

## Backpropagation Network의 Autoassociation

### Memory기법을 통한 패턴 인식에 응용

진성일\* · 김인철\* · 배건성\*

(1990. 7. 2. 접수)

## Pattern Recognition Application Using Autoassociative Backpropagation Network

Sung-II Chien, In-Cheol Kim, and Geun-Sung Bae

(Received July 3, 1990)

**Abstract** In this paper, autoassociative multi-layer perceptron model is used for image recollection and recognition. The feedback structure returning autoassociative image output and recognition result improves noise reduction effect based on multi-layer perceptron model. Additionally, modified backpropagation learning algorithm with momentum parameter variations is introduced to improve the network learning time.

### I. 서 론

최근에 와서 다층(multi-layer) 신경 회로망은 여러가지 특성 즉, 대규모 병렬 처리가 가능하고, 잡음에 강하고, 또한 기억 용량이 선형 연상 메모리<sup>1)</sup>나 비선형 연상 메모리<sup>2,3)</sup>등의 다른 신경 회로망보다 큼으로 인해 그 사용 분야가 매우 다양해지고 있다. 특히 음성인식과 영상인식에서 유용하게 이용되고 있으며 앞으로 인공지능에 대한 전반적인 연구에서 큰 역할을 할것으로 기대된다.

다층 신경 회로망의 학습 이론은 최근에 여러가지가 제시되고 있으나 “Generalized Delta Rule”<sup>4,5)</sup>를 이용한 backpropagation(BP) 학습 이론이 일반적으로 널리 이용되고 있다. 다층 신경 회로망을 이용한 최근까지의 영상 인식 연구에서는 영상의 왜곡 불변 특성(feature)을 입력으로 하여 단순히 이동, 크기 변화, 회전에

불변한 영상 분류(image classification) 출력을 얻는데 주안점이 주어졌다<sup>6)</sup>.

본 논문에서는 이러한 기존의 영상 분류에만 한정된 영상 인식 문제에서 한층 더 발전하여 영상 분류와 영상 복원을 겸한 신경 회로망을 설계하였으며 또한 autoassociative memory 기법<sup>7)</sup>을 이용하여 입력과 똑같은 출력을 얻는 신경 회로망을 구현함으로써 영상 복원 및 영상 분류의 신뢰도를 향상시키기 위해 피드백 개념을 도입할 수 있도록 하였다. 즉, 여러 비율로 노이즈가 섞이거나 일부분이 삭제된 문자 영상이 입력되어도 원래의 저장된 영상으로 복원 및 분류가 이루어지도록하고 아울러 출력된 영상이 불완전한 경우 입력단으로 피드백하여 완전한 영상으로의 복원 및 영상 분류가 이루어지도록 하였다.

또한 BP 학습 이론의 최대 단점인 느린 학습 시간을 개선하기 위해 수정된 BP 학습 이론을 도입하여 다층 신경 회로망의 원래의 학습 시

\* 慶北大學校 工科大學 電子工學科

간보다 반이상 절감된 속도로 학습되도록 하였다.

## II. 다층 신경 회로망의 학습 이론

본 실험에서는 다층 신경 회로망의 학습 이론으로서, 학습 시간 개선을 위해 Fahlman<sup>8)</sup>이 제안한 수정된 BP 학습 이론을 사용하였으며, 또한 학습 도중 Momentum값을 적절히 조정함으로써 학습 시간을 최대한 줄일 수 있었다. 사용된 학습 이론을 요약하면 다음과 같다.

