

論文98-35S-4-11

확률적 확산을 이용한 스테레오 정합 알고리즘

(New Stereo Matching Algorithm Based on Probabilistic Diffusion)

李相和*, 李忠雄*

(Sang-Hwa Lee and Choong-Woong Lee)

요 약

본 논문에서는 확률적 확산을 이용한 스테레오 정합 알고리즘을 제안한다. Bayesian 모델에 기초하여 일반화된 스테레오 정합 기법 공식을 유도하고, 새로운 확률모델을 적용한 기법을 구현하고 있다. 이웃하고 있는 깊이정보간의 확률적인 독립성과 유사성을 기초로 하여 제안된 확률모델에 따라서 유도된 일반적인 확산 알고리즘 공식은 다른 형태로 변형되어 에너지공간을 확산시키며, 안정적으로 수렴된 에너지공간으로부터 최적의 깊이정보를 추정한다. 모의실험 결과에 의하면, 일반적으로 유도된 확산공식은 스테레오 영상간의 깊이정보를 추정하는데 좋은 성능을 보였으며, 제안된 확률모델에 기초한 기법과 함께 기존의 다른 방법들에 비하여 보다 우수한 성능을 보여주었다. 이러한 실험결과는 유도된 확산공식이 스테레오 정합에서 효과적인 기법이 될 수 있음을 의미하며, 본 논문에서 제안된 확률모델도 일반적인 확률분포를 근사적으로 예측하는데 적절하고 타당함을 보여주는 것이다.

Abstract

In this paper, the general formula of disparity estimation based on Bayesian Maximum A Posteriori (MAP) algorithm is derived and implemented with simplified probabilistic models. The probabilistic models are independence and similarity among the neighboring disparities in the configuration. The formula is the generalized probabilistic diffusion equation based on Bayesian model, and can be implemented into the some different forms corresponding to the probabilistic models in the disparity neighborhood system or configuration. And, we propose new probabilistic models in order to simplify the joint probability distribution of disparities in the configuration. According to the experimental results, the proposed algorithm outperformed the other ones, such as sum of squared difference(SSD) based algorithm and Scharstein's method. We can conclude that the derived formula generalizes the probabilistic diffusion based on Bayesian MAP algorithm for disparity estimation, and the proposed probabilistic models are reasonable and approximate the pure joint probability distribution very well with decreasing the computations to 0.01% of the generalized formula.

I. 서 론

1. 스테레오 영상
스테레오 정합은 각각 다른 시점에서 만들어진 스테레

오 영상내에서 물체의 깊이정보를 추정하는 기법이다. 스테레오 정합은 2차원의 스테레오 영상을 이용하여 3차원의 깊이정보를 추정하며, 3차원 영상에서의 객체 분리, 영상내의 입체구조 추정, 영상의 합성 등에서 용

* 正會員, 서울대학교 電氣工學部

(School of Electrical Eng., Seoul Nat'l Univ.)

※ 이 논문은 1995년도 한국학술진흥재단의 대학부설

연구소 연구과제 연구비에 의하여 연구되었음

接受日字: 1997年12月15日, 수정완료일: 1998年3月30日

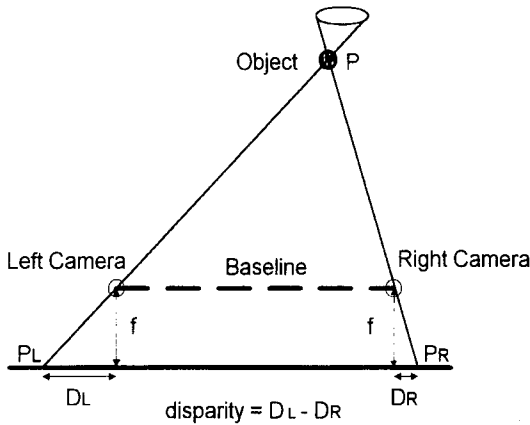


그림 1. 스테레오 영상 및 깊이정보
Fig. 1. The concept of the stereogram and the disparity.

용할 수 있는 분야이다^[2,3,7]. 스테레오 영상 및 깊이 정보(disparity)는 그림 1에서 개념적으로 설명되어 있다. 기본적으로 스테레오 영상은 여러 개의 동일한 초점을 갖는 카메라에 의하여 얻어지게 되는데, 그림 1에서는 일반적인 경우로서 두 개의 카메라를 이용한 스테레오 영상을 보여주고 있다. 두 카메라를 연결한 선을 기저선(baseline)이라 하며, 물체는 렌즈를 통과하여 기저선과 평행한 영상평면(image plane)에 투영된다. 영상평면이 기저선과 평행하게 되면, 깊이정보는 투영모델(perspective model)을 기초로 하는 1차원의 선형적인 기하학 구조로 단순화되며, 이러한 구조를 1차원의 epipolar 구조라고 한다^[5]. 일반적인 스테레오 정합에서는 기법의 단순함을 위하여 1차원의 epipolar 구조를 만족하도록 스테레오 영상을 형성하며, 이러한 경우에 그림 1에서와 같이 간단하게 깊이정보를 설명할 수 있다. 즉, 물체의 동일한 지점(P)이 두 영상평면에 투영되고(PL, PR), 각 카메라의 초점에서 영상평면으로 내린 수선의 교점으로부터 각각의 투영된 영상지점의 거리(DL, DR)간의 차이가 깊이정보이다.

2. 다양한 스테레오 정합 기법

현재까지 스테레오 영상으로부터 깊이정보를 추정하기 위하여 많은 기법들이 제안되었다. 오차제곱합(sum of squared differences) 기법^[9,10]은 현재의 화소 위치를 중심으로 블록을 설정하고, 일정한 거리의 범위 내에서 블록을 평행이동 시키면서 스테레오 영상간의 화소값의 차이를 제공하여 그 블록에 속하는 모든 값

