

論文94-31B-12-15

국소적인 연결을 갖는 신경회로망을 이용한 스테레오 정합

(Stereopsis with Cellular Neural Networks)

朴成晙*, 蔡洙翊*

(Sungjun Park and Soo-Ik Chae)

要約

본 논문에서는, 국소적인 연결을 갖는 이산시간 신경회로망(discrete-time cellular neural networks: DTCNN)을 이용한 새로운 스테레오 정합 방법을 제안한다. DTCNN에서 각 원소는 주변 이웃 원소들과의 국소적인 연결만을 가진다. 스테레오 정합을 위한 처리과정이 기하적으로 국소적인 특성에 의존하기 때문에, DTCNN은 스테레오 정합에 적합하고, 또한 집적회로로 구현하기에 적합하다. 그러므로 본 논문에서는 두개의 연결 패턴(template)을 갖는 복층 DTCNN을 스테레오 정합에 이용하여 연결 패턴은 오차 역전파 학습 방식(back propagation learning rule)으로 구하는 방법을 제안한다. 이 제안한 방법의 성능을 무작위 점으로 이루어진 여러가지 스테레오 영상(random dot stereogram)을 이용하여 평가한 결과, Marr-Poggio 방법의 것보다 우수함을 보였다.

Abstract

In this paper, we propose a new approach of solving the stereopsis problem with a discrete-time cellular neural network(DTCNN) where each node has connections only with its local neighbors. Because the matching process of stereo correspondence depends on its geometrically local characteristics, the DTCNN is suitable for the stereo correspondence. Moreover, it can be easily implemented in VLSI. Therefore, we employed a two-layer DTCNN with dual templates, which are determined with the back propagation learning rule. Based on evaluation of the proposed approach for several random-dot stereograms, its performance is better than that of the Marr-Poggio algorithm.

I. 서론

*正會員. 서울大學校半導體共同研究所 및 電子工學科
(Inter-University Semiconductor Research Center & Dept. of Elec. Eng., Seoul Nat'l Univ.)
接受日: 1994年 2月 1日

인간은 두 눈의 망막에 맺힌 두 영상간의 차이를 통해 물체의 원근을 판단한다. 이러한 스테레오 비전(stereo vision)은 로보틱스(robotics), 원격 감지(remote sensing), 의용 기기 등 여러 분야에 응용

되고 있다. 이에 대한 연구가 오랫동안 진행되어 왔음에도 불구하고, 이를 실제로 응용하기 위한 계산 모델(computational model)을 만드는 것은 아직도 어려운 문제로 남아 있다.

스테레오 영상을 통한 원근 인식을 위한 계산 과정은 좌우 영상을 서로 정합(correspondence)시키는 것과 정합된 영상으로부터 원근(disparity)을 추출하는 것으로 나눌 수 있다. 정합 과정은 원근 추출 과정에 비해 계산량이 크며, 2차원 영상으로부터 3차원 정합을 찾는 문제이므로 많은 해가 존재할 수 있다. 그러므로, 정합 문제를 해결하기 위한 계산 모델의 목표는 여러 개의 제한 조건을 만족하면서 가장 잘 정합된 해를 구하는 것이다.

이 정합 문제를 해결하기 위하여 여러 방법들이 제안되었으며^[10, 11], 이 방법들은 문제를 간단하게 하기 위해 여러 가정들을 사용한다. 대표적인 가정으로는 Marr와 Poggio가 제시한 방법에서 사용된 유일성(uniqueness)과 평활성(smoothness)이 있다. 유일성은 스테레오 영상의 정합시, 동시에 한쪽 영상의 한 부분이 다른 쪽 영상의 두 개 이상의 부분과 정합될 수 없다는 가정이고, 평활성은 인식 대상 물체의 3차원적 표면은 물체의 경계를 제외하고 다른 부분에서는 급격히 변하지 않는다는 가정이다.

