식 (10)에서 정의된 사후 에너지 함수를 사용한다.
- (2) 선택. 적합도에 따라 다음 세대를 위한 염색체를 사용한다.
- (3) 교배. 이 단계에서는 교접과 돌연변이가 일어난다. 먼저 교접 과정에서 임의로 선택된 두 개의 염색체를 재구성하여 그 자손 중 하나를 선택한다. 돌연변이 과정에서는 임의로 선택된 염색체의 비트 값들을 바꾸어 준다.

3. 종료 조건

종료 조건은 제안된 시스템의 전체 종료 조건과 각 단계에서의 종료 조건으로 나뉘어진다. 먼저 안정도 기준(stability criterion)을 정의한다. 각 세대에서 안정도는 다음과 같이 정의된다.

$$\text{안정도}(\%) = \frac{\text{바로 전 단계와 같은 레이블 값을 가지는 화소들의 수}}{\text{영상의 전체 화소들의 수}} \times 100$$

만약, 안정도가 정의된 각각의 경계값 이상이 되면 안정도 기준에 도달한다. 각 단계의 유전자 알고리즘의 종료 조건은 다음과 같다 : 최대 반복 세대수에 도달할 때나; 최대 안정도 기준에 도달할 때나 ; 연속한 세대간에 안정도 기준에 도달하는 횟수가 정의된 수 이상 일 때에 종료된다.

시스템의 전체 종료 조건은 최대 반복 세대수에 도달할 때 ; 최대 안정도 기준에 도달할 때 ; 연속한 세대간에 안정도 기준에 도달하는 횟수가 정의된 수 이상일 때이다.

IV. 실험 결과 및 분석

본 논문에서 제안한 방법의 성능을 검사하기 위하여, 200개의 영상을 가지고 실험하였다. 제안한 시스템은 펜티엄 PC에서 Visual C++로 Window환경 하에서 구현되었다. 입력 도구로는 삼성 SV-33 캡코더를 사용하

였다. 최대 레이블의 수는 16으로 한 점의 이웃은 주위의 연속된 8개의 점으로 이루어진다. 최대 반복 수는 500으로, 안정도의 경계값은 99.95%, 그리고 최대 안정도 기준은 99.99%로 두었다. 마지막으로, 최대 안정화 도달 회수는 5로 두었다. 제안된 방법의 효율성을 보여주기 위해서 실제의 영상을 가지고 실험이 이루어졌다. 칼라, 노이즈, 블러링과 같은 많은 특징들을 고려하여 영상을 분할하는 제안된 방법의 효율성을 검증하기 위해, 각 고려되는 특징들에 따라 실험을 수행하고 그 결과를 분석하였다.

그림 4는 194×175 크기의 실험 영상에 대한 제안된 방법의 분할 결과들을 보여준다. 그림 4(a)는 관측 영상을 보여주고, 153×153 그림 4(b)는 칼라 특징 값만을 탐색하면서 분할한 결과를 보여준다. 그림 4(c)는 칼라 특징 값과 블러링 행렬을 탐색하면서 수행한 결과이다. 그림 4(d)는 칼라 특징 값, 블러링 행렬, 노이즈 모두를 탐색하면서 분할한 결과이다. 그림 5은 153×153 크기의 실험 영상에 대한 제안된 방법의 분할 결

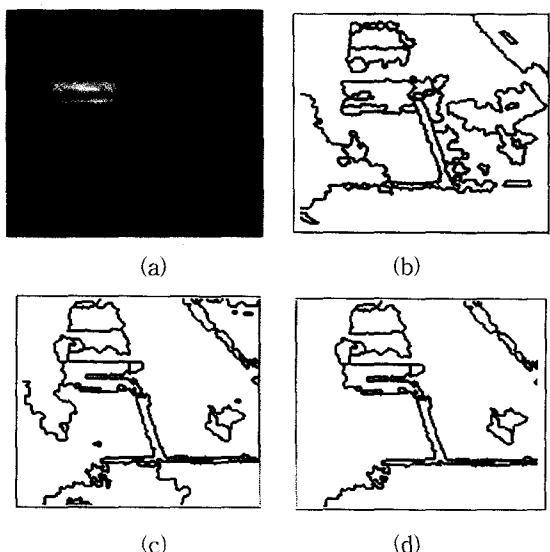


그림 4. 분할 결과의 예(실험 1) : (a) 원래의 영상; (b) 칼라 특징값만을 탐색; (c) 칼라 특징값과 블러링 행렬을 탐색; (d) 칼라 특징, 블러링 행렬, 노이즈를 탐색

