

계층적 Hopfield 신경 회로망을 이용한 Optical Flow 추정

(Optical Flow Estimation Using the Hierarchical Hopfield Neural Networks)

金 文 甲 * , 秦 成 一 **

(Mun Gab Kim, and Sung Il Chien)

요 약

본 논문에서는 계층적 Hopfield 신경 회로망을 이용한 optical flow를 추정하는 방법을 제안한다. 연속되는 두 영상이 주어졌을 때, Zhou와 Chellappa는 Hopfield 신경 회로망을 이용하여 optical flow를 계산하는 방법을 제안하였다. 이들이 제안한 알고리즘의 문제점은 회로망에 자체 귀환이 존재하여 회로망이 매번 반복될 때 마다 에너지를 검토하여 에너지가 감소되었을 때만 뉴런 상태를 받아들였다. 이는 Hopfield 모델의 수렴 조건에 위배된다. 또, 하나의 문제점은 영상에서 물체의 이동이 클 때는 계산 시간이 많이 걸리며 수렴이 잘되지 않아 효율적인 변위를 구할 수 없다는 것이다. 이 논문에서는 Zhou와 Chellappa 회로망의 문제점을 개선하여 Hopfield 모델의 수렴 조건을 만족시켰으며, 또한 계층적 구조를 이용하여 변위가 클 때도 빠른 수렴 속도로 안정되게 optical flow를 구할 수 있었다.

Abstract

This paper presents a method of implementing efficient optical flow estimation for dynamic scene analysis using the hierarchical Hopfield neural networks. Given the two consequent images, Zhou and Chellappa suggested the Hopfield neural network for computing the optical flow. The major problem of this algorithm is that Zhou and Chellappa's network accompanies self-feedback term, which forces them to check the energy change every iteration and only to accept the case where the lower the energy level is guaranteed. This is not only undesirable but also inefficient in implementing the Hopfield network. The another problem is that this model cannot allow the exact computation of optical flow in the case that the disparities of the moving objects are large. This paper improves the Zhou and Chellappa's problems by modifying the structure of the network to satisfy the convergence condition of the Hopfield model and suggesting the hierarchical algorithm, which enables the computation of the optical flow using the hierarchical structure even in the presence of large disparities.

I. 서 론

* 正會員, 大宇重工業 特殊事業本部 電子技術室

(Elec. Eng. Dept. Special Product Div.)

** 正會員, 慶北大學校 電子工學科

(Dept. of Elec. Eng., Kyungpook Univ.)

接受日字: 1993年 10月 7日

인간의 시각은 정지 영상보다 운동 영상에 민감하므로, 운동 영상을 해석하는 것은 중요한 의미가 있다. 운동 영상을 해석하는 것은 물체의 운동 그 자체뿐만 아니라 물체의 상대적 깊이나 구조를 인식하는데

이용할 수 있고, 운동 경계를 알아냄으로써 움직이는 물체와 고정된 물체를 분할^[1]하는 데에도 유용하기 때문이다. 현재 운동 영상을 해석하는 연구가 활발히 진행되고 있다^[2]. 운동 영상을 해석하는 방법을 대체적으로 두가지로 분류해 보면, 특징 기반법(Feature-based method)^[2,3,4]과 Intensity-based 방법^[2,5-8]으로 나눌 수 있다. 특징 기반법은 3차원 물체의 특징인 모서리나 경계등과 같은 특징들을 추출하여, 이 특징들의 정합(Matching)에 의해 변위(Disparity)를 추정한다. Intensity-based 방법은 영상의 밝기의 시간적 변화와 국부적 구조 즉, 공간 경사와 시간 경사의 관계로부터 변위를 구하는 방법이다. 전술한 이러한 방법들은 많은 반복 처리로 행해져야 하기 때문에, 여러 제한 조건을 동시에 만족하는 병렬 회로망이 요구되는데, 이를 신경 회로망으로 구현할 수 있다.

Zhou와 Chellappa^[9]는 Hopfield 신경 회로망^[10,11]을 이용한 3차원 뉴런 구조를 가지는 회로망을 구현하여 optical flow를 구하였다. 이러한 신경 회로망을 구현하기 위해서는 에너지 함수가 필요하다. Zhou와 Chellappa가 구현한 에너지 함수는 두 영상의 차를 나타내는 Current 항과 이웃한 화소간 변위의 유사성을 나타내는 평탄성(Smoothness)항으로 구성된다. Zhou와 Chellappa가 구현한 신경 회로망은 뉴런들이 병렬 처리를 하지만, 이 회로망이 가지는 문제점은 에너지 함수중 평탄성항이 상호 비교되는 출력 뉴런들 사이의 차의 자승으로 구성되어 있어, 이는 회로망에 자체 제환(Self-feedback)을 초래하여 Hopfield 모델의 수렴 조건에 위배된다는 것이다. 이러한 문제로 인해 이 회로망은 뉴런 상태의 변화 여부를 결정하기 위해 에너지 검사 과정을 필요로한다. 또, 하나의 문제점은 실영상에서 변위가 클 경우는 계산 시간이 많이 걸리며, 수렴이 잘되지 않는 문제점을 동반한다.

