

## 은닉노드의 특징값을 기반으로 한 최적신경망 구조의 BPN 성능분석

강경아\*, 이기준\*, 정채영\*\*

### Performance Analysis of Optimal Neural Network structural BPN based on character value of Hidden node

Kyung-A Kang\*, Kee-Jun Lee\*, Chai-Young Jung\*\*

#### 요 약

은닉노드는 주어진 문제에서 입력패턴(input pattern)들의 특징을 구분해주는 중요한 역할을 한다. 이 때문에 최적의 은닉노드 수로 구성된 신경망 구조가 성능에 가장 큰 영향을 주는 요인으로 중요성이 대두되고 있다. 그러나 역전파(back-propagation) 학습 알고리즘을 기반으로 하여 은닉노드 수를 결정하는데는 문제점이 있다. 은닉노드 수가 너무 적게 지정되면 주어진 입력패턴을 충분히 구분할 수 없게 되어 완전한 학습이 이루어지지 않는 반면, 너무 많이 지정하면 불필요한 연산의 실행과 기억장소의 낭비로 과적응(overfitting)이 일어나 일반성이 떨어져 인식률이 낮아지기 때문이다. 따라서 본 논문에서는 백 프로퍼게이션 알고리즘을 이용하여 학습을 수행하는 다층 신경망의 학습오차 감소와 수렴률을 개선을 위하여 신경망을 구성하는 매개변수를 가지고 은닉노드의 특징값을 구하고, 그 값은 은닉노드를 제거(pruning)하기 위한 평가치로 사용된다. 구해진 특징값 중 최대값과 최소값을 갖는 노드를 감소(pruning)대상에서 제외하고 나머지 은닉노드 특징값의 평균과 각 은닉노드의 특징값을 비교하여 평균보다 작은 특징값을 갖는 은닉노드를 pruning시키므로서 다층 신경망의 최적 구조를 결정하여 신경망의 학습 속도를 개선하고자 한다.

#### Abstract

The hidden node plays a role of the functional units that classifies the features of input pattern in the given question. Therefore, a neural network that consists of the number of a suitable optimum hidden node has been on the rise as a factor that has an important effect upon a result. However, there is a problem that decides the number of hidden nodes based on back-propagation learning algorithm. If the number of hidden nodes is designated very small, perfect learning is not done because the input pattern given cannot be classified enough. On the other hand, if designated a lot, overfitting occurs due to the unnecessary execution of operation and extravagance of memory point. So, the recognition rate is been low and the generality is fallen. Therefore, this paper suggests a method that decides the number of neural network node with feature information consisted of the parameter of learning algorithm. It excludes a node in the pruning target, that has a maximum value among the feature value obtained and compares the average of the rest of hidden node feature value with the feature value of each hidden node, and then would like to improve the learning speed of neural network deciding the optimum structure of the multi-layer neural network as pruning the hidden node that has the feature value smaller than the average.

\* 조선대학교 대학원 전산통계학과

\*\* 조선대학교 자연과학대학 전산통계학과

## I. 서론

BPN은 패턴인식, 시스템제어, 최적화 문제등의 응용분야에 이용되고 있는 신경망 학습 알고리즘이다.[1,2] 그러나 다층 퍼셉트론을 학습시키는데 기준의 역전파 학습 알고리즘을 그대로 사용하기 때문에 발생되는 문제점들 즉, 지역적인 해(local minima)에 의해 전역적인 해(global minima)가 수렴되지 않는다는 점과 초기 역전파 학습 파라미터의 값 설정에 대한 문제점을 여전히 가지고 있어 좋은 성능을 얻지 못하였다.[3,4] BPN의 학습에 있어서 가장 중요한 목표는 학습을 완료한 이후에 학습 과정에 참여하지 않은 임의의 예제에 대해서도 가능한 한 정확한 분류 판단을 내릴 수 있는 최대한의 일반성을 획득하는 학습결과를 갖도록 하는 것이다. 그런데 BPN의 온닉노드수가 필요 이상으로 많은 경우 학습하는 과정에서 학습에 참여한 예제에 대한 분류능력은 상승하는 반면, 학습에 참여하지 않은 임의의 예제에 대한 분류능력이 오히려 저하되어 일반화 능력이 떨어지는 과적용의 결과를 초래한다.[5] 그 이유로는 주어진 입력패턴에 대한 학습에서 특별한 예제나 잡음예제까지도 초과하여 학습하게 됨에 따라 일반성이 저하되는 원인이 되기 때문이다. 따라서 신경망을 이용한 문제해결에서는 주어진 문제영역에 적합한 최적의 온닉노드 수로 구성된 신경망 구조를 설계하는 것이 신경망 성능에 가장 큰 영향을 미치는 중요 요인으로 인식되었다.