들을 합한다. 각 평행이동 거리 중에서 최소의 오차제곱합을 갖는 거리를 깊이정보로 추정한다. 이 방법은 구현하기가 매우 쉽고 블록의 크기 및 형태에 따라서 적응적이고 다양한 기법을 도입할 수 있는 장점이 있는 반면에, 블록의 크기에 지나치게 성능의 영향을 받고, 블록의 크기가 커질수록 깊이정보가 지역통과 필터링(low pass filtering)되어 명확해야 할 물체의 경계가 번지는 단점이 있다. 화소값변화에 기반한 기법 (gradient based algorithm)^[14,15]은 화소의 차이만을 기준으로 하지 않고, 그 변화량을 오차추정의 기준으로 도입하여 새로운 비용함수를 정의한 것이다. 실제 영상의 경우, 물체를 보는 시점이나 각도에 따라서 같은 색이라 하더라도 다르게 보이는 경우가 많은데, 이러한 시각적인 특성을 고려하여 물체의 깊이정보를 추정하고자 하는 것이다. 제안된 비용함수는 화소값의 차이를 기준으로 한 부분과 변화량을 기준으로 한 부분의 두 가지로 구성되어 있으며, 스테레오 영상의 내용에 따라서 서로 적응적으로 가중합되어 깊이정보를 찾는다. 이 기법은 새로운 비용함수의 도입과 인간 및 카메라의 시각특성을 고려한 점에서 좋은 성능을 갖고 있지만, 균일하게 화소값이 변하는 영역에 대해서 문제가 제기되고 있다. 확산에 기반한 기법(diffusion based algorithm)^[11,12]은 공간영역에서의 에너지확산 방정식에 의하여 각 화소위치에서 구해진 오차에너지를 확산시키고, 최소의 에너지를 갖는 깊이정보를 추정하는 기법이다. 에너지확산 방정식은 에너지함수의 시간영역에서의 1차미분과 공간영역에서의 2차미분이 동일함을 나타낸 선형관계식으로서, 화소값을 기반으로 하여 구해진 오차에너지를 확산시킨다. 확산에 의하여 에너지분포가 안정하게 수렴된 후에 최소의 에너지를 갖는 깊이정보를 추정한다. 그러나 일반적인 영상의 비선형성을 고려하면, 이 방법은 선형관계식에 기반을 두고 있기 때문에 보다 정확한 깊이정보의 추정을 위하여 다양하고 적응적인 비선형 기법을 도입하는데 어려움이 있다.

3. 본 논문의 내용 및 구성

본 논문에서는 깊이정보의 추정을 위하여 Bayesian 모델을 기반으로 한 확률적 확산기법을 제안한다^[4]. 이 기법은 Markov Random Field(MRF) 이론^[4,8]과 다양한 확률모델에 따라서 확산관계식을 유도하고 있다. 주어진 스테레오 영상에 대하여, 깊이정보간의

관계와 화소값의 관계에 의한 오차에너지를 구하고 이를 MRF이론에 의하여 확률적으로 확산시켜서 조건부 확률이 가장 높은 깊이정보를 추정한다. 오차에너지를 부터 확률을 구하기 위하여 Gibb 확률분포^[8]를 도입하고 있는데, 이 확률분포는 에너지영역의 값을 확률영역으로 일대일 변환시키는 함수이다. 앞에서 설명한 확산에 기반한 기법과 마찬가지로 오차에너지공간, 또는 확률공간이 확산에 의하여 수렴한 후에 최소의 오차에너지를 갖거나 최대의 확률을 갖는 깊이정보를 추정한다. 이 기법은 앞에서 언급한 확산방정식에 기반한 기법과는 달리, 비선형적인 확률적확산에 기초를 두고 있으며, 깊이정보에 대한 확률모델에 따라서 다양하고 적응적인 기법이 가능하다는 장점이 있다.

본 논문의 구성은 다음과 같다. 2장에서는 스테레오 정합을 위한 Bayesian Maximum A Posteriori (MAP) 추정에 대하여 일반적이고 기본적인 이론을 정리하고 있다. 3장에서는 일반화된 확률적 확산공식을 유도하고, 부등식에 의한 분석을 통하여 확률 및 오차 에너지의 수렴성을 확인한다. 4장에서는 깊이정보에 대한 확률모델을 제안하고, 이를 적용하여 다시 새로운 확산공식을 유도한다. 모의실험결과는 5장에서 제시되며, 끝으로 6장에서는 본 논문에서 제안한 기법에 대하여 결론을 내리고 있다.

II. Bayesian Maximum A Posteriori (MAP) 추정

Bayesian 모델에 기반한 스테레오 정합 기법은 각각 다른 시점에서 만들어진 스테레오 영상에 대하여 깊이정보의 조건부확률을 최대로 만드는 깊이값을 추정한다. 이를 수식적으로 기술하면, 다음과 같이 다시 정리할 수 있다.

$$\text{maximize } p(\mathbf{D}|\{\mathbf{I}\}), \{\mathbf{I}\} = \{\mathbf{I}_R, \mathbf{I}_K, K=1,2,\dots\}. \quad (1)$$

식 (1)에서 $\{\mathbf{I}\}$ 는 스테레오 영상을 의미하고, \mathbf{I}_R 는 기준이 되는 스테레오 영상이다. \mathbf{D} 는 3차원의 입체구조인 깊이정보를 하나의 2차원의 벡터로 표현한 것이다. 그런데 일반적으로 깊이정보의 완전한 분포는 잘 알려져 있지 않고 모든 경우에 대하여 확률을 구하기에는 지나치게 많은 계산량이 요구되기 때문에, 식 (1)에서의 조건부확률을 직접적으로 구하는 것은 매우 어

려운 문제이다. 따라서 일반적으로 이용되는 측정값을 확률값으로 변환시켜 주는 새로운 함수가 필요하다. Gibb 확률분포는 확률변수가 에너지함수의 변수로 정의된 지수함수로서 다음과 같이 나타낸다.

$$p(x) = C \exp\left\{-\frac{E(x)}{T}\right\}. \quad (2)$$

Gibb 확률분포에서 $E(x)$ 는 확률변수 x 에 대한 에너지함수로서, 일반적으로 x 는 오차를 의미하고 이를 제곱함으로써 쉽게 오차에 대한 에너지를 구할 수 있다. 즉, Gibb 확률분포는 에너지공간에서 확률공간으로 일대일 변환시켜 주는 함수이다. 이제 Gibb 확률분포를 이용하여 확률공간에서 정의된 스테레오 정합 문제를 에너지공간의 문제로 변환할 수 있다^[4,8].

$$p(\mathbf{D}|\{\mathbf{I}\}) \propto \exp\{-E(\mathbf{D}|\{\mathbf{I}\})\}. \quad (3)$$

식 (3)에 의하면 Bayesian 모델에 의한 스테레오 정합은 조건부확률 $p(\mathbf{D}|\{\mathbf{I}\})$ 을 최대화하는 깊이정보를 추정하는 것으로부터 $E(\mathbf{D}|\{\mathbf{I}\})$ 을 최소화하는 깊이정보를 찾는 문제로 새롭게 정의할 수 있다. 식 (3)의 조건부확률은 확률이론에서의 Bayesian 등식에 의하여 식 (4)의 관계식을 만족하고, 이 식을 Gibb 확률분포에 의하여 역변환시키면 식 (5)를 얻을 수 있다.

$$p(\mathbf{D}|\{\mathbf{I}\}) = \frac{p(\{\mathbf{I}\}|\mathbf{D})p(\mathbf{D})}{p(\{\mathbf{I}\})}, \quad (4)$$

$$E(\mathbf{D}|\{\mathbf{I}\}) \propto E(\{\mathbf{I}\}|\mathbf{D}) + E(\mathbf{D}). \quad (5)$$

