

온너노드 가중치와 활성화를 기반으로 한 다층 퍼셉트론 Pruning 기법

정희원 강명아*, 이기준*, 정채영*

A Pruning Method of Multi-Layer Perceptrons Based on the Weights and Activation of Hidden Units

Myung A Kang*, Kee Jun Lee*, Chae Young Chung* *Regular Members*

요약

다층 전방향 네트워크를 이용하는 신경망에 대한 연구가 활발히 수행되고 있다. 그 중에서 다층 퍼셉트론은 여러 응용분야에서 가장 성공적으로 적용되어온 신경망 모델이다. 이러한 다층 퍼셉트론을 학습시키는데 오류 역전과 학습 알고리즘이 많이 사용되고 있다. 그러나 특정 문제를 해결하기 위한 신경망 구조를 설계할 때 최적의 네트워크 종파 노드의 수를 결정짓는 것은 어려운 문제이다. 본 논문에서는 3계층 신경망구조에서 온너층 노드수를 감소시키는 방법을 이용하여 이러한 문제를 해결해보자 한다. 제안한 방법은 신경망의 구조학습을 통하여 최적의 온너층 노드수를 갖는 네트워크를 결정하고 온너층의 가중치 값을 결정한다.

ABSTRACT

It has been known that the multi-layer perceptrons have the difficulty of determining the optimal structure of networks for the given training samples. To cope with this problem, this paper presents a method of pruning the hidden units of multi-layer perceptrons. In our method, the pruning of hidden units are determined by the feature values calculated from the outputs and weights of hidden units. As a result, the proposed method shows as efficient learning of multi-layer perceptrons with near optimal number of hidden units.

I. 서론

다층 신경망 모델들은 광범위한 분야에 효과적으로 적용되어 왔다.⁽¹⁾⁽²⁾⁽³⁾ 이 신경망 모델들의 특징중의 하나는 학습을 할 수 있다는 것이다. 오류 역전과 학습 방법은 가장 많이 사용되는 학습방법이고 패턴인식과 분류 등의 분야에서 사용되고 있다. 최근에는 최적의 온너층 노드수의 크기를 결정하여 3계층 신경망을 구성하는 연구가 활발히 수행되고 있다.⁽⁴⁾⁽⁵⁾⁽⁶⁾ 오류 역전과 학습방법은 오차 표면의 기울기, 학습률 그리고 모멘텀을 이용하여 오차를 감

소시키는 방향으로 연결강도 값을 수정하면서 오차가 0에 접근 할 때까지 학습을 반복한다. 즉, 오차 표면의 기울기와 학습률의 크기에 따라 탐색 보폭의 크기가 정해지는데, 오차 표면이 평지인 곳에서는 오차 표면의 기울기가 작기 때문에 탐색보폭 또한 작게되어 전역적 최적해로의 수렴을 위해 많은 반복 학습이 필요하게 되므로 학습시간이 오래 걸리게 된다. 역전과 알고리즘의 학습이 성공적으로 수행되기 위해서는 먼저 주어진 문제에 적합한 최적의 신경망 구조를 결정하여야 한다. 온너층의 노드수가 너무 적게 정해지면 주어진 입력패턴을 충분히 구분할 수 없게 되고, 구조를 너무 크게 하면

* 조선대학교 자연과학대학 전산통계학과

접수번호: 99179-0506, 접수일자: 1999년 5월 6일

과적용이 되어 일반화 성능이 떨어지게 되므로 주어진 문제에 적합한 온너총 노드수로 구성된 신경망 구조가 전역적 최적해로 수렴하는 신경망의 성능에 가장 영향을 주는 것으로 그 중요성이 대두되었다.¹¹⁾

이러한 문제를 해결해나가기 위한 방안으로 Hagiwara는 전체 학습패턴에 대하여 역전파된 오차값을 모두 더하여 이 값이 가장 큰 온너총 노드를 제거해야 할 노드로 간주하였고⁶⁾, Hirose는 학습 정제 현상을 지역적 최소치에 의한 것으로 간주하고 이를 제거하기 위해 학습의 정체시마다 노드를 추가시켜 학습하여 네트워크가 수렴상태에 도달한 후에 온너총 노드수를 축소시켜 다시 수렴에 도달하게 하여 온너총의 노드수를 결정하고 지역적 최소치를 빛이나는 방법을 제안하였다.⁷⁾