기존의 신경망 구조 설계문제는 정형화된 원칙이 존재하지 않아 신경망 개발 전문가의 주관적인 경험적 지식 및 시행착오에 의존하여 왔지만 이를 해결하기 위한 많은 연구가 최근 활발하게 이루어지고 있다. 온닉노드 수를 줄여 pruning방법으로 신경망 구조를 결정하는 프루닝 기법은 어떤 문제에 관해 적당한 크기의 신경망을 발견하는 것에 목적을 두고 발전되었다. pruning에 대한 연구는 신경망 구성요소 중 가장 작은 가중치를 갖는 연결선을 제거하는 방법[6]으로 시작하였지만, 최근에는 신경망의 크기나 학습시간의 단축등 실행을 최적화 하기 위한 방법으로 연구가 발전되었다.

대표적인 연구로 Hirose는 온닉노드의 추가와 삭제를 혼합한 연구를 수행하였다.[7] 학습 중 100회마다 오차를 검사하여 전 단계의 오차보다 1%이상 감소하였을 경우 학습을 진행하고 그렇지 않은 경우 지역적 최소치에 빠진 것으로 간주하여 이를 탈피하기 위한 한 개의 온닉노드를 온닉층에 추가시킨 후 이 노드와 연결된 가중치를 초기화 한 뒤에 다시 학습을 수행하였다. 동작이 수렴할 때까지 반복한 뒤 다시 추가된 온닉노드를 하나씩 제거하고 위 과정을 수렴이 되지 않을 때까지 반복하여 최종 온닉노드 수를 결정하였다. 또한, 집단수준 진화능력의 유전자 알고리즘과 개체수준의 탐색인 신경망 학습 능력을 병합한 방법이 제안되었다[8,9]. 이 방법은 다층 신경망의 전체 자승 에러가 임계치 이하로 감소하면 신경망 학습이 전역적 최적해에 근접하게 수렴한 것으로 가정하여 에러가 임계치에 도달하는 전역적 최적해 근처까지는 유전자 알고리즘을 사용하여 수렴하고, 그 결과인 가장 높은 적합도의 해를 역전파 알고리즘 파라미터의 초기값으로 한 학습으로 전역적 최적해에 수렴하도록 하였다. 그러나 이 방법은 온닉노드 수와 학습률, 모멘텀, 연결강도의 탐색에서 학습상태를 반영하지 않은 유전자 알고리즘 연산으로 인해 탐색성능이 효율적이지 못하였다.

본 논문에서는 신경망을 구성하는 각 매개변수를 이용하여 온닉노드를 제거하기 위한 평가치로 사용하였다. 이 때 최대값을 갖는 노드를 제거대상에서 제외하고 나머지 온닉노드 특징값의 평균과 각 온닉노드의 특징값을 비교하여 평균보다 작은 특징값을 갖는 온닉노드를 제거시키므로써 다층 신경망의 최적 구조를 결정하여 신경망의 학습 속도를 개선하였다. 제안한 신경망 구조의 효율성을 확인하기 위하여 XOR, 전가산기, 4-bit parity 문제에 적용시켜 보았으며 성능평가를 위하여 전체 인식률 및 학습의 수렴속도를 전통적인 BPN과 비교하였다.

