

Dempster-Shafer 이론을 이용한 움직임 벡터 추정

正會員 최 철 영*, 최 윤 식**

The Displacement Vector Estimation using Dempster-Shafer Theory

Cheol Young Choi*, Yoon Sik Choe** *Regular Members*

要 約

순차시간영상에서 얻어지는 움직임 벡터는 이미지 처리분야나, 컴퓨터 시각분야등에서 중요한 정보로서 사용되어 왔으므로, 정확한 움직임 벡터의 추정은 그 동안의 많은 연구의 대상이 되어왔다. 화소값에 기반한 움직임 벡터 추정에는 ill-posed 문제가 내재되어 있는데, 이것을 해결하기 위한 방법으로 MRF(Markov 랜덤 필드) 모델을 이용한 정규화기법이 최근에 사용되고 있다. 성능이 좋은 움직임 벡터 추정을 위해, 기존의 연구들은, 확률을 최대화하는데 있어서 전역적 해를 구하는 최적화 방법에 치우쳐져 있었다. 본 논문에서는 모델링에 개선을 두어서 관찰 모델과 움직임 벡터 모델의 설계에 불확실성이 존재할 수 있다는 가정하에서, 불확실성을 부여할 수 있는 퍼지 측도로 각 모델을 설계하였고, 이러한 퍼지 측도를 설계하고 · 통합하는 방법으로 D-S이론을 사용하였다. 제안된 추정기법의 효율은 모의실험에 의하여 검증되었고, 결론적으로 D-S 이론을 사용한 움직임추정기법은 확률측도와 똑 같은 인자를 가지고서도, 관찰 모델과 움직임 벡터 모델을 신뢰 함수로 설계함으로써, 움직임 벡터 추정에 큰 개선효과를 주었다.

ABSTRACT

Since displacement vector obtained in sequential images has been utilized as an important information in image processing and computer vision, precise estimation of it has been one of the popular research topics. The estimation of displacement vector based on pixel value Ill-posed problem is inherent. To solve this, the regularization method using MRF model has been proposed recently. For better estimation of displacement vector, the researches were inclined to optimization method which finds the global solution maximizing the probability. However, in this paper, it is showed that the improvements of modelling results the better estimation of displacement vector. That is,

*LG전자 멀티미디어 연구원

**연세대학교 전기공학과

論文番號:97092-0307

接受日字:1997年 3月 7日

assuming that uncertainty was in the observation model and displacement vector model, the each model was designed by means of fuzzy measure endowed with uncertainty. D-S theory is the generalized theory which can design the fuzzy measure and integrate uncertain information. Simulation demonstrates the efficiency of the proposed method, as a result, the motion vector estimation using D-S theory gives the better estimation results from designing the observation model and the displacement vector model by means of belief function, in spite of having the same parameter with that of probability measure.

I. 서 론

순차시간영상에서 나타나는 움직임 변위 벡터는 이미지 처리분야나 컴퓨터 시각분야 등에서 최근에 상당한 관심이 되어 왔으며, 그러한 분야에서 중요한 정보로 사용되어 왔다. 그러나 실제상황에서는 움직임 변위 벡터의 추정에 잡음이 있는 경우가 많으며, 이러한 문제 외에도 움직임이 존재하는 물체가 배경 안으로 사라지거나, 배경안에 있었던 물체가 밖으로 드러나게 되는 문제점, 국소적인 하나의 화소에 대한 움직임 변위 벡터를 추정하는 데에서 나타나게 되는 문제점등이 존재한다. 그러므로, 화소마다의 정확한 추정이 요구되는데, 이를 위해 미리 주어진 가정을 하고, 그러한 조건이 만족되는 상황에서 움직임 변위 벡터를 추정하게 된다.

그 조건은 다음과 같다. 움직임의 변위가 크지 않고, 주변 화소의 움직임은 유사한 분포를 갖으며, 물체가 배경안으로 사라지거나, 배경안에 있다가 나타나는 상황이 존재하지 않는다는 것이다.

수학적으로 움직임 변위 벡터를 추정하는데에는 위와 같은 내재적 문제점에 의한 ill-posed문제가 있게 된다. [3], [4] Ill-posed문제는 Hadamard[3]의 관점에서 세가지 수학적 성질을 만족하지 못하다는 것인데, 첫째는 그 해가 해공간에 존재하여야 한다는 것이고, 둘째는 유일해를 가져야한다는 것이며, 마지막으로는 데이터에서 오차가 영으로 접근할 때, 그 해에서 유도되는 오차도 영으로 접근해야 한다는 것이다. 이를 해결하기 위한 주된 착상은 적당한 사전 지식을 도입하여 해결가능한 해로 제한하는 것이다. 일반적으로 움직임 추정에서의 이러한 ill-posed 문제를 해결하는 방법이 정규화인데, 이것은 움직임을 추정하는 데 있어서 조건을 주어서 유일하고 안정적인 해를 얻고자 하는 방법이다. 이러한 조건은 사전지식 정

보에 해당되고, 일반적으로 평탄성정보가 사용된다.

기존 방법에서는 평탄성이란 사전 정보를 MRF(Markov 랜덤 필드)로 모델링하여 이를 GRF(Gibbs 랜덤 분포)로 수식화 하였다. 반면에 본 논문에서는 D-S이론의 기본 확률화를 할당의 설계에 이 정보를 고려하여 설계하였다. 본 논문에서 이처럼 퍼지 측도를 일반화시킨 D-S이론을 사용한 이유는, 기존의 확률식의 설계에는 사전정보의 선택과 클릭의 선택등에 무시할 수 없는 모호성이 존재한다는 가정에 기인한다. D-S이론은 측도의 설계의 모호성을 표현할 수 있으며, 정보의 부가에 따른 퍼지 측도 결합규칙을 수학적으로 규칙화 하고 있기 때문이다.

