

점증적 모델에서 최적의 네트워크 구조를 구하기 위한 학습 알고리즘

An Learning Algorithm to find the Optimized Network Structure in an Incremental Model

이 종찬* 조상엽**
Jong-Chan Lee Sang-Yeop Cho

요약

본 논문에서는 패턴 분류를 위한 새로운 학습 알고리즘을 소개한다. 이 알고리즘은 학습 데이터 집합에 포함된 오류 때문에 네트워크 구조가 너무 복잡하게 되는 점증적 학습 알고리즘의 문제를 해결하기 위해 고안되었다.

이 문제를 위한 접근 방법으로 미리 정의된 판단기준을 가지고 학습 과정을 중단하는 전지 방법을 사용한다. 이 과정에서 적절한 처리과정에 의해 3층 전향구조를 가지는 반복적 모델이 점증적 모델로부터 유도된다. 여기서 이 네트워크 구조가 위층과 아래층 사이에 완전연결이 아니라는 점을 주목한다.

전지 방법의 효율성을 확인하기 위해 이 네트워크는 EBP로 다시 학습한다. 이 결과로부터 제안된 알고리즘이 시스템 성능과 네트워크 구조를 이루는 노드의 수 면에서 효과적임을 발견할 수 있다.

Abstract

In this paper we show a new learning algorithm for pattern classification. This algorithm considered a scheme to find a solution to a problem of incremental learning algorithm when the structure becomes too complex by noise patterns included in learning data set.

Our approach for this problem uses a pruning method which terminates the learning process with a predefined criterion. In this process, an iterative model with 3 layer feedforward structure is derived from the incremental model by an appropriate manipulations. Notice that this network structure is not full-connected between upper and lower layers.

To verify the effectiveness of pruning method, this network is retrained by EBP. From this results, we can find out that the proposed algorithm is effective, as an aspect of a system performance and the node number included in network structure.

Keyword : Pattern Classification, Incremental Learning, Pruning Method, Optimized Network Structure

1. 서론

여러 연구들로부터 신경망 모델의 학습능력은 네트워크 구조가 중요한 요소로 작용한다고 알려져 있다. 그러나 EBP를 비롯한 대부분의 반복적(iterative) 학습 알고리즘을 사용하는 모델에서는 네트워크 형태를 학습 전에 정해 주어야 하고 학습하는 동안 변경이나 확장이 불가능하다. 이러한 점

은 내부층(internal layer)의 노드 수가 학습을 위해 적절한지를 결정하는 판단 기준이 없어 정보환경이 자주 바뀌는 경우 등을 극복하는 데에 문제로 남아 있다. 이에 반해 학습 중에 자동으로 네트워크 토플로지(topology)에 필요한 만큼의 은닉(hidden) 노드를 추가함으로써 신경망 구조를 확장할 수 있는 연구가 여러 방향에서 이루어 졌다[4-10]. 이 방법들을 점증적(incremental) 학습이라 한다.

이러한 모델들 중에 Fisher의 선형분리 함수[1]를 이용하여 가중치 벡터(weight)를 결정하고 엔트로피(entropy)를 이용하여 임계치(threshold)를 결정하

* 종신회원 : 청운대학교 인터넷컴퓨터학과 교수
jclee@mail.chungwoon.ac.kr(제1저자)

** 종신회원 : 청운대학교 인터넷컴퓨터학과 교수
sycho@mail.chungwoon.ac.kr(공동저자)

는 방법을 학습패턴에 따라 반복적으로 학습에 적용하는 방법이 제안[2][3]되었다. 이 모델에서 가중치는 최적의 투사면(projection plane)을 의미하며 패턴들을 이 면에 투사한다. 또한 임계치는 이렇게 투사된 면에서 패턴을 분류하기 위한 최적의 초평면(hyperplane)을 결정하는 데에 사용되었다. 또한 대부분의 점증적 학습 모델의 분류 네트워크 형태가 이진트리이고, 하나의 분리 영역은 루트(root)에서 말단(leaf) 노드까지의 경로에 의해서 결정되며, 이들 경로간의 순서는 학습과정 중에 결정된다는 점이 병렬 알고리즘으로 부적절하다는 점을 지적하였다. 이를 위해 복잡한 패턴을 분류하기 위해 최소 3개의 층이 필요하다는 점에 착안하여 점증적 학습 모델의 네트워크 구조를 3층을 가지는 반복적 네트워크 구조로 변경될 수 있음을 보였다[3].

