

대규모 광학적 구현을 위한 TAG 신경회로망 모델

TAG neural network model for large-sized optical implementation

이 혁재, 이 수영

한국과학기술원 전기 및 전자공학과

In this paper, a new adaptive learning algorithm, Training by Adaptive Gain (TAG) for optical implementation of large-sized neural networks has been developed and its electro-optical implementation for 2-dimensional input and output neurons has been demonstrated. The 4-dimensional global fixed interconnections and 2-dimensional adaptive gain-controls are implemented by multi-facet computer generated holograms and LCTV spatial light modulators, respectively. When the input signal pass through optical system to the output classifying layer, the TAG adaptive learning algorithm is implemented by a personal computer. The system classifies three 5x5 input patterns correctly.

1. 서론

신경회로망은 기존의 von Neumann형 컴퓨터가 잘 해결하지 못했던 복잡한 분류 문제나 적응 제어 문제에 탁월한 성능을 가진 것으로 널리 알려져 있다. 이러한 장점을 잘 살리기 위해서는 대규모 특수 하드웨어의 구현이 요구되기 때문에 현재 대부분의 인공 신경회로망은 von Neumann형 컴퓨터상에서 소프트웨어만으로 구현되고 있는 실정이다. 따라서, 많은 연구자들은 인공 신경회로망에 적합한 구현방법 및 구현소자를 찾고 있다.

최근에 VLSI 기술을 이용하여 제작된 neural chip 이 시판되고 있으나, 많은 수의 뉴론을 갖는 인공 신경회로망에는 궁극적으로 적합하지 못할 것이다. 광기술을 이용한 신경회로망의 구현은 광의 여러가지 성질에 기인된 많은 이점을 제공하지만, 역시 문제점을 내포하고 있다. 특히, 가변요소를 만들기 위해 사용하는 고성능의 공간광변조기(SLM)는 상당한 고가격에 시판되고 있으므로 대규모의 구현을 시행할때 가변요소의 양은 결정적 제한요인이 된다. 따라서, 본 논문에서 구현성과 현재의 기술수준을 잘 타협시킨 모델을 제안하며, 그 모델의 명칭을 Training by Adaptive Gain(TAG)이라 지칭하기로 한다.

광신경회로망의 구현방법은 크게 두가지로 나누어 지는데, vector-matrix 곱셈기와 holographic correlators로 이루어진다. Vector-matrix 곱셈기를 이용한 최초의 신경회로망 구현은 1985년 Farhat 등에 의해 구현된 1 차원 입출력을 가진 Hopfield 모델^[1]이다. 그후, 많은 연구의 초점은 2 차원 입출력을 가진 신경회로망의 광학적 구현에 모아 지게 되었으며 multi-facet hologram^[2], volume hologram^[3], 혹은 lenslet array 와 공간 광변조기^[4] 등을 이용하여 2 차원 구현이 이루어 질 수 있음을 보였다. 따라서, 본 논문에서도 TAG 모델의 광학적 구현을 위해 Lohmann-type binary CGH(Computer Generated Hologram)^[5]를 이용하여 global fixed interconnection을 구성 하였고, 상용 LCTV 을 사용한 local gain 만으로 적응 학습이 가능함을 보임으로써 대규모 2 차원 신경회로망의 구현 기반을 확립하였다.

2. TAG 모델의 소개

신경회로망 구현이 대규모이어야 하고 global interconnection 을 모두 adaptive element 로 구현해야 한다면 현재의 기술 수준으로는 거의 불가능할 것이다.

그리하여, 구현성을 좋게 하기 위해서는 가급적이면 adaptive element 의 수를 적게 해야 할 것이다. 만일 입력 뉴런의 수가 M^2 이고 출력 뉴런의 수가 N^2 이라면, Perceptron 은 adaptive element 의 수가 $M^2 \times N^2$ 인 반면, TAG 은 $M^2 + N^2$ 이 되므로 TAG 모델의 adaptive element 수가 대폭 줄어 든다. 그러나, Performance 와 Capacity 에 있어서는 다소 떨어지게 되는 단점을 갖고 있다^[6].