2장에서부터는 기존의 GRF(Gibbs 랜덤 필드)라는 확률측도 설계된 것에 비교하여, 퍼지 측도로 어떻게 구현하게 되는지를 알아보고, 같은 상황과 인자를 가지고 둘의 성능 비교를 해보도록 하겠다.

II. 기존 추정방법(MRF(Markov 랜덤 필드))

지금까지, 움직임 변위 벡터의 정확한 해를 얻기 위한 수학적인 방법은 MRF(Markov 랜덤 필드)로 모델링 한 대상 함수가 최소가 되는 상태, 즉 그 확률이 최대가 되는 상태를 구하는 것이라 하겠다. [1], [2] 즉, MRF(Markov 랜덤 필드) 모델은 그와 동가인 GRF(Gibbs 랜덤 필드)로 간결하게 수학적으로 표현되고 [6], GRF(Gibbs 랜덤 필드)로 공식화 될 대상함수는 lagrange 곱셈자를 사용한 비선형함수가 되므로, GRF(Gibbs 랜덤 필드)식의 전역적인 극값을 찾는 Simulated Annealing(가상 가열 냉각)을 사용하여 각 화소당 최적화된 움직임 변위벡터를 구하게 된다.

1. 움직임 변위 벡터 추정을 위한 GRF(Gibbs 랜덤 필드)의 설계

$$P(X=x) = \frac{1}{Z} e^{-U(x)/T} \quad (2.1)$$

GRF(Gibbs 랜덤 필드)는 위와 같은 형태의 확률 분포 함수를 말한다. 여기서 $x=(x_1, x_2, \dots, x_N)$ 을 나타낸다. $U(x)$ 는 에너지 함수이며, 다음과 같은 형태를 가진다.

$$U(x) = \sum_{c \in C} V_c(x) \quad (2.2)$$

$V_c(x)$ 은 포텐셜이라 불리고, 클릭 c 만의 함수이며, C 는 클릭들의 집합이다. GRF(Gibbs 랜덤 필드)에서 Z 는 정규화 상수로서 분리함수라 불린다.

$$Z = \sum_x e^{-U(x)} \quad (2.3)$$

여기서 x 는 L (가능한 모든 상태의 수) 가지의 경우에 대하여 얻어지는 식(2.1)의 분자항을 모두 더한 것과 같다. 이것을 계산하기란 매우 어렵지만, SA로 MAP이 최대가 되는 상태를 추정할 때는 그 값이 동일하므로 고려하지 않아도 되게 된다. T 값은 물리적으로 온도에 해당되며, T 값이 크면 $U(x)$ 값에 덜 영향을 받아 평탄해지고, T 값이 적으면 $U(x)$ 값에 따른 분포를 유지하게 된다. 이러한 성질은 SA에 직접 이용된다.

적은 움직임이 존재하는 순차시간 영상중에서 x^t 와 x^{t-1} 관찰이 주어졌을 때, 가장 그럴듯한 d^t 를 추정하는 것이 움직임 벡터 추정의 기본 전략이라 할 수 있다. 이를 위해 공식화되는 확률은 다음과 같이 표현되며, Bayesian 규칙에 의하여 관찰 모델과 움직임 벡터 모델로 나뉘어 표현된다.

$$p(d^t | x^t, x^{t-1}) = \frac{p(x^t | d^t, x^{t-1}) p(d^t | x^{t-1})}{p(x^t | x^{t-1})} \quad (2.4)$$

이러한 확률을 d^t 에 대하여 최대화 하는 것은 MAP에 해당되며, 분모는 d^t 에 관계없는 정규화상수가 되어 무시 된다. 즉, GRF(Gibbs 랜덤 필드)의 Z (분리함수)에 해당되는 것이 분모이고, 분자는 GRF(Gibbs 랜덤 필드)의 지수 함수가 된다.

$$\begin{aligned} \hat{d}^t &= \arg \max p(d^t | x^t, x^{t-1}) \\ &= \arg \max p(x^t | d^t, x^{t-1}) p(d^t | x^{t-1}) \end{aligned} \quad (2.5)$$

GRF(Gibbs 랜덤 필드)가 MRF(Markov 랜덤 필드)가 되기 위해 선택된 1차 이웃 시스템 η 은 그림 2.1과 같다. c 는 S 의 부분집합으로서, 그림 2.1에서와 같은 형태를 갖는 1차 클릭이다. 이때, $x^t = \{x_i^t, i \in S\}$ 은 t 번째 영상에서 η 라는 이웃 시스템 위에서 정의된 랜덤 변수의 집합이다. 또한, $d^t = \{d_i^t, i \in S\}$ 는 x^t 에서 움직임 벡터들이고, d_i^t 는 x_i^t 에서 추정가능한 x^{t-1} 에서 x^t 로의 움직임 벡터이다. 내재하는 ill-posed 문제를 해결하는 정규화방법의 관점에서 바라본다면, $p(d^t | x^{t-1})$ 는 평탄성 조건에 해당되며, 사전 지식이라 할 수 있다.