스테레오 영상, $\{\mathbf{I}\}$ 는 이미 주어져 있는 고정된 값으로 이에 대한 확률은 상수처럼 취급할 수 있고 깊이정보에 대하여 독립적인 값이므로 본 논문에서의 수식 전개 과정에서는 고려하지 않고 있다. 식 (5)는 확률적으로 에너지를 확산시키는 방식이므로 확률공간의 문제를 에너지공간에서 기술하고 있다. 식 (5)에서 첫 번째 에너지항은 깊이정보가 주어져 있을 때, 스테레오 영상간의 화소값의 차이에 의한 에너지를 의미하며, 식 (6)에서처럼 기준이 되는 영상의 화소값과 깊이정보만큼 이동시킨 다른 스테레오 영상의 화소값 사이의 차이를 이용하여 얻어진다.

$$E(\{\mathbf{I}\}|\mathbf{D}) = \sum_{\mathbf{I}_K \in \{\mathbf{I}\}} \rho_i(\mathbf{I}_R - \mathbf{I}_K(\mathbf{D})). \quad (6)$$

식 (6)에서 $\mathbf{I}_K(\mathbf{D})$ 는 깊이정보 \mathbf{D} 만큼 스테레오 영상

의 확산을 이동시킨 것이며, $\rho_i(\cdot)$ 는 에너지함수로서 일반적으로 제곱함수, $\rho_i(x) = x^2$ 이 사용된다. 에너지함수가 제곱함수인 경우, Gibb 확률분포는 Gaussian 확률분포가 되며, Dirac-delta 함수, $\rho_i(x) = c \cdot \delta(x)$ 인 경우에는, 차이가 0일 때를 제외하고 균일한 값을 갖는 Dirac-delta 분포가 된다. 이러한 분포는 매우 극단적인 경우로서, 본 논문에서는 이 두 분포를 포함하면서 모든 경우의 에너지 확률분포를 갖도록 일반화된 에너지함수를 사용한다. contaminated Gaussian 에너지함수는 다음과 같이 정의되는 에너지함수로서, 두 개의 매개변수에 의하여 Gaussian 확률분포와 Dirac-delta 확률분포 사이의 모든 확률분포를 포함할 수 있다.

$$\rho_i(x) = -\log \left((1 - \varepsilon_i) \exp \left\{ -\frac{x^2}{2 \sigma_i^2} \right\} + \varepsilon_i \right). \quad (7)$$

식 (7)에서 매개변수 σ_i 는 확률변수의 분포에 대한 폭을 나타내는 표준편차로서, 확률적으로 의미가 있는 오차, x 의 범위를 결정하는 대단히 중요한 요소이다. 이 매개변수에 의하여 확률적으로 높은 관계가 있는 주위의 깊이정보가 적응적으로 선택되어 에너지공간을 확산시킨다. 매개변수 ε_i 는 contaminated Gaussian 에너지함수의 포화된 최대값을 결정하는 요소이다. 일반적인 $\rho_i(x) = x^2$ 함수에서는 변수의 값이 평균에서 멀어질수록 에너지의 값이 무한히 증가하고 이것은 Gaussian 확률분포에서 0으로 수렴하면서 계속 작아지지만, contaminated Gaussian 함수에서는 일정한 값을 벗어나면 에너지 및 확률값이 포화된다. 이것을 확률적 확산의 측면에서 설명하면, σ_i 의 오차내에서는 높은 확률을 적용하고, 어느 정도의 오차 이상에 대해서는 모두 같은 수준의 낮은 확률을 적용하여 에너지를 확산시키는 역할을 하는 것이다. 매개변수 ε_i 는 포화되는 에너지의 수준을 결정하는 요소가 되며, 식 (5)에서 두 에너지함수의 가중치를 변화시킨다. 그림 2는 contaminated Gaussian 에너지함수를 보여주고 있다.

식 (5)에서 두 번째 항, $E(\mathbf{D})$ 는 깊이정보의 분포를 기반으로 하는 에너지로, 인접하고 있는 깊이정보의 상관성을 반영하고 있는 에너지이다. 깊이정보의 분포가 비교적 연속적이고 균일하면, 이 에너지의 값은 작아지고, 깊이정보의 분포가 비연속적이고 변화가 클 때는, 이 에너지의 값은 증가한다. 이것은 MRF 이론에 기초하여 인접한 깊이정보간의 유사성을 고려하기 위




그림 2. Contaminated Gaussian 에너지 그래프. 원점에서 멀어짐에 따라 함수값은 포화된다. 이것이 일반적인 제곱함수와의 차이가 된다.

Fig. 2. Contaminated Gaussian energy graph. As the point is far away from origin, the value of the function is saturated. this is the different characteristics from the usual square function.

한 에너지로서, 인접한 깊이정보 사이에는 연속성과 상관성이 크다는 것을 이용함과 동시에 추정된 깊이정보들의 균일성을 보장하는 기능을 한다. 이 에너지 항은 확률적 확산의 과정에서 깊이정보의 분포를 균일화시키고, 이웃하는 깊이정보의 유사성을 증가시켜 스테레오 영상의 전체 깊이정보를 추정하는데 매우 중요한 기능을 한다. 본 논문에서는 식 (5)의 첫 번째 에너지함수와 마찬가지로 이 깊이정보에 기반한 에너지에 대해서도 contaminated Gaussian 에너지함수를 적용하고 있다.

$$\rho_d(x) = -\log \left((1 - \varepsilon_d) \exp \left\{ -\frac{x^2}{2 \sigma_d^2} \right\} + \varepsilon_d \right). \quad (8)$$

식 (8)에서도 두 매개변수, σ_d 와 ε_d 를 조절하여 인접한 깊이정보간의 상관성과 유사성을 이용한 확률적 확산을 할 수 있다. 즉, 표준편차, σ_d 에 의하여 상관성을 적용할 수 있는 깊이정보의 오차범위를 결정할 수 있고, ε_d 에 의하여 최대 에너지수준 또는 최소 확률수준을 조절하여 확산값에 기반한 에너지와의 가중치를 변화시킬 수 있다. Contaminated Gaussian 에너지함수를 사용하는 것은 확률적으로 상관성이 적은 깊이정보가 추정되었을 때, 그 오차의 정도가 일정한 범위를 벗어나는 깊이정보에 대해서는 최소의 동일한 확률을 적용하기 위해서이다. 즉, 오차가 큰 것들은 추정하는 과정에서 확률적으로 배제하는 것이다.




그림 3. 영상평면(xy plane)과 깊이정보(d)축에 의한 3차원의 에너지공간. 각 위치 (x,y,d)에서 에너지값이 존재하고 이들은 확률적으로 확산된다.

Fig. 3. The energy space with xy-image plane and disparity axis(d). The energy value exists at every point, (x,y,d) and is diffused probabilistically.