이 스테레오 정합 문제는 국소적(local)이며, 비선형적인(nonlinear) 성질을 갖고 있으며, 제한 조건을 가장 잘 만족시키는 해를 찾는 최적화 문제로 간주될 수 있다. 신경회로망을 이용하면 반복 처리하여 주어진 에너지를 최소화하는 해를 구할 수 있으므로, 본 논문에서는 다층 DTCNN을 이용한 스테레오 정합 방법을 제안한다. 다층 DTCNN은 스테레오 정합 문제와 같이 국소적인 연결 특성을 지니고 있으며, 이 특성은 VLSI 구현에 적합한 구조를 갖게 한다. 그리고, 다층 DTCNN에 필요한 연결 패턴(template)을 구하기 위해 오차 역전파 학습 방식을 사용하였다. 본 논문의 II장에서는 지금까지 연구된 기존의 방법들에 대해 소개하고, III장에서는 정합 문제를 대응 문제로 변환하여 다루는 방법을 기술하며, IV장에서는 DTCNN을 이용하여 정합 문제를 해결하는 방법을 설명하고, V장에서는 오차 역전파 학습 방법(error back propagation learning rule)을 사용하여 연결 패턴을 결정하는 방법을 기술하고, VI장에서는 실험 결과를 제시한다.

II. 스테레오 정합을 위한 기존 방법들

최근에는 신경회로망이 영상 복원 등과 같은 최적화 문제에 효과적임이 발표되었고^[12], 스테레오 정합의 세

한 조건을 최소화 에너지 함수로 모델링하여 신경회로망을 이용하여 정합 문제를 풀려는 시도들이 있었다.^[4, 5] 스테레오 정합 문제를 해결하기 위해 Marr와 Poggio는 인간의 시각 특성을 바탕으로 유사성, 평활성 및 유일성의 정합의 세 가지 제한 조건을 제안하고 비용함수를 이용한 반복적인 협동 알고리듬(Iterative cooperative algorithm)을 제안하였다.^[11] 그러나 이 방법에서는 주변 원소와의 홍분성/억제성 연결 강도의 값이 모두 같아야 하는데, 이 연결 강도의 최적치를 결정하는데 어려움이 있다. Pineda는 이를 개선하기 위하여 주변 원소와의 연결 강도들이 각각 서로 다른 값을 가질 수 있도록 알고리듬을 변형시켰으나 이는 오히려 Marr-Poggio 방법에 비해 결정해야 할 연결 강도의 수가 많아져 최적의 값을 찾기가 더욱 어려워진다.^[3] Zhou는 Marr와 Poggio의 반복적인 협동 알고리듬을 Hopfield 신경회로망에 적용하였다.^[5] 유사성과 평활성의 제한 조건은 에너지함수로 대응하였으나 유일성의 제한 조건은 Max_Net 방법을 도입하였다. 그러나 Max_Net의 방법은 시스템의 초기 상태에 전적으로 의존하기 때문에 국소적 최소점에 빠질 우려가 있다. 또한 이 모델에는 평활성의 조건에서 자체 궤환이 존재하므로 Hopfield 모델이 가지고 있는 수렴 조건을 만족하지 못한다.

Nasrabadi는 Hopfield 신경망 모델을 이용하여 특징점을 기초로 하는 스테레오 정합 알고리듬을 제안하였다.^[2] 그러나 그의 알고리듬은 영상에서 특징점을 추출하기가 어렵고, 또한 특징점을 기반으로 하기 때문에 원근 정보가 부족하여, 연결 강도가 입력되는 영상에 따라 달라지므로 하드웨어로 구현할 때 연결 강도를 변경할 수 있게 만들어야 하는 어려움이 있다. 또한 특징점 정합시 대응하는 영상의 모든 특징점 후보들을 탐색해야 하므로 특징점의 수가 많아질 수록 필요한 뉴런의 수가 커진다. Sun 등은 정합 문제를 풀기 위하여 연상 기억(associative memory) 형태의 신경회로망을 사용하였다.^[4] Hebbian 학습 방식을 이용하여 같은 층(layer)에 있는 뉴런들은 서로 홍분 관계의 연결을, 다른 층에 있는 뉴런과는 억제 관계의 연결을 갖게 하였다. 그러나 이 방법은 많은 연결을 갖은 신경회로망이 필요하므로 구현에 어려움이 있다. Khotanzad는 연결 강도를 정하기 위해 오차 역전파 학습 방식을 사용하는 순방향(feed forward) 신경회로망을 도입하였다.^[6] 그러나 이 방법은 순방향 연산만 수행하므로 최적이 아닌 해가 얻어질 가능성이 있다.