그림 2-1 Single layer TAG 모델의 구조

간단한 single layer TAG 모델의 구조를 그림 2-1 에 나타내었다. 그림에 보인 바와 같이 가운데의 global interconnection 은 fixed element 를 사용하여 구현성을 용이 하도록 하고, 앞단과 뒷단에 adaptive element 을 첨가하여 적응학습 되도록 하였다. 각 출력 y_{ij} 는 다음과 같이 Sigmoid function 을 적용한 형태로 나타낼 수 있다.

$$y_{ij} = S\left(\sum_k \sum_l v_{ij} T_{ijkl} w_{kl} x_{kl}\right) \quad (2-1)$$

여기서, x_{kl} 는 kl 번째 입력 뉴런의 activation 이고, $v_{ij} T_{ijkl} w_{kl}$ 는 kl 번째 입력 뉴런과 ij 번째 출력 뉴런 사이의 interconnection 이 된다. 그리고, $S(\cdot)$ 는 Sigmoid function 을 의미한다. 여기서, fixed interconnection T_{ijkl} 의 값은 미리 결정되는데 random 하게 설정할 수도 있고, standard 입력과 출력 패턴에 대해

어느 임의의 학습 알고리즘 으로 부터 얻어 질 수도 있다. BAM 모델의 경우, 저장되는 패턴의 수가 매우 많으면, random interconnection 으로 볼 수 있으므로 T_{ijkl} 가 random 일때는 supervised learning 중 fixed learning 되었다고 생각할 수 있다.

TAG 모델을 적응학습시키기 위하여 출력단에서의 error 는 Perceptron 경우와 마찬가지로 sum-squared error 를 다음과 같이 정의하고,

$$E = \frac{1}{2} \sum_i \sum_j (y_{ij}^s - t_{ij}^s)^2 \quad (2-2)$$

steepest descent method 에 의해 E 를 최소화시키기 위해 adaptive element v_{ij} 와 w_{kl} 에 대한 E 의 편미분을 계산하는 것이 필요하다. 따라서, 각각에 대해 chain rule 을 적용하면 다음과 같이 얻어진다.

$$\frac{\partial E}{\partial v_{ij}} = \sum_k \delta_{ij}^s \hat{y}_{ij}^s / v_{ij} \quad (2-3)$$

$$\frac{\partial E}{\partial w_{kl}} = \sum_i \gamma_{kl}^s x_{kl}^s / w_{kl} \quad (2-4)$$

식 (2-3), (2-4) 은 Perceptron 과 마찬가지로 그림 2-1 에서 알수 있듯이 학습시키고자 하는 interconnection 의 입력 activation 과 출력 error 와의 상관치만큼의 값을 갖는다. 식 (2-3) 의 \hat{y}_{ij}^s 는 식 (2-1) 에서 입력 x_{kl}^s 에 대한 Sigmoid function 의 argument 을 의미하고, δ_{ij}^s 와 γ_{kl}^s 는 각각 출력과 입력에서의 error 를 나타내며 다음과 같다.

$$\delta_{ij}^s = (y_{ij}^s - t_{ij}^s) S'(\hat{y}_{ij}^s) \quad (2-5)$$

$$\gamma_{kl}^s = \sum_i \delta_{ij}^s v_{ij} T_{ijkl} w_{kl} \quad (2-6)$$

식 (2-6) 는 error γ_{kl}^s 가 출력 error δ_{ij}^s 의 Back-propagation 에 의해 계산되어짐을 보여준다. 따라서, multi-layer Perceptron 과 같이 error back-propagation 을 이용하여 TAG 모델을 multi-layer 로

쉽게 확장시킬 수 있다. 한가지 주목할 사항은 TAG 모델의 gradient 제산은 어느 경우에도 vector-matrix 곱셈을 포함하지 않으며, 단지 point-to-point scalar 곱셈만으로 충분히 해결되므로 학습시간이 절약된다.

3. Lohmann type binary CGH

인공 신경회로망을 구현한다는 견지에서, 결국에 봉착하는 문제는 대규모 밀집된 interconnection 을 어떻게 효율적으로 실현할 것인가 이며, 그 실현 방법 중 현재 가장 많은 parallel interconnection 을 제공하는 방법은 thick holographic associative networks 와 multi-facet hologram 을 이용하는 것이다. 본 논문에서 TAG 모델을 구현하기 위해 multi-facet hologram 을 사용하는데, optical table 에서 직접 만들 수도 있지만, 제작의 편의성을 위해 CGH 를 사용했다.

CGH 는 회절 물체가 주어지고 회절되는 field 를 구하는 보통의 회절 문제와는 달리 언어야할 영상은 미리 기술되어져 있고 회절 물체를 즉, 홀로그램을 언어내야 한다는 점에서 inverse problem 과 연관된다. CGH 를 encoding 하는 방식에 따라 크게 나누어 보면, Cell-oriented hologram 과 Point-oriented hologram 으로 나누어 질 수 있다. Cell-oriented hologram 은 resolution cell 이라 불리는 작은 사각형으로 CGH 표면을 나누고, 그 cell 의 transmittance 을 hologram 형태에 따라 binary, real nonnegative, real bipolar, complex 로 구성한다. 반면, Point-oriented hologram 은 hologram 상의 continuous object wave 에 point nonlinearity 을 가한 결과로 생각할 수 있다. 그 continuous wave front function 은 closed form 으로 알려져 있거나, 혹은 interpolation 에 의해 DFT 로 부터 얻어질 수 있다. 그리고, 본 논문의 실험을 위해서 Binary cell-oriented hologram 중 Lohmann type 을 이용했다.