점증적 학습 모델은 별도의 알고리즘 없이 학습 중에 네트워크 구조가 결정된다. 그러나 오류 등의 영향으로 네트워크가 필요 이상으로 확장되는 문제가 발생될 수 있다. 이러한 문제는 모델의 성능에 영향을 줄 수 있을 뿐만 아니라 수행 속도 면에서도 불리한 요소로 작용한다. 본 논문에서는 이 문제를 해결하기 위해 점증적 모델을 학습할 때 허용 가능한 오류율을 미리 정하고 이 범위 이내에서만 네트워크 확장을 허용하는 방법을 제시한다. 이러한 방법을 전지(pruning) 알고리즘이라고 하며, 이미 반복적 학습 모델에서는 여러 각도로 연구가 진행되었다[4-10]. 이들 연구의 대부분은 은닉층의 노드수와 가중치를 결정하는 문제에 초점을 맞추어 연구가 진행되었다. 그러나 본 논문에서 제안하는 전지 알고리즘은 점증적 학습을 진행하는 중에 노드수는 물론 가중치도 결정되므로 별도로 고려할 필요가 없다는 점이 과거의 연구와 차이가 있다.

2. 배경

2.1 점증적 학습 모델

본 논문에서 사용하고 있는 패턴 데이터는 c개

의 부류(class)를 가지는 n 차원의 벡터라고 정의 한다. 이를 패턴을 각 부류에 따라 분류하기 위한 함수로서 (2.1)과 같은 선형분리식(hyperplane)을 정의한다.

$$\begin{aligned} \text{Hyperplane}(P) &= \{ X \mid X \in R^n \text{ and } W^T X = T \} \\ \text{Where, } \quad X &: \text{Input Vector} \quad R^n : \text{Real Space} \\ W &: \text{Weight Vector} \quad T : \text{Threshold} \end{aligned} \quad (2.1)$$

이 선형분리함수에 따라 입력 패턴 X는 (2.2)식과 같이 P^L과 P^R으로 분리된다.

$$\begin{aligned} P^R &= \{ X \mid X \in H^n \text{ and } W^T X \geq T \} \\ P^L &= \{ X \mid X \in H^n \text{ and } W^T X < T \} \end{aligned} \quad (2.2)$$

이 모델의 네트워크 구조는 하나의 입력노드, 여러 개의 은닉노드들, 부류수 만큼의 출력노드로 구성되며, 각 노드는 가중치 벡터와 임계값을 가지고 있다[2]. 학습이 이루어지는 동안, 입력 패턴들에 따라 가중치 벡터와 임계값이 결정되고 (2.1)식에 의해 결정된 초평면은 임의 부류가 이루는 표면의 일부가 되면서 네트워크는 확장된다.

Fisher의 선형분리함수[1]를 이용하여 임의의 분포를 가지는 입력 패턴 데이터에 대한 최적의 가중치 벡터를 결정하는데, 이 과정은 다음과 같다. c개의 부류를 가지는 Fisher의 식은 (2.3)에 나타나 있다. 이 식은 각 패턴들을 투사면에 투사했을 때 투사점들로 이루어지는 부류 간의 상호 거리 (B)는 최대로 멀리 떨어지게 하고, 동시에 동일 부류에 속한 투사점들은 가능한 모여 있는 것이 최적의 분류라는 직관을 반영한 것이다.

$$\frac{W^T B W}{W^T V W} = \frac{W^T [\sum_i (\bar{X}_i - \bar{X}) (\bar{X}_i - \bar{X})^T] W}{W^T [\sum_i \sum_j (X_{ij} - \bar{X}_i) (X_{ij} - \bar{X}_i)^T] W} \quad (2.3)$$

여기서 (2.3)식의 최대값을 얻기 위해 Cauchy-Schwartz에 따라 $a = V^{1/2}W$ 라 놓으면 이 식은

$\frac{\alpha^T V^{-1/2} B V^{-1/2} \alpha}{\alpha^T \alpha}$ 이 된다. $V^{1/2} B V^{1/2}$ 의 고유값

들 중에 가장 큰 고유값(λ_1)에 상응하는 고유 벡터(e_1)를 구한다. Cauchy-Schwartz 부등식에 의해 $\alpha = e_1$ 일 때 $V^1 B$ 는 최대값을 갖는다. 따라서 가중치 벡터(W)는 $V^{1/2} e_1$ 로 정한다.