본 논문에서는 국소적인 연결을 갖는 다층 이산시간 신경회로망(discrete-time cellular neural

network: DTCNN)을 사용하여 스테레오 정합을 하는 방식을 제안하였다. 다중 DTCNN은 Hopfield 신경회로망과는 달리 국소적인 연결만을 가지기 때문에 하드웨어 구현이 용이하며, 또한 주변의 정보를 가지고 정합을 판단하는 스테레오 정합에 적합한 구조를 갖고 있다. 또한 Marr-Poggio 알고리듬의 단점인 연결 강도의 세기를 결정하는 어려움은 오차 역전파 학습을 이용하여 연결 패턴을 구하는 방법으로 해결하였다.

III. 다대일 대응 문제로의 변환

스테레오 정합을 수행하기 위해 해야 할 첫째 과정은 정합 문제를 다대일 대응 문제로 변환하는 것이다. 이를 위해 먼저 좌우 영상의 극상선(epipolar row)로 부터 초기 정합 행렬(initial match matrix: IMM)을 구성한다. 그림 1에 6개의 화소로 이루어진 좌우 극상선으로부터 IMM을 구성하는 방법을 도시하였다. 좌우 영상의 화소 값들은 행렬의 밑과 왼쪽에 각각 위치되어 있고, 행렬의 (i, j) 번째 원소의 값은 왼쪽 i 번째 행 값과 밑의 j 번째 열 값을 Exclusive NOR해서 얻어진다. 이렇게 해서 구한 IMM은 올바른 정합이 포함된 모든 가능한 정합을 가지고 있다.

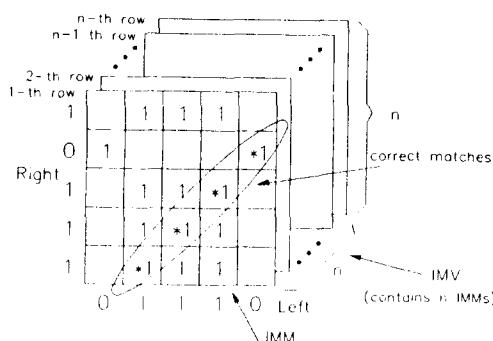


그림 1. IMM과 IMV의 구성 예

Fig. 1. Example of IMM and IMV.

스테레오 정합의 가장 중요한 과정은, 모든 가능한 정합을 포함하고 있는 IMM으로부터 올바른 정합만을 분리해내는 것이다. 이를 위해 유일성과 평활성의 제한 조건을 사용하였다. 유일성 조건은 IMM에서 각각의 행과 열을 따라 단 하나만의 원소만이 "1"의 값을 가지도록 제한한다. 평활성의 조건은 IMM에서 올바른 정합이 45° 방향으로 배치되도록

즉 주변의 원소들이 같은 원근(iso-disparity)를 갖도록 제한한다. 제한 조건들은 IMM 원소들 사이에 가중치 연결을 둘으로써 구현될 수 있다. 유일성 조건은 수직과 수평 방향의 원소들 사이는 억제성 연결로, 평활성 조건은 45° 방향의 원소들은 흥분성 연결로 구현된다. 연결들은 IMM의 모든 원소와 연결되지 않고 한 원소로부터 일정한 거리내에 있는 원소들 사이에만 존재하도록 한다. IMM에 대해 수 차례 반복하여 가중치가 곱해진 입력들의 합을 구하는 연산을 수행하면 대부분의 잘못된 정합은 제거되고 올바른 정합만이 남는다. 이 결과로 얻어진 행렬을 최종 정합 행렬(final match matrix: FMM)이라 부른다.