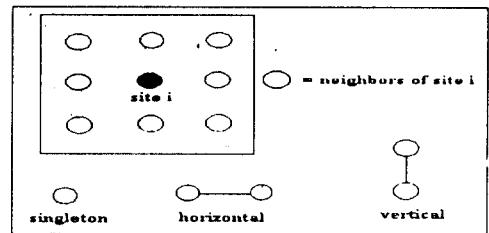


그림 1. 1차 이웃 시스템

Fig 1. First order neighboring system

관찰 모델은 화소상용을 구체화한 것으로, 화소값에는 Gaussian additive 잡음 의한 변화가 있을 것이라 가정한 모델이다. 그러므로, GRF(Gibbs 랜덤 필드)에서의 에너지 함수를 다음과 같이, 중간치가 x_i^t 이고 일정한 분산(σ^2)를 갖는 Gaussian 분포를 갖는 확률분포로 표현할 수 있다. 그러므로, 식 (2.4)의 첫째 항은 다음과 같이 표현할 수 있다.

$$p(x^t | d^t, x^{t-1}) = Z_x^{-1} \exp[-U_x(x^t | d^t, x^{t-1})] \quad (2.6)$$

여기서,

$$U_x(x^t | d^t, x^{t-1}) = \sum_i (x_i^t - x_{id_i^t}^{t-1})^2 / 2\sigma^2 \quad (2.7)$$

이웃 시스템 η 와 S 의 부분집합인 클릭 c 에 대하여,

$$p(d^t | x^{t-1}) = Z_d^{-1} \exp[-U_d(d^t | x^{t-1})] \quad (2.8)$$

여기서,

$$U_d(\mathbf{d}' | \mathbf{x}^{t-1}) = \sum_{c \in C} \beta_j \|\mathbf{d}(x_i, t) - \mathbf{d}(x_j, t)\|^2 \quad (2.8)$$

단, $i \neq j, j \in C$

이것은 움직임 벡터의 평탄성 조건이 된다.

식(2.4)가 구체화 된 것으로, 이러한 두 확률 모델에 의하여 통합된 것이 식(2.10), 식(2.11)이며, lagrange 곱셈자(λ) 의하여 적절한 해의 공통집합을 갖도록 제한하고 있다.

$$p(\mathbf{d}' | \mathbf{x}', \mathbf{x}^{t-1}) = \frac{1}{Z} \exp[-U(\mathbf{d}' | \mathbf{x}', \mathbf{x}^{t-1})] \quad (2.10)$$

여기서,

$$U(\mathbf{d}' | \mathbf{x}', \mathbf{x}^{t-1}) = U_x(\mathbf{x}' | \mathbf{d}', \mathbf{x}^{t-1}) + \lambda U_d(\mathbf{d}' | \mathbf{x}^{t-1}) \quad (2.11)$$

$$Z = Z_x * Z_d$$

움직임 벡터를 정확히 추정하기 위해선, 비선형 분포를 따르는 이 확률 함수를 최대화하는 $\hat{\mathbf{d}'}$ 를 구하는 것이 기본 목표라 하겠다. 이를 위해 사용되는 최적화 방법으로는 Simulated Annealing(가상 가열 냉각)을 사용한다. [5](III-3절을 참고)

III. D-S이론에 기반한 움직임 벡터 추정

기존의 모델링에 기반한 방법은 각 움직임 벡터에 대해 확률을 할당하여, 그 확률의 MAP을 구하였다. 각 모델의 확률측도는 적절한 임의 선택이라는 가정하에서, 어느 정도의 확신도를 갖게된다. 즉, 확률측도가 그 모델에 완벽하지 못하기 때문에, 어느 정도의 불확실성이 존재하게 된다. [9] 그러므로, 불확실성을 표현할수 있는 퍼지 측도라는 새로운 측도를 필요로 하게 되며, 이러한 측도가 보다 그럴듯하고·직관적이며 데이터에 대한 보다 포괄적인 표현이 될 것이다. 확률측도에서는 각 측도를 통합하여 개선하는데 bayesian 규칙이 사용되는데, 이에 반하여 퍼지 측도에서도 각 측도를 통합하는 새로운 규칙이 필요하게 된다. 이것이 바로 D-S 이론의 dempster의 결합 법칙이다. [9], [10], [11] 앞으로 이 장에서 두 규칙이

어떤 관계가 있는지 비교·설명될 것이며, 이는 실험 결과에 대한 분석적인 판단의 기준이 될 것이다.

1. D-S 이론 정의

이 이론은 퍼지 측도인 신뢰 함수를 기본으로 하여, 그것의 결합함수를 정의 하는 것으로 구성되어 있다. D-S이론에는 응용분야마다 문제의 집합에는 서로 배타적인 개개의 모든 가정들의 초기 가설들의 집합인 “분별구조”가 존재한다. 이 것을 Θ 라고 하고 주어진 Θ 에 대하여, 특정 증거에 기반하여 Θ 의 부분집합에 확신도의 정도를 부여하는 함수가 존재한다. 이것을 기본확률할당이라고 하며, 개별적 증거에 따라 관련되는 부분집합에 대해 믿음의 정도를 부여한다. 기본확률할당은 다음과 같이 정의 된다.

모든 $A \in P(\Theta)$ 에 대하여,

$$m: P(\Theta) \rightarrow [0, 1] \quad (3.1)$$

1. $0 \leq m(A) \leq 1$, 모든 $A \subseteq \Theta$ 에 대하여,

$$2. m(\emptyset) = 0$$

$$3. \sum_{A \subseteq \Theta} m(A) = 1$$

여기서 $m(A)$ 는 A 에 대한 신뢰도를 나타낼 뿐, A 의 부분집합에 대해서는 어떠한 신뢰도도 나타내지 않는다. A 는 m 에서의 “총점 요소”라 하고, m 에서의 모든 총점 요소의 집합을 m 의 “core”라고 하며, $k(m)$ 로 표시한다.

