

자기조직화 교사 학습에 의한 패턴인식에 관한 연구

박찬호*

요 약

본 연구에서는 자기조직화 교사학습 신경망인 SOSL(Self-Organized Supervised Learning)과 이 신경망의 구조를 제안한다. SOSL신경망은 하이브리드 형태의 신경망으로써 다수 개의 컴포넌트 애러 역전파 신경망들과 수정된 PCA신경망으로 구성된다.

CBP신경망은 군집화되고 복잡한 입력패턴에 대하여 교사학습을 병렬적으로 수행한다. 수정된 PCA신경망은 군집화 및 지역투영에 위하여 원 입력패턴을 보다 작은 차원으로 변환시키기 위하여 사용된다. 제안된 SOSL은 많은 입력패턴을 가짐으로써 큰 네트워크 크기를 가지게 되는 신경망에 효과적으로 적용이 가능하다.

I. 서론

신경회로망은 패턴 분류 및 인식, 비선형 시스템 식별 및 제어, 그리고 로봇제어 등과 같은 매우 다양한 응용분야에서 활발히 사용되고 있다. 문제에 따라 적용되는 신경망의 종류 또한 매우 다양하며 그중 교사학습을 수행하는 대표적인 신경망으로는 다층 퍼셉트론 신경망을 들 수 있으며, 비 교사학습 즉 패턴을 분류하는 알고리즘으로는 kohonen 및 LVQ 신경망 등을 들 수 있다.

또한 학습도중 신경망의 구조적 변화에 따라 네트워크를 분류하면 나타내면 신경망의 뉴런수와 뉴런간의 연결이 학습도중 고정적인 형태와 동적으로 변하는 형태 두 가지로 나누어 볼 수 있다. 고정적인 형태의 대표적인 신경망인 애러역전파신경망(EBP: Error Back-Propagation)은

학습시간이 오래 걸리고 일반화에 약한 단점을 가지고 있다.^[1] 이러한 고정구조의 신경망은 특히 입력패턴의 특성을 신경망에서 구조적으로 고려하지 못한다. 만약 입력패턴의 수가 신경망이 감당할 수 있는 학습용량을 초과한다면 이 신경망은 학습을 끝낼 수 없다.

이런 문제를 해결하기 위해서는 학습도중 신경망의 구조를 변화시킬 수 있는 동적 신경망의 제안이 필요하다. 이에 관한 연구는 이전에도 진행되었으나 입력패턴의 수와 복잡도를 고려하여 중간 뉴런의 수를 결정하는 선택적 주의집중 방법이나(Selective attention method) 점진적으로 네트워크의 크기를 증가 또는 감소시키는 방법(Constructive or Destructive method)들이 제안되어져 왔다.^[2-3] 그러나 이러한 경우에도 입출력패턴의 차원수가 증가하거나 비선형 연산의 복잡도가 증가하는 경우에는 전체 네트워크의 크기를 결정할 수 없는 제한을 가질 수밖에 없다.

SOSL신경망을 제안하기 위하여 본 연구에서는 3가지 주요요소를 고려하였다. 첫 번째 요소

* 부천대학 인터넷응용과 전임강사

는 동적 신경망 구조상에서의 패턴 군집화이다. 제안한 군집화 방법은 하나의 패턴 군집으로부터 시작하여 출력뉴런의 수를 자기조직화하여 점차적으로 군집의 수를 늘려나가는 방법을 사용한다. 또한 제안한 신경망에서 CBP(Component BP)의 일반화 능력을 향상시키기 위하여 2가지 학습방법을 중복하여 사용한다.

두 번째 요소로는 수정된 PCA(Principal Component Analysis) 방법을 이용한 지역투영방법이다. 하나의 신경망구조상에서 높은 차원을 가지는 입력패턴은 전체 신경망의 크기와 학습에 나쁜 영향을 미치게 된다. 따라서 본 연구에서는 CBP 신경망으로 입력되는 훈련패턴의 차원 감소를 위하여 수정된 PCA방법을 사용한다. 따라서 전체 훈련패턴에 대한 전역투영 대신 제안된 방법에 따라 분할된 패턴들을 지역투영시키는 방법을 사용함으로써 학습속도의 향상과 CBP 신경망의 크기를 감소시킬 수 있었다.

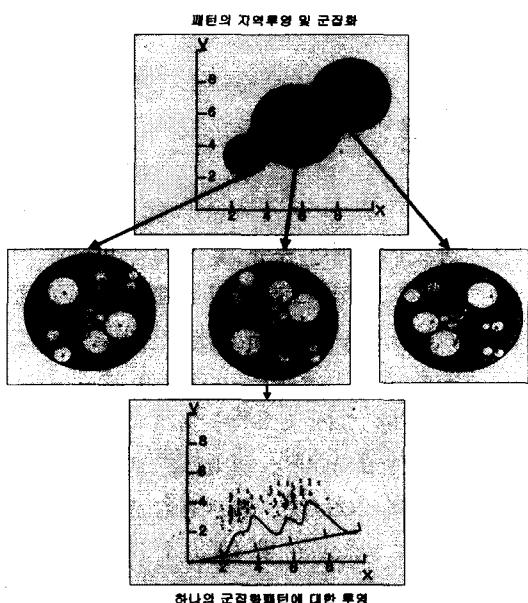
세 번째 요소로는 내부병렬화(intra parallelism)를 들 수 있다. 거의 모든 신경망들은 하나의 층을 구성하는 뉴런들의 병렬화를 수행하고 있다(inter parallelism). 제안한 SOSL신경망은 CBP로 불리우는 다수개의 모듈화된 신경망을 병렬로 수행할 수 있도록 구성함으로써 하드웨어 구현시 보다 빠른 학습속도를 얻을 수 있도록 하였다.