입력패턴 각각을 투사면(W)에 투사($W^T X$)하고 투사 방향에서 분리면을 결정하는 임계값을 결정하게 되는데 다음과 같은 엔트로피식을 사용한다.

$$H(C|\delta^d) = PL^*H(p_1) + PR^*H(p_2) \quad (2.4)$$

여기서 d 는 투사면상의 투사점들을 순서대로 정렬했을 때, 임의의 두 투사점 사이의 평균, $d_k = (W^T X_{k-1} + W^T X_k) / 2$, $k=1, \dots, (\text{패턴의 갯수}-1)$ 을 말한다.

$$PL^* = n_1 / (n_1 + n_2), PR^* = n_2 / (n_1 + n_2)$$

$n_1(n_2)$: d 를 기준으로 왼쪽(오른쪽) 영역에 속한 패턴의 개수

$$H(p_i) = - \sum p_{ij} \log_2 p_{ij} \quad i=1, 2$$

$i=1, 2 \quad j=1, \dots, \text{부류의 수}$

x_{ij} = 각 영역(왼쪽, 오른쪽)에서 각 부류 j 의 패턴 갯수

$$p_{ij} = x_{ij} / n_i$$

투사면에 투사된 각 입력패턴의 점들을 작은 값부터 순서에 따라 d_1 부터 d_{n-1} 까지 d 를 기준으로 입력패턴을 왼쪽과 오른쪽으로 나누고 (2.4)식을 이용해 최소의 엔트로피 값을 갖는 위치를 찾아 이 위치의 d 값을 임계값으로 정한다.

2.2 반복적 학습 모델로의 변환

앞 절에서 설명한 점증적 모델을 반복적 모델로 변환하는 과정은 다음과 같다.

Step 1 : 입력층은 학습패턴의 차원수 만큼의 노드들로 구성한다.

Step 2 : 첫 번째층은 점증적 학습에 따라 형성된 결정트리의 말단노드들을 제외한 은닉노드들 만을 배열한다. 입력층과 첫 번째 층 사이의 가중치 벡터와 임계치는 점증적 모델에서와 같은 값들을 갖는다.

Step 3 : 두 번째층은 점증적 모델의 말단 노드들만으로 구성되며 첫 번째 층에서 나누어 놓은 초평면들을 결합하여 각 부류별로 영역을 형성하는 역할을 한다. 첫 번째 층(j)과 두 번째 층(i) 사이의 가중치와 임계치는 점증적 모델의 결정트리에서 입력노드에서 말단 노드까지의 경로에 의해 다음과 같이 결정된다.

$$\sigma_{iL} = -1, \sigma_{iR} = +1$$

$$W_{ij}(\text{weight}) = \sigma_{iD},$$

$$T_i(\text{Threshold}) = \sum |\sigma_{iD}| - 0.5$$

여기서, $i=0, \dots, (\text{분류된 영역의 수}-1)$ 라 할 때 i 번째 경로에 따라 σ_{iD} ($D=L$ (left space), $D=R$ (right space))가 표시된다.

Step 4 : 세 번째층은 학습 패턴의 부류수 만큼의 노드들로 구성되며 두 번째층에서 분류해 놓은 각 부류의 영역들을 부류별로 통합하는 역할을 담당한다. 두 번째층(j)과 세 번째층(i) 사이의 가중치와 임계치는 각 영역의 부류에 따라 다음과 같이 결정된다. 만일 i 번째 경로에 의해 형성된 영역이 j 부류를 포함하면 : $R_{ij} = 1$