기존의 연구들에서도 알 수 있듯이 신경망의 성능은 매개 변수들에 의해 좌우되고 특히 가중치와 온너총의 갯수 및 노드수에 큰 영향을 받는다.¹⁰⁾ 따라서 본 논문에서는 온너총 노드수의 감소방법을 기반으로 온너총 노드수를 구하는 방법을 기술한다. 이 알고리즘은 뉴런들이 활성화되거나 비활성화될 때 주어지는 값을 사용하며, 이 방법을 이용하여 구성된 신경망의 구조는 단순 학습동안 학습이 종료되면 온너총 노드의 수와 가중치값이 동시에 결정되어진다. 그러므로 최적의 온너 노드수를 가지는 신경망을 구성할 수 있다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 나총 신경망으로 인식하는 과정을 보이며, 3장에서는 나총 신경망의 온너총 노드수 결정 방법을 제안한다. 그리고 4장에서는 실험결과를 5장에서는 본 논문의 결론을 기술한다.

II. MLP 신경망

단층 신경망에서 발전된 나총 신경망은 입력층, 1개 이상의 온너총, 그리고 출력층으로 구성된 신경망으로써 일반적으로 다층 신경망의 학습 알고리즘으로 배 프로파게이션 학습 알고리즘이 널리 사용되고 있다. 배 프로파게이션 학습방법은 식(1)의 오차함수를 통하여 목표값에 접근되어간다.

$$E = \frac{1}{2} (d_k - y_k)^2 \quad (1)$$

이때 y_k 는 패턴에 대한 출력층 k 번째 노드의 출력값이고 d_k 는 교사데이터의 값이다. 식(1)은 가중

치를 변경하여 오차를 최소화하는 최적의 가중치를 결정한다. 이때 식(2)를 이용하여 가중치를 변경한다.

$$w_n^{t+1} = w_n^t + \alpha \delta x^k + \beta \Delta w^{k-1} \quad (3)$$

위 식(2)에서 w_n^t 는 뉴런 i 에서 뉴런 j 로의 가중치이고 α 는 학습율, δ 는 출력노드의 오차신호, x^k 는 온너노드의 출력값, β 는 모멘텀, Δw 는 반복횟수를 나타내고 $\beta \Delta w^{k-1}$ 은 모멘텀항이다.

각층의 뉴런들은 입력총합을 활성화함수에 적용시켜 각 노드의 출력값을 정한다. 이때 사용하는 활성화함수로는 식(3)의 양극성 시그모이드 함수를 사용하며 -1(유) 또는 1(양)의 값에 근사하게 되는 출력값을 갖도록 조정된다.

$$x_j = \frac{1 - \exp(-\sum_i x_{ji})}{1 + \exp(-\sum_i x_{ji})} \quad (3)$$

III. MLP의 온너총 노드수 결정법

이전의 Hiroaki에 의해 제안된 온너총 감소방법⁹⁾은 온너총 뉴런이 활성화되거나 비활성화 될 때 나오는 복징값 C_j 의 값에 의하여 결정한다. j 번째 뉴런의 C_j 값이 크면 (i.e. $|x_j| \approx 1$) C_j 값이 작을 때 (i.e. $|x_j| \approx 0$)에 비하여 오차함수에 좀더 중요한 역할을 하게된다. 이 C_j 값은 식(4)에 의해 주어진다.

$$C_j = \frac{2}{1 - x_j^2} \quad (4)$$

위 식(4)에서 C_j 의 값은 j 번째 온너노드의 특징값이고 x_j 는 이 뉴런의 출력값이다. 따라서 C_j 값이 큰 온너노드는 작은 값을 가지는 뉴런에 비하여 네트워크상에서 중요한 의미를 가진다고 볼 수 있고 작은 특징값을 가지는 뉴런은 감소되어진다.

하지만 위에서 언급한 Hiroaki의 방법은 온너총 노드가 큰 특징값을 가진다 할지라도 온너총과 출력층을 연결하는 가중치의 값이 상대적으로 작을 때 출력노드에 큰 영향을 준다고 할 수 없고 반대로 작은 특징값을 가지는 온너노드라 할지라도 가중치의 값이 큰 경우 출력노드에 작은 영향을 준다고 단정을 지울 수 없다. 또한 출력층의 노드가 2개 이상인 경우 각각의 출력노드에 대하여 가중치와 음성이 나름으로 특징값 계산을 달리 해주어야 필요성이 있다.