III. 확률적 확산에 의한 스테레오 정합

이 장에서는 화소 단위로 확률적 확산에 의한 스테레오 정합 기법을 일반화시켜서 유도하고 이를 해석하여, 확률적 확산과정에서 깊이정보의 확률분포와 확률모델이 어떠한 영향을 미치는가를 분석한다. 우선 일반화된 확률적 확산 방정식을 유도하기 전에 에너지공간에 대한 개념을 도입할 필요가 있다. 그림 3은 에너지공간에 대한 개념도이다. x와 y축은 영상평면이고, d축은 깊이값에 대한 축으로서 3차원의 각 위치, (i,j,d)에서 에너지값이 계산되고, 주위의 깊이정보를 확률적으로 이용하여 확산이 이루어진다. 에너지공간은 화소값의 차이에 기반하여 모든 깊이값에 대하여 영상의 전 영역에서 구해지며, 이러한 초기값들은 3장에서 유도되는 확률적 확산방정식과 깊이정보에 대한 확률모델에 의하여 d축을 따라서 반복적으로 확산되어 진다. 이 에너지공간은 여러 번의 반복적인 확산에 의하여 안정적으로 수렴하고 이 에너지공간에서 각 d축을 따라서 최소의 에너지를 갖는 깊이값을 그 영상평면의 깊이정보로 추정하게 된다.

1. 확산방정식의 유도

영상평면의 위치 (i,j)에서의 깊이값을 $d_{i,j}$ 라 하고, 3

차원 에너지공간에서 각 위치 (i,j,d)에서의 에너지를 $E(d_{i,j})$ 라 하자. 확률적 확산방정식의 유도는 2장의 식 (5)에서 설명된 두 가지의 에너지함수를 구체적으로 구현하는 과정이다. 그런데 Markov Random Field (MRF) 이론에 의하면, 이웃하고 있는 깊이정보들간의 확률분포가 미리 주어져 있다면, 어떤 위치에서의 깊이 정보를 정확하게 추정할 수 있다는 것이 증명되어 있다^[4,8]. 이러한 MRF 이론에 기초하여 깊이정보에 기반한 에너지함수를 구할 수 있다. 즉, $d_{i,j}$ 를 구하기 위하여 (i,j)에서 인접하고 있는 깊이정보들의 확률분포를 주어진 조건으로 이용한다. 이제 확률적 확산에 의한 스테레오 정합 문제는 2장의 식 (1)에서 정의한 조건부 확률을 최대화하는 문제에서, 스테레오 영상 { I }와 이웃하고 있는 깊이정보의 집합을 이용한 조건부확률의 최대화 문제로 발전시킬 수 있다.

$$\text{maximize } p(d_{i,j} | \{ I \}, \mathbf{d}_N), \text{ or, minimize } E(d_{i,j} | \{ I \}, \mathbf{d}_N). \quad (9)$$

식 (9)에서 \mathbf{d}_N 은 이웃하고 있는 깊이정보들에 대한 벡터로서, 인접하는 깊이정보에 대한 어떠한 구조(configuration)도 포함하고 있는 기호이다. 이 벡터는 2장의 식 (5)에서 화소값에 기반한 에너지함수에는 영향을 주지 않지만, 깊이정보에 기반한 에너지함수와 확률적 확산에서 매우 중요한 영향을 주는 요소이다. 화소값에 기반한 에너지는 스테레오 영상의 각 화소의 위치에서 가능한 모든 깊이값에 대하여 구해지며, 이로부터 3차원의 에너지공간이 형성된다. 화소값에 기반한 에너지는 확률적인 확산을 수행하기 전에 구해지는 값으로 $E_o(d_{i,j})$ 라고 정의되고, 두 개 이상의 스테레오 영상을 고려하여 다음과 같이 계산된다.

$$E_o(d_{i,j}) = \frac{1}{n(\{ I \}) - 1} \sum_{I_n \in \{ I \}} \rho_i (I_n(i, j) - I_n(i, j + d_{i,j})). \quad (10)$$

1장의 서론에서 언급하였듯이, 스테레오 영상간에는 1차원의 epipolar 기하학적 구조^[5]가 성립한다는 가정을 하고 있으므로, 식 (10)에서는 1차원적인 깊이정보만을 고려하고 있다. 이제 깊이정보에 기반한 에너지함수는 주위의 깊이정보들을 이용하여 깊이정보들간에서 서로 상관성과 유사성을 높여 주는 방향으로 기능을 하도록 정의되어야 한다.

$$E(d_{i,j} | \mathbf{d}_N) = \sum_{d_n \in \mathbf{d}_N} \rho_d(d_{i,j} - d_n). \quad (11)$$

식 (11)은 이러한 원리에 따라 깊이정보들간의 오차에 의한 에너지를 정의한 것이다. N 은 이웃하는 깊이 정보들의 집합을 의미하는데, 깊이정보에 대한 확률모델에 따라서 다양한 형태를 가질 수 있다. 식 (10)과 (11)로부터 2장에서 식 (5)와 같은 확률적 확산을 위한 완전한 에너지 함수를 구할 수 있다.

$$E(d_{i,j} | \{I\}, \mathbf{d}_N) \propto E_o(d_{i,j}) + \sum_{d_n \in N} \rho_d(d_{i,j} - d_n). \quad (12)$$

식 (12)는 화소 단위에서 얻어진 에너지 방정식으로서 확률적 확산은 두 번째 항인 깊이정보에 기반한 에너지항에 의하여 수행된다. 다시 에너지공간에서 정의된 식 (12)를 Gibb 확률분포를 이용하여 확률공간으로 변환시킨다. Bayesian 모델은 확률공간에서의 수학적 이론에 의하므로, 쉽게 구현할 수 있는 에너지공간을 일대일 확률공간으로 대응시키고, 이를 확률이론에 의하여 수학적인 조작을 함으로써, 구체적이고 정확한 확률공간 및 에너지공간에서의 오차측정 함수를 유도할 수 있다.

$$p(d_{i,j} | \{I\}, \mathbf{d}_N) \propto p_o(d_{i,j}) \cdot \prod_{d_n \in N} \exp\{-\rho_d(d_{i,j} - d_n)\}. \quad (13)$$

확률이론에 의하면, 확률변수 x 의 확률분포함수는 다른 확률변수 y 를 조건으로 하는 조건부 확률분포와 y 의 확률분포함수로부터 구할 수 있다.

$$p(x) = \sum_y p(x|y) p(y). \quad (14)$$

깊이정보는 일종의 확률변수이므로, 식 (14)를 식 (13)에 적용하면, 식 (15)와 같은 식을 얻을 수 있다.

$$p(d_{i,j} | \{I\}) = \sum_{all \mathbf{d}_N} p(d_{i,j} | \{I\}, \mathbf{d}_N) p(\mathbf{d}_N). \quad (15)$$

이제 식 (13)을 식 (15)에 대입하면, 식 (16)을 얻을 수 있다.

$$p(d_{i,j} | \{I\}) \propto p_o(d_{i,j}) \cdot \sum_{N \in S} [p(\mathbf{d}_N) \prod_{d_n \in N} \exp\{-\rho_d(d_{i,j} - d_n)\}]. \quad (16)$$

다시 식 (16)을 Gibb 확률분포에 의하여 에너지공간으로 일대일 대응시키면, 최종적으로 식 (17)을 얻을 수 있다.

$$E(d_{i,j} | \{I\}) \propto E_o(d_{i,j}) - \log \left[\sum_{N \in S} [p(\mathbf{d}_N) \prod_{d_n \in N} \exp\{-\rho_d(d_{i,j} - d_n)\}] \right]. \quad (17)$$




그림 4. 인접한 깊이정보의 기하학적 형태의 예. 투명한 원이 이웃하는 깊이정보를 의미한다. 기하학적 구조 및 크기는 영상의 특징에 따라서 중요한 역할을 한다.