그렇지 않으면 : $R_{ij} = 0$

$$W_{ij}(\text{Weight}) = R_{ij}$$

$$T_i(\text{Threshold}) = \sum R_{ij} - 0.5$$

3. 점증적 학습 모델의 전지작업

3.1 제안된 점증적 모델의 전지작업

대부분의 점증적 학습 알고리즘의 네트워크 구

조는 이진 트리 형태를 가지고 있으며 이 네트워크 구조가 학습 중에 완성되므로 노드수를 미리 정할 필요는 없다. 그러나 점증적 모델에서는 학습 중에 새로운 문제가 고려되어야 한다. 정해진 알고리즘에 의해 학습이 이루어지는 동안 너무 많은 노드들을 생성하는 경우가 많기 때문이다. 이러한 문제는 학습 패턴에 오류가 많이 포함되어 있을 수록 더욱 심각하다. 제안된 알고리즘에서도 분류된 영역에 하나의 부류만이 있을 때까지 알고리즘을 반복하도록 되어 있기 때문에 이러한 문제는 발생한다. 이러한 경우 계산상의 속도 뿐만 아니라 재귀적(recursive)으로 처리되는 알고리즘의 특성에 따라 트리의 깊이가 더해질 때마다 기억공간의 낭비 문제는 매우 심각하다. 더욱이 이렇게 구성된 네트워크의 성능면에서도 오류의 영향 때문에 좋지 않게 되는 경우가 많다. 따라서 이러한 문제를 해결하기 위한 별도의 알고리즘이 고려되어야 한다.

본 논문의 2.1절에서 소개된 학습과정 중에, 지적한 문제에 대한 해결 방안으로 학습 알고리즘에 다음과 같은 사항을 추가 고려하였다.

▶ IF($N(\cdot) > \text{Prun Rate}$) {

- ① 왼쪽(오른쪽) 노드를 만든다.
- ② 왼쪽(오른쪽) 패턴들 각각을 이 노드의 입력 패턴으로 한다.
- ③ 학습을 계속한다.

}

ELSE {

분류가 완전히 이루어진 것으로 보고 학습을 중단한다.

}

여기서 Prun Rate는 어느 정도의 오류를 허용할 것인지를 학습 전에 정한 값으로 백분율 단위로 하고 있다. 또한 i 노드에서의 학습 패턴 P 에 대해 $N(\cdot)$ 는 다음과 같이 정하여 하나의 영역에 포함된 오류의 정도를 표시하였다.

$$N_i(P) = \frac{(\#TE - \#MCE)}{\#MCE} \times 100.0 \quad (3.1)$$

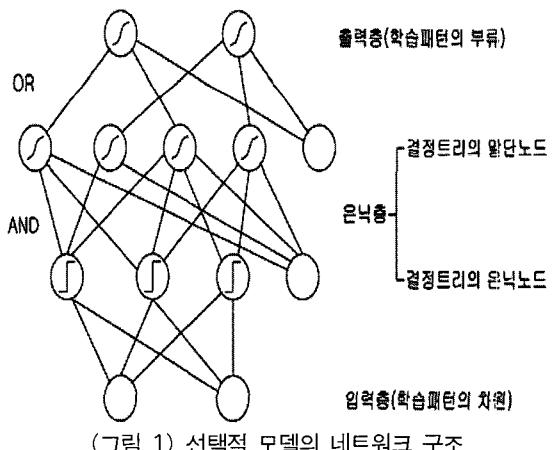
#TE : 노드 i 에 입력된 총 패턴수

#MCE : #TE 중에 가장 많은 수를 갖는 부류의 패턴수

3.2 선택적 학습 알고리즘

2.2절에서 점증적 모델의 학습과정에서 구성되어진 결정트리 구조를 반복적 모델의 구조인 3층을 갖는 구조로 변환하는 알고리즘을 소개하였다. 이 변경된 네트워크 구조는 입력층과 첫번째 은닉층 사이의 연결을 제외하고는 완전연결(full connection)이 아닌 부분적인 연결성(partial connection)을 가지고 있었다. 본 절에서는 앞 절의 절단 알고리즘을 노드의 절단작업으로 보고, 중간의 부분 연결성을 가중치의 절단작업으로 본다는 관점에서 출발하여 이를 반복성을 갖는 알고리즘을 이용해 학습할 수 있는 방안을 제안한다.