- (1) 먼저 아래층의  $i$ 번째 뉴런과 윗층의  $j$ 번째 뉴런 사이의 시냅스 강도(weight)값인  $w_{ij}$ 와 각 뉴런의 threshold  $\theta_j$ 를 random하게 초기화한다.
- (2) 출력층에서 각각의 뉴런에 대한 실제 출력 값을 계산한다.

$$O_j = 1 / (1 + \text{EXP} - (\sum w_{ij} o_i + \theta_j)) \quad (1)$$

- (3) 출력 에러 정정 과정에서 출력층과 은닉층 각 뉴런에서의 에러값  $\delta_j$ 를 다음과 같이 계산한다<sup>8)</sup>.

$$\delta_j = \tanh^{-1}(t_j - o_j) (o_j(1-o_j) + 0.1) \quad (\text{출력층}) \quad (2)$$

$$\delta_j = o_j(1-o_j) \sum_k \delta_k w_{kj} \quad (\text{은닉층}) \quad (3)$$

- (4) 각 시냅스 값을 조정한다.

$$\Delta W_{ji}(t) = \epsilon \delta_j o_i + a \Delta W_{ji}(t-1) \quad (4)$$

여기서  $\epsilon$ 는 학습율을 나타내며  $a$ 는 momentum항을 나타낸다. 즉, 수정된 BP 학습 이론은 출력층 뉴런에서의 에러 계산시 식(2)와 같이 원래의 BP 학습 이론의 에러 계산식에 상수항을 더함으로써 원하는 출력과 실제 출력 사이의 차가 1인 경우 에러값이 0이 되는 것을 방지하고, 또한 Hyperbolic Arctangent 함수를 도입하여 그 차를 에러 계산시 더 잘 반영함으로써 학습 시간을 크게 개선시켰으며, 또한 본 논문에서는

Momentum값을 학습 도중 적절히 조정함으로써 학습 시간을 더욱 줄일 수 있었다.

## III. 실험

### 1. 다층 신경 회로망의 학습

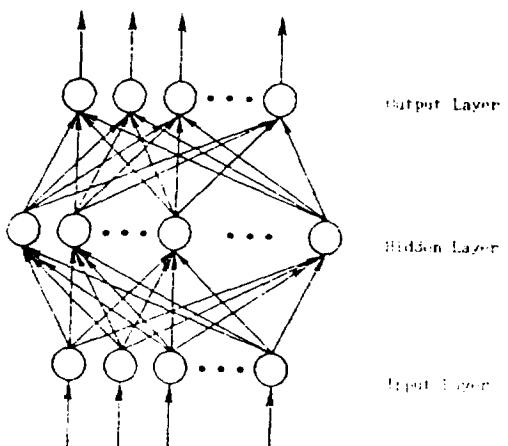


그림 1. 2-층 Perceptron 신경 회로망 구조.

Fig. 1. 2-layer Perceptron neural network structure.

본 실험에서는 그림 1과 같은 입력층, 은닉(hidden)층, 그리고 출력층으로 이루어진 2층 Perceptron 신경 회로망을 이용하였으며, 입력 층은 크게 169개의 영상 뉴런과 26개의 분류 뉴런으로 나누어진다. 학습시 영상 뉴런항에는 그림 2에 표시된 A에서 Z까지의 26개 문자 영상을 형성하는  $13 \times 13 (= 169)$ 개 각각의 pixel값이 입력된다. 그림 2에 나타난 표준 입력 문자는 이진 영상으로써 각 pixel값은 0 또는 1의 값을 가진다. 또한 분류 뉴런항에는 각 문자 분류를 위한 차원이 26인 벡터값이 입력된다. 각각의 벡터는 A에서 Z에 이르는 각 문자에 대해 1개의 "1" bit와 25개의 "0" bit로 이루어져 있다. 예를 들어 "A" 문자는 첫번째 bit가 1이고 나머지 bit는 0이 된다. 즉, bit의 위치가 각각의 문자를 나타내도록 코딩하였다.