Fig. 4. Example of segmentation results(experiment 1) : (a) original image; (b) The results searched for only color; (c) The results searched for color and blurring; (d) The results searched for color, blurring, and noise.

과들을 보여준다. 그림 5(a)는 관측 영상을 보여주고, 그림 5(b)는 칼라 특징 값만을 탐색하면서 분할한 결과를 보여준다. 그림 5(c)는 칼라 특징 값과 블러링 행렬을 탐색하면서 수행한 결과이다. 그림 5(d)는 칼라 특징 값, 블러링 행렬, 노이즈 모두를 탐색하면서 분할한 결과이다.

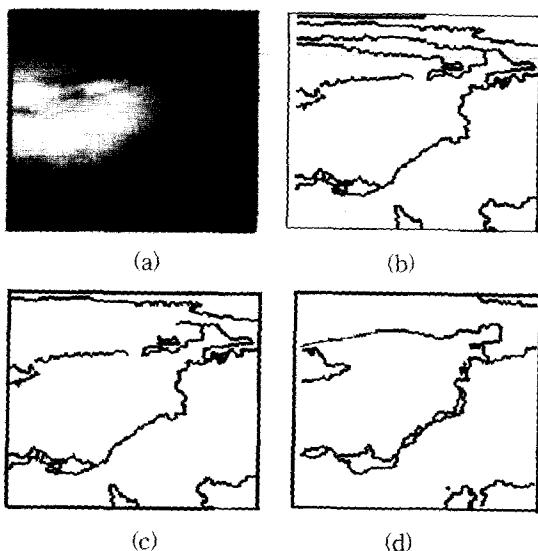


그림 5. 분할 결과의 예(실험 2) : (a) 원래의 영상; (b) 칼라 특징값만을 탐색; (c) 칼라 특징값과 블러링 행렬을 탐색; (d) 칼라 특징, 블러링 행렬, 노이즈를 탐색

Fig. 5. Example of segmentation results(experiment 2) : (a) original image; (b) The results searched for only color; (c) The results searched for color and blurring; (d) The results searched for color, blurring, and noise.

그림 6은 실험 1(그림 4)에서 세대수와 안정도와의 관계를 보여주는 것이다. 그림에서 보여지듯이 고려하는 파라미터가 많아질수록 최대 안정도 기준에 도달하는 반복 세대수가 감소하는 것을 알 수 있다. 그림 7은 실험 1에서 세대수와 사후 에너지 함수와의 관계를 보여준다. 이 그림은 고려하는 파라미터가 많아질수록 사후 에너지 함수는 더 빠른 속도로 감소한다는 것을 보여준다.

그림 6과 그림 7은 제안된 사후 에너지 함수를 최소화함으로써 영상분할이 이루어진다는 것을 보여준다. 제안된 방법의 영상분할 결과를 평가하기 위해서, 본

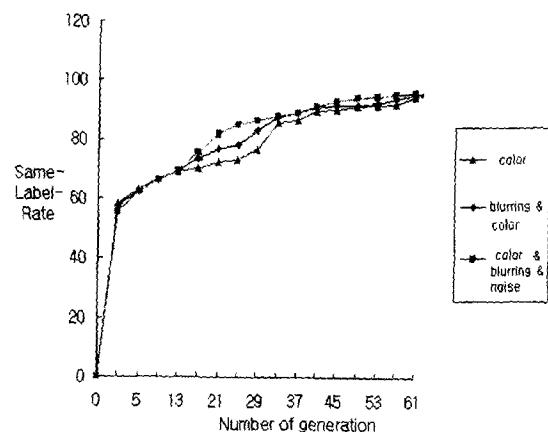


그림 6. 세대수와 안정도와의 관계

Fig. 6. Relations between samelabelrate and the number of generations.