이 모델의 네트워크 구조는 그림 1과 같이 임계노드와 비선형노드 구조를 함께 가지는 혼합된 형태의 노드들로 구성된다. 이 네트워크의 학습은 반복성을 갖는 모델의 대표적인 알고리즘인 EBP를 사용한다. 학습을 위한 초기 과정으로, 첫번째 은닉층은 점증적 알고리즘의 학습과정에서 결정된 은닉노드의 수만큼으로 구성하여 가중치와 임



계치를 그대로 사용한다. 또한 두번째 은닉층 및 출력층에 각각 편기(bias)노드 하나씩을 추가하고, 각 노드의 가중치로 0과 1사이의 난수(random number)를 할당한다.

학습은 다음과 같이 이루어진다.

첫번째 은닉층의 출력값(O)은 다음과 같이 임의 부류의 영역(H_m^n) 범위 안에 들어가는 경우에만 활성화 되도록 하였다.

$$\text{IF}((\sum w_{ij}X_j) > T_i) \quad O_i = 1 \\ \text{ELSE} \quad O_i = 0$$

이 출력값(O)을 다음층에서 입력받아 EBP 알고리즘의 학습이 이루어진다. 이 학습과정은 AND와 OR 논리에 맞도록 시스템이 적응되도록 하는 과정이라고 볼 수 있다. 여기서 주목할 점은 EBP가 비선형의 시그모이드 함수를 사용한다는 것이다. 비선형 활성화 함수는 입력에 대한 출력값을 현 층에서 임계함수처럼 확실하게 결정 내리지 않고 현재의 결과를 다음 층에 넘김으로써 다음층에서 보다 확실한 결과를 산출하도록 한다. 이러한 점이 신경회로망 모델들에서 시그모이드 함수를 활성화 함수로 써 사용하고 있는 이유가 되며 오류에 대해 좋은 반응을 이끌어 내도록 하는 요인이 되고 있다.

학습은 모델 구조가 EBP와 다르게 부분 연결성을 갖고 있어, 반복과정에 의한 EBP의 가중치 변화량을 다음과 같이 변경한다.

$$\Delta_p w_{ji}(n+1) = C_{ji}(\eta \delta_p, O_{p_i} + \alpha \Delta_p w_{ji}(n)) \quad (3.2)$$

여기서 C_{ji} 는 상위층의 j노드와 하위층의 i노드 사이에 연결성이 있으면 1, 그렇지 않으면 0의 값을 가진다.

4. 구현

구현을 위한 데이터로는 Sleep Stage Scoring Data (SSSD)를 사용했다. SSSD는 인간이 수면상태에

있을 때 아날로그 형태의 뇌파를 머리의 여러 군데 (variable 수)에서 측정한 후 이를 양자화(quantization)해 디지털 형식의 데이터로 재구성한 것으로 연속 신호를 이산 형태로 바꾸는 양자화 과정 중에 생기는 오류로 데이터의 특성상 많은 오류를 포함하고 있다. 사용한 데이터는 11개의 variable과 6개의 부류를 가지는 1200여 개의 패턴들 중 799개를 임의로 뽑아 학습을 시키고 나머지 437개를 실험에 사용했다.

제안된 전지 알고리즘의 성능 실험을 위한 구현은 다음과 같이 3가지로 이루어졌다.

- ① Fisher : Prun Rate(PR, $0 \leq PR \leq 100$)에 대해 2.1 절의 알고리즘을 수행해 가중치와 임계값과 노드갯수를 정하고, 성능을 평가.
- ② Prun : ①과정의 가중치와 임계값을 입력받아 완전연결성을 가지는 EBP로 학습을 한 후, 성능을 평가.
- ③ Sel : ①과정의 가중치와 임계값을 입력받아 부분연결성을 가지는 EBP로 학습을 한 후, 성능과 연결의 감소율을 평가.

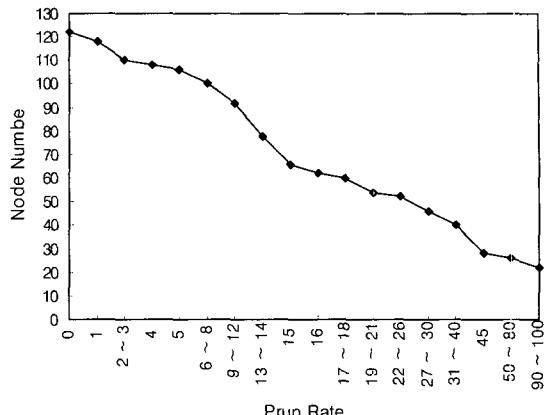
PR은 0~30%까지는 1%씩 증가하며 실험하였고, 30% 이후는 5%씩 증가하며 실험하였다. EBP의 학습율(learning rate)로 η 는 0.2를, α 는 0.7로 하고 학습하였다.