본 논문에서는 이러한 Zhou와 Chellappa 모델의 문제점을 개선하여 Hopfield 신경 회로망의 수렴 조건을 만족시켰으며, 변위가 클 경우는 계층적(Hierarchical) 구조를 이용하여 수렴 속도를 증가시켰으며 보다 효율적인 optical flow를 계산할 수 있었다.

Zhou와 Chellappa는 회로망의 성능을 향상시키기 위해 영상의 밝기값이외에 이동과 회전에 불변인 주곡률(Principal Curvature)을 피쳐(feature)로 사용하였다. 본 논문에서도 사용된 주곡률을 Zhou와 Chellappa의 방법인 영상의 밝기값을 연속 함수로 바꾸어 주곡률을 구하지 않고, 디지털 영상 자체에서 구하는 알고리즘을 제시하였다.

II. 회전 불변 피쳐 추출

Intensity-based 방법에서는 보편적으로 영상의 밝기값이 피쳐로 이용되는데, 실영상(real image)에서 밝기값은 잡음에 민감하여, 정확한 optical flow를 구할 수 없다. 좀 더 정확한 optical flow를 구하기 위해 영상의 밝기값이외에 다른 피쳐를 생각할 수 있다. 여러 피쳐중 영상의 밝기값의 변화를 물체의 움직임으로 가정하여, 이동과 회전에 불변하는 주곡률^[12]을 피쳐로 사용하면 좀 더 정확한 optical flow를 구할 수 있다. 영상의 임의의 한 점(i,j)에서 주곡률은 그 점에서의 밝기값 함수의 법선 곡률값중 최고 최소값으로 정의되며, 주곡률은 밝기값의 함수인 가우스 곡률 G(Gaussian Curvature)과 평균 곡률 M(Mean Curvature)로 식(1) 및 (2)와 같이 표현할 수 있다.

$$K1 = M + \sqrt{M^2 - G} \quad (1)$$

$$K2 = M - \sqrt{M^2 - G} \quad (2)$$

여기서, K1은 최대 주곡률이고, K2는 최소 주곡률이다. Zhou와 Chellappa는 전술한 주곡률을 구하기 위해 주어진 디지털 영상에서 화소와 화소사이에 subpixel을 첨부하여 Chebychev 다항식을 이용하여 연속적인 함수값으로 바꾸어 주곡률을 구했다. Zhou와 Chellappa가 제안한 주곡률 추출 방법은 정확한 곡률은 구할 수 있지만 많은 계산량이 요구된다는 단점이 있다.

본 논문에서는 주곡률을 보다 빠르게 구하기 위해 주어진 디지털 영상을 연속적인 함수값으로 바꾸지 않고 디지털 영상에서 직접 주곡률을 아래와 같은 방법으로 구했다. 주곡률이 위의 식 (1),(2)에 의해 구해지는데, 이때 이용된 가우스 곡률과 평균 곡률을 다음 식(3),(4)로 표현 할 수 있다.

$$G = \frac{f_{uu}f_{vv} - f_{uv}^2}{(1 + f_u^2 + f_v^2)} \quad (3)$$

$$M = \frac{1}{2} \frac{f_{uu} + f_{vv} + f_{uu}f_v^2 + f_{vv}f_u^2 - 2f_u f_v f_{uv}}{(1 + f_u^2 + f_v^2)^{3/2}} \quad (4)$$

여기서 f_u, f_v 는 화소에서 각각 u,v 방향으로의 일차 미분값들이며, f_{uu}, f_{vv}, f_{uv} 는 2차 미분값들이다. 이러한 미분치는 Yang^[13]이 제안한 그림 1과 같은 연산자를 사용하여 구할 수 있다. 위의 방법으로 구해진 미분치들을 가지고 가우스 곡률과 평균 곡률을 구하였다. 이 방법으로 계산량을 줄일수 있었다. Zhou와 Chellappa는 최대,최소 주곡률을 영상의 밝기값과 더불어 피

처로 사용했지만 본 논문에서는 최대,최소 주곡률이 유사한 의미를 가지고 있기에 계산량을 줄이기 위해 최대 주곡률만을 사용하였다.