좌우 영상의 극상선사이의 행별 대응은 2차원 영상에서 수직 방향의 의존성을 고려하지 않았다. 행간의 관계(inter-row relation)을 고려하기 위해 알고리듬은 다음과 같이 확장된다. 먼저, 두개의 좌우 극상선으로부터 하나의 2차원 IMM을 구성하고, 이렇게 구성된 IMM들을 그림 1에서와 같이 차례대로 쌓아서 3차원의 초기 정합 입체(initial match volume: IMV)를 구성한다. 구성된 입체 내부의 한 원소로부터 일정한 거리안에 있는 주변 원소들의 집합은 앞에서와는 달리 2차원에서 3차원으로 확장된다. 본 논문에서는, 자신을 제외하고 24개의 이웃 원소를 포함하는 그림 2와 같은 이웃 구조를 이용한다. 이 이웃 구조에서 흥분성 관계를 가지는 주변 원소들은 원반 형태를 이루고 있고 억제성 관계를 가지는 원소들은 수평 방향의 축을 따라 분포하고 있음을 알 수 있다. 이와 같이 스테레오 정합 문제는 3차원의 IMV로부터 3차원의 최종 정합 입체(final match volume: FMV)를 구하는 대응문제로 변환된다.

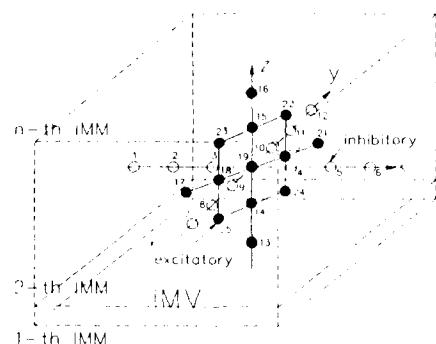


그림 2. IMV내의 한 원소에 대한 주변 원소 구조
Fig. 2. A neighborhood structure in IMV.

IV. 다층 DTCNN을 이용한 스테레오 정합

단층(single layer) DTCNN은 영상처리에 효과적인 것으로 알려져 있으나, 복잡한 영상 처리를 위해 서는 좀더 일반적인 개념이 필요하며, 이에 대한 해결방법으로 여러 층의 DTCNN을 사용하는 구조가 발표되었다.^[7]

$$x_i^c(k) = \sum_{d \in N_r(c)} A_i^d y_i^d + I_i(k) \quad (1)$$

$$y_i^c(k+1) = f(x_i^c(k)) = \begin{cases} 1 & \text{if } x_i^c(k) \geq 0 \\ -1 & \text{if } x_i^c(k) < 0 \end{cases} \quad (2)$$

식 (1), (2)에서 $y_i^c(k)$ 는 위치 c 에 있는 원소의 시간 k 에서의 상태를 나타내며, 1은 층의 위치를 가리킨다. $N_r(c)$ 는 원소 c 를 중심으로 하는 이웃 구조를 포함하는 원소 집합을 나타내며, d 는 이웃 원소의 상대적 3차원적 위치를 나타내므로, 연결 패턴 $\{A_i^d, d \in N_r(c)\}$ 은 A_i 로 표기한다. 연결 패턴을 사용한 연산은 한 원소 c 로부터 거리 r 내에 있는 주변 원소들에 대해서만 상응하는 가중치를 곱해서 더하는 것이다. 다층 DTCNN을 구현할 때, 한 층에 대한 회로만으로 순차적으로 연결 패턴만 바꾸면 되므로 각 층에 대하여 별도의 회로가 필요하지 않다.

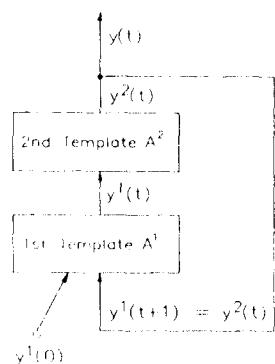


그림 3. 복층 DTCNN의 구조

Fig. 3. Architecture of the two-layer DTCNN.

본 논문에서는 스테레오 정합 문제를 해결하기 위해 그림 3와 같이 순환적인 두개의 연결 패턴을 갖는 복층(2-layer) DTCNN을 사용하였다. 복층 DTCNN을 이용하는 방법은 그림 2에서 나타난 3차원 주변구조(neighborhood structure)를 이용하여 두개의 연결 패턴을 순차적으로 사용한다. 첫번째연

결 패턴으로 연산된 출력 $y_1(t)$ 는 두번째 연결 패턴을 사용하여 연산하기 위한 입력으로 사용되며, 이와 같은 두번째 출력 $y_2(t)$ 도 다시 첫번째 연결 패턴을 이용한 연산시, 입력으로 사용함으로써 반복 연산이 가능하다.