Fig. 4. Examples of Geometry of Configurations. The empty circles are neighboring disparities. The geometric structure and area play an important role with respect to the characteristics of images.

식 (17)은 일반화된 확률적 확산방정식으로서, 깊이 정보들에 대하여 어떠한 확률적인 모델이나 가정이 없이 유도된 것이다. 즉, 이웃하고 있는 깊이정보의 구조나 연합확률분포, $p(\mathbf{d}_N)$ 에 대하여 어떠한 제약이나 조건이 존재하지 않으며, 모든 형태를 포괄할 수 있도록 유도된 것이다. 식 (17)을 살펴보면, 확률적 확산은 Markov Random Field 이론에 의하여 도입된 깊이정보의 연합확률분포, $p(\mathbf{d}_N)$ 과 그 기하학적인 구조 N 에 의하여 이루어짐을 알 수 있다.

그림 4는 이웃하고 있는 깊이정보의 기하학적인 구조 N 에 대한 네 가지의 예를 보여주고 있다. 네 가지의 경우는 인접하는 화소들의 위치 및 영역을 다르게 보여주는 것으로, 일반적으로 영역이 넓고 많은 인접 화소들을 이용할수록 더욱 우수한 효과를 얻을 것이다. 그러나, 본 논문에서는 최소한의 인접 화소만으로도 (그림 4의 (a)) 충분히 MRF 이론에 따라서 효과적인 확산이 이루어짐을 보여줄 것이다. 이러한 배경에는 뒤에서 다시 설명하겠지만, 인접한 화소들의 확률적 독립

성을 가정하고 있기 때문이다. 즉, 멀어질수록 상관성이 떨어지므로, 일반적인 경우는 그림 4의 (a)로도 충분한 효과를 얻을 수 있다. 물론, 객체의 경계가 있는 부분에서는 깊이정보의 분포가 방향성을 가질 수 있으므로, 정확성을 위하여 보다 많은 주위의 값들을 적용해야 한다. 그러나, 본 논문에서는 우선적으로 확률적 확산에 의한 깊이정보의 추정 기법을 제안하고 있는 만큼, 그러한 세세한 성능의 향상을 위한 실험은 향후의 연구과제로서 보는 것이 적절할 것으로 판단된다.

2. 확산방정식의 제한조건

식 (17)을 이용하여 반복적으로 에너지공간을 확산시킬 경우, 에너지공간은 안정적으로 확산되어 수렴되어야 한다. contaminated Gaussian 에너지함수를 이용하고 있는 것은 확률적으로 상관성이 적을 것으로 예측되는 깊이정보가 추정되었을 때, 그 오차의 정도가 일정한 범위를 벗어나는 깊이정보에 대해서 최소한의 동일한 확률을 적용하기 위해서이다. 즉, 오차가 큰 것들은 추정하는 과정에서 확률적으로 배제하는 것이다. 만약, 에너지공간의 값들이 반복적인 확산을 통하여 전체적으로 계속 증가한다면, 에너지공간이 안정적으로 수렴하지 않으므로 정확한 깊이정보를 추정할 수 없게 된다. 또, 계속 감소하는 경우에는 수렴이 되어 확산이 끝나기 전에 대부분의 값들이 0으로 되어 여러 개의 깊이정보가 동시에 추정되는 문제가 발생한다. 이러한 이유로 에너지공간의 안정성과 수렴성을 보장하기 위하여, 다음과 같은 제한조건이 필요하다.

$$\sum_{d_{i,j} \in D} p(d_{i,j} | \{I\}) = 1. \tag{18}$$

식 (18)을 통하여 에너지공간은 식 (17)에 의하여 반복적으로 확산되더라도 전체 에너지의 합은 보존이 되면서 수렴하게 된다. 식 (18)을 만족시키기 위해서 각 깊이정보의 확률은 식 (19)에 의하여 구하고, 이 두 식 (18)과 (19)를 적용하면, 식 (17)의 비례관계는 등식의 관계로 바꿀 수 있다.

$$p(d_{i,j} | \{I\}) = \frac{\exp\{-E(d_{i,j} | \{I\})\}}{\sum_{d_{i,j} \in D} \exp\{-E(d_{i,j} | \{I\})\}}. \tag{19}$$

3. 확산방정식의 해석

이 절에서는 확률적 확산방정식을 일반적인 부등식을 이용하여 에너지공간의 상한(upper bound)과 하한

(lower bound)을 구하고, 이를 정성적으로 해석한다. 여기서의 해석은 다음 장에서 제안하고 유도할 새로운 확률모델의 이론적인 배경이 된다.

우선, 산술평균과 기하평균 사이에 존재하는 부등식을 이용하자. 즉, 모든 양수의 항에 대하여 다음의 부등식이 항상 성립한다^[6].

$$\sum_{k=1}^K a_k \geq K \sqrt[K]{\prod_{k=1}^K a_k}, \quad \text{for all } a_k > 0. \tag{20}$$

식 (17)에서 log의 변수에 들어가는 항들은 연합확률분포에 의한 확률값과 지수함수에 의한 값이므로 모두 양수(positive number)이다. 그러므로 산술평균 및 기하평균 사이의 부등식 (20)을 확산방정식에 적용하여 다음과 같이 바꿀 수 있다.

$$\begin{aligned} & \log \left[\sum_{\mathbf{d}_N \in S} \{p(\mathbf{d}_N) \prod_{d_{i,j} \in N} \exp(-\rho_d(d_{i,j} - d_n))\} \right] \\ & \geq \log \left[n(S)^{n(S)} \sqrt[n(S)]{\prod_{\mathbf{d}_N \in S} \{p(\mathbf{d}_N) \prod_{d_{i,j} \in N} \exp(-\rho_d(d_{i,j} - d_n))\}} \right] \\ & = \log n(S) + \frac{1}{n(S)} \left[\sum_{\mathbf{d}_N \in S} \{ \log p(\mathbf{d}_N) - \sum_{d_{i,j} \in N} \rho_d(d_{i,j} - d_n) \} \right]. \end{aligned} \tag{21}$$