## II. BPN의 특성 및 온닉노드의 기능

BPN은 지도 학습규칙으로서 주어진 입력에 대해 원하는 출력과 실제 계산된 출력사이의 오차값에 따라 정의되는 오차함수를 최소화하기 위하여 기울기강하법을 사용한다.[10]

$$E = \frac{1}{P \cdot N_m} \sum_{s=1}^P \sum_{i=1}^{N_m} [d_{s,i} - y_{s,i}^M]^2 \quad (1)$$

이 때문에 학습 수렴 속도가 느리다는 것과, 지역적 최소치(local minima)에 빠질 염려가 있다는 단점이 있다. BPN은 오류표면의 기울기와 학습률, 모멘트에 의하여 오류를 감소시키는 방향으로 연결강도를 수정하면서 오류가 0에 근접할 때까지 학습을 반복한다. 즉, 오류표면의 기울기와 매개변수의 크기에 따라 연결강도 변화량이 정해지는데, 오류표면이 평지인 곳에서는 기울기가 작기 때문에 연결강도의 변화량 또한 작게 되어 전역적 최적해에 수렴하기 위해 많은 반복학습이 필요하게 된다. 따라서 학습률, 모멘트와 같은 매개변수에 의해 신경망 학습속도의 성능이 좌우되므로 최적의 매개변수 설정이 필요하다.

### 2.1 은닉노드 수가 신경망 학습에 미치는 영향

다중 신경망 구조 결정은 은닉층 수와 은닉노드 수를 결정하는 것이다. 은닉노드는 학습이 진행됨에 따라 입력 패턴의 특징을 구분해주는 역할을 하므로 신경망 설계시 가장 중요한 요소라 할 수 있다. 은닉 노드 수를 너무 크게 설정하면 계산해야 하는 연결강도가 증가되어 많은 학습시간과 기억장소가 낭비되고, 반대로 너무 적으면 구성된 노드로 나타낼 수 있는 표현공간이 작아져 많은 반복 학습으로도 주어진 문제에 대해 전역적인 해의 수렴을 하지 못하게 된다.[11] 따라서 최적의 은닉노드 수는 구분 영역을 완전하게 형성할 수 있어 전역적 최적해의 수렴이 가능한 만큼의 충분한 개수인 동시에 단순한 구조의 개수여야 한다. 문제 영역에 따라 다수개의 은닉층으로 구성된 MLP구조가 유용하기도 하지만, 대부분의 응용문제 해결에 필요한 MLP구조는 한 개의 은닉층만으로도 충분히 해결될 수 있음을 알 수 있다. 은닉노드는 문제의 입력과 출력을 매칭시키는 역할을 하므로 은닉노드 수가 문제의 성격에 비해 너무 적게 설정되면 문제를 해결할 수 없고, 반대로 너무 많은 은닉노드 수를 가지고 학습을 할 경우에는 노드 수의 증가로 인해 학습시간이 오래 걸리게 되어 과적응(overfitting)에 빠지게 된다. 그 이유로는 주어진 입력패턴에 대한 학습에서 특별한 예제나 잡음에 까지 초과 학습하게 되어 일반성이 저하되는 요인이 된다.

## III. 수렴율 개선을 위한 매개변수 설정

BPN의 수렴속도는 신경망을 구성하는 초기 연결강도, 신경망 구조, 학습률 그리고 모멘트 등의 매개변수 값에 의존한다.

### 3.1 학습률과 모멘트

학습률은 BPN의 수렴특성을 결정하는 중요한 매개변수이고 학습속도는 학습률의 크기에 비례한다. 그러나 학습률이 지나치게 크면 진동하여 학습시간이 오래 걸리게 된다. 이런 점을 해결하기 위하여 학습률과 함께 모멘트를 추가하여 진동을 방지하고 학습속도를 개선한다. 모멘트는 현재의 오차함수가 변화된 방향에 과거의 변화량을 반영하여 연결강도 공간에서 오차함수의 지나치게 빠른 변화를 효과적으로 제거하는 기능을 수행하게 된다. 모멘트를 이용한 연결강도의 생성은 다음과 같이 표현된다.

$$\Delta W_{ji}(t+1) = -\eta \frac{\partial E}{\partial W_{ji}} + \alpha \Delta W_{ji}(t) \quad (2)$$