V. 오차 역전파 학습 방식을 이용한 연결 패턴의 결정

제안한 복층 DTCNN 구조에서는 IMV내의 한 원소의 정합 여부를 결정하기 위해, 거리 r 내에 있는 $(n-1)$ 개의 주변 원소들 뿐만 아니라 주변 원소들의 주변 원소들도 정합 결정 과정에 참여하게 된다. 즉, 첫번째 연결 패턴을 사용한 계산 과정에서는 정합 결정 대상의 원소 와 $(n-1)$ 개의 주변 원소들이 각각 자신의 주변 원소로부터 영향을 받아 자신의 상태를 결정하고, 두번째 연결 패턴을 사용한 계산 과정에서는 정합 결정 대상의 원소가 한 번 계산 과정을 마친 $(n-1)$ 개의 주변 원소들로부터 영향을 받아 정합을 결정한다. 이러한 일련의 과정들이 반복적으로 수행되어 IMV내의 가능한 정합 중에서 제한 조건을 만족하지 않는 것들 중 대부분은 제거되고 올바른 정합들이 남는다.

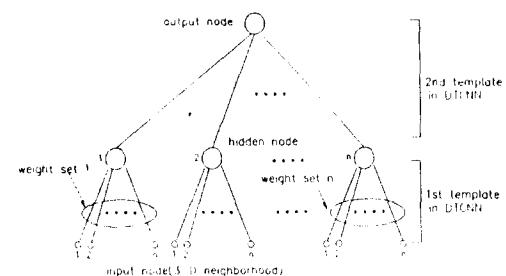


그림 4. 국소적으로 연결된 신경회로망 구조

Fig. 4. Architecture of the locally connected network.

이러한 복층 CNN의 연결 패턴을 구하기 위해서, 그림 4에서와 같은 국소적으로 연결된 신경회로망 (locally connected neural network: LCNN)을 사용하였다. LCNN은 입력층, 은닉층, 출력층으로 구성되어 있으며, 입력층은 n 개의 원소 집단 H_i 으로 묶여진 n^2 개의 입력으로 구성되며 은닉층은 입력층의 n 원소 집단으로부터 입력을 받는 n 개의 원소로 구성되어 있고, 하나의 원소로 출력층이 구성된다. n 개의 원소 집단으로 구성된 입력층은 한 원소 집단내에

서 각 입력들은 특정한 은닉층 원소와만 연결되며, 다른 원소 집단의 입력과 연결된 은닉층 원소와는 연결되지 않는다. 또한 각 입력 원소 집단내에서 위치에 연결 강도는 모든 원소 집단내에서 동일하다. 이는 DTCNN 연결 패턴의 공간 불변성(space invariance)을 만족시키기 위한 제한 조건이다. 본 논문에서는 그림 2의 이웃 구조를 사용하므로 $n=25$ 이다.

LCNN과 복층 DTCNN과의 대응 관계는 다음과 같다. i번째 입력 원소 집단은 정합 결정 대상 원소의 i번째 주변 원소 및 이를 중심으로 한 주변 원소들의 집합이며, 입력층에서 은닉층으로 계산 결과가 전달되는 것은 복층 DTCNN에서 첫번째 연결 패턴으로 계산하는 과정에 해당된다. 이와 마찬가지로 은닉층에서 출력층으로 계산 결과가 전달되는 것은 복층 DTCNN에서 두번째 연결 패턴으로 계산하는 과정에 해당된다.

복층 DTCNN과 이러한 대응 관계를 가지는 LCNN을 학습시켜 얻어진 최종 연결 강도는 복층 DTCNN의 연결 패턴으로 사용되는 데, 오차 역전파 학습 방법을 사용하여 LCNN을 학습시키기 위해서는 다음과 같은 제한 조건이 필요하다. DTCNN 연결 패턴의 공간 불변성을 만족시키기 위해, 식 (3)와 같이 모든 입력 원소 집단내에서는 위치에 따라 연결 강도가 같아야 하므로, 식 (3)를 만족시키기 위해 학습시 오차를 전파시킬 때에는 식 (5)과 같이 각 원소 집단내에서 위치가 같은 입력 원소별로 생신시킬 값 $\delta\omega_i^{t+1}(H_j)$ 을 모두 모아서 평균하여 각 입력 원소와 은닉층과의 연결 강도를 생신 $\Delta\omega_i^{t+1}$ 시킴으로써 각 원소 집단내에서 위치에 따른 연결 강도가 모두 동일하게 유지시킨다.