또한 은닉층은 35개의 뉴런으로 이루어져 있으며, 출력층은 입력층과 똑같은 169개의 영상 복원 뉴런과 패턴 분류를 위한 26개의 분류 뉴런으로 이루어져 있다. 출력층의 분류 뉴런함은 문자 영상의 분류와 더불어 복원된 출력 영상의 신뢰도를 측정하는 기준이 된다. 즉, 주어진 입력에 대해 다중 Perceptron 신경 회로망의 출력층 분류 뉴런함에서 최대값( $M_v$ )을 갖는 뉴런을 찾아 그 위치에 따라 문자 분류를 한다. 또한 일반적으로 실험용 영상에 노이즈가 없거나 미미한 경우 복원된 영상에 에러가 없을뿐만 아니라 분류 뉴런함에서의  $M_v$ 값은 "1"에 아주 가까운 값을 가지며 반면에 노이즈가 심한 경우는 복원된 영상에 에러가 생기고 또한  $M_v$ 값이

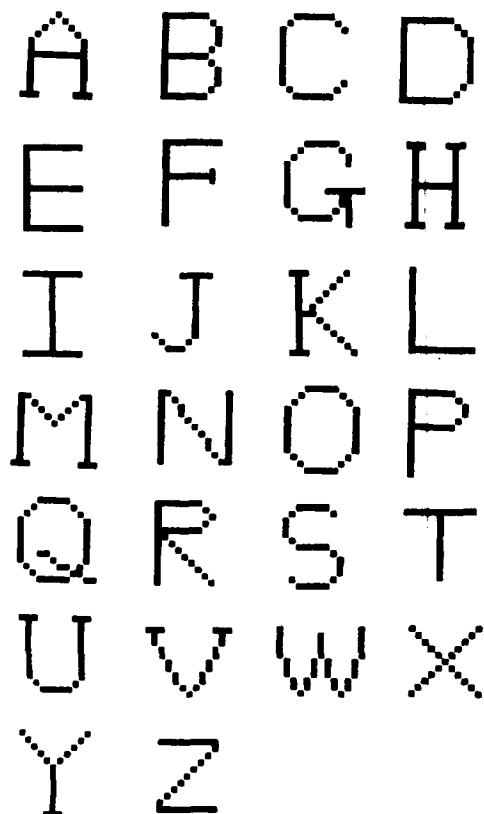


그림 2. 저장된 표준 문자 영상  
Fig. 2. Stored image set.

상대적으로 작아지므로  $M_v$ 값을 이용하여 출력된 영상의 신뢰도를 측정할 수 있다.

Backpropagation 학습시 우리는 두 학습 파라메타  $\epsilon$ (learning rate)와  $\alpha$ (momentum)함을 trial-and-error 방법으로 각각 0.01과 0.9로 초기화 하였으며<sup>5,9)</sup>, 학습 시간 개선을 위해 momentum값을 학습 동안 1.0까지 증가시켰다.

그리고 전술한 다중 신경 회로망 학습 이론을 이용하여 각각의 패턴에 대해 195개로 이루어진 각 출력 뉴런에서 얻어진 에러를 제곱하여 더한값인 패턴에러(Pss)를 구한뒤 패턴 에러의 총합인 전체에러(Tss)가 1.0이하가 될때까지 학습시켰으며(본 실험 결과 Tss=0.987) 학습 시간은 floating-point accelerator board를 장치한 32-bit 80386 machine을 사용하여 MS-DOS상에서 약 2시간이 소요되었다.

## 2. 영상 복원 과정 및 실험 결과

본 논문에서 제안한 다중 Perceptron 신경 회로망을 이용한 영상 복원 및 분류법은 그림 3과 같은 과정으로 이루어진다. 즉, 일차적으로 테스트시에는 영상 정보만이 존재하고 분류 정보는 알 수 있으나 autoassociation 학습 효과에 의해 영상 부분 정보가 그림 3에 입력되면 영상 정보뿐만 아니라 분류 정보도 연상적으로 획득된다. 이 분류 정보도 피드백 시에는 입력으로 주어진다. 전술한 내용에 따라 입력층에 각 문자 분류를 위한 백터값을 0으로 초기화하고 다양한 비율의 무작위 노이즈를 첨가한 문자 영상이나 일부분이 삭제된 문자 영상만을 입력하여 출력에서의 영상 복원 및 분류를 조사한다. 여기서 무작위 노이즈 비율은 다음과 같이 정의한다.