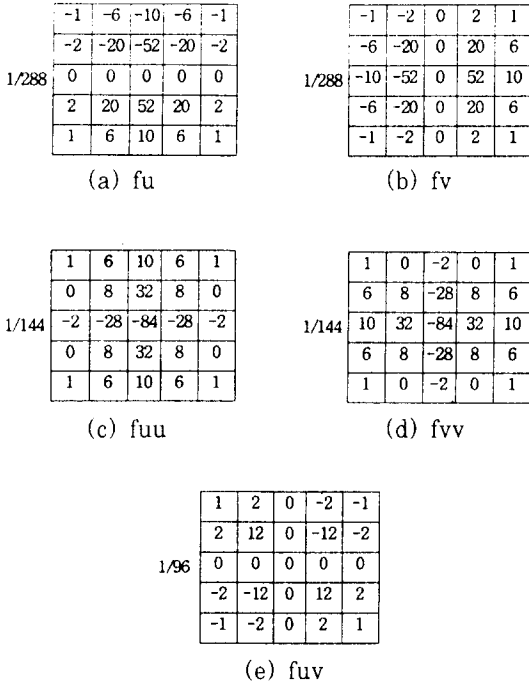


그림 1. Yang 과 Kak이 제안한 미분 연산자들.
 (a) u 방향 1차 미분 연산자.
 (b) v 방향 미분 연산자.
 (c)(d)(e) 2차 미분 연산자들

Fig. 1. Yang and Kak's differential operators.
 (a) First differential operator of u direction
 (b) First differential operator of v direction
 (c)(d)(e) Second differential operators

III. Zhou와 Chellappa 알고리즘

연속되는 두 영상이 주어졌을때, Zhou와 Chellappa는 Hopfield 신경 회로망을 이용하여 optical flow 를 구하는 시스템을 구현했다. 그들이 제안한 신경 회로망의 구조는 그림 2와 같다. 이 구조는 $N_r \times N_c$ 크기의 뉴런들로 구성된 것이 영상의 각 화소의 변위를 나타내도록 여러개 존재하며 이들 변위층은 서로 배타적이다.

즉, 영상의 임의의 한 점 (i, j) 위치에 존재하는 여러 변위층들의 각 뉴런중 순 입력(Net input)이 최대

인 한 변위층의 뉴런이 여기(Firing)되면, 나머지 변위층의 뉴런들은 휴지(Resting)상태가 된다.




그림 2. Zhou Chellappa가 제안한 Optical Flow를 위한 신경 회로망

Fig. 2. Zhou and Chellappa's Neural Network for Optical Flow Computation.

순 입력은 각 변위층에서 (i, j) 뉴런을 중심으로 평탄화 창내에서 연결 강도를 구하고 외부에서 공급되는 입력 전류 $(I_{i,j,k,l})$ 을 이용하여 구한다. 출력은 $N_r \times N_c \times (2D_i + 1) \times (2D_j + 1)$ 개의 뉴런들을 원소로 하는 3차원 구성으로 되어있는데, 각 화소마다 구성된 $(2D_i + 1) \times (2D_j + 1)$ 개의 변위층들의 뉴런들은 변위가 $u = -D_i, v = -D_j$ 에서 $u = D_i, v = D_j$ 사이를 나타낸다. 여기서, N_r 과 N_c 는 각각 영상의 행과 열의 크기이며, D 는 최대 변위(maximum disparity)를 나타낸다. $V = \{V_{i,j,k,l}; 1 \leq i \leq N_r, 1 \leq j \leq N_c, -D_i \leq k \leq D_i, -D_j \leq l \leq D_j\}$ 는 (i,j,k,l) 번째 뉴런의 상태를 나타내는 회로망의 상태 집합이다. 예를 들어, 뉴런 $V_{i,j,k,l}$ 가 1이라면 영상의 한 점 (i,j) 에서 i 방향으로 k, j 방향으로 l 의 변위라는 것을 의미한다. 만일, 뉴런들이 모두 연결 되어 있다면 3차원 Hopfield 모델의 총 에너지는 식(5)와 같다.

$$E = -1/2 \sum_{i=0}^{N_r} \sum_{j=0}^{N_c} \sum_{k=-D_i}^{D_i} \sum_{l=-D_j}^{D_j} T_{i,j,k,l} V_{i,j,k,l} V_{m,n,p,q} - \sum_{i=0}^{N_r} \sum_{j=0}^{N_c} \sum_{k=-D_i}^{D_i} \sum_{l=-D_j}^{D_j} I_{i,j,k,l} V_{i,j,k,l} \quad (5)$$

여기서, $T_{i,j,k,l,m,n,p,q}$ 은 m,n,p,q 번째 뉴런에서 i,j,k,l 번째 뉴런에 연결된 연결 강도(Weight)이며, $I_{i,j,k,l}$ 는

i, j, k, l 번째 뉴런으로 들어오는 입력을 나타낸다. 이 모델에서 임의의 지점 (i, j, k, l) 의 뉴런은 모든 뉴런들로부터 연결 강도를 통하여

$$\sum_{m=0}^{N_r} \sum_{n=0}^{N_c} \sum_{p=-D_1}^{D_1} \sum_{q=-D_2}^{D_2} T_{i,j,k,l,m,n,p,q} V_{m,n,p,q} \text{와 입력 단자를 통하여}$$