본 논문에서는 뉴런이 활성화되거나 비활성화될 때 생성되는 온너노드의 특징 정보와 연결가중치, 읍셋값을 이용하여 온너층의 노드수를 축소시키는 방법을 제안한다.

먼저 초기에 설계된 신경망 구조를 이용하여 배포로퍼케이션 학습알고리즘을 수행하여 학습이 수렴되면 식(5)를 이용하여 온너노드의 특징값을 구한다.

$$C_j = w_{ji} * H_j * \theta_j \quad (5)$$

여기서 C_j 는 j 번째 온너노드의 특징값이며, w_{ji} 는 i 번째 입력노드에서 j 번째 온너노드의 가중치, H_j 는 j 번째 온너노드의 출력값, θ_j 는 j 번째 온너노드의 읍셋값이다. 이 특징값 C_j 가 풀수록 ($|x_i| \approx 1$) 특징값이 작을 때($|x_i| \approx 0$)에 비하여 출력노드에 강한 역할을 수행한다 할 수 있다. 제안된 온너노드 감소 알고리즘은 학습 수렴 시 사용되지 않은 온너노드들을 감소한다. 식(6)에서와 같이 먼저 구해진 온너노드의 특징값 중 최대크기를 가지는 온너노드를 감소대상에서 제외를 시키고 나머지 온너노드의 평균값을 구하여 각 온너노드의 절대값과 비교, 이보다 작은 경우 감소대상 노드로 포함시킨다. 따라서 알고리즘을 수행하면 적용되는 문제에 따라 온너노드의 수는 최소 2개로 수렴될 수 있다. 불필요한 노드들이 제거된 신경망을 이용하여 재학습을 시행하고 또다시 학습이 수렴되는 위의 과정들을 반복적으로 수행한다.

$$\bar{C} = \sum_{j=0}^{N-1} \frac{C_j}{N-1} \quad (6)$$

이렇게 구성된 신경망을 이용하여 학습을 수행하면 학습 진행은 평형상태, 학습 진행 상태, 수렴상태의 연속된 다른 3가지 상태로 구성되는 것을 볼 수 있다(그림[1]). 평형상태는 임의의 값으로 가중치를 초기화하여 학습이 제대로 이루어지지 않고 오차값도 감소되지 않는다. 학습 진행 상태는 급속히 수렴하기 시작한다. 이 단계에서 신경망을 구성하기 위해 필요한 정보들이 거의 만들어진다. 수렴상태에서는 최소 자승 오차값은 작아지고 따라서 수렴오차 또한 작아진다. 평형상태와 학습상태에서는 최소자승오차의 큰 값 때문에 큰 값을 가지는 가중치를 변화시킨다. 학습이 수렴되면 온너노드의 특징값을 이용하여 불필요한 온너노드들을 제거한다. 온너노드수가 감소되어 재구성된 네트워크는 작은 값을 가지는 r.m.s Error 값으로 초기화되어 학

습을 재시작하고 r.m.s Error가 급속히 증가되어 평온한 형태의 그래프의 모습을 지니게 된다. 이후 재구성된 신경망 구조가 안정된 상태에 도달하면서 신경망은 학습수렴상태를 다시 유지하게 된다.

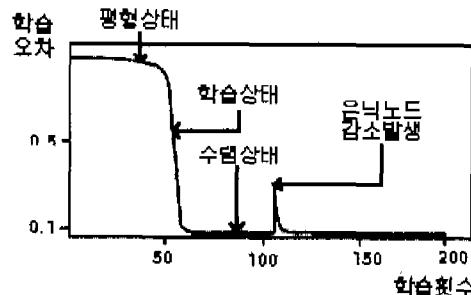


그림 1. 신경망 r.m.s Error 학습곡선

IV. 실험 및 결과

본 연구의 신경망 구조 설계 시스템은 Pentium 166MHz 시스템에서 Visual C++을 이용하여 구현되었다. 실험은 제안된 알고리즘과 Hiroaki 알고리즘에 신경망의 구조를 테스트하는데, 일반적인 신경망 성능평가문제로 사용되는 XOR와 전가산기 문제와 함께 실생활에 적용하기 위하여 편기체 영문자 인식문제를 적용시켜보았다.