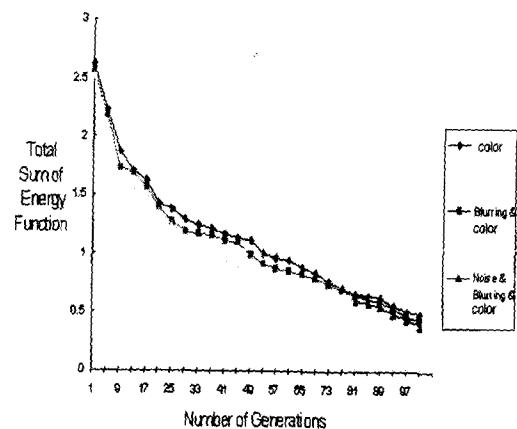


그림 7. 세대수와 사후 에너지 함수와의 관계

Fig. 7. Relations between a posterior energy function and the number of generations.

논문에서는 Jianqing Liu와 Yee-Hong Yang에 의해 제안된 평가 기준을 사용하였다^[7]. 표 1은 실험 1과 실험 2의 실험 결과 평가를 보여준다. 표 1에서의 함수 “F”는 다음과 같이 정의된다.

$$F(I) = \sqrt{R} \times \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}}$$

여기서 I 는 분할되는 영상을, R 은 분할된 영상에서 영역의 수, A_i 는 영역 i 의 화소들의 수, 그리고 e_i 는 영역 i 의 칼라 오차로 다음과 같이 정의된다. 영역 i 에 있는 각 화소들의 관측된 영상과 분할된 영상을 간에 칼라 값의 Euclidean distance의 합으로 정의된다.

\sqrt{R} 은 너무 많은 영역을 가지는 분할에 벌점(penalty)을 주는 전역적인(global) 항이고, $\frac{e_i^2}{\sqrt{A_i}}$ 는 크기가 작거나 큰 칼라 오차를 가지는 영역에 분할을 주기 위한 국소적인 항이다. e_i^2 은 영역에 적절한 칼라 값이 할당되었는지를 나타내는 항이다. F 의 값이 작을수록 분할 결과가 더 좋다는 것을 의미한다. 그리고, “평균 칼라 에러”는 e_i 의 평균값, 즉 $(\sum_{i=0}^R e_i)/R$ 을 의미한다. 표 1에서 보여지듯이 고려하는 파라미터가 많아짐에 따라 분할 결과의 질이 향상된다는 것을 알 수 있다. 그럼 6과 그림 7, 그리고 표 1로부터 본 논문에서 제안된 방법이 많은 파라미터를 고려하는 복잡한 문제를 다루는 데 효율적이라는 것을 보여준다.

표 1. 실험 1과 실험 2의 결과 평가

Table 1. Evaluation of Experiments 1 and 2.

	측정치	영역의 수	F	평균 칼라 에러
실험 1	결과 (b)	31	604.50	22561.61
	결과 (c)	23	462.07	39706.87
	결과 (d)	20	403.61	43083.20
실험 2	결과 (b)	23	915.40	23911.26
	결과 (c)	21	880.95	26457.10
	결과 (d)	15	389.10	35059.87

본 논문에서는 제안된 방법을 자동 차량 추출 시스템에 적용하였다. 차량 추출은 도로 영상에 대해서 교통량, 속도 등과 정보를 구하는 도로 정보 시스템에서 중요한 단계이다. 제안된 방법으로 관측 영상을 먼저 분할한 후, 얻어지는 각 영역에 대해서 그 영역의 평균 칼라 값을 계산하였다. 그리고 가장 큰 영역을 차지하는 영역의 근처 칼라 값을 도로 색으로 간주하고, 차량을 추출하였다. 그림 8(a)는 154×224 크기의 입력 영상을 보여준다. 그림 8(b)는 제안된 방법으로 수행된 분할 결과를 보여준다. 그리고 그림 8(c)는 각 영역의 평균 칼라 값을 보여주고, 8(d)는 추출된 차량을 보여준다. 실험 결과는 제안된 분할 방법이 정지된 도로 영상에 대해서 차량을 추출하는데 효율적이라는 것을 보여준다.