$I_{i,j,k,l}$ 를 동기적(synchronous)으로 받는다. 따라서, 한 뉴런에 들어오는 순 입력은 식(6)와 같다.

$$u_{i,j,k,l} = \sum_{m=0}^{N_r} \sum_{n=0}^{N_c} \sum_{p=-D_1}^{D_1} \sum_{q=-D_2}^{D_2} T_{i,j,k,l,m,n,p,q} V_{m,n,p,q} + I_{i,j,k,l} \quad (6)$$

Zhou와 Chellappa가 제안한 에너지 함수는 두 영상의 차를 나타내는 current 항과 이웃한 화소간의 변위의 유사성을 나타내는 평탄성항으로 구성되어 있으며, 뉴런들의 상태는 "1" 또는 "0"의 값을 가진다. Zhou와 Chellappa가 제안한 에너지 함수는 식(7)와 같다.

$$E = \sum_{i=0}^{N_r} \sum_{j=0}^{N_c} \sum_{k=-D_1}^{D_1} \sum_{l=-D_2}^{D_2} \{ A [(K11(i,j) - K21(i\otimes k, j\otimes l))^2 + (K12(i,j) - K22(i\otimes k, j\otimes l))^2] + (g1(i,j) - g2(i\otimes k, j\otimes l))^2 \} V_{i,j,k,l} + B/2 \sum_{i=0}^{N_r} \sum_{j=0}^{N_c} \sum_{k=-D_1}^{D_1} \sum_{l=-D_2}^{D_2} \sum_{s \in S} (V_{i,j,k,l} - V_{(i,j)\otimes s, l})^2 \quad (7)$$

여기서, $K11(i,j)$, $K12(i\otimes k, j\otimes l)$ 는 첫 영상의 최대, 최소 주곡률이며, $K21(i,j)$, $K22(i\otimes k, j\otimes l)$ 는 둘째 영상의 최대, 최소 주곡률이다. $g1(i,j)$, $g2(i\otimes k, j\otimes l)$ 는 첫째, 둘째 영상의 밝기값이다. S 는 점 (i,j) 를 중심으로 $(0,0)$ 를 제외한 평탄화 창내의 이웃한 지수들의 집합이며, 부호 \otimes 의 의미는 다음과 같다.

$$f(a\otimes b) = \begin{cases} f(a+b) : 0 \leq a+b \leq N_r, N_c \text{ 일 경우} \\ 0 : \text{그외} \end{cases}$$

A, B 는 상수이다.

식(7)의 첫번째 항은 current 항을 나타내고, 두번째 항은 평탄화 조건을 나타내는데 임의의 한 점 (i,j,k,l) 에서 출력이 "1"이면 평탄화 창내의 모든 출력이 "1"일때 에너지가 최소가 되고, 출력이 "0"일때 창내의 모든 출력이 "0"일때 에너지가 최소로 된다. 평탄화 창을 5×5 로 했을 경우 뉴런들 사이의 연결 강도와 순 입력은 식(5)와 식(7)을 비교 하여 구하면 식(8) 및 식(9)와 같다.

$$T_{i,j,k,l,m,n,p,q} = -48B \delta_{i,m} \delta_{j,n} \delta_{k,p} \delta_{l,q} + 2B \sum_{s \in S} \delta(i,j) \cdot (m,n) \otimes s \delta_{k,p} \delta_{l,q} \quad (8)$$

$$I_{i,j,k,l} = -A [(K11(i,j) - K21(i\otimes k, j\otimes l))^2 + (K12(i,j) - K22(i\otimes k, j\otimes l))^2] (g1(i,j) - g2(i\otimes k, j\otimes l))^2 - (g1(i,j) - g2(i\otimes k, j\otimes l))^2 \quad (9)$$

$$\text{여기서, } \delta_{i,j} = \begin{cases} 1 & i=j \text{ 일 경우} \\ 0 & i \neq j \text{ 일 경우이다.} \end{cases}$$

입력에 대한 출력의 전달 특성은 영상의 한 점 (i,j) 에 $(2D_1+1) \times (2D_2+1)$ 개의 변위층 뉴런들중에서 최대 값을 가지는 뉴런만을 여기시킨다. 식(8)의 연결 강도는 대칭적 ($T_{i,j,k,l,m,n,p,q} = T_{m,n,p,q,i,j,k,l}$)이며, 자체 제한 ($T_{i,j,k,l,i,j,k,l} \neq 0$)이 되어있다. 이 회로망은 자체 제한이 존재하여, 각 뉴런 상태가 변할때 마다 뉴런의 에너지가 감소되는 것이 아니라 증가할 수도 있다. 이로 인해 Zhou와 Chellappa는 뉴런의 상태 변화 여부를 결정하기 위해 뉴런들의 에너지를 검토하였다. 뉴런 여기 상태가 (m,n,p,q) 에서 (m,n,p',q') 번째로 변함으로 인해 에너지 변화는 식(10)와 같다.