$$\% \text{ PIXEL NOISE} = \frac{\text{error pixel}}{\text{total image pixel}} \times 100 \quad (5)$$

예를 들어 전체 pixel 갯수중 노이즈로 인하여 10%가 변화를 일으키면 10%의 노이즈가 첨가되었다고 정의한다. 그림 4에서는 각각 2개로

이루어진 영상을 보이고 있는데 상단의 영상은 노이즈가 첨가된 입력을 나타내고 하단의 영상은 복원된 출력을 나타낸다. 노이즈가 15% 첨가할 때까지는 복원이 완벽하게 이루어지나(그림 4 (a) 및 (b)) 노이즈가 그 이상 첨가되면 영상 복원이 완벽하지 않음을 알 수 있다(그림 4 (c) 및 (d)).

피드백이 없을 시 거의 모든 영상들은 노이즈가 10% 첨가되거나 영상의 1/5이 삭제되더라도 거의 완벽하게 본래의 영상으로 복원된다. 그러나 더 이상의 노이즈가 첨가되거나 문자 영상이 삭제되면 영상 복원이 완벽하지 않고 경우에 따라서는 문자 판별에도 오류가 발생하게 된다. 이러한 경우 피드백 즉, 출력된 영상 및 분류 벡터값을 0.5를 기준으로 threshold하여 이진화 한 뒤 입력 단으로 되돌리는 방식을 이용하여 에러를 줄임으로써 좀 더 많은 노이즈가 첨가되더라도 원래의 영상으로 복원되도록 하며 또한 문자 판별의 오류도 감소하도록 하였다(그림 5(b)). 그러나 과도한 노이즈가 첨가될 경우 피드백을 수행하여도 random한 문자나 다른 문자로 복원되며 문자 판별 오류도 감소되지 않는다(그림 5(c)).

입력 영상 문자에 노이즈가 10%, 15%, 20% 첨가된 경우 피드백을 적용하지 않았을 때와 3 번의 피드백을 수행하였을 때 복원 영상과 원래 저장된 문자 영상 사이의 서로 일치하지 않는 pixel수를 평균한 평균 에러 pixel수(Np)와 전체 문자 분류율(Pc)를 표 1에 수록하였다. 표 1의 (a)에서 보듯이 노이즈가 10% 가 첨가 될 때부터 영상 복원에 에러가 발생하고 영상 분류에도 에러가 발생함을 알 수 있다. 또한 노이즈가 심 할수록 영상 복원 및 분류율이 나빠짐을 알 수 있다. 그러나 표 1의 (b)에서 보듯이 전술한 피드백을 수행하면 영상 복원 및 분류율이 크게 개선됨을 알 수 있으며, 특히 노이즈가 10% 인 경우 완벽한 영상 복원 및 분류가 이루어진다. 전술한 이제까지의 실험 결과 중 영상 복원

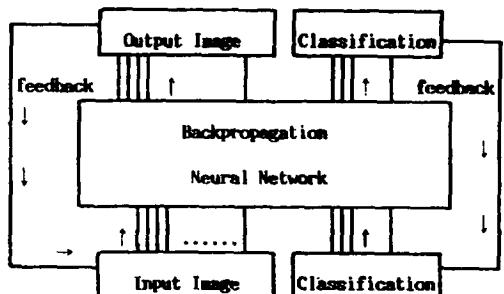


그림 3. feedback을 이용한 영상 복원 및 분류.  
Fig. 3. Image recovery and classification with feedback.