기본확률할당의 정의를 살펴보면, 이 것은 확률 측도가 아님을 알 수 있는데, 그 이유는 다음과 같다.

1. 일반적으로 $m(X) = 1$ 이 아니다.

2. 일반적으로 $A \subset B$ 일 때,

$$m(A) \leq m(B)$$

3. 일반적으로 $m(A)$ 와 $m(\bar{A})$ 의 관계가 존재치 않는다.

반면, 특정 증거가 주어졌을 때, 집합 A 에 대한 총 확신도는 자기자신의 집합인 A 에만 달려있는 것이 아니라, A 의 부분집합에도 달려있게 된다. 기본확률할당이 주어졌을 때, 이같은 총 확신도를 표현하는 가산적인 새로운 함수가 존재한다. 바로 이 함수가 신뢰 함수가 되며, 기본확률할당의 관점에서 다음과 같이 정의된다.

분별구조를 Θ 라고 하고, m 을 Θ 위에서 정의된 기본화를 할당이라고 할 때, 신뢰 함수는

$$Bel: 2^\Theta \rightarrow [0, 1]$$

여기서, 모든 $A \subseteq \Theta$ 에 대하여,

$$Bel(A) = \sum_{A \subseteq B} m(B) \quad (3.2)$$

이고, 다음의 성질을 만족한다.

1. $Bel(\Theta) = 1$, 왜냐하면, $\sum_{A \subseteq \Theta} m(A) = 1$.
2. 오직 하나의 요소만을 포함하는 $A \subseteq \Theta$ 에 대하여 $Bel(A) = m(A)$
3. $A \subseteq \Theta$ 이고, $B \subseteq \Theta$ 에 대하여, $Bel(A) + Bel(B) \leq Bel(A \cup B)$.

이 성질은 퍼지 측도의 그것과 같다.

기본화를 할당 m_1, m_2 로 표현되는 두 가지 독립적인 증거들이 적절하게 결합되어 결합 기본화를 할당이라는 새로운 확신도를 얻을 수 있다. 이처럼 독립적인 증거들을 통합하는 규칙이 필요한데, D-S 이론에서는 Dempster의 결합 규칙이라는 방법으로 이를 수행하고 있다.

정의 : Dempster의 결합 규칙

Θ 를 분별구조라고 하고, Θ 위의 가정들에 대하여 정의된 기본화를 할당 m_1 과 m_2 가 설계되어 $m_1 \oplus m_2$ 라는 두 정보의 통합함수가 다음과 같이 존재할 때,

$$m_1 \oplus m_2: 2^\Theta \rightarrow [0, 1].$$

$$1. m_1 \oplus m_2(\emptyset) = 0.$$

$$2. 1. m_1 \oplus m_2(A) = \frac{\sum_{B \cap C = A} m_1(B) \cdot m_2(C)}{1 - \sum_{B \cap C = \emptyset} m_1(B) \cdot m_2(C)}.$$

단, $A \neq \emptyset$.

그러면,

$$Bel_1 \oplus Bel_2: 2^\Theta \rightarrow [0, 1]$$

$$Bel_1 \oplus Bel_2(A) = \sum_{B \subseteq A} m_1 \oplus m_2(B).$$

이때, $K = \sum_{A \cap B = \emptyset} m_1(A) \cdot m_2(B)$ 를 총 불일치량이라 하며, 이것은 논리적으로 서로 배타적인 가정 A 와 가정 B 에 대해서는 A 이고 B 일 수 없다는 것을 의미 한다.

2. 기본 확률 할당의 설계

주어진 가설들에 대하여 확신의 정도를 부여하는 기본확률할당은 관찰되는 여러 증거로부터 얻어지게 된다. 움직임 범위 벡터 추정을 위해서 얻어질수 있는 증거들은 화소상용 증거와 평탄성 증거들이다. 이러한 증거외에도 line 필드 같은 증거들이 더 포함됨으로써 성능의 개선을 보일 수 있겠지만, 확률측도에 기반한 bayesian 정보 개선과의 성능 비교를 위해서 앞선 두 증거만을 사용한다.

m_o 를 화소상용 증거에 의한 측도라고 할 때, m_o 를 식(2.6), 식(2.7)과 똑같은 식으로 설계한다. 이는 제 2 장에서 설계된 bayesian 방법과의 성능 비교를 위한 것으로, 차이점은 식(2.7)이 측도 설계의 불확실성이 없는 확률측도라고 가정함에 반하여, 식(3.3)은 그러한 측도 설계에 대해 확신도를 주어 불확실성을 남겨 놓았다는 점이다.

현재 영상의 어느 한점 x_i 에 대하여,

$$m_o(d(x_i, t)) = Z_{m_o}^{-1} \exp[-U_o(d(x_i, t))] \quad (3.3)$$

여기서,

$$U_o(d(x_i, t)) = \sum_i (x_i^t - x_{i-d_i}^{t-1}) / 2\sigma^2 \quad (3.4)$$

단, $A \neq \emptyset$

$$Z_{m_o} = \sum_{j \in R_i} m_o(d(x_j, t)) + m_o(\Theta) \quad (3.5)$$

이 때, R_i 는 x_i 에서의 움직임 탐색 범위이다.

m_s 를 평탄성 증거에 의한 측도라고 할 때, m_s 를 식(2.8), 식(2.9)과 똑같은 식으로 설계한다. 마찬가지로, 두 측도의 차이점은 식(2.8), 식(2.9)가 불확실성이 없는 측도로 가정함에 반하여, m_s 는 설계에 확신도를 주어 불확실성을 남겨 놓았다는 점이다.