$$\Delta E = - \left(\sum_{m=0}^{N_r} \sum_{n=0}^{N_c} \sum_{p=-D_1}^{D_1} \sum_{q=-D_2}^{D_2} T_{m,n,p,q,i,j,k,l} V_{i,j,k,l} + I_{m,n,p,q} \right) \Delta V_{m,n,p,q} + 1/2 (-1)^a T_{m,n,p,q,m,n,p,q} - \left(\sum_{m=0}^{N_r} \sum_{n=0}^{N_c} \sum_{p=-D_1}^{D_1} \sum_{q=-D_2}^{D_2} T_{m,n,p,q';i,j,k,l} V_{i,j,k,l} + I_{m,n,p,q} \right) \Delta V_{m,n,p',q'} + 1/2 (-1)^a T_{m,n,p',q';m,n,p',q'} \quad (10)$$

$$\text{여기서, } a = \begin{cases} 1 & \Delta V = 1 \text{ 일 경우} \\ 2 & \Delta V = -1 \text{ 일 경우} \end{cases}$$

$$\Delta V_{m,n,p,q} = V_{m,n,p,q}^{new} - V_{m,n,p,q}^{old}$$

$$\Delta V_{m,n,p',q'} = V_{m,n,p',q'}^{new} - V_{m,n,p',q'}^{old}$$

$$\Delta E = E^{new} - E^{old}$$

이렇게 검토한 에너지 변화량 ΔE 가 음수이면 뉴런 상태를 받아 들이고, 양수이면 그이전 상태를 유지한다. 이러한 Zhou와 Chellappa의 알고리즘들은 Hopfield 모델의 수렴 조건에 위배된다.

IV. 제안된 알고리즘

본 논문에서는 Zhou와 Chellappa의 회로망이 자체 제한을 가짐으로 인해 생기는 문제점을 극복하기 위해 뉴런 상태값을 "1" 또는 "-1"로 하였다. 이러한 뉴런 상태값의 변화는 이준재등^[14]이 신경 회로망을 이용한 스트레오 정합에 사용한 것을 본 논문에서는 2차원으로 확장하여 optical flow 계산에 이용하였다. 이렇

개 뉴런 상태값을 변화시킴으로 인해 회로망이 Hopfield 모델의 수렴 조건을 만족하여 회로망이 반복 처리됨에 따라 회로망이 안정된 상태로 수렴한다. 본 논문의 알고리즘으로 optical flow를 구하는 에너지 함수를 구성하면 식(11)와 같다.

$$E = \sum_{i=0}^{N_i} \sum_{j=0}^{N_j} \sum_{k=-D_i}^{D_i} \sum_{l=-D_j}^{D_j} \{A [K1(i, j) - K2(i\oplus k, j\oplus l)]^2\} \\ + C [g_1(i, j) - g_2(i\oplus k, j\oplus l)]^2 V_{i,j,k,l} \\ - B/2 \sum_{i=0}^{N_i} \sum_{j=0}^{N_j} \sum_{k=-D_i}^{D_i} \sum_{l=-D_j}^{D_j} \sum_{s \in S} V_{i,j,k,l} V_{(i,j)\oplus s,k,l} \quad (11)$$

여기서, $K1(i,j)$ 는 첫번째 영상의 최대 주곡률이며, $K2(i,j)$ 는 두번째 영상의 최대 주곡률이다. A, B, C는 상수이며, $g_1(i,j)$, $g_2(i,j)$ 는 첫째, 둘째 영상의 밝기값이다. 식(11)의 첫째항은 current 항을 나타내는데 이는 변위층을 따라 가장 비슷한 점이 정합될때 에너지가 최소가 된다. 둘째항은 평탄화 조건을 나타내는 것으로, Zhou와 Chellappa가 식(7)에서 나타낸 것과 같이 상호 비교되는 출력 뉴런들 사이의 차의 자승으로 나타낸 것을 상호 비교되는 뉴런들의 곱으로 구성했다. 임의의 점 (i,j,k,l) 에서 출력이 "1"이라면 평탄화 창내의 모든 출력이 "1"일때 에너지가 최소가 되며, 출력이 "-1"일때도 마찬가지로 모든 출력이 "-1"일때 에너지가 최소가 되어, Zhou와 Chellappa의 평탄성항과 의미가 같다. 연결 강도와 입력을 구하기 위해 식(5)와 식(11)을 비교하여 다음 식(12) 및 식(13)과 같이 구할 수 있다.