$$\omega_i(H_1) = \omega_i(H_2) = \omega_i(H_3) = \dots = \omega_i(H_n) \quad (3)$$

$$\omega_i^{t+1} = \omega_i^{t+1} + \Delta\omega_i^{t+1} \quad (4)$$

$$\Delta\omega_i^{t+1} = \frac{1}{n} \sum_{j=1}^n \delta\omega_i^{t+1}(H_j) \quad (5)$$

VI. 실험 결과 및 고찰

제안한 복층 DTCNN 방식의 성능을 평가하기 위해 컴퓨터로 생성한 무작위 점으로 구성된 스테레오 영상(random dot stereogram: RDS)를 사용하였다. RDS는 무작위로 생성된 점들로 채워진, 비슷한 구조를 가지는 한쌍의 영상으로 구성되며, 한 영상의

어떤 부분이 다른 영상과 비교하여 상대적으로 좌 또는 우로 이동되어져 있다. 사람이 스테레오스코프(stereoscope)를 통하여 RDS를 관찰하면 이동된 부분이 위나 아래로 떠있는 것처럼, 즉 거리가 다르게 보이게 된다. RDS 영상의 한 예가 그림 5 (a), (b)에 나타나 있으며 (c)는 이를 3차원적으로 복원한 형태이다. 그림 5에서 보인 RDS는 3층의 피라미드 형태의 구조를 가지고 있으며 각각의 사각형 모양의 층이 배경에 비해 떠있는 것처럼 인지된다. 이러한 예로 부터, 스테레오 정합 방법에 의한 거리 인식은 물체의 모양이나 친숙도에 의존하지 않는다는 것을 알 수 있다.

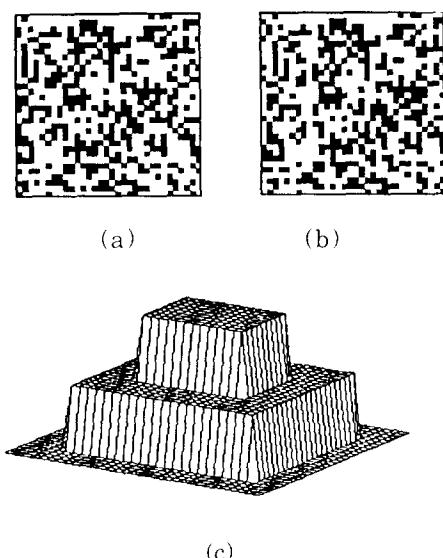


그림 5. RDS 영상의 예 (a) 좌 영상 (b) 우 영상 (c) 3차원 형태

Fig. 5. A RDS image example. (a) Left image. (b) Right image. (c) 3-dimensional form.

여러 가지 원근을 가지는 32×32 크기의 RDS로부터 실제적인 원근 사상도를 구한 실험을 통해 제안한 방법의 효용성을 실험하였다. 이러한 RDS로부터 오차 역전파 학습 방식을 이용하여 복층 DTCNN의 연결 패턴을 구했다. 이를 위해 50%의 밀도를 갖는 (검은 점과 흰 점의 포함도가 같음) RDS를 사용했다. 사용된 RDS에는 3개의 다른 원근이 존재한다. 이로 부터 3차원 IMV를 구성하여 이를 학습의 입력으로 사용하였고, 이에 대응되는 FMV를 목표값으로 사용하여 연결 패턴을 구했다. RDS의 크기가 $32 \times$

32이므로 구성되는 IMV와 대응되는 FMV사이에 가능한 입출력쌍은 32²개가 존재한다. 이 많은 입출력쌍들 중에서, 25개 원소를 갖고 있는 이웃 구조에 대한 입출력 패턴쌍을 200개 선택하여 학습에 이용하였으며, 사용된 학습률 η 는 0.2, 모멘텀(momentum) α 는 0.8이다. 학습 결과로 얻어진 연결 패턴 A_1 , A_2 는 표 1과 같다. 표 1에서 연결 패턴의 위치는 그림 2의 이웃 구조에서 표기한 번호를 이용하였다.