식(2)에서의 학습률  $\eta$ 과 모멘트  $\alpha$ 는 0과 1 사이의 값으로 경험적이나 무작위로 설정되고 있다. 이 경우에는 초기에 설정된  $\mu$ 와  $\alpha$ 의 값이 변하지 않고 학습과정 동안에 항상 동일한 값으로 유지되며, 빠른 학습속도를 얻기 위한 적절한 상호 관계를 가지는  $\mu$ 와  $\alpha$  값의 설정이 어렵다. 따라서 학습과정에서 학습속도에 영향을 미치는 인수를 찾아  $\mu$ 와  $\alpha$ 를 그에 적응조정하면 그 속도를 개선할 수 있을 것이다. 즉, 초기에 무작위로 설정한  $\mu$ 와  $\alpha$ 를 알고리즘의 초기 단계에서는 크게하고 점차 최적해에 가까워 질수록 적응 감소시키면 학습속도를 개선시킬 수 있다. 위 식에서 연결가중치  $W_{ji}$ 의 변화에 영향을 미치는 인수로 오차함수의 기울기는 연결가중치에 대한 오차함수의 미분값이다. 여기서 그 미분값은 오차함수의 변화량에 따라 달라지며 그 변화량은 다시 뉴런 출력  $X$ 의 변화량에 의존하고 이는 각 층 뉴런의 표준편차  $\delta$ 에 의존한다. 그러므로 초기 학습률과 초기 모멘트를 무작위한 값으로 설정하고 BPN을 적용하면서 각 층 뉴런 출력

의 평균과 표준편차를 계산한다. 계산된 표준편차  $\delta$ 에 비례하는 변화를 초기의 학습률과 모멘트에 각각 인가하면 이들 학습 매개변수를 조정할 수 있다.<sup>12)</sup> 이때의 평균값과 표준편차 계산식은 각각 다음과 같다.

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (3)$$

$$\delta = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}} \quad (4)$$

또한 학습률과 모멘트를 각각 표준편차에 적응조정하기 위한 식은 다음과 같다.

$$\begin{aligned} \eta(k) &= \eta_o + \delta_\eta(k) \\ \mu(k) &= \mu_o + \delta_\mu(k) \end{aligned} \quad (5)$$

### 3.2 연결강도를 위한 오차함수

BPN은 학습과정에서 연결강도 변화량을 계산할 때 다른 연결강도가 고정되어 있는 상태의 오차표면경사를 추적한다. 그러나 학습을 수행할 때 다른 연결강도들도 동시에 수정되므로 실제로 추적해야 할 오차표면도 변하게 된다. 이러한 점을 고려하여 온닉노드의 출력값이 학습시 발생하는 오차에 미치는 영향을 학습에 반영시킨다.

$$E_s = \frac{1}{P \cdot N_m} \sum_{s=1}^P \sum_{i=1}^{N_m} [d_{s,i} - y_{s,i}^M]^2 + \frac{1}{2} \sum_j (\alpha \frac{\partial E_o}{\partial U_j})^2 \quad (6)$$

위 식에 정의된 오차함수는 온닉노드의 출력값에 대한 오차의 변화율을 기준의 오차함수에 추가한 형태로 온닉노드의 출력값의 변화가 오차표면에 미치는 영향을 감소시키므로서 학습시 각 연결강도를 변경할 때 연결강도간의 의존성을 줄이고자 하는 것이다.

역전파 알고리즘을 수행한다. 각 층 노드의 출력에 대한 평균과 표준편차를 계산한 후 학습률과 모멘트의 값을 식(5)와 같이 표준편차에 대하여 조정을 행한다. 이로서 수렴율에 대한 매개변수 설정이 끝나면 온닉노드 삭제 과정을 수행한다. pruning은 BPN을 구성하는 매개변수의 값을 가지고 식(7)과 같이 삭제조건을 결정한다.