$$T_{i,j,k,l,m,n,q} = B \sum_{s \in S} \delta_{(i,j),(m,n)} \oplus_s \delta_{k,p} \delta_{l,q} \quad (12)$$

$$I_{i,j,k,l} = -A [K1(i,j) - K2(i\oplus k, j\oplus l)]^2 \\ - C [g_1(i,j) - g_2(i\oplus k, j\oplus l)]^2 \quad (13)$$

연결 강도와 입력이 구해지면, 각 뉴런들은 동기적으로 연결 강도와 순 입력을 받아 뉴런 상태를 재조정한다. 이때 입력에 대한 출력의 전달 특성은 영상의 한 점 (i,j) 에 존재하는 $(2D_i+1) \times (2D_j+1)$ 개의 변위층 뉴런들중에서 최대값을 가지는 변위층의 뉴런만을 여기서 지켰다. 이 구조는 Zhou와 Chellappa의 알고리즘에 의해 구한 식(8)와 다른점은 뉴런들 사이의 연결 강도에 자기 자신은 연결이 없다는 점이다. 이러한 이유에 의해 이 회로망은 Hopfield 모델의 수렴 조건을 만족시켜, 회로망이 반복됨에 따라 에너지를 검토할 필요가 없다. 본 논문에서 제안한 알고리즘은 다음과 같다.

(1) 뉴런의 초기 상태는 다음 규칙에 의해 정한다.

$$V_{i,j,k,l} = \begin{cases} 1 & I_{i,j,k,l} = \max(I_{i,j,k,l} - D_i \leq k \leq D_j, \leq 1 \\ & \leq D_j) \text{일 경우} \\ -1 & \text{그외} \end{cases}$$

여기서, $I_{i,j,k,l}$ 은 (i,j,k,l) 번째의 입력이다.

(2) 모든 뉴런의 상태 변화는 동기적으로 선택한다.

(3) 선택된 한 뉴런에서 순 입력을 계산한다.

$$u_{i,j,k,l} = \sum_{m=0}^{N_i} \sum_{n=0}^{N_j} \sum_{p=-D_i}^{D_i} \sum_{q=-D_j}^{D_j} T_{i,j,k,l,m,n,q} V_{m,n,p,q} + I_{i,j,k,l}$$

(4) 뉴런의 상태는 순 입력을 입력으로 하여 (1)의 규칙을 따른다.

(5) 상태 변화가 있다면 (2)로 되돌아가고, 없다면 출한다.


V. 계층적 구조

본 논문에서는 변위가 클 경우 수렴 속도를 높이고, 보다 효율적인 optical flow를 구하기 위해 계층적 구조를 이용하였다. 즉, 주어진 영상을 적당한 간격으로 표본화하여 저해상도의 영상(coarse image)으로 재구성한후 제안한 알고리즘으로 optical flow를 구하였다. 이렇게 구한 저해상도에서의 최종 결과를 보간(interpolation)하여 고해상도의 영상(fine image)에서의 초기 정보로 이용하였다. 이때 보간은 주위 변위들의 평균을 취하였다. 고해상도의 영상에서는 보간된 결과를 이용하여 optical flow를 다음과 같은 방법으로 구하였다. 평탄성 성질을 이용하여 고해상도의 영상에서 변위는 저해상도의 영상에서 구한 변위와 유사하다는 성질을 이용하여 영상에서 임의의 점 (i,j) 에 존재하는 $(2D_i+1) \times (2D_j+1)$ 개의 변위층 뉴런들중에서 순 입력이 최대값을 가지는 뉴런의 변위층을 찾는 것이 아니라 이전 상태에서의 변위를 포함한 이웃한 8개의 변위내에 존재한다는 가정하에 이들 9개의 변위층의 뉴런들에서 순 입력이 최대값을 가지는 변위층의 뉴런만을 여기서 지키는 방법을 사용하였다.


VI. 실험 및 결과

본 실험에서는 Zhou와 Chellappa의 알고리즘과 본 논문에서 제안한 알고리즘을 비교하기 위해 40%의 밀도를 가지는 random dot 영상^[15]과 C.C.D. 카메라로 받은 실영상을 아무런 전처리없이 사용하였으며, 실험에 사용된 영상의 크기는 128x128이다. 또한, 실험에서는 5x5 평탄화창을 사용했으며, random dot 영

상과 실영상에서 변위층을 81개로 구성했다. 연결강도는 전영상에 대해 연결되어 있지않고, 주변의 동일한 변위층에 대해 5x5창을 사용하였다. 시스템의 출력은 변위층에서 최대값만을 가지는 뉴런을 여기시켰는데, 초기 상태에서 최대값이 여러개 일때는 무작위로 선택하여 한 뉴런만 여기시켰으며, 시스템이 반복 처리되면서 최대값이 여러개 일때는 반복 처리 이전 상태를 유지하도록 하였다.