표 1. 학습 결과로 얻어진 연결 패턴
Table 1. Learned Weights.

연결 패턴 위치	첫번째 층 연결 패턴	첫번째 층 연결 패턴
1	0.00	-1.31
2	0.13	-2.17
3	-0.42	-2.70
4	-0.15	-4.58
5	0.16	-1.57
6	0.24	-2.45
7	0.01	-2.21
8	-0.06	-2.46
9	0.07	-4.08
10	-0.53	-3.52
11	-0.04	-1.92
12	-0.10	-1.47
13	0.08	0.01
14	0.14	0.57
15	0.22	1.34
16	0.36	1.32
17	-0.05	0.67
18	0.03	2.12
19	0.40	2.19
20	0.67	2.39
21	0.44	2.11
22	0.85	-5.37
23	-0.29	0.69
24	-0.24	1.10
25	-0.29	1.02

학습으로부터 얻어진 두개의 연결 패턴을 복층 DTCNN에 사용하여, 여러가지 RDS에 대해 제안한 방식의 성능을 평가하였다. 얻어진 결과는 얻어진 원근 사상도의 형태로 나타냈다. 제안한 방법의 성능을 평가하기 위해 오른쪽 영상에 각각 3%, 6%, 9%, 12%의 잡음을 첨가한 RDS들과 10%에서 40%의 낮은 밀도를 갖는 RDS들을 사용하였다. 또한 학습으로 결정한 연결 패턴의 일반화 정도를 평가하기 위하여 학습에 사용되지 않은 구조를 포함하고 있는 RDS도 사용하였으며, 그 결과를 그림 6, 7, 8에 나타냈다.

각 경우마다 성능 비교를 위해 Marr-Poggio 방법에서 얻어진 결과도 같이 제시하였다.

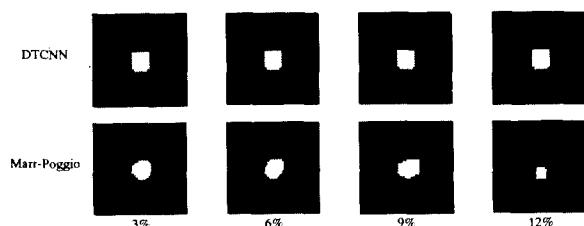


그림 6. 오른쪽 영상에만 각각 3%, 6%, 9%, 12%의 잡음을 첨가한 RDS에 대한 결과

Fig. 6. Results for the RDS's with 3%, 6%, 9%, and 12% noises.

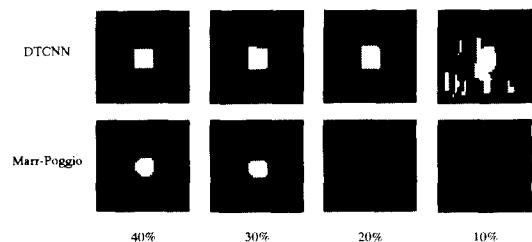


그림 7. 낮은 밀도를 갖는 RDS에 대한 결과 (40%, 30%, 20%, 10%)

Fig. 7. Results for the RDS's with different densities. (40%, 30%, 20%, and 10%)

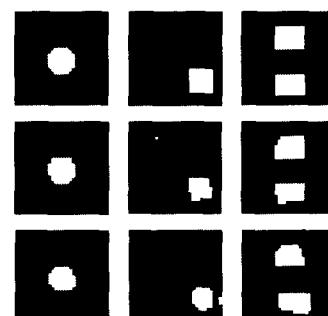


그림 8. 학습에 사용된 RDS와는 다른 구조를 포함하고 있는 RDS에 대한 결과

Fig. 8. Results for several RDS's with different structure.

실험 결과에 의하면, 제안한 방법이 Marr-Poggio 방법에 비해 올바로 정합된 화소의 수에서 우수함을 알 수 있다. 이 결과는 복층 DTCNN이 두개의 연결 패턴을 사용하여 계산하므로, Marr-Poggio의 경우

보다 정합을 위해 더 많은 주변 화소들이 참조되기 때문이라고 판단된다. 또한 Marr-Poggio 알고리듬에서는 연결 강도를 결정하기 위해 유일성 및 평활성 제한 조건을 명시적으로 고려해야 했으나, 제안하는 방법에서는 이 제한 조건들이 학습 과정에서 연결 패턴에 반영되었다고 볼 수 있다.