현재 영상의 어느 한점 x_i 에 대하여,

$$m_s(d(x_i, t)) = Z_{m_s}^{-1} \exp[-U_s(d(x_i, t))] \quad (3.6)$$

여기서,

$$U_s(d(x_i, t)) = \sum_{c \in C} \beta_c \|d(x_i, t) - d(x_j, t)\|^2 \quad (3.7)$$

단, $i \neq j, j \in C$

$$Z_{m_s} = \sum_{j \in R_i} m_s(d(x_j, t)) + m_s(\Theta) \quad (3.8)$$

이 때, R_i 는 x_i 에서의 움직임 탐색 범위이다.

이와 같이 설계된 기본화를 할당에 대하여, dempster의 결합 규칙에 적용한 식은 다음과 같다.

$$m_O \oplus m_S(d(x_i, t)) = \frac{\sum_{A \cap B = d(x_i, t)} m_O(A) \cdot m_S(B)}{1 - \sum_{A \cap B = \emptyset} m_O(A) \cdot m_S(B)} \quad (3.9)$$

단, $A, B \subset 2^\Theta$

식(3.9)에서 총 불일치량 부분인 $\sum_{A \cap B = \emptyset} m_O(A) \cdot m_S(B)$

는 영이 되므로 무시한다. 신뢰 함수가 singleton에 대해서만 정의되었으므로, $m_O = Bel_O \circ$ 이고 $m_S = Bel_S \circ$ 된다.

그러므로,

$$Bel_O \oplus Bel_S(d(x_i, t)) = m_O \oplus m_S(d(x_i, t)) \quad (3.10)$$

가 된다.

3. 최적화 기법(SA)

비용 함수 또는 대상 함수라고 불리는 함수의 최대 혹은 최소 값을 구하는 것을 목적으로 하는 기법을 최적화라고 한다. 이것은 본 논문에서 식(2.10)의 확률 함수를 최대화하는 d^t 를 구하는 부분에 해당되는 것이다. 바꾸어 해석하면, 식(2.11)의 에너지 함수 즉, 대상 함수를 최소화 하는 d^t 를 구하는 것이 된다. 이산 랜덤 필드 모델에서는 분리함수의 계산이 힘들기 때문에 이완형식의 알고리듬인 metropolis 알고리듬을 사용한다. [7], [8]

IV. 실험 및 고찰

1. 실험 영상

실험에 사용된 영상은 CCD 카메라로 실시간으로 찍은 sequence 영상들 중에, 화소의 움직임이 크지 않은 두 영상만을 선정하여 사용하였다. 그림 2와 그림 3이 바로 그것이다. CCD 카메라는 배경에 고정되어 있어서, 배경은 잡음을 제외하고는 움직임이 없으며, 흰색상의 회색하의를 입은 사람만이 왼쪽에서 오른쪽으로 3픽셀정도 이동하고 있다.

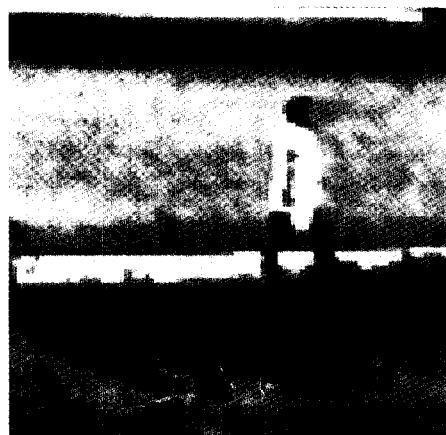


그림 2. 이전 영상

Fig 2. Previous image



그림 3. 현재 영상

Fig 3. Current image

두 영상이 주어졌을 때, 현재 영상내에서의 어느 한 화소에 대한 움직임 벡터를 추정하기 위해서는, 먼저 그 화소를 중심으로 상하·좌우로 움직임 가능한 거리만큼의 많은 움직임 벡터 가능 화소들을 정해야 한다. 즉, 제한적인 움직임 탐색 범위가 존재하게 되고, 그 범위안의 화소들은 각각 움직임 벡터 가설들이 되는 것이다.

본 논문에서 움직임 추정에 사용되는 두 영상은 다음과 같다.

2. MRF(Markov 랜덤 필드) 모델링에서의 인자 설정
 식(2.6)과 식(2.7)의 관찰 모델과 식(2.8)과 식(2.9)의 움직임 벡터 모델은, 이전 영상에서의 실제 움직임 벡터의 위치($\bar{d}(x_i, t)$)가 주어졌을 때, 가장 확률이 높은 움직임 벡터의 위치($d^t(x_i, t)$)를 추정하는 것이다. 즉 자체를 각 가설에 대한 확률분포로 보았다. 이 때, 식(2.7)에서 적용되는 인자 σ^2 는 x_i^t 를 중간값으로 하고, 움직임 탐색 범위내의 화소들에 대한 분산이 된다. 다시 말하면, 관찰모델은 $\bar{d}(x_i, t)$ 에서의 $x_i^t - \bar{d}_i^t$ 를 중심으로 Gaussian 분포를 따른다고 가정한 모델이다. 식(2.9)에서의 β_j 인자는 임의 값으로서, 적당한 값으로 대치해 준다. 본 실험에서는 1.0으로 설정하였다. 마지막으로 식(2.11)에서의 인자는 정규화 인자값으로 식(2.7)이 최소가 되고 식(2.9)가 최소가 되는 공통집합이 존재하도록 설계를 해주면 된다. 그리고, 평탄성을 위한 클러스터의 설정은 계산량을 줄이기 위해, 1차 이웃 시스템으로 한정하였다. 표 1은 실험에서 사용한 변수 값을 정리해 놓았다.