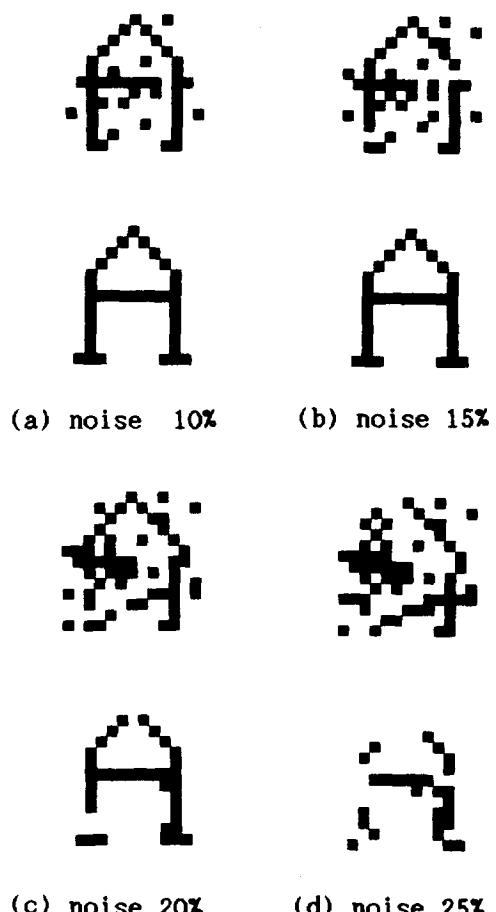


그림 4. noise 입력 영상 및 복원 영상(No feedback)  
Fig. 4. Noisy inputs and recovered images.

결과를 그림으로 나타내면 그림 5과 같다. (a)의 경우 노이즈가 15% 첨가된 경우 피드백을 적

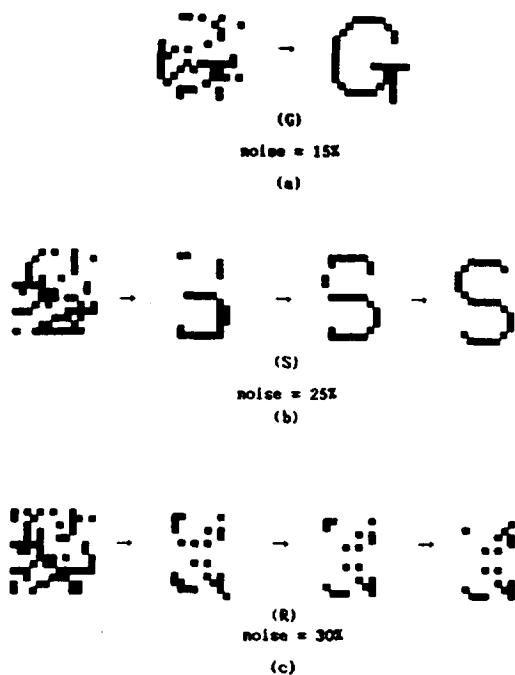


그림 5. 노이즈 영상의 영상 복원.

Fig. 5. Noise removal effect on the noisy images.

NOISE	10%	15%	20%
$N_p$	0.154	2.038	5.462
$P_c(\%)$	96.15%	96.15%	88.46%

(a)

NOISE	10%	15%	20%
$N_p$	0	0.269	1.846
$P_c(\%)$	100%	96.15%	96.15%

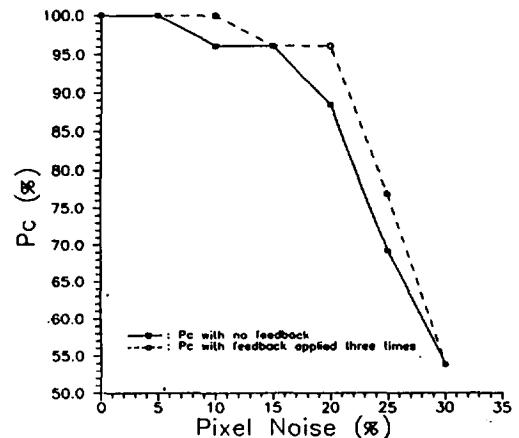
(b)

표 1. 출력에서의 영상 복원 및 분류율.

- (a) feedback이 없을 때
- (b) 3번의 feedback이 있을 때

Table 1. Image recoveries and classifications.