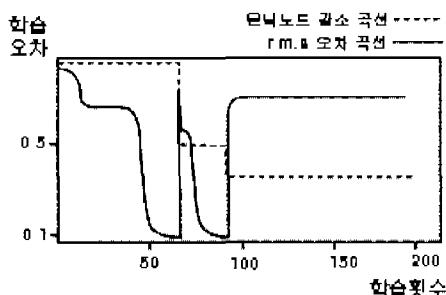
4.1 XOR

본 실험에서는 2-8-1 구조를 가지는 전방향 네트워크를 초기 구조로 설정하였다. 이 구조에서는 학습률은 0.4, 모멘텀은 0.7, 학습오차는 0.01, 그리고 학습횟수는 200회이다. 그림[2]의 (a),(b)는 Hiroaki 알고리즘과 제안된 알고리즘을 수행한 후의 r.m.s 학습오차곡선과 온너층 감소곡선을 보여주고 있다. 두 알고리즘을 각각 이용하여 학습을 수행한 후 초기 2-8-1인 네트워크의 구조가 제안된 알고리즘을 이용한 경우 성능의 악화 없이 2-2-1의 신경망 구조로 구성되었다. 그러나 Hiroaki 알고리즘을 이용한 경우 2-2-1의 구조를 얻었지만 학습이 수렴되지 않아 성능이 악화된 것을 알 수 있다.

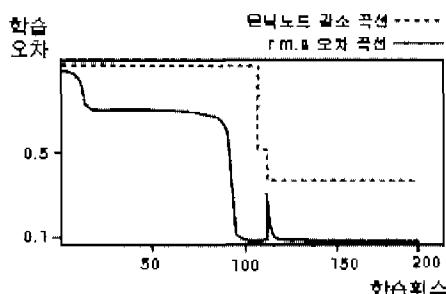
Hiroaki 알고리즘을 수행한 (a)의 경우, 제안된 알고리즘을 수행한 (b)에 비하여 재구성된 네트워크를 이용한 학습을 수행할 때 오차 범위가 크고 온너층 감소 범위가 작은 이유는 온너층 각 노드의 특징값 계산시 각 온너노드와 연결된 가중치, 그리고 읍셋의 영향과 무관하게 온너노드의 특징값을 구했기

때문에 감소된 노드 중 학습수렴에 큰 영향을 미친다. 온너노드가 제거된 것이라고 분석할 수 있다.

그림 [2]의 (a),(b)를 살펴보면 온너 노드수가 감소할 때 학습의 r.m.s Error가 급속히 증가됨으로 뾰족한 형태의 그래프를 보여주고 있다. 이러한 현상은 재구성된 네트워크가 작은 값으로 가지는 r.m.s Error값으로 초기화되어 학습을 시작한나고 볼 수 있기 때문이다.