표 1. 기존방법에서 사용된 인자 값

Table 1. Parameter values in MRF model

변수명	변수값	비고
σ^2	210.0	식 (2.7)에서 관찰 모델의 분산
β_j	1.0	식 (2.9)
λ	1.0	식 (2.11)에서의 regularization 변수

이러한 변수를 사용했을 때, 움직임 탐색 범위에 따라서 그 성능이 달라지는데, 본 논문에서는 단방향 상하·좌우로 각각 4에서 8 화소까지 사용하여 비교해 보았다. 그러므로, 한 화소의 움직임 벡터 추

정당 움직임 탐색 범위내에서 방문하게 되는 화소수는 81에서 289가 된다.

3. D-S이론에서의 인자 설정

일반적으로 확률 측도로 설계되었던 관찰 모델과 평탄성 모델에는 평탄성이라는 사전지식의 선택과 클러스터의 선택등에 의한 불확실성이 존재한다고 가정할 수 있다. 본 논문에서는 제 2장에서 설계된 모델에 이러한 불확실성이 존재한다고 가정하고, 각각을 신뢰할 수로 설계하였다. 즉, 각 측도에 확신도를 주고, 나머지는 불확실성으로 돌리는 것이다. 예를 들어, 관찰 모델에서 설계된 측도 식(2.6), 식(2.7)에서처럼 x^t 위의 한 화소(x_i, t)가 x^{t-1} 위의 한 화소인($x_{i-d_i^t}, t-1$)로 정합되는 정도를 나타낸다 해도, 그러한 식과 다르게 설계된 측도로 똑같은 상황을 나타낸다면, 각각의 설계된 측도에 대한 추정의 확신도를 줄 필요가 생기기 때문이다.

본 실험에서는 확률 측도와의 성능 비교를 위해서 식(2.6), 식(2.7)의 식(2.8), 식(2.9)과 똑같은 상황으로 기본확률을 학당을 설계하였다. 즉, 불확실성 $m_o(\Theta)$ 값만을 제외하고, 기존방법에서의 식(2.6), 식(2.7)의 관찰 모델식은, D-S이론에서의 식(3.3), 식(3.4)은 같은 값이 된다. 그리고, 불확실성 $m_s(\Theta)$ 값만을 제외하고, 기존방법에서의 식(2.8)과 식(2.9)은, D-S이론에서의 식(3.6)과 식(3.7)과 같은 값이 된다. 결국, 확률 측도와 같은 값으로 함수 설계는 되지만 결합하는 과정에서 $m_A(x)*m_s(\Theta) + m_B(x)*m_o(\Theta)$ 만큼 불확실성의 영향이 나타나는 것이다. 여기서 $m_o(\Theta)$ 와 $m_s(\Theta)$ 는 설계자의 임의적인 값이라 할 수 있다. 신뢰할 수가 singleton에 대해서만 정의되었으므로, 식 (3.3)에서부터 식 (3.8)에 존재하는 기본확률학당 m_o 와 m_s 는 각각 Bel_o 와 Bel_s 와 동일하게 된다.

본 실험에서 설정된 인자는 표 2에서와 같다.

표 2. D-S 이론에서 사용된 인자 값

Table 2. Parameter values in D-S theory

변수명	변수값	비고
σ^2	210.0	식 (3.4)에서 분산
β_j	1.0	식 (3.7)
$m_s(\Theta)$	10^{-11}	식 (3.8)
$m_o(\Theta)$	10^{-5}	식 (3.5)

4. 충실도를 통한 두 방법의 성능 비교.

화률측도에 의한 움직임 벡터 추정의 성능과 신뢰 함수에 의한 움직임 벡터 추정의 성능을 비교하기 위해서 다음과 같은 실험을 하였다. $m_o(\Theta)$ 과 $m_s(\Theta)$ 의 설정에 따라 신뢰 함수에 의한 움직임 벡터의 추정의 성능은 상당히 다른 결과를 보인다. 앞의 실험에서는 같은 움직임 탐색범위일 때, 신뢰 측도에 의한 움직임 벡터의 추정이 화률 측도보다 떨어지는 결과를 보였는데, $m_o(\Theta)$ 와 $m_s(\Theta)$ 를 같이 10^{-6} 로 설계되었을 때는 반대의 결과를 보임을 알 수 있다. 즉, $m_o(\Theta)$ 와 $m_s(\Theta)$ 은 응용에 따라 임의로 설정할 수 있는 값이기 때문에, 좀 더 나은 성능을 보려면 적절한 선택을 하여야 할 것이다. 이때, σ^2 는 실험영상에 종속되는 값이고, λ 는 임의 값이지만 D-S이론과의 실험비교를 위해 1.0으로 하였다.