실험 결과 Sel에서는 PR 4%까지, Prun에서는 PR 31~40%까지 Fisher의 결과와 비슷하거나 우수한 결과를 나타냄을 표 1에서 확인할 수 있다. 그림 2는 PR이 감소함에 따라 노드수가 감소하는 것을, 그림 3은 Prun이 완전 연결성을 가지고 있고 Sel이 점진적 학습 방법에 의해 부분 연결성을 가지고 있음에 따라 학습에 관련되는 가중치의 수가 PR의 변화에 따라 감소하는 과정을 보였다. 이 실험을 통해 종합적으로 반복적 모델인 Prun과 Sel에서 PR이 높은율을 가졌을 때 상당히 저조한 결과를 보이고 있다. 이는 반복적 학습 모델에서 노드의 수가 적정한 수보다 적었을 때 일

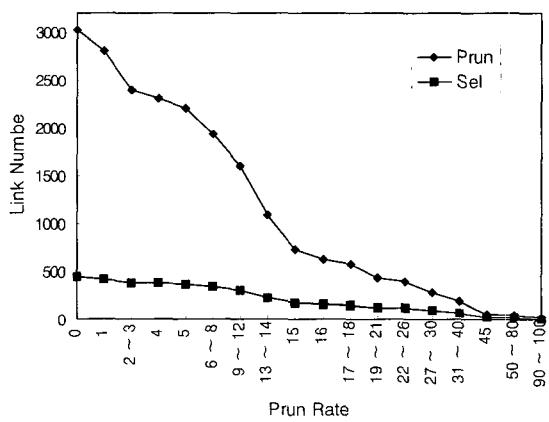
어나는 현상이라고 해석된다.

(표 1) 전지작업 실험 (* : $\eta = 0.2$)

Prun Rate (%)	Node Number		Correct Rate(%)		Link Number Rate(%)	
	Hidden	Leaf	Fisher	Prun		
			Link Num	Sel Link Num		
0	51	52	84.872	87.436 3022	85.897 442	14.63
1	49	50	85.385	87.949 2806	85.641 423	15.07
2~3	45	46	85.128	88.205 2398	81.538 386	16.10
4	44	45	84.872	87.179 2301	85.897 379	16.47
5	43	44	84.872	87.179 2206	(*) 84.615 369	16.73
6~8	40	41	82.821	86.410 1933	(*) 82.564 345	17.85
9~12	36	37	82.564	86.410 1597	(*) 83.590 309	19.35
13~14	29	30	83.333	84.359 1086	(*) 84.615 234	21.55
15	23	24	85.128	81.795 726	(*) 85.385 181	24.93
16	21	22	82.051	81.795 622	(*) 83.846 168	27.01
17~18	20	21	82.051	84.103 573	(*) 78.462 160	27.92
19~21	17	18	82.051	83.333 438	(*) 81.538 133	30.37
22~26	16	17	81.282	79.744 397	(*) 33.846 126	31.74
27~30	13	14	81.026	82.051 286	(*) 81.538 99	34.62
31~40	10	11	77.949	77.179 193	(*) 67.436 80	41.45
45	4	5	79.487	(*) 55.897 61	(*) 79.231 28	45.90
50~80	3	4	79.231	(*) 56.154 46	78.974 21	45.65
90~100	1	2	58.462	(*) 8.718 22	58.462 6	27.27



(그림 2) PR과 노드수의 비교



(그림 3) PR과 가중치 수의 비교

5. 결론

본 논문에서는 점증적 학습 모델에서 학습 패턴에 오류가 포함되었을 경우 너무 많은 노드들이 네트워크의 확장 과정에서 포함될 수 있다는 점의 해결 방안을 제시하였다. 즉, 확장성을 갖는 모델의 학습에서 전체 패턴을 완벽하게 분리할 때까지 학습하지 않고 중간에 미리 정한 임계값 까지의 정확도 정도까지만 학습을 진행한다. 이 결과를 3층의 네트워크 구조로 변경한 후 비선형 활성화 함수를 사용하는 EBP 알고리즘을 학습과정에 적용해 새롭게 구성된 네트워크 구조를 학습하는 방향이다.