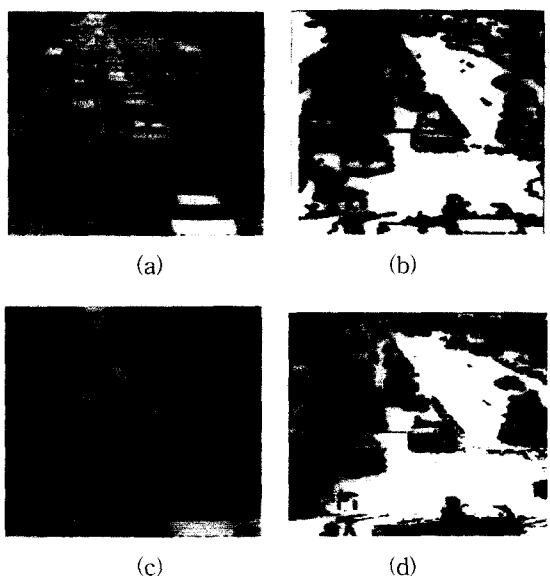


그림 8. 제안된 방법의 응용 예 : (a) 원래의 영상; (b) 제안된 방법에 의해 수행된 분할 결과; (c) 영역의 평균 칼라 값; (d) 추출된 차량

Fig. 8. The application example of the proposed method : (a) original image; (b) The segmentation results performed by the proposed method; (c) The color mean of each region; (d) The extracted vehicles.

V. 결 론

본 논문은 노이즈와 블러링에 의해 오염된 영상에 대한 분할 방법을 제안했다. 정교한 분할과 실 영상에의 적용을 위해서 관측 영상에서 칼라, 블러링, 노이즈와 같은 많은 특징 값을 고려하였다. 많은 특징 값을 고려하기 때문에 관측된 영상에 대해서 최적의 레이블 값을 얻어내는 것은 복잡하다. 이러한 이유로, 본 논문에서는 MRF 모델을 사용하여 영상을 모델링 하였다. MRF 모델은 오염된 영상에 효율적이고, MRF 모델에서 어떤 화소의 확률 값을 전제 이미지가 아니라 주위의 화소에 의존한다. 본 논문에서는 주어진 관측 영상에 대해 영상 레이블의 조건부 확률 분포(conditional probability distribution)를 최대화하는 레이블을 최적의 레이블로 추정하였다. Bayesian 추정에서 이러한 형태는 사후 확률 최대화 추정(Maximum a posteriori or MAP estimation)으로 알려져 있다. Hammersley-clifford 이론은 MRF-Gibbs equivalence를 증명했다. 따라서 사후 확률 최대화의 문제는 사후 에너지 함수

의 최소화로 나타내어진다. 사후 에너지 함수를 최소화하기 위해서는 함수에 포함되어 있는 칼라, 블러링 행렬, 노이즈의 분산과 평균과 같은 파라미터가 탐색되어져야 한다. 본 논문에서는 파라미터들이 서로 독립적이라고 가정하였다. 더불어 영상의 국소성은 각 파라미터의 탐색이 분산적으로 수행할 수 있다는 것을 보인다. 각 파라미터의 탐색 알고리즘으로 유전자 알고리즘을 사용하였다. 많은 파라미터가 포함된 복잡한 식을 최적화하기 위해서 본 논문에서는 계층적이고 분산적인 분할 알고리즘을 제안하였다. 실 영상을 가지고 실험한 결과는 제안된 방법이 실제의 영상을 분할하는데 효율적이라는 것을 보여준다.

제안된 방법은 다음과 같은 장점을 가진다. 첫째, 제안된 방법은 강한 병렬성을 가진다. 둘째, 차량 추출과 같은 다른 여러 컴퓨터 비전 문제에 확장해서 적용될 수 있다. 마지막으로, 관측 영상에서 많은 파라미터를 고려하기 때문에 손상이 많이 된 실 영상에의 적용이 가능하다.