표 3과 그림 4를 보아 $m_o(\Theta)$ 와 $m_s(\Theta)$ 의 값을 부여함으로써, 기존의 MRF(Markov 랜덤 필드)방법보다 더 좋은 성능을 구할 수 있다. 그러나, $m_o(\Theta)$ 와 $m_s(\Theta)$ 의 값이 매우 적게 설계했을 특수한 경우에만, D-S이론을 사용한 움직임 추정이 기존 방법보다 나은 성능을 보이는 것으로 보아, 기존의 MRF(Markov 랜덤 필드) 방법이 불확실성이 별로 없는 잘 설계된 추정방법이라는 것도 유추해 낼 수 있다. 그림 4는 각 화소가 이전영상에서 현재영상으로 천이된 정도를 방향과 크기로 나타내 주는 그림이다.

표 3. D-S 이론과 화률측도에 기반한 추정의 충실도 비교

Table 3. Comparison of fidelities based on D-S theory with probability measure

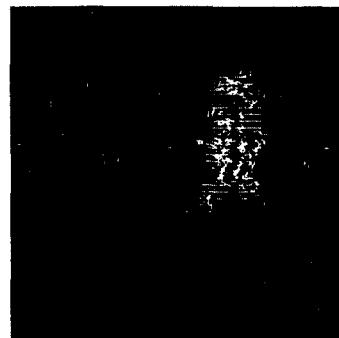
추정기준	추정방법	PSNR (db)	SNR (db)	탐색 범위(단방향)
화률 측도	SA	27.796	23.023	4
D-S 이론	SA	28.703	23.935	4

만약에, $m_o(\Theta)$ 와 $m_s(\Theta)$ 를 영으로 설계하게 되면 불확실성이 사라지며, 이때는 화률 측도와 신뢰 함수가 같은 상태가 되며, 움직임 벡터 추정의 성능도 같아지게 된다. 다음은 표 4과 그림 5은 그러한 결과를 보이고 있다.

최적화된 해를 찾는 Simulated Annealing(가상 가열 냉각)이라는 방법 때문에 상당한 계산량과 처리시간을 요하는 것이, 기존방법이나 제안된 방법이나 큰 제약이 되긴하지만, 제안된 방법은 화소당 정확한 움직임 벡터를 구하는 데는 매우 효과적인 방법이라는 것을 알 수 있다. 또한, 움직임 정도가 큰 영상일수록 계산량과 시간이 많이 소요되는데 그 이유는 탐색범위가 커지기 때문이다. 기존의 MRF(Markov 랜덤 필드)방법에 비해서도 제안된 방법이 $m_A(x)*m_s(\Theta) + m_B(x)*m_o(\Theta)$ 많큼 계산량이 많아지게 된다. 또한, 탐색범위가 클수록 움직임 추정의 충실도가 떨어지는 데(표 5 참조), 그 이유는 적은수의 영상 sweep에



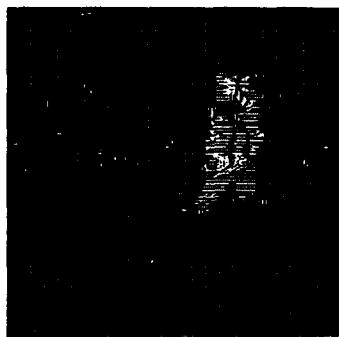
(a) 화률측도에 기반한 추정



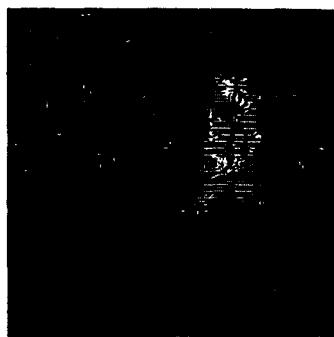
(b) D-S이론에 기반한 추정

그림 4. 각 측도에 기반한 추정

Fig 4. Esitimation based on each measure



(a) 화률측도에 기반한 추정



(b) D-S이론에 기반한 추정

그림 5. 불확실성을 배제했을 때, 각 측도에 기반한 움직임 벡터 추정의 비교

Fig 5. Comparison of motion vector estimation without uncertainty

표 4. 불확실성을 배제했을 때, 화률측도에 기반한 추정과 D-S 이론에 기반한 추정과의 충실태 비교

Table 4. Comparisir of fidelities without uncertainty

추정 기준	추정 방법	PSNR (dB)	SNR (dB)	탐색 범위 (단방향)
화률 측도	SA	27.796	23.028	4
D-S 이론	SA	27.796	23.028	4

표 5. D-S 이론에서 탐색 범위에 따른 움직임 보상된 영상과 원 영상간의 충실태 비교

Table 5. Comparisir of fidelities as varing search range in D-S theory

탐색 범위 (단방향)	PSNR (dB)	SNR (dB)
4	26.101	21.333
5	24.705	19.937
6	23.791	19.023
7	23.694	18.926
8	23.601	18.833

대해, SA가 전역적인 극값에 도달할 확률이 작아지기 때문이다. 이는 기존의 MRF(Markov 랜덤 필드) 방법에서도 마찬가지로 나타난다.

또다른 D-S이론의 설계의 어려움은 $m_O(\Theta)$ 와 $m_S(\Theta)$ 의 설정이 매우 임의적이기 때문에, 영상에 따라 그 설정이 달라진다는 점이다.