식 (21)에서 S는 이웃하는 깊이정보들에 대하여 모든 형태의 집합을 원소로 갖는 집합을 의미한다. 이 집합의 원소의 개수, 즉 이웃하는 깊이정보 집합의 모든 형태의 수는 깊이정보의 집합을 D라 할 때, 다음과 같이 구해진다.

$$n(S) = \sum_{k=1}^{n(G)} [n(D)]^{n(N_k)}. \tag{22}$$

식 (22)에서 G는 이웃하는 깊이정보의 기하학적 형태를 원소로 하는 집합이다. 식 (21)에 의하여 식 (17)에서의 에너지는 다음과 같은 상한(upper bound)을 갖는다.

$$\begin{aligned} E(d_{i,j} | \{I\}) & \leq E_d(d_{i,j}) \\ & - \log n(S) - \frac{1}{n(S)} \sum_{\mathbf{d}_N \in S} \{ \log p(\mathbf{d}_N) - \sum_{d_{i,j} \in N} \rho_d(d_{i,j} - d_n) \}. \end{aligned} \tag{23}$$

에너지의 최소화라는 측면에서 식 (23)을 고려하면, 이웃하는 깊이정보들의 연합확률분포, $p(\mathbf{d}_N)$ 의 값이 클수록 전체 에너지의 상한은 감소하며, 확률적 확산에서 더욱 빠르게 확산과정이 일어남을 알 수 있다. 즉, $p(\mathbf{d}_N)$ 의 값이 크다는 것은 현 위치의 깊이정보가 확률적 확산과정에서 더욱 높은 가능성으로 빠르게 인접하는 깊이정보들의 값으로 수렴되어 간다. 이러한 분석

을 바탕으로 다음 장에서는 깊이정보의 확률적 모델을 적절하게 설정하여 확산과정에서 우수한 성능을 보이는 연합확률분포를 제안할 것이다.

이제 에너지의 하한(lower bound)을 구하기 위하여 식 (24)의 Holder의 부등식을 적용한다. Holder의 부등식은 다음과 같이 정의되어 있다^[6].

$$\sum_{i=1}^n |x_i y_i| \leq \left(\sum_{i=1}^n |x_i|^\alpha \right)^{\frac{1}{\alpha}} \left(\sum_{i=1}^n |y_i|^\beta \right)^{\frac{1}{\beta}}, \quad \frac{1}{\alpha} + \frac{1}{\beta} = 1, \quad 1 < \alpha < \infty. \tag{24}$$

식 (24)의 Holder의 부등식은 $\alpha=2$ 인 경우, Schwarz 부등식이 되는데, 본 논문에서는 일반적으로 기술하기로 한다. 이 Holder의 부등식을 식 (17)에 적용하여 하한을 구한다. 즉, 식 (17)에서 두 항, $p(\mathbf{d}_N)$ 와 $\prod_{d_n \in N} \exp\{-\rho_d(d_{i,j} - d_n)\}$ 을 각각 x_i, y_i 로 대체하면, 앞에서의 식 (21)에서 정리한 것과 마찬가지로 부등식의 관계를 유도할 수 있다.

$$\begin{aligned} & \log \left[\sum_{N \in S} \left\{ p(\mathbf{d}_N) \prod_{d_n \in N} \exp(-\rho_d(d_{i,j} - d_n)) \right\} \right] \\ & \leq \log \left[\left(\sum_{N \in S} [p(\mathbf{d}_N)]^\alpha \right)^{\frac{1}{\alpha}} \left(\sum_{N \in S} \left[\prod_{d_n \in N} \exp(-\rho_d(d_{i,j} - d_n)) \right]^\beta \right)^{\frac{1}{\beta}} \right] \\ & = \frac{1}{\alpha} \log \left(\sum_{N \in S} [p(\mathbf{d}_N)]^\alpha \right) + \frac{1}{\beta} \log \left(\sum_{N \in S} \left[\prod_{d_n \in N} \exp(-\rho_d(d_{i,j} - d_n)) \right]^\beta \right). \end{aligned} \tag{25}$$

이제 확산방정식 (17)에 식 (25)의 결과를 대입하면, 다음과 같이 에너지의 하한을 구할 수 있다.

$$\begin{aligned} E(d_{i,j}|I) & \geq E_0(d_{i,j}) - \frac{1}{\alpha} \log \left(\sum_{N \in S} [p(\mathbf{d}_N)]^\alpha \right) \\ & \quad - \frac{1}{\beta} \log \left(\sum_{N \in S} \left[\prod_{d_n \in N} \exp(-\rho_d(d_{i,j} - d_n)) \right]^\beta \right). \end{aligned} \tag{26}$$

식 (26)에서도 $p(\mathbf{d}_N)$ 의 값에 따라서 에너지의 하한 뿐만이 아니라, 확률적 확산의 수렴과 속도를 결정할 수 있다.

IV. 제안하는 확률모델과 확산방정식

이 장에서는 깊이정보에 대하여 두 가지의 확률모델을 제안하고, 이를 구현하기 위한 확률적 확산방정식을 유도한다. 이미 3장에서 식 (17)과 같이 유도된 확산방정식에서 보면, 깊이정보들간의 연합확률분포를 구해야 한다. 그러나, 이러한 확률분포를 구하는 것은 실제의 경우에서 대단히 어려운 일이며, 많은 계산량을 요구하기 때문에, 현실적으로는 구현이 불가능하다. 따라서 본 논문에서는 이러한 문제를 해결하기 위하여 새로운




그림 5. 제안된 평면구조 모델과 에너지 공간에서의 확률적 확산. 각 깊이정보는 모든 깊이정보의 영역에 대하여 확률적인 확산을 한다. 빗금친 사각형은 평면구조의 이웃하는 깊이정보들을 의미하며 모든 깊이정보의 범위에서 이들의 연합확률분포에 위한 확산이 이루어진다.

Fig. 5. The proposed Plain Configuration Model and Probabilistic Diffusion. Four neighboring disparities construct a configuration. Three dimensional energy space is diffused with all the possible configurations over the disparity range based on the Plain Configuration Model.

확률적 모델을 제안하고자 한다. 이 확률모델은 원래의 순수한 연합확률분포에 최대한 비슷해야 하면서, 동시에 적은 계산량과 쉬운 구현으로 확률적 확산의 성능을 향상시킬 수 있어야 한다.

1. 확률적 독립성(Independence)

인접하고 있는 깊이정보들의 연합확률분포는 대단히 구하기가 어렵기 때문에 단순화시키는 것이 필요하다. 특히, 인접하고 있는 깊이정보들간에는 상관성이 존재하므로, 정확한 연합확률분포의 구현은 어렵다. 따라서 본 논문에서는 인접하고 있는 깊이정보들간의 상관성을 다소 잃어버리는 하지만, 구현 가능성을 위하여 인접하고 있는 깊이정보들간에는 확률적으로 서로 독립이라는 확률모델을 제안한다.