Lohmann type CGH 를 만드는 전체적인 절차는




그림 3-1 CGH 를 만드는 전체적 절차

그림 3-1 에 나타내었다. 우선, object 선택은 64×64 pixel 을 갖도록 했고, 다음 순서로 Fourier Transform 은 FFT 알고리즘을 사용했으며, SUN 3/110 workstation 을 이용하여 monitor 에 Lohmann type binary cell-oriented hologram 을 encoding 한 다음, 그 그림을 laser printer 을 통해 OHP 용지에 그렸다. 그 OHP 용지를 광학적으로 80:1 로 축소하여 HRP 에




그림 3-2 (a) resolution cell
(b) Lohmann type CGH 패턴

기록하였다. 그림 3-2(a) 는 Lohmann type 인 경우 하나의 resolution cell 을 보여 주고 있다. 그림에서 알 수 있듯이 resolution cell 에서 변화 시켜 줄 수 있는 변수는 네가지인데, 그 중 두가지 변수는 diffraction efficiency 를 최대로 하도록 하고 영상을 x 축에 맺도록 하기 위해 $Q_{jk}=0$, $W_{jk}=1/2$ 로 고정시키고 (다른 변수를 고정시킬 수도 있다), 알고자 하는 영상을 FFT 한 결과의 정규화된 진폭과 위상을 resolution cell 의 aperture 높이와 측면 변위에 관계시키면 된다. 그림 3-2(b) 는 64×64 의 resolution cell 로 이루어진 하나의 CGH 로서 coding 된 결과를 보여준다. 위와 같이 하여 얻어진 영상은 sample point 에서만 정확한 값을 갖고 그 사이에서는 zero 의 값을 가지므로 해서 생기는 speckle 현상을 보여준다. 이러한 speckle 을 가급적 제거하기 위하여 FFT




그림 3-3 (a) 재생된 "1" image
(b) "1" 와 "7" 의 summation

하기전에 object 가 random phase 를 갖도록 하여 diffuser 의 효과를 얻도록 하면된다.

그림 3-3(a) 은 "1" 모양의 패턴을 CGH 로 기록한 다음 reconstruction 되는 image을 보여준다. 그림 3-3(b) 은 "1" 와 "7" 패턴의 summation 을 잘 수행하고 있음을 보여준다.

4. 전기광학적 구현을 위한 TAG 모델의 수정

TAG 모델을 실제 광학으로 구현 할때는 nonnegative 값으로 수행해야 되기 때문에 모델을 수정해야 한다. 따라서, 다음과 같이 두가지 경우로 수정될 수 있음을 알 수 있다.

1. Unipolar 일 경우

TAG 모델에서 Sigmoid 함수의 argument \hat{y}_{ij} 는

$$\hat{y}_{ij} = \sum_{k,l} v_{ij} T_{ijkl} w_{kl} x_{kl} = v_{ij} \hat{y}_{ij}^* \quad (4-1)$$

그러나, CCD 카메라로 detect 되는 실제값은 다음과 같다.

$$\hat{y}_{ij}^{*(det)} = \sum_{k,l} (T_{ijkl} + T_0)(w_{kl} + w_0)x_{kl} \quad (4-2)$$

여기서, x_{kl} 는 "1", "0" 의 값을 갖고, T_0 와 w_0 는 각각 CGH, LCTV 의 offset 양을 나타낸다. 그러면 식 (4-2) 의 $\hat{y}_{ij}^{*(det)}$ 는 다음과 같이 된다.

$$\hat{y}_{ij}^{*(det)} = \hat{y}_{ij}^* + \hat{y}_{ij}^{*C} + \hat{y}_{ij}^{*C'} \quad (4-3)$$

여기서,

$$\begin{aligned} \hat{y}_{ij}^* &= \sum_{k,l} T_{ijkl} w_{kl} x_{kl} \\ \hat{y}_{ij}^{*C} &= \sum_{k,l} T_{ijkl} x_{kl} \\ \hat{y}_{ij}^{*C'} &= \sum_{k,l} T_0 (w_{kl} + w_0) x_{kl} \end{aligned}$$