V. 결 론

본 논문에서는 기존의 모델기반의 움직임 벡터 추정에 있어서, 각 움직임 벡터에 대해 확률을 할당했던 것과는 다르게, 그것을 퍼지 측도의 하나인 D-S이론의 신뢰 합수로 바꾸어 모델에 변형을 주었다. 이는 관찰 모델과 움직임 벡터 모델에서 설계되었던 합수에 불확실성이 존재한다고 보고, 각 합수에 확신도를 부여한 것이다. 모델기반의 움직임 벡터 추정에 있어 개선점을 얻어내기 위한 기존의 연구로는 최적화 기법에 주로 한정되어 있었다. 그 것에 반하여 모델링의 설계에 개선점을 둘으로써 추정 성능에 어떠한 영향이 있는지 알아보고, 기존의 확률측도와 신뢰 합수사이에 어떤 공통 집합이 있는지 알아보려고 하는 것이 본 논문의 목적이라고 하겠다.

확률측도에서는 두 모델을 lagrange 곱셈자로써 정규화했던 개념이, D-S이론에서는 dempster의 결합 규칙으로 정보를 결합하는 관점으로 바뀌었다는 사실은 특이할 만하다. 이 때, D-S이론에서는 두 기본확률할당은 서로 다른 두 정보의 기준에 의해서 구해졌지만, 확률적으로 독립이라고는 볼 수 없다. 이는 MAP에 의해서 설계된 두 모델이 조건적 확률 측도로서 서로 정규화되는 상황과 같다.

본 논문에서의 결과를 정리하면 다음과 같다.

1. 움직임 변위 벡터 추정에서 확률 축도 대신 퍼지 축도이론의 하나인 D-S이론의 적용으로 성능의 개선점을 볼 수 있었다. 이 때, 설계가 간단한 난순지지 함수보다는 불확실성의 정도를 조절할 수 있게 설계된 신뢰 함수가 좋은 성능을 나타내었다.

2. 확률축도의 움직임 변위 벡터경우나 D-S이론의 움직임 변위 벡터경우나, 움직임 탐색범위가 커질수록 움직임 복원된 영상의 충실도가 떨어졌다. 그러므로, 큰 움직임이 존재하는 순차시간 영상에는 사용하기 부적합한 알고리듬이라는 것을 실험적으로 알게 되었다.

3. 신뢰 함수의 설계시 불확실성을 없애 각 축도를 설계할때는 축도의 관점에서 확률축도와 동일하게 되며, 움직임 추정의 결과도 같게 되었다.

퍼지 축도는 확률축도를 포함한 보다 일반적인 축도이며, 설계된 함수에 확신도를 줄 수 있는 매우 유용한 축도이다. 이러한 퍼지 축도를 표현하고, 중거를 통합하는 규칙이 일반화되어 정리되어 있는 D-S이론은 불확실성이 존재한다고 가정되는 응용 분야에 매우 유용하게 사용될 수 있을 것이다. 또한, 확률 축도와 신뢰 함수의 관계가 보다 체계적으로 세워지게 되면, 그 응용분야는 더욱 커질것이라고 생각되어 진다.

참 고 문 헌

- J. Konrad and E. Dubois, "Estimation of image motion fields: Bayesian formulation and stochastic solution," in Proc. ICASSP'88 (New York), pp. 1072~1075, 1988.
- J. Konrad and E. Dubois, "Bayesian estimation of motion vector field," IEEE Trans. Patt. Anal. Machine Intell., vol. 14, pp 910~927, 1992.
- M. Bertero, T. A. Poggio, and V. Torre, "Ill-posed problems in early vision," Proc. IEEE, vol. 76, pp. 869~889, Aug. 1988.
- T. Poggio, V. Torre, C. Koch, "Computational vision and regularized theory," Nature, vol. 317, pp. 314~319, Sep. 1985.
- S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and Bayesian restoration of images," IEEE Trans. Patt. Anal. Machine Intell.,

- vol. 6, no. 6, pp 721~741, 1984.
- J. Besag, "Spatial interaction and the statistical analysis of lattice systems," J. Royal Statist. Soc., series B, vol. 36, pp 192~236, 1974.
- N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, A. H. Teller, and E. Teller, "Equations of state calculations by fast computing machines," J. Chem. Phys., vol. 21, pp 1087~1091, 1953.
- S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, "Optimization by simulated annealing," Science, vol. 220, pp 671~680, 1983.
- G. J. Klir and T. A. Folger, Fuzzy Sets, Uncertainty, and Information, Prentice-Hall, 1992.
- H. E. Kyburg, Jr., "Bayesian and non-Bayesian evidential updating," Arifit. Intell., vol. 31, pp 271~293, 1987.
- G. Shafer, R. Srivastava, "The Bayesian and Belief-fuction formalisms: A General perspective for auditing," J. Practice and Theory, pp 482~521. 1990.



최 철 영(Cheol Young Choi) 정회원

1971년 7월 25일 생
1994년 2월: 연세대학교 전기공학과(학사)
1996년 8월: 연세대학원 전기공학과(공학석사)
1997년 9월~현재: LG전자 멀티미디어(연) 연구원



최 윤 식(Yoon Sik Choe) 정회원

1957년 2월 12일 생
1979년 2월: 연세대학교 전기공학과 졸업 (공학사)
1984년 5월: 미국 Case Western Reserve 대, 시스템 공학과 대학원 졸업 (M.S.E.E.)

1987년 5월: 미국 페실베니아 주립대학, 전기공학과 대학원 졸업(M.S.)
1990년 12월: 미국 Purdue 대학, 전기공학과 대학원 졸업 (Ph.D.)
1990년 11월~1993년 2월: (주)현대전자 산업전자기기 연구소, 책임연구원
1993년 3월~현재: 연세대학교 전기공학과 조교수
※주관심분야: 디지털 영상 신호처리, 영상압축, 컴퓨터시각