2. 평면구조 모델(Plain configuration model)

3장에서 분석하였듯이 연합확률분포는 가능한 한 확률적으로 높은 상관성을 고려하여 구해져야 한다. 일반적으로 화소값은 하나의 영상내에서 연속적이고 균일하게 분포하는 경우가 일반적이는데, 이러한 분포는 깊이 정보에 대해서도 비슷하다.

즉, 물체 및 배경의 거리관계는 그 경계를 제외하고는 대부분 일정하거나 부드럽게 변화하는 경향이 강하다. 따라서 깊이정보에 대해서도 분포상의 연속성과 주위와의 상관성이 매우 크다고 가정할 수 있다. 본 논문에서는 이러한 특성을 고려하여 평면구조 모델을 제안한다. 식 (17)에서 볼 수 있듯이, 확률적 확산을 위해서는 연합확률분포를 구해야 하는데, 모든 깊이정보들이 아직 완벽하게 추정된 값들이 아닌 부정확한 것이므로 합당하고 근거있는 예측을 할 수 밖에 없다. 그리고, 깊이정보 상호간에 연속성과 상관성이 매우 크므로, 인접한 깊이정보들은 하나의 기하학적 형태에서는 일정하다고 가정할 수 있다. 즉 비교적 가까운 거리에 있는 깊이정보들은 서로 동일하다라고 가정하는 것이다. 이러한 가정을 평면구조 모델이라고 부르기로 하고, 이에 대한 개념적인 그림을 그림 5에서 보여주고 있다.

3. 제안하는 기법의 확산방정식

이제 앞에서 제안한 이웃하는 깊이정보에 대한 두 가지의 확률모델을 적용하여 확산방정식을 유도해 보자. 우선 확률적 독립이라는 모델에 의하여, 연합확률분포는 각 깊이정보의 확률분포의 곱으로 표현된다.

$$p(\mathbf{d}_N) = \prod_{d_n \in N} p(d_n). \quad (27)$$

3장에서와 마찬가지로 확률이론을 식 (27)에 대해서 적용하면,

$$p(d_{i,j} | \{I\}) = \sum_{N \in S} \left\{ p(d_{i,j} | \{I\}, \mathbf{d}_N) \prod_{d_n \in N} p(d_n) \right\}. \quad (28)$$

식 (15)를 식 (28)에 대입하고 Gibb 확률분포를 이용하여 확률공간 및 에너지공간에서의 새로운 확률방정식을 유도할 수 있다. 즉, 제안된 확률모델을 적용하여 얻어진 구현가능한 확률적 확산방정식이다. 앞에서와 마찬가지로 식 (29)는 확률공간에서, 식 (30)은 에너지공간에서 유도된 확률적 확산방정식이다.

$$p(d_{i,j} | \{I\}) \propto p_0(d_{i,j}) \sum_{N \in S} \left[\prod_{d_n \in N} p(d_n) \exp\{-\rho_d(d_{i,j} - d_n)\} \right], \quad (29)$$

$$E(d_{i,j} | \{I\}) \propto E_0(d_{i,j}) - \log \left[\sum_{N \in S} \left[\prod_{d_n \in N} p(d_n) \exp\{-\rho_d(d_{i,j} - d_n)\} \right] \right]. \quad (30)$$

식 (30)은 제안한 기법을 유도한 에너지 확산방정식으로서 5장의 모의실험에서 적용될 관계식이다. 식 (19)와 (20)의 에너지보존을 위한 제한조건이 마찬가지로




그림 6. 실험에 사용된 스테레오 영상, (a),(b) 중심 및 정확히 계산된 깊이정보 (random dot), (c),(d) face 영상

Fig. 6. Test stereo images. (a),(b) center and pure disparity map of random dot, (c), (d) face

로 적용되면서 확산을 수행한다.

V. 모의실험 및 결과

1. 모의실험 환경

본 논문에서는 5개로 구성된 스테레오 영상을 사용하여 모의실험을 수행하고 있다. 5개의 스테레오 영상은 상하좌우의 네 개와 이들의 중심에 있는 하나로 구성되어 있으며, 각 수직 및 수평축으로 1차원의 epipolar 기하학적 구조를 만족하고 있다.




그림 7. 확률적 확산에 의한 깊이정보의 수렴. 반복적인 확산에 따라 상관성이 높은 주위의 깊이정보로 수렴해 간다.

Fig. 7. Convergence of the disparity map by the probabilistic diffusion. As the diffusion is iterated, the disparity becomes converged to the neighboring disparities which have high correlation.

본 논문에서는 그림 4의 (a) 형태만을 적용하여 유도된 확산공식과 제안한 알고리즘의 모의실험을 실시하였다.

그림 6은 모의실험에 사용된 스테레오 영상들 각각의 중심영상과 실제로 알려진 깊이정보의 값들을 나타낸 것이다. random dot 영상은 미리 계산되어 얻어진 영상이며, face 영상은 5개의 카메라에 의하여 직접 촬

영되어 만들어진 영상이다. 각 영상의 크기는 다음과 같다.

random dot: 64 x 64, face: 384 x 288.

그리고 실험에서 사용한 에너지 함수의 값들은 다음과 같다.

$$\epsilon_i = 0.1, \quad \epsilon_d = 0.01, \quad \sigma_i = 5, \quad \sigma_d = 0.5$$




그림 8. 다양한 기법과의 성능 비교, random dot. (a) SSD에 의한 방법, (b) Scharstein에 의한 방법, (c) 순수 연합확률모델, (d) 제안한 확률모델에 의한 방법


Fig. 8. Comparison of the experimental results for random dot. (a) SSD, (b) Scharstein's, (c) the pure probability model which does not adopt the plain configuration model, (d) the proposed method.

2. 모의실험 결과


우선 그림 7은 확률적 확산에 의한 스테레오 정합 기법의 수렴과정을 보여주고 있다. 초기의 에너지공간에서 추정된 깊이정보의 영상으로부터 매 회의 반복적인 확산을 거친 후 추정된 깊이정보 영상들을 순서대로 보여주고 있다. 그림 7에서 보면, 반복적인 확산을 통하여 에너지공간은 안정적으로 수렴하며, 확산을 통하여 더욱 정확한 깊이정보의 추정이 가능하다. 그림 7의 결과는 본 논문에서 제안한 평면구조 모델을 이용하여 만들어진 영상이다.

그림 8의 (c)는 random dot 영상에 대하여 평면구조 모델을 적용하지 않고 순수한 연합확률분포를 구하여 확산을 한 결과이다. 그림 8의 (c)의 결과는 다음에서 비교할 다른 기법들, SSD와 Scharstein의 방법 [12,13]에 비하여 우수한 성능을 보여주고 있다. 그림 7과 그림 8 (c) 결과는 확률적인 확산에 의한 스테레오 정합 기법이 본 논문에서 올바르게 유도되었음을 의미하는 것이다.