(a) Hiroaki 알고리즘을 수행한 r.m.s. Error 곡선 및 온너노드 감소곡선

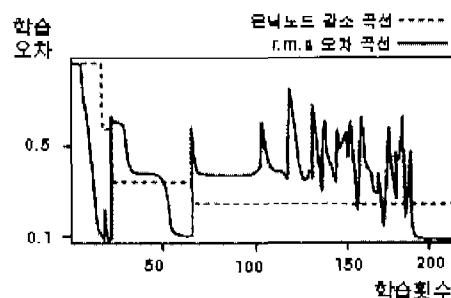


(b) 제안된 알고리즘을 수행한 r.m.s. Error 곡선 및 온너노드 감소곡선

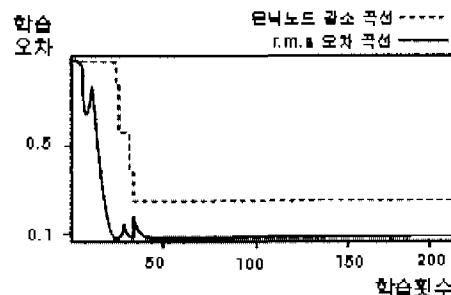
그림 2. XOR 문제

4.2 전가산기

이 실험은 XOR 문제에 비하여 좀더 복잡하고 복수개의 출력노드를 가지는 전가산기에 대한 분석을 시행하여 보았다. 초기에 설정된 신경망 구조는 3-16-2 구조를 가지는 전방향 네트워크를 초기 설정하였다. 이 구조에서는 학습률은 0.4, 모멘텀은 0.7, 학습오차는 0.01, 그리고 학습횟수는 300회로 지정하였다. 그림[3]의 (a),(b)는 각각 Hiroaki 알고리즘과 제안된 알고리즘을 수행한 결과를 보여주고 있다. 그림[3] (a),(b)를 통해서 알 수 있듯이 두 알고리즘을 수행한 결과 초기 설정된 3-16-2의 신경망 구조는 성능의 악화 없이 설정된 학습횟수 범위 내에서 3-2-2의 구조로 재구성되었다.



(a) Hiroaki 알고리즘을 수행한 r.m.s. Error 곡선 및 온너노드 감소곡선



(b) 제안된 알고리즘을 수행한 r.m.s. Error 곡선 및 온너노드 감소곡선

그림 3 전가산기 문제

그림 [3]의 Hiroaki 알고리즘을 수행한 (a) 경우 네트워크의 구조는 3-2-2 구조로 설정되었지만 r.m.s 오차의 곡선을 살펴보면 제안된 알고리즘을 수행한 (b)에 비하여 오차의 변동폭이 크다는 것을 알 수 있다. 이것은 Hiroaki 알고리즘이 제거할 온너노드를 선택할 때 온너노드의 특징값만을 이용하므로 복수개의 출력노드에 대한 각각의 영향력을 무시한 결과이다.

제안된 알고리즘에서는 출력층이 복수개인 경우 온너노드의 특징값을 각각의 출력노드에 대한 연결 가중치와 음색값을 고려하여 제거한 온너노드를 선택하기 때문에 온너노드 감소시 발생되는 r.m.s 오차변동의 폭이 Hiroaki 알고리즘보다 작음을 알 수 있다.

4.3 필기체 영문자 인식

필기체 영문자 인식 시스템에서는 EPSON GT-9500 영상스캐너를 이용하여 영상을 입력받아 한 문자씩 영역분할과정을 거쳐 20×20 의 크기로 정규화하여, 총 30 Sets를 모집단으로 형성하였다.

그리고 이중 13 Sets를 학습 패턴으로, 나머지 17

a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z
 a b c d e f g h i j k l m n o p q r s t u v w x y z

그림 4. 학습에 사용된 필기체 영문자 일부 패턴들

Sets를 테스트 패턴으로 설정하여 실험하였다. 인식 시스템은 필기체 영문자 특징추출부분과 인식부분으로 나눌 수 있다. 특징추출부분은 M특징 추출함수를 이용하여 필기체 문자 이진영상으로부터 불변의 특징을 추출하여 패턴의 모집단을 형성한다. 모집단으로 생성된 패턴들은 $100 \times 50 \times 10$ 의 신경회로망에 의하여 학습되어 인식을 위한 패턴자료로 사용되어 진다.

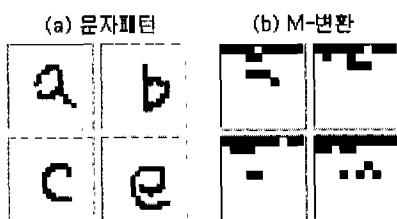


그림 5. 입력패턴과 M변환 결과

초기 설정된 신경망은 $100 \times 50 \times 26$ 의 신경망으로 구성하였고, 학습율은 0.4, 모멘텀은 0.7을 부여하였고, 학습오차 0.01, 그리고 학습횟수는 300회로 설정하였다. 초기 가중치는 -0.5에서 0.5사이의 임의값으로 초기화하였다.

제안된 최적화 알고리즘을 수행한 결과 표 [1]은 최적화 학습 횟수별 온너노드의 감소 현황을 보여주고 있고, 그림 [6]는 온너노드 감소곡선과 r.m.s 오차곡선을 나타내고 있으며, 초기 설정된 $100 \times 50 \times 26$ 신경망 구조는 총 203회의 초기화 학습 과정을 거쳐 $100 \times 28 \times 26$ 의 구조로 최적화 되었다.