$$T_j = w_{ji} * \frac{2}{1-x_j^2} \quad (7)$$

노드 삭제를 위한  $T_j$ 는 온닉층의 j번째 노드의 출력값  $|x_j| \approx 1$ 이면  $|x_j| \approx 0$ 에 비하여 큰 값을 가지므로 출력층에 큰 영향을 준다고 볼 수 있다. 구해진 온닉노드의 출력값 중 최대값과 최소값을 가지는 온닉노드는 평균값에 영향을 미칠 수 있으므로 truncate시키고 나머지 온닉노드의 출력값  $T_j$ 를 평균하여 각 온닉노드의 절대값과 비교한 후 이 값보다 작은 경우 이 노드를 제거한다.

$$\bar{T} = \frac{\sum T_j}{|B|-2} \quad (8)$$

여기서,  $B$ 는 온닉노드 출력값의 집합

$$T_j \in B - \{\alpha, \beta\}$$

$$\alpha = \max T_j \in B, \beta = \min T_j \in B$$

신경망 구조 결정을 위한 제안된 pruning 과정은 제거대상 온닉노드를 선택하기 위하여 먼저 출력노드 수에 따라 두 부분으로 나뉘어 진다. 출력노드가 단수인 경우, 온닉노드의 개수만큼 각 출력노드에 대한  $T_j$ 와 평균값을 비교하여 제거 온닉노드를 선택한다. 만약 미 제거 대상 온닉노드 수가 2개 이하인 경우 제거 알고리즘을 수행하지 않는다. 출력노드 수가 복수인 경우, 모든 온닉노드에 대한 각각의 출력노드의  $T_j$ 를 구한 후 제거 대상 온닉노드의  $T_j$ 가 모든 출력노드의 평균값과 비교하여 작은 경우 제거 작업을 수행한다.

## IV. 온닉노드 pruning 알고리즘

pruning과정을 수행하기 전에 먼저 초기 학습률과 모멘트를 임의의 값으로 지정한 후 연결가중치를 이용하여

## V. 실험 및 고찰

본 논문에서 제안한 신경망 구조의 유용성을 입증하기 위하여 XOR, Full-adder, Parity bit를 Hiroaki가 제안한 pruning 알고리즘인 Novel BP와 함께 비교 실험하였다.

학습을 위한 초기 신경망 환경은 문제의 특성에 따라 각각  $2 \times 10 \times 1$ ,  $3 \times 10 \times 2$ ,  $4 \times 10 \times 1$ 의 구조로 지정하였으며, 신경망 매개변수인 학습률과 모멘트의 초기값은 각각 0.4와 0.8을 주었고 적응조정을 거친 후 적절한 값으로 재 설정되었다. 그리고 학습오차는 0.01, 학습횟수는 200회로 지정하였다.

(표1)에 보여지는 바와 같이 59회에 7개의 노드가 삭제되었고 이후 재학습을 통하여 학습횟수 60회에 1개의 노드가 삭제되어  $2 \times 2 \times 1$ 의 구조로 최적화되었다.

신경망 구조의 최적화 수행시기는 NBP의 경우 학습횟수 36에서 시작하여 81회까지 45회의 학습을 통하여 최적화 시켰지만 제안된 알고리즘의 경우 59회에 시작하여 60회까지 한 번의 학습으로 최적화를 마쳤다. 최적화 알고리즘의 초기 수행은 일차적으로 학습이 수렴된 이후에 이루어지므로 최적화 알고리즘의 수행시기는 최적화 알고리즘 수행 시점부터 알고리즘 종료시점까지로 볼 때, 제안된 알고리즘의 수렴속도가 빠르다는 것을 알 수 있다.

표 1. NBP와 제안된 알고리즘의 은닉층 최적화 및 학습오차 비교

Table 1. Comparsion of learning error and Hidden layer Optimized of NBP and Proposed algorithm

	Novel_bp		Proposed_bp	
	학습횟수	은닉노드수	학습횟수	은닉노드수
XOR	36	4	59	3
	41	3	60	2
	81	2		
	0.001516		0.001346	
Full-adder	22	6	28	6
	24	3	30	2
	49	2		
	0.002625		0.002347	
Parity bit	32	6	4	6
	37	4	5	3
	63	2	17	2
	0.000320		0.000251	