그림 8의 (a), (b), (d)는 random dot 영상에 대하



(a)



(b)



(c)

그림 9. 다양한 기법과의 성능 비교, face (a) SSD에 의한 방법, (b) Scharstein에 의한 방법, (c) 제안한 확률모델에 의한 방법.

Fig. 9. Comparison of the experimental results for random dot. (a) SSD, (b) Scharstein's, (c) the proposed method.

여 본 논문에서 제안한 평면구조 모델 기법과 SSD 및 Scharstein 방법의 성능과 비교한 것이다. 그림 8에서 SSD는 적응적 median filtering을 반복적으로 적용한 것이며, 두 확률적 확산 기법은 완전히 똑같은 환경에서 얻은 결과이다. 그림 9는 face 영상에 대하여 세 가지의 기법을 비교한 것이다. 앞의 결과에서와 마찬가지로 제안한 기법에서 보다 우수한 성능을 확인할 수 있다. 더욱 정확한 물체의 구별과 선명한 경계를 제안한 기법에서 확인할 수 있다.

VI. 결 론

본 논문에서는 확률적 확산을 이용한 스테레오 정합 알고리즘을 제안하였다. Bayesian 모델에 기초하여 일반화된 스테레오 정합 기법 공식을 유도하고, 새로운 확률모델을 적용한 기법을 구현하였다. 이웃하고 있는 깊이정보간의 확률적인 독립성과 유사성을 기초로 하여 제안된 확률모델에 따라서 유도된 일반적인 확산 알고리즘 공식은 다른 형태로 변형되어 에너지공간을 확산시키며, 안정적으로 수렴된 에너지공간으로부터 최적의 깊이정보를 추정하였다. 모의실험 결과에 의하면, 일반적으로 유도된 확산공식은 스테레오 영상간의 깊이정보를 추정하는데 좋은 성능을 보였으며, 제안된 확률모델에 기초한 기법과 함께 기존의 다른 방법들에 비하여 보다 우수한 성능을 보여주었다. 이러한 실험 결과는 유도된 확산공식이 스테레오 정합에서 효과적인 기법이 될 수 있음을 의미하며, 본 논문에서 제안된 확률모델도 일반적인 확률분포를 근사적으로 예측하는데 적절하고 타당함을 보여주는 것이다.

본 논문에서의 결과는 다음과 같이 정리할 수 있다. 첫째 Bayesian 모델을 기초로 하여 확률적 확산에 의한 스테레오 정합 문제를 정립하고 이를 일반화 시켜서 유도하였다. 둘째, 다양한 영상과 매개변수에 대한 실험을 통하여 본 논문에서 유도된 확산방정식은 스테레오 정합을 위하여 좋은 기법이 될 수 있음을 확인하였다. 셋째, 제안한 새로운 확률모델은 적은 계산량으로도 충분히 완전한 확률모델을 대체하여 효과적인 성능을 보여 주었다. 그리고, 넷째, 본 논문에서 유도된 확산방정식과 제안된 기법은 각각 다른 기존의 성능에 비하여 우수함을 보여 주었다.

참 고 문 헌

[1] Rafael C. Gonzalez, *Digital Image Processing*, Addison Wesley, 1994.
 [2] R.M. Haralick and L.G. Shapiro, *Computer and Robot Vision*, Addison Wesley, 1993.
 [3] D.H. Ballard and C.M. Brown, *Computer Vision*, Prentice Hall, 1982.
 [4] R. Chellappa and A. Jain, *Markov Random Fields*, Academic Press, 1993.
 [5] Gang Xu and Zhengyou Zhang, *Epipolar Geometry in Stereo, Motion and Object*

Recognition, Kluwer Academic Publishers, 1996.

- [6] Erwin Kreyzig, *Introductory Functional Analysis with Applications*, WIE Wiley, 1978.
 [7] U. R. Dhond and J. K. Aggarwal, "Structure from stereo-a review," *Trans. on Systems, Man, and Cybern.*, Vol.19 No.6, pp.1489-1510, Nov./Dec. 1989.
 [8] 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, No. 6, pp. 721-741, Nov. 1984.
 [9] T. Kanade and M. Okutomi, "A stereo matching algorithm with an adaptive window: Theory and experiment," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. PAMI-16, No.9, pp.920-932, Sept. 1994.
 [10] M. Okutomi and T. Kanade, "A multiple-baseline stereo," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. PAMI-15, No.4, pp.353-363, 1993.
 [11] R. Szeliski and G. Hinton, "Solving random-dot stereograms using the heat equation," *Proc. of IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR'94)*, pp.194-201, June, 1994.
 [12] D. Scharstein and R. Szeliski, "Stereo Matching with Non-Linear Diffusion," *Proc. of In IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR-96)*, pp. 343-350, San Francisco, CA, June 1996.
 [13] D. Scharstein, *View Synthesis Using Stereo Vision*, Dissertation for Ph. D Degree, Cornell University, Feb. 1997.
 [14] D. Scharstein, "Matching Images by Comparing their gradient fields," *Proc. of International Conference on Pattern Recognition(ICPR'94)*, Vol. 1, pp. 572-575, Oct. 1994.

- [15] Ze-Nian Li and Gongzuh Hu, "Analysis of Disparity Gradient Based Cooperative Stereo," *IEEE Trans. on Image Processing*, Vol. 5, No. 11, pp.1493-1506, Nov. 1996.
- [16] F.M. Porikli, "Stripe Mesh Based Disparity Estimation by Using 3-D Hough Transform," *Proc. of ICIP-97*, Santa Barbara, USA, Vol.III, pp.240-243, Oct. 1997.
- [17] Sang Hwa Lee, Jong-Il Park, C.W. Lee, "A New Stereo Matching Algorithm Based on Bayesian Model," *Proc. of ICASSP-98*, Seattle, USA, May 1998, will be published.

 저 자 소 개

李 相 和(正會員)

1994년 2월 : 서울대학교 전자공학과 학사. 1996년 2월 : 서울대학교 전자공학과 석사. 1996년 3월~ : 서울대학교 전기공학부 박사과정 재학중. ※ 관심분야 : 영상복원, 컴퓨터비전

李 忠 雄(正會員)

1958년 3월 : 서울대학교 전자공학과 학사. 1960년 9월 : 서울대학교 전자공학과 석사. 1971년 4월 : 일본 동경대학교 전자공학과 박사. 1989년 1월~현재 : IEEE의 Fellow 임명. 1991년 6월-1997년 8월 : 서울대학교 뉴미디어통신공동연구소 소장. 1971년 10월~현재 : 서울대학교 전기공학부 교수. ※ 관심분야 : 통신이론, 영상 및 HDTV 신호처리