- (a) with no feedback
- (b) with feedback applied three times.

그림 6. Pixel Noise에 따른 Classification rate ( $P_c\%$ )Fig. 6. Classification rate( $P_c$ ) vs. Pixel noise.

용하지 않아도 원래의 영상으로 복원됨을 나타내며 (b)와 같이 25%의 노이즈가 첨가된 경우 반복된 피드백 수행으로 원래의 영상으로 복원됨을 알 수 있다. 그러나 (c)와 같이 과도한 노이즈가 첨가될 경우 피드백을 반복적으로 수행하여도 원래의 영상으로의 복원이 실패함을 알 수 있다.

또한 대표적인 Pixel Noise 변화에 따른 분류율 변화를 그림 6에 수록하였다. 그림 6은 어느 정도 노이즈가 첨가되더라도 영상 분류에는 오류가 발생하지 않고 좀 더 많은 노이즈가 첨가되어 문자 판별의 오류가 생겨 문자 분류율(Classification Rate =  $P_c$ )이 감소되는 경우에도 피드백을 이용하여 문자 분류율( $P_c$ )을 증가 시킬 수 있음을 보여준다.

#### IV. 결 론

본 논문에서는 autoassociative 다층 Perceptron 모델을 이용하여 영상 복원 및 분류를 겸하는 신경 회로망을 설계하였다. 또한 수정된 BP 학습 이론을 도입하여 기존 학습 이론의 느린

학습 시간을 개선시킬 수 있었다. 신경 회로망 학습을 위한 입력으로는 26개의 영문자 영상 및 분류 벡터값을 사용하였으며 학습 후 여러 비율로 노이즈를 추가한 영상이나 일부분이 삭제된 영상만을 입력시켜 영상 복원 및 분류에 대한 결과를 제시하였다.

본 실험 결과로 부터 상당한 노이즈가 추가되어도 영상 복원 및 분류가 완벽하게 이루어지고 또한 피드백에 의해서 노이즈 제거 효과가 증가됨을 알 수 있다.

## V. 참 고 문 헌

1. F. Fogelman Soulie, P. Gallinari, and S. Thiria, "Learning and Associative Memory," NATO ASI Series, vol. F30, *Pattern Recognition Theory and Applications* (Edited by P. A. Devijver and J. Kittler), pp. 249-276, 1987.
2. J. J. Hopfield, "Neural network and physical systems with emergent collective computational abilities," *Proc. Nat. Acad. Sci. USA*, vol. 79, pp. 2554-2558, 1982.
3. B. Kosko, "Bidirectional Associative Memories," *IEEE Trans. Sys. Man. Cybern.*, vol. 18, pp. 49-58, 1988.
4. D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Internal Representation by Error Propagation," *Parallel Distributed Processing : Exploration in Microstructures of Cognition*, vol. 1, D. E. Rumelhart, and J. L. McClelland(Eds.), Cambridge, MA : MIT Press, pp. 318-362, 1987.
5. J. C. Pemberton, J. J. Vidal, "When Is the Generalized Delta Rule a Learning Rule," *IEEE International Conference on Neural Network Sandiego, California*, vol. 1, pp. 309-315, 1988.
6. A. Khotanzad, J. H. Lu, "Distortion Invariant Character Recognition by a Multilayer Perceptron and Back Propagation Learning," *IEEE International Conference on Neural Network Sandiego, California*, vol. 1, pp. 625-632, 1988.
7. T. Kohonen, *Self-Organization and Associative Memory*, Springer Verlag, 1984.
8. S. E. Fahlman, "Faster-Learning Variations on Backpropagation : An Empirical Study," *Proc. Connectionist Models Summer School Carnegie Mellon University*, pp. 38-51, 1988.
9. S. Y. Kung, J. N. Hwang, "An Algebraic Projection Analysis for Optimal Hidden Units Size and Learning Rates in Back Propagation Learning," *IEEE International Conference on Neural Network Sandiego, California*, vol. 1, pp. 363-370, 1988.