(a)



(b)

그림 3. 40%의 밀도를 가진 Random Dot 영상들


(a) 왼쪽 영상 (b) 오른쪽 영상

Fig. 3. Random Dot Images with 40% density.


(a) Left Image (b) Right Image

그림 3는 40%의 밀도를 가지는 random dot 영상이며, 흰부분이 255, 검은부분이 0의 값을 가진다. 그림 3의 (a)는 움직임이 없는 영상이고, 그림 3의 (b)는 128x128 영상에서 중심을 기준으로 하여 40x40 크기에서 dot를 $u=2, v=2$ 로 이동시켰으며, 20x20 크기에서는 $u=-2, v=-4$ 로 이동 시켰다. 이에대한 결과는 그림 4에 나타내었으며, 실험에 사용된 변수는 $A=1.785, B=5418.75, C=1$ 이다. 그림 4의 (a)는 Zhou와 Chellappa의 알고리즘으로 수행한 결과이며,

그림 4의 (b)는 제안한 알고리즘으로 수행한 결과이다. 결과에서 나타난것과 같이 두 결과가 비슷한 함을 알 수있었다. 그림 5은 움직이는 자동차 영상이다.



(a)



(b)

그림 4. Random Dot 영상의 실험 결과

(a) Zhou와 Chellappa의 알고리즘

(b) 본 논문에서 제안된 알고리즘

Fig. 4. Experimental Results of Random Dot Images.

(a) Zhou and Chellappa's Algorithm

(b) Proposed Algorithm in this Paper

그림 5의 (a)는 첫번째 영상이고, (b)는 두번째 영상이다. 실험에 사용된 변수는 $A=3.26, B=5418.75, C=1$ 이다. 그림 6의 (a)는 Zhou와 Chellappa의 알고리즘으로 수행한 결과로 실험 결과가 영상에서의 모 습과 유사하나 자동차앞 유리부분에서 변위는 다른 부분과 차이가 있음을 알수 있다. 그림 6의 (b)는 본 논문에서 제안한 계층적 구조를 이용한 결과이다. 즉, 표 본화된 영상(64x64)에서 구한 optical flow 결과를 보간한 후 고해상도의 영상에서 초기 정보로 이용했으며, 고해상도의 영상에서는 optical flow 계산을 전체

의 변위층에 대해 계산하는 것이 아니고, 평탄화 성질을 이용하여 저해상도에서 구한 변위를 중심으로 이웃한 8개의 변위층에서 계산한 결과인데, 실영상에서 이동된 물체와 유사한 모습을 나타내었으며, 변위도 주위 것과 동일하게 나타났다.



(a)




(b)

그림 5. 자동차 영상(128x128)
(a) 첫번째 영상 (b) 두번째 영상


Fig. 5. Car Images(128x128).
(a) First Image (b) Second image

그림 7은 Zhou와 Chellappa의 알고리즘과 본 논문에서 제안한 알고리즘과의 성능 비교를 위해 회로망이 반복 처리됨에 따른 뉴런의 상태 변화수를 나타내었다. A는 Zhou와 Chellappa가 제안한 방법으로 피쳐로는 영상의 밝기값과 최대, 최소 주곡률을 사용하였다. 표에 나타난 것과 같이 회로망이 반복되어도 수렴하지 않는다. B는 본 논문에서 제안한 방법으로 계층적 구조를 사용하지 않고 수행한 결과이며 피쳐로는 영상의 밝기값과 최대 주곡률만을 사용했다. 이 실험 결과도 A와 유사하게 회로망이 반복됨에 따라 수렴이 되지 않았다. C는 본 논문에서 제안한 방법으로 계층적 구조의 전 단계인 표본화된 영상(64x64)에서 optical flow를 구한 결과이다. D는 본 논문에서 제안한 방법

으로 계층적 구조를 이용했다. 즉, C의 결과를 이용하여 고해상도에서 optical flow를 구한 결과이다.



(a)



(b)

그림 6. 자동차 영상에 대한 실험 결과
(a) Zhou와 Chellappa의 알고리즘

Fig. 6. Experimental Results of Car Image.
(a) Zhou and Chellappa's algorithm (b) Proposed Algorithm in this Paper

실험 결과에 나타난 것과 같이 빠른 속도로 수렴함을 알 수 있었다. E는 표본화된 영상에서 optical flow를 구한 것으로 피쳐로 영상의 밝기값만을 사용한 실험 결과이다. F는 본 논문에서 제안한 방법으로 계층적 구조를 이용했다. 즉, E의 실험 결과를 이용한 것이다. 이 결과로 알 수 있는 것은 시스템의 성능을 향상시키기 위해서 밝기값이외의 피쳐가 필요하다는 것이다.