식 (4-3) 에서 두번째와 세번째항은 correction 항을 나타내는데, 세번째항은 interconnection 의 새기가 T_0 로 만으로된 출력 뉴론 (extra bit) 하나를 별도로 뚫음으로서 해결된다. 그러나, 두번째 항은 spatial multiplexing, 즉 CGH 로 만든 interconnection T 를 공간상에 동일하게 두개 만들거나, time multiplexing 을 하여야 할 것이다. 일단은, 식 (4-3) 의 두번째 항을 구하기 위해서는 부가적인 절차가 필요한데, 다음과 같이 구해진다.

$$\begin{aligned} \hat{y}_{ij}^{*(subdet)} &= \sum_{k,l} (T_{ijkl} + T_0) w_0 x_{kl} \\ &= \sum_{k,l} T_{ijkl} w_0 x_{kl} + \sum_{k,l} T_0 w_0 x_{kl} \\ &= \hat{y}_{ij}^{*C} + \hat{y}_{ij}^{*C'} \quad (4-4) \end{aligned}$$

따라서, 얻고자 하는 \hat{y}_{ij}^* 는

$$\begin{aligned} \hat{y}_{ij}^* &= \hat{y}_{ij}^{*(det)} - \hat{y}_{ij}^{*C} - \hat{y}_{ij}^{*C'} \\ &= (\hat{y}_{ij}^{*(det)} - \hat{y}_{ij}^{*(subdet)}) - (\hat{y}_{ij}^{*C'} - \hat{y}_{ij}^{*C}) \quad (4-5) \end{aligned}$$

와 같이 된다.

2. Bipolar 일 경우

$w_{kl} x_{kl}$ 의 값을 positive 값과 negative 값으로 나누어 생각할 수 있는데, 본 논문에서는 w_{kl} 와 x_{kl} 의 곱셈을 컴퓨터에서 수행했다. 그러나, 실제 구현시 w_{kl} 는 positive 의 값만 될수 있다. 그러므로, 전체 시스템을 광학적으로 모두 구성한다면 w_{kl} 를 positive 로 설정하고 입력 x_{kl} 의 값에 따라서만 positive part 와 negative part 로 나누어 생각할 수 있다.

$$\begin{aligned} \hat{y}_{ij}^{*P(det)} &= \sum_k \sum_l (T_{ijkl} + T_0) w_{kl}^P x_{kl}^P \\ &= \sum_k \sum_l T_{ijkl} w_{kl}^P x_{kl}^P + \sum_k \sum_l T_0 w_{kl}^P x_{kl}^P \\ &= \hat{y}_{ij}^{*P} + \hat{y}_{ij}^{*PC} \end{aligned} \quad (4-6)$$

$$\begin{aligned} \hat{y}_{ij}^{*N(det)} &= \sum_k \sum_l (T_{ijkl} + T_0) w_{kl}^N x_{kl}^N \\ &= \sum_k \sum_l T_{ijkl} w_{kl}^N x_{kl}^N + \sum_k \sum_l T_0 w_{kl}^N x_{kl}^N \\ &= \hat{y}_{ij}^{*N} + \hat{y}_{ij}^{*NC} \end{aligned} \quad (4-7)$$

$$\begin{aligned} \hat{y}_{ij}^* &= \hat{y}_{ij}^{*P} - \hat{y}_{ij}^{*N} \\ &= (\hat{y}_{ij}^{*P(det)} - \hat{y}_{ij}^{*N(det)}) - (\hat{y}_{ij}^{*PC} - \hat{y}_{ij}^{*NC}) \end{aligned} \quad (4-8)$$

Unipolar 에서와 같이 extra bit 를 출력단에 두어 T_0 에 의한 correction 항을 구해 내도록 하였다. Bipolar 인 경우도 spatial multiplexing, time multiplexing 양쪽이 가능한데, 본 논문에서는 time multiplexing 방법을 사용했다.