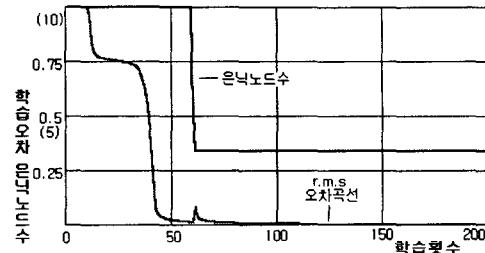


그림 1. XOR의 노드 수 감소 및 r.m.s 오차곡선  
Fig 1. Node reduce and r.m.s error curve of XOR

전기산기 역시 2회의 학습과정을 거쳐  $3 \times 2 \times 2$ 의 구조로 최적화가 이루어져 NBP 알고리즘의 27회의 학습 후 이루어진 최적화보다 학습 수렴 속도가 빠르다는 것을 알 수 있다. 학습오차는 두 알고리즘이 크게 차이는 없지만 제안된 알고리즘이 비교적 안정하게 나타남을 알 수 있다. 그리고 전기산기는 다른 실험과 달리 출력노드가 2 개로 이루어져 있어 은닉노드를 삭제할 때 복수개의 출력 노드의 값을 고려해야하지만 (그림 2)와 (그림 3)의 그 래프에서 알 수 있듯이 NBP 알고리즘은 이 사항을 반영하지 않아서 오차의 변동폭이 제안된 알고리즘보다 크고 진동이 심한 것을 알 수 있다.

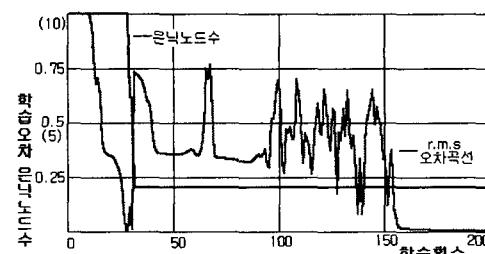


그림 2. F\_Adder 노드 수 감소 및 r.m.s 오차곡선  
Fig 2. Node reduce and r.m.s error curve of F\_Adder

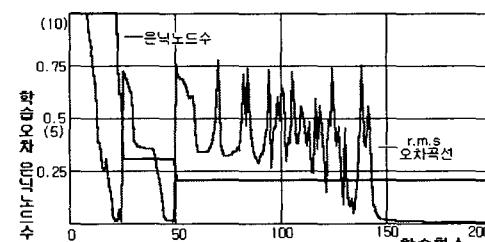


그림 3. N\_F\_Adder의 노드 수 감소 및 r.m.s 오차곡선  
Fig 3. Node reduce and r.m.s error curve of N\_F\_Adder

페리티 비트는 4bit parity를 사용하였다. (표 1)과 (그림 4)에 보여지듯이 13회의 학습을 통하여 3번의 pruning과정을 거쳐  $4 \times 2 \times 1$ 의 구조로 최적화가 이루어 졌고 학습오차도 안정된 상태를 보였다.

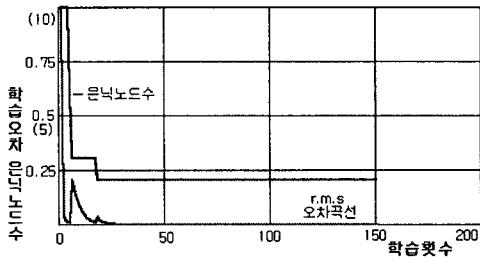


그림 4. Parity bit의 노드 수 감소 및 r.m.s 오차곡선  
Fig 4. Node reduce and r.m.s error curve of Parity bit

## VI. 결 론

본 논문에서는 다층 신경망 구조의 학습속도 개선과 수렴률 향상을 위하여 은닉노드 삭제를 통한 최적화된 신경망 구조를 설계하였다.