제안된 영상분할 방법은 단일 프로세스 상에서 수행되어졌다. 단일 병렬 기계에서 수행된다면 실시간 분할이 가능할 것이다. 향후 연구 과제는 제안된 방법을 병렬 기계에서 수행함으로써 실시간 가능함을 보이는 것 그리고, 제안된 방법을 물체 인식과 같은 여러 가지 컴퓨터 비전 문제에까지 확장하는 것이다.

참 고 문 헌

- [1] N. R. Pal and S. k. Pal "A Reviews On Image Segmentation Techniques," Pattern Recognition. Vol. 26, No. 9, pp. 1277-1294, 1983.
- [2] Philippe Andrey and Philippe Tarroux, "Unsupervised Image Segmentation using a Distributed Genetic Algorithm," Pattern Recognition, Vol. 27, No. 5, pp. 659-673, 1994.
- [3] S. Gemam and D. Geman, "Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images", IEEE Trans. Pattern Anal. Mach. Intell., PAMI-6, pp. 721-741, 1984.
- [4] D. J. Ballard and C. M. Brown, Computer Vision, pp 116, Prentice-Hall, Inc., EnglewoodCliffs, NJ, 1992.
- [5] J. M. Hammersley, and P. Clifford, "Markov field on finite graphs and lattices," 1971.
- [6] J. Besag, "Spatial Interaction and the Statistical Analysis of Lattice Systems," Journal of the Royal Statistical Society, Series B 36, pp. 192-236, 1974.
- [7] Jianqing Liu, Yee-Hong Yang, "Multiresolution Color Image Segmentation," IEEE Trans. on PAMI, vol. 16, no. 7, pp. 689-700, July, 1994.
- [8] H. J. Kim, D. W. Kim, S. K. Kim, J. U. Lee and J. K. Lee, "Automatic Recognition of a Car License Plate using Color Image Processing", Engineering Design and Automation Journal, Vol. 3, No. 1, 1997.
- [9] J. W. Kim and B. P. Zeiger, "Hierarchical Distributed Genetic Algorithms: A Fuzzy Logic Controller Design Application", IEEE EXPERT, vol. 11, no. 3, pp. 76-84, 1996.
- [10] Eun Yi Kim, Jin Wook Kim, Se Hyun Park, and Hang Joon Kim, "An MRF Model based Image Segmentation using Hierarchical Distributed Genetic Algorithm," Proc. Second IEEE Int. Conf. on Intelligent Processing Systems, pp. 438-442, 1998.
- [11] 김 은이, 박 세현, 김 진욱, 김 항준, "계층적 분산 유전자 알고리즘을 이용한 MRF 모델에 기반한 영상의 분할," 한국정보과학회 가을 학술발표논문집, vol. 25, no. 2, pp. 470-472, 1998
- [12] Hang Joon Kim, Eun Yi Kim, Jin Wook Kim, and Se Hyun Park, "An MRF Model based Image Segmentation using Hierarchical Distributed Genetic Algorithm," IEE Electronics Letters, Vol 34, No. 25, pp. 2394-2395, 1998.
- [13] Jin Wook Kim, Eun Yi Kim, Se Hyun Park, and Hang Joon Kim, "Segmentation of MRF based Image using Hierarchical Genetic Algorithm," ACCV'98, vol. 1, pp. 730-737, 1998.

저자소개

金 恩 伊(正會員)

1997년 경북대학교 컴퓨터공학과
졸업(공학사), 1999년 경북대학교
대학원 컴퓨터공학과 졸업(공학硕
士). 1999년~현재, 경북대학교 대
학원 컴퓨터공학과 박사과정. 주관
심분야는 영상처리, Motion analysis,
Computer Vision

朴 世 玎(正會員) 第 36卷 C編 第 8號 參照

鄭 基 哲(正會員) 第 36卷 C編 第 8號 參照

金 恒 俊(正會員) 第 36卷 C編 第 8號 參照