표 1. 학습횟수별 온너노드 개수 변경

학습횟수	온너노드 개수	학습횟수	온너노드 개수
42회	65개	65회	37개
43회	53개	66회	35개
45회	49개	79회	33개
46회	46개	150회	31개
58회	44개	161회	30개
61회	42개	189회	29개
64회	39개	245회	28개

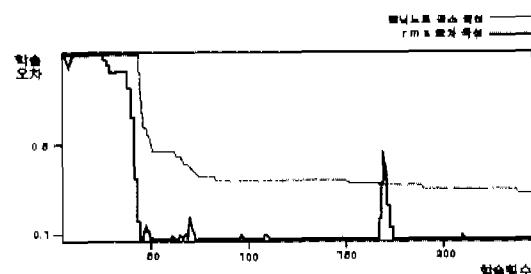


그림 6. 제안된 알고리즘을 수행한 r.m.s Error 곡선 및 온너노드 감소 곡선

그림 [6]에서 학습 오차 곡선의 진행을 살펴보면 온너노드의 감소 때 발생하는 오차 곡선의 상승폭이 이전의 실험에서와는 달리 큰 폭을 나타내고 있지 않고, 오히려 학습초기에는 r.m.s 학습오차의 값이 감소하거나 기존의 값을 유지하는 경우를 발견 할 수 있다. 그 이유는 과(過) 설정된 온너 노드 중에서 실제 학습에 영향을 미치는 온너 노드에 비하여 영향을 미치지 않는 온너 노드의 비율이 그만큼 높다는 것을 알 수 있다. 그러므로 실제 용용 문제를 신경망에 적용하고자 할 때 겪게되는 온너노드 수 결정방법을 제안된 최적화 알고리즘으로 수행하였을 때 더 큰 운영상 효율을 얻을 수 있으리라 본다.

표 [2]는 사용자가 임의로 설정한 $100 \times 100 \times 26$ 구조, $100 \times 80 \times 26$ 구조, $100 \times 60 \times 26$ 구조, $100 \times 40 \times 26$ 구조, 그리고 최적화 된 신경망에서 얻은 28개의 온너노드로 구성된 $100 \times 28 \times 26$ 개의 신경망

표 2. 5개의 신경망 구조를 적용한 인식률

신경망 구조	학습률	학습률
$100 \times 100 \times 26$	96.38 %	91.82 %
$100 \times 80 \times 26$	93.25 %	86.65 %
$100 \times 60 \times 26$	95.83 %	91.25 %
$100 \times 40 \times 26$	94.73 %	88.61 %
$100 \times 28 \times 26$	94.51 %	89.76 %

을 이용하여 학습 패턴 및 테스트 패턴에 대한 인식률을 나타낸 것이다.

위 표 [2]에서 온너노드 100개인 $100 \times 100 \times 26$ 구조인 신경망에서의 학습패턴과 테스트 패턴에 대한 인식률은 다른 신경망 구조에 비하여 높은 인식률을 나타내지만 그렇다고 특별한 만큼 좋은 성능을 보이지는 않는다. 오히려 제안된 최적화 알고리즘을 수행하여 얻은 $100 \times 28 \times 26$ 구조의 신경망은 작은 온너노드의 개수로 임의로 설정된 다른 신경망 구조에 비하여 비슷한 성능을 나타내었다. 또한 패턴 인식 속도에 있어서도 적은 계산시간을 요구함으로 인식 시간별 인식률로 비교하였을 때 우수한 성능을 낼 수 있다.

V. 결론

본 논문에서는 맥 프로퍼케이션 학습알고리즘을 수행하는 다층 뉴런 네트워크에서 온너노드의 크기를 최적화 하는 알고리즘을 제안하였다. 이 알고리즘은 온너노드의 출력값과 연결강도, 유탭값을 이용하여 복잡값 C_i 를 구하였고 이 복잡값이 작은 온너노드들을 네트워크 구조에서 제거한다.

이 알고리즘을 이용하여 작성된 최적화 네트워크의 성능은 동일작업을 수행하는 일반적인 네트워크에 비하여 우수한 성능을 보였다. 또한 기존에 발표된 Hiroaki 알고리즘에 비하여 온너노드의 출력값, 연결강도, 유탭을 이용함으로써 제거대상이 되는 온너노드들을 잘 찾아낼 수 있었다.