5. 실험결과

그림 5-1 은 TAG 모델의 전기광학적 구현을 설명하는 전체적 구조를 보여준다. 구현구조는 personal computer (P.C.) 에 의해 조절되는 두개의 path 로 이루어 지는데, 아래 path 는 적응학습시에 error back-propagation 을 위한 것이고, 위의 path 는 recall 을 위한 것이다. Forward path 의 local gain w_{kl} 과 backward path 의 local gain v_{ij} 는 각각 입력 x_{kl} 과 출력 error δ_{ij} 와 결합되어 있다. 이것은 gray level 을 갖는 2-D SLM (상용 LCTV) 으로 구성하였다. 그리고, Forward path 의 출력 local gain v_{ij} 와 backward path 의 w_{kl} 은 P.C. 에 의해 구성된다. Fixed global interconnection 은 multi-facet hologram





그림 5-1 TAG 모델의 광학적 구현도

(Lohmann-type binary CGH) 으로 구성하였는데, 여기서 한가지 주목할 사항은 양 path 에 똑같은 multi-facet hologram 을 이용하기 위하여 다른 N^4 interconnection 구조를 갖고있다. Error gradient 계산은 단지 scalar multiplication 만 요구되므로, P.C. 에 의해 쉽게 계산할 수 있다. 그림 5-1 은 forward path 와 backward path 모두를 고려한 것이다. 그러나, 본 논문에서는 구현의 용이성을 위하여 backward path 는 P.C. 에서 처리하도록 하였고, 실제 학습이 끝난 상태에서는 그림 5-1 의 forward path 만 필요하기 때문에 recall stage 만을 광학적으로 생각해보기로

CASE 1



CASE 2




그림 5-2 실험을 위해 사용된 5x5 입력 패턴

했다. 그림 5-2 는 실험에 사용된 5x5 입력 패턴을 보여준다. 입력이 unipolar 인 경우에 CASE 1 의 패턴을 학습시킨 결과를 그림 5-3 에 나타내었으며,




그림 5-3 입력이 unipolar 일때 실험결과 (CASE 1)

η_1, η_2 는 앞단과 뒷단의 학습률을 나타낸다. 간단한 패턴임에도 불구하고 상당히 많은 fluctuation 과 학습횟수를 보여주고 있다. 입력이 bipolar 인 경우에는 CASE 2 의 패턴을 학습시켰는데, 그것의




그림 5-4 입력이 bipolar 일때 실험결과 (CASE 2)

결과를 그림 5-4 에 나타내었다. 그림 5-4(a) 는 식 (2-2) 에서 정의한 error 를 학습횟수에 따라 그렸고, 그림 5-4 (b),(c),(d) 는 각 출력 뉴런에서 새가지 패턴의 출력값을 보여준다.

6. 결론

TAG 모델을 광학적으로 구현하기 위하여 입력이 unipolar 인 경우와 bipolar 인 경우로 나누어 학습을 시켰는데, unipolar 인 경우에는 LCTV 의 작은 on/off ratio 로 인하여 '0' 의 값이 실제적으로는 어떤 상수값을 갖기 때문에 생기는 error 를 보상해 주지 못해서 잘 학습이 되지 않았다. 그러나, bipolar 인 경우에는 양수부분과 음수부분을 나누어 처리 함으로써 얻는 성능향상과 각각 나눈 부분에서 '0' 값에 대한 error 는 P.C. 에서의 뻤셈으로 인해 어느정도 상쇄되므로 학습이 잘 됨을 알 수 있었다. 따라서, 본 논문에서는 TAG 의 학습 알고리즘을 통하여 대규모 광학적 구현의 용이성을 증명했으며, 5x5 의 이진 입력 3 개를 서로 다르게 인식하는 실험을 통해 TAG 모델의 구현 가능성을 보였다. 결국, TAG 은 적은 수의 adaptive element 을 가지고 적응학습이 가능하며, 쉽게 구현될 수 있기 때문에 실제적으로 넓은 응용 범위를 갖는다.

References

- [1] N.H. Farhat, D. Psaltis, A. Prata, and E.G. Paek, "Optical Implementation of the Hopfield Model," Appl. Opt., Vol.24, pp.1469, 1985.
- [2] J.S. Jang, S.W. Jung, S.Y. Lee, and S.Y. Shin, "Optical Implementation of the Hopfield Model for Two-Dimensional Associative Memory," Opt. Lett., Vol.13, pp.248, 1988a.
- [3] D. Brady, X.-G. Gu, and D. Psaltis, "Photorefractive crystals in optical neural computers," Pro. SPIE 882 Neural Network Models for Optical Computing, pp.132, 1988.
- [4] J.S. Jang, S.Y. Shin, and S.Y. Lee, "Programmable quadratic associative memory using holographic lenslet arrays," Opt. Lett. Vol.14, pp.838, 1989.
- [5] A.W. Lohmann and D.P. Paris, "Binary Fraunhofer holograms generated by computer," Appl. Opt., Vol.6, pp.1737, 1967.
- [6] H.J. Lee, B.Y. Koh, and S.Y. Lee, "Re-training neural networks with local gain controls only for slightly modified input patterns," Proc. of ICFNN, Iizuka, Japan, pp.973, 1990.