VII. 결 론

본 논문에서는 optical flow 계산을 Hopfield 신경 회로망을 이용하여 구한 Zhou와 Chellappa 회로망의 문제점인 Hopfield 신경 회로망의 수렴 조건을 만족시키지 못한 점을 신경 회로망의 뉴런 상태를 변화시켜 Hopfield 수렴 조건을 만족시켰으며, 변위가 클 경

우 Zhou와 Chellappa의 알고리즘으로는 수렴 속도가 느리며, 회로망이 반복되어도 수렴하지 못한 문제점을 보다 효율적이고 빠른 수렴 속도로 optical flow를 구하기 위해 계층적 구조를 이용하여 개선하였다.




그림 7. 시스템의 반복에 따른 뉴런 상태의 변화수
Fig. 7. Changed Number of Neural State about system's iteration.

Random dot 영상과 같이 인위적인 영상에서는 Zhou와 Chellappa 알고리즘과 본 논문에서 제안한 알고리즘이 유사한 결과를 보였지만, 자동차 영상과 같은 변위가 큰 실영상에서는 Zhou와 Chellappa 알고리즘과 본 논문에서 제안한 방법중 본 논문에서 제안한 방법이 빠른 수렴 속도로 좀 더 안정된 결과를 얻을 수 있었다.

참 고 문 헌

[1] G. Adiv, "Determining three-dimensional motion and structure from optical flow generated by several moving objects," *IEEE. Tran. on Pattern Anal. Machine Intell.*, vol.PAMI-7, no.4, pp.384-401, July, 1985.
 [2] J. K. Aggarwal, and N.Nandhakumar, "On the computation of motion from sequences of images - a review," *Pro. IEEE*, vol.76, No.8, Aug, 1983.
 [3] J. M. Prager, and M. A. Arbib, "Computing the optical flow: the matching algorithm and prediction," *Computer*

Vision, Graphics, and Image Processing, vol.24, pp. 271-304, 1983.
 [4] S. T. Barnard, and W. B. Thompon, "Disparity analysis of images," *IEEE Trans. on Pattern Anal. and Machine Intell.*, vol.2, no.4, pp.333-340, 1980.
 [5] J. K. Kearney, W. B. Thompos, and D. L. Boley, "Optical flow estimation : an error analysis of gradient-based method with local optimazation," *IEEE. Trans. Pattern Anal. Machine Intell.*, vol. PAMI-9, no.2, Mar.1987.
 [6] B. K. P. Horn, and B. Schunk, "Determing optical flow," *Artificial Intelligence*, vol.17, pp.185-203, 1981.
 [7] B. G. Schunk, "The image flow constraint equation," *Computer Vision, Graphics, and Image Processing*, vol.35, pp.20-46, 1986.
 [8] M. Yachida, "Determing velocity map by spation-temporal neighborhoods from image sequences," *Computer Vision, Graphics, and Image Processing*, vol.21, pp.262-279, 1983.
 [9] Y. T. Zhou, and R. Chellappa, "Compu-tion of Optical Flow Using A Neural Network," In. Proc. *IEEE. Intl. Conf.on Neural Network*, July, 1988.
 [10] J. J. Hopfield, "Neurons with graded response have collective computational properties link those of two-states neurons," *Neurocomputing*, MIT press, Cambridge, Machasetts, pp.576-583, 1988.
 [11] J. J. Hopfield, and D. W. Tank, "Neural computation of decisions in optimization problems," *Biol.Cybn.*, vol.52, pp. 141-152, 1985.
 [12] B. K. P. Horn, *Robot Vision*, MIT Press, Cambridge, Massachusetts, 1986.
 [13] H. S. Yang, and A. C. Kak, "Determination of the Identity Poision and Orientation of the Topmost Object in a Pile," *Computer Vision, Graphics, and Image Processing*, vol.36, pp.229-255, 1986.

- [14] 이 준재, 조 석재, 하 영호 "스트레오 정합을 위한 최적화 에너지 함수의 신경회로망 모델링," 대한 전자 공학회지, vol.28, no.1, pp.66-73, 1991
- [15] B. Julesz, "Binocular Depth Perception of Computer-Generated Patterns," *Bell System Technical J.*, vol.39, pp. 1125-1162, Sept.,1960

저 자 소 개



金 文 甲(正會員)

1964년 2월 14일생. 1990년 2월 경북대학교 전자공학과 학사. 1992년 2월 경북대학교 전자공학과 석사. 1992년 2월 ~ 현재 대우중공업 특수사업본부 전자기술실. 주관심분야는 영상처리,

Computer Vision등임.

秦 成 一(正會員) 第 31卷 B權 第 4號 參照.

현재 경북대학교 전자공학과 부교수