이 복잡값의 정보는 온너노드들을 감소시키기 위하여 온너층 노드들 사이에 분포되고 노드가 제거된 후에 재구성된 네트워크는 작은 값을 가지는 r.m.s Error 값으로 초기화되어 학습을 시작하기 때문에 일시적으로 r.m.s Error 값이 급속히 증가되는 상태를 보인다. 하지만 r.m.s 학습중 수렴된 상태에서 제거된 노드들은 대부분 무시해도 좋다고 볼 수 있다.

그러므로 최종 결정된 온너층 노드의 수는 XOR과 전가산기의 문제에서처럼 학습수렴에 결정적 영향을 미치는 온너노드로 압축된다고 할 수 있다. 따라서 본 논문에서 제안한 온너층 감소알고리즘은 좀더 크고 복잡한 문제를 시행함에 있어서 유연성을 가진 알고리즘이라 할 수 있다.

마지막으로 향후연구는 온너층 노드에 대한 Pruning 알고리즘은 일차적으로 학습 수렴 이후 수행이 되는데 학습 수렴 이전의 온너층 감소여부에 대한 연구가 필요할 것이라 생각된다.

참고문헌

- [1] D.O.Hebb. The organization of behaviro,John wiley, New York, 1949.
- [2] Richard Lippmann, An Introduction to Computing with Neural Nets, IEEE ASSP Magazine, pp. 4-22, April, 1987.
- [3] R.Hecht-Nieisen, Neurocomputing, Addison-Wesley Publishing Co.,1989.
- [4] S.Y.Kung and J.N. Hwang, An algebraic projection analysis for optimal hidden units size and learning rates in back-propagation learning, Proc. IJCNN88, vol. 1, pp. 363-370, July. 1988.
- [5] Q.Xue, Y. Hu, and W.J. Tompkins, Analysis of the hidden units of back-propagation model by singular value decomposition(SVD), Proc. IJCNN90, vol. 1, pp. 739-742, Jan. 1990
- [6] M. Hagiwara, Novel back propagation algorithm for reduction of hidden units and acceleration of convergence using artificial selection, Proc. IJCNN90, Vol. 1, pp. 625-630, June 1990.
- [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] Nelson, M.M. and Illingworth, W.T., "Neural Networks," MIT press, Vol. 1, 2, 1992.
- [9] Hiroaki Kurokawa "A Novel Back-Propagation Algorithm with Optimal Number of Hidden Units" ICANN, Vol 1, 1993.
- [10] D.E.Rumehart, R. Durbin, R. Golden, & Y.Chauvin, Backpropagation : the basic theory", in Backpropagation - Theory Architectures, and Applications, Y. Chauvin and D.E. Rumelhart(Eds.), pp.1-34, Lawrence Eribaum Associates, Publishers, 1995.
- [11] Syozo Yasui, "Convergence Suppression and Divergence Facilitation : Minimum and Joint Use of Hidden Units by Multiple Output", Neural Networks, Vol. 10, no. 2, pp. 353-367, 1997.

강 명 아(Myung A Kang)



1992년 : 광주대학교
전자계산학과 (공학사)
1995년 : 조선대학교 일반대학원
전산통계학과 (이학석사)
1999년 : 조선대학교 일반대학원
전산통계학과 (이학박사)

1999년 3월~현재 : 순천 청암대학 전산정보처리과
조빙교수

<주관심 분야> 신경망, 영상처리, 패턴인식, 유전자 알고리즘

e-mail: angelfox386@netsgo.com

이 기 준(Kee Jun Lee)



1994년 : 조선대학교
전산통계학과(이학사)
1997년 : 조선대학교 일반대학원
전산통계학과(이학석사)
1999년 3월~현재 : 조선대학교
일반대학원 전산통계학과
박사과정

1999년 3월~현재 : 조선대학교 전산통계학과 강사

<주관심 분야> 신경망, 패턴인식, 인공지능, 분산에
이전트 시스템

e-mail: cholee@shinbiro.com

정 채 영(Chae Young Chung)

1983년 : 조선대학교 컴퓨터공학과 (공학사)
1986년 : 조선대학교 일반대학원 전자과 전산전공
(공학석사)
1989년 : 조선대학교 일반대학원 전자과 전산전공
(공학박사)
1986년~현재 : 조선대학교 자연과학대학 수학·전산
통계학부 부교수
<주관심 분야> 영상처리, 신경망, 데이터베이스, 멀
티미디어 컨벤츠
e-mail: cyjung@mail.chosun.ac.kr