VII. 결 론

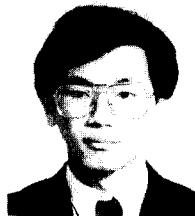
본 논문에서는 국소적인 연결과 두개의 연결 패턴을 갖는 이산시간 신경회로망(DTCNN)을 이용하는 스테레오 정합 방법을 제안했다. DTCNN은 정합 문제와 같이 국소적 연결 특성을 가지고 있으며 이는 신경회로망의 VLSI 구현에도 적합한 것이다. Marr-Poggio 방식의 단점인 최적의 연결 강도를 찾는 어려움을 오차 역전파 학습 방식을 이용하여 복층 DTCNN에 필요한 연결 패턴들을 구함으로 해결하였다. 제안한 방법의 성능을 평가하기 위해 잡음이 첨가된 정도와 밀도가 다른 RDS들, 그리고 학습에 사용되지 않은 패턴을 포함하는 RDS에 대해 실험을 수행한 결과, Marr-Poggio 방법보다 성능이 우수함을 보였다. 그러나 제안한 방법은 반복 연산을 사용하므로, DTCNN의 수렴특성에 대한 자세한 연구가 필요하다고 본다.

参考文献

- [1] D. Marr and T. Poggio, "Cooperative computation of stereo disparity," *Science*, vol. 194, pp. 283-287, Oct. 1976.
- [2] N. M. Nasrabadi and C. Y. Choo, "Hopfield network for stereo vision correspondence," *IEEE Trans. Neural Networks*, vol. 3, pp. 5-13, Jan. 1992.
- [3] F. J. Pineda, "Generalization of back-propagation to recurrent neural networks," *Phys. Rev. Lett.*, vol. 59, pp. 2229-2232, Nov. 1987.
- [4] G. Z. Sun, H. H. Chen, and Y. C. Lee, "Learning stereopsis with neural networks," in *Proc. IEEE First Int. Conf. on Neural Networks*, San Diego, CA, pp. 345-355, Jun. 1987.
- [5] Y. T. Zhou and R. Chellappa, "Stereo matching using a neural network," in *Proc. IEEE Int. Conf. Acoustics, Speech, and Signal Processing*, pp. 940-943, Apr. 1988.
- [6] A. Khotanzad, A. Bokil, and Y. W. Lee, "Stereopsis by constraint learning feed-forward neural networks," *IEEE Trans. Neural Networks*, vol. 4, pp. 332-342, Mar. 1993.
- [7] H. Harrier, "Multi-layer discrete-time cellular neural networks using time-variant templates," *IEEE Trans. Circuits Syst.*, vol. 40, pp. 191-199, Mar. 1993.
- [8] L. O. Chua and L. Yang, "Cellular neural networks: Theory," *IEEE Trans. Circuits Syst.*, vol. 35, pp. 1257-1272, Oct. 1988.
- [9] J. Hopfield and D. Tank, "Neural computation of decision in optimization problems," *Biol. Cybn.*, vol. 52, pp. 141-152, 1985.
- [10] U. R. Dhond and J. K. Aggarwal, "Structure form stereo - A review," *IEEE Trans. Syst., Man, Cybern.*, vol. 19, Nov./Dec. 1989.
- [11] M. Drumheller and T. Poggio, "On parallel stereo," in *Proc. IEEE Int. Conf. on Robotics and Automation*, vol. 3, pp. 1439-1448, 1986.

* 이 논문은 교육부 박도체분야 학술연구 조성비에 의해 연구되었음

著者紹介



朴成晙(正會員)

1966年 12月 28日生. 1989年 서울대학교 전자공학과(공학사).
1991年 서울대학교 대학원 전자공학과(공학석사). 1991年 3月 ~
현재 서울대학교 대학원 전자공학과 박사과정 재학중. 주관심 분야
는 신경회로망 및 집적회로 설계 등임.

蔡洙翊(正會員) 第31卷 B編 第5號 參照

서울대학교 전자공학과 및 반도체
공동연구소 교수