이 과정을 통해서 전지작업의 목표가 되는 학

습을 위한 적절한 노드수와 노드간을 연결하는 가중치의 수를 결정할 수 있었다. 또한 결과로부터 어느 정도의 오류가 패턴에 포함되었다 하더라도 시스템의 성능에 커다란 영향이 없는 학습 네트워크 구조를 구할 수 있음을 보았다.

데이터에 따라 오류의 정도가 차이가 있으며 알고리즘에 따라 오류가 매우 많이 포함된 경우 학습에 시간이 많이 소요될 뿐만 아니라 학습 성능이 좋지 않은 결과도 발생한다. EBP에 의해 학습이 불가능할 정도로 오류가 많이 포함된 일부 음성데이터(Peters and Barney) 등의 실험을 통해 제안된 알고리즘이 오류가 많이 포함된 패턴의 분류에 적합함을 확인할 수 있었다.

참고문헌

- [1] R.A.Johnson, D.W.Wichern, "Applied Multivariate Statistical Analysis. 2ED", pp. 470~542, Prentice-Hall International Editioned, 1988.
- [2] J.C.Lee, Y.H.Kim, W.D.Lee, S.H.Lee, "Pattern Classifying Neural Network using Fisher's linear discriminant function", Vol1, IJCNN June, 1992.
- [3] J.C.Lee, Y.H.Kim, W.D.Lee, S.H.Lee, "A method to find the structure and weights of layered neural networks, WCNN, pp. 552~555, June 1993.
- [4] M. Hagiwara, "A simple and effective method for removal of hidden units and weights", Neurocomputing 6, pp. 207~218, 1994.
- [5] S.Y.Kung, J.N.Hwang, "An algebraic projection analysis for optimal hidden units size and learning rates in back-propagation learning", IJCNN Vol I, pp. 363~370, 1988.
- [6] A.S.Weigend, D.E.Rumelhart, B.A.Huberman, "Generalization by weight-elimination with application to forecasting", Advances in Neural Information Processing Systems 3, Morgan Kaufmann, pp. 875~882, 1991.
- [7] J.Sietsma, R.J.F.Dow, "Neural net pruning-why and how", IJCNN Vol I, pp. 325~333, 1988.
- [8] M.Hagiwara, "Novel back propagation algorithm for reduction of hidden units and acceleration of convergence using artificial selection", IJCNN Vol I, pp. 625~630, 1990.
- [9] S.J.Hanson, L.Y.Pratt, "Comparing biases for minimal network construction with back-propagation, Advances in Neural Information Processing Systems 1, Morgan Kaufmann, pp. 177~185, 1989.
- [10] K.Murase,Y.Matsunaga,K.Murase, "A back-propagation algorithm which automatically determines the number of association units", IJCNN Vol 1, pp. 783~788, singapore, 1991.
- [11] J.C.Lee, W.D.Lee, M.S.Han, "An Learning Algorithm to find the Optimized Network Structure in an Incremental Model", Lecture Notes in Artificial Intelligence 1711, Springer-Velag, pp. 500~508, 1999.

● 저자 소개 ●

이종찬



1988년 충남대학교 계산통계학과(학사)
1990년 충남대학교 대학원 계산통계학과(석사)
1996년 충남대학교 대학원 전산학과(박사)
1996년~현재 : 청운대학교 인터넷컴퓨터학과 교수
관심분야 : 신경회로망, 패턴분류, 정보보호, 인터넷
E-mail : jclee@mail.chungwoon.ac.kr

조상엽



1986년 한남대학교 전자계산학과(학사)
1988년 중앙대학교 대학원 전자계산학과(석사)
1993년 중앙대학교 대학원 전자계산학과(박사)
1993년~1994 중앙대학교 컴퓨터소프트웨어 연구소 객원연구원
1995년~현재 : 청운대학교 인터넷컴퓨터학과 교수
관심분야 : 인공지능, 퍼지이론, 패트리네트 응용, 인터넷
E-mail : sycho@mail.chungwoon.ac.kr