다층 신경망의 매개변수를 은닉노드를 제거하기 위한 평가치로 사용하였고, 특히 수렴률 향상을 위하여 학습율과 모멘트를 노드의 출력에 따라 조정시킨 값을 가지고 네트워크 환경을 재설정 하였다. 은닉노드 삭제를 위하여 각 은닉노드에서 출력되는 값 중 최대값과 최소값을 갖는 노드를 제거대상에서 제외하고 나머지 은닉노드 특징값의 평균과 각 은닉노드의 특징값을 비교하여 평균보다 작은 특징값을 갖는 은닉노드를 제거시키므로서 다층 신경망의 최적 구조를 결정하여 신경망의 학습 속도를 개선하였다. 제안된 알고리즘을 NBP 알고리즘과 비교하여 벤치마크 문제에 적용시켜 본 결과 수렴속도와 학습오차면에서 전 보된 결과를 얻을 수 있었다.

## 참고문헌

- [1] D.O.Hebo The Organization of Behavior, John Wiley, New York ,1949.
- [2] J.Hertz, A. Krogh, and R.G.Palmer, Introduction to the theory of neural computation, vol. 1, Addison-Wesley Publishing Co., 1991.
- [3] Heng Guo and Saul B. Gállo, "Analysis of Gradient Descent Learning Algorithms for Multilayer Feedforward Neural Networks," IEEE Transactions on Circuits and Systems, Vol. 38, No. 8, pp.883~894, 1991.
- [4] Macro Gori and Alberto Tesi, "On the Problem of Local Minima in Backpropagation," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 14, No.1, 1992.
- [5] Geoffrey F. Miller and M. Todd, "Designing Neural Networks using Genetic Algorithms," Proceedings of the third international conference on Genetic Algorithms, pp.379-384, 1989.
- [6] J. Sietsma and R. J. F. Dow, Creating artificial neural networks that generalize. Neural Networks, pp67-69, 1991.
- [7] Yoshio Hirose, Koichi Yamashita and Shimpei Hijiya, Back-Propagation Algorithm Which Varies the Number Hidden Units, Neural Networks, vol. 4, pp.61-66, 1991.
- [8] S.Y.Kang and J.N.Hwang, An algebraic projection analysis for optimal hidden units size and learning rates in back-propagation learning, Pro. UCNN88,

vol. 1, pp.363-370, July, 1988.

- [9] Q.Xue, Y.Hu, and W.J.Tompkins,  
Analysis of the hidden units of  
backpropagation model by singular value  
decomposition (SVD). Proc. IJCNN 90,  
vol. 1, pp. 739 - 742 , Jan. 1990.
- [10] P.D.Wasserman, Neural Computing :  
Theory and Practice, New York, Van  
Nostrand Reinhold, 1989.
- [11] 강수연. "유전자 학습 알고리즘을 이용한 다층  
신경망 구조 결정에 관한 연구." 석사 학위논문,  
경희대학교 컴퓨터공학과 pp. 21~32.
- [12] 조용현, 최홍문, "학습 파라미터의 적응조정에 의  
한 다층신경망의 학습속도 개선", pp 313-316

### 저자 소개



#### 강 경 애

1993년 동신대학교 물리학과 (이학사)  
1998년 조선대학교 일반대학원 전산통계  
학과 (이학석사)  
1999년 3월 ~현재 조선대학교 일반대학  
원 전산통계학과 박사과정  
관심분야 : 신경망, 영상처리, 패턴인식,  
유전자알고리즘



#### 이 기 준

1994년 조선대학교 전산통계학과 (이학사)  
1997년 조선대학교 일반대학원 전산통계  
학과 (이학석사)  
1998년 3월 ~ 현재 조선대학교 일반대학  
원 전산통계학과 박사과정  
관심분야 : 신경망, 패턴인식, 인공지능, 분  
산 에이전트 시스템



#### 정 채 영

1983년 조선대학교 컴퓨터공학과 (이학사)  
1986년 조선대학교 일반대학원 전자과 전  
산전공 (공학석사)  
1989년 조선대학교 일반대학원 전기과 전  
산전공 (공학박사)  
1986년 ~ 현재 조선대학교 자연과학대학  
수학·전산통계학부 부교수  
관심분야 : 영상처리, 신경망, 데이터베이  
스, 멀티미디어 컨텐츠