II. 지역적 투영 및 패턴 군집화

주성분 분석 방법인 PCA(Principal Component Analysis)는 입력패턴에 대한 최적의 선형변환을 수행하는 확률적 방법으로 잘 알려져 있다. PCA는 n 차원의 입력패턴을 m 차원의 출력 공간

으로 투영한다. 신경회로망 분야에서는 입력 뉴런의 차원을 감소시켜 전체 신경망의 크기를 감소시키는 전처리 방법으로써 효과적으로 사용되어 왔다.^[5-7] 그러나 이 방법이 가지는 큰 문제점의 하나로는 감소된 입력패턴의 차원수가 너무 작은 경우에는 오히려 일반해로의 근사가 어려워져 학습속도가 증가한다는 점이다. 또한 패턴에 대한 주성분의 잘못된 전역투영은 교사학습에 대한 어려움을 발생시킨다.

이러한 문제를 해결하기 위하여 본 연구에서는 지역투영을 사용하였다. 그림1에서는 PCA를 이용한 패턴군집화와 지역투영방법을 보여준다.



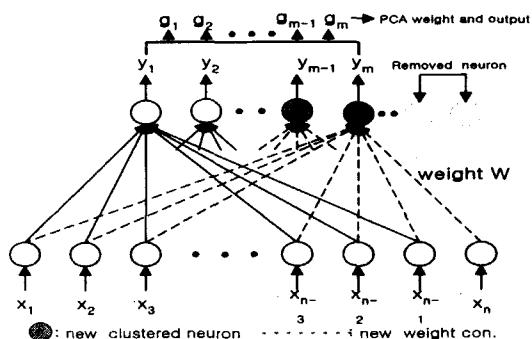
(그림 1) 패턴 군집화에 의한 지역투영

2.1. 패턴 군집화 신경망

패턴 군집화란 일정한 규칙에 의하여 클러스터의 수를 결정하는 것을 말하며 이에 관한 신

경망은 위의 규칙을 이용하여 위상적으로 매핑하는 비교교학습을 수행한다^[8-9]. Kohonen신경망에서는 출력 뉴런의 수가 결정될 때 입력패턴들은 각 출력뉴런 즉, 패턴부류를 대표하는 하나의 뉴런에 할당되어진다. LVQ신경망은 이와 유사한 패턴 분류방법을 사용하지만 출력층의 뉴런수가 고정되어진 교사학습을 수행한다. 이러한 신경망들은 고정된 출력뉴런을 가지게 됨으로써 학습도중 동적으로 군집의 수를 결정할 수 없고 또한 하나의 군집에 포함되는 패턴의 수 또한 결정할 수 없다. 본 연구에서는 출력뉴런의 수를 학습 도중 자유롭게 변화될 수 있도록 구성된 신경망을 제안함으로써 군집의 수와 하나의 군집에 포함되는 패턴의 수 또한 결정할 수 있도록 하였다.

비정상적인 학습근사와 안정된 가중치변화를 위하여 하나의 군집에 해당되는 패턴의 수와 전체 군집의 상한을 결정하였다. 만약 신경망이 위의 안정조건을 만족하면 신경망의 구조는 고정되며 각 가중치 변화가 거의 없을 때까지 학습은 계속된다.



(그림 2) 패턴군집화 신경망 구조

제안한 신경망에서는 가중치의 변화는 Kohonen 신경망과 동일하며 수식(1)에 의하여 유클리디안

거리에 의한 승자뉴런 i 가 결정되어진다.

$i(x) : \arg \min(D_i)$: 최소거리를 갖는 승자뉴런

$$D_i = \| (X_i(t) - W_{ij}(t))^2 \| \quad (1)$$

수식(2)는 제안한 신경망의 가중치 갱신을 위하여 사용된다.

$$W_{ij}(t+1) = W_{ij}(t) + \gamma (X_i - W_{ij}) \quad (2)$$

γ : 학습상수

적절한 군집내 패턴의 수를 얻기위해서는 각 패턴에 할당되는 파라메터 Dis_i 를 결정하여야 하며 이를 나타내면 수식(3)과 같다.

$$Dis_i(t+1) = Dis_i(t) - \eta(1 - \bar{A}/A) \quad (3)$$

수식(3)에서 Dis_i 는 각 패턴에 대한 거리 파라메터를 나타내며 η 는 비례함수를 나타낸다. \bar{A} 는 하나의 군집에 포함되는 패턴수의 기대 평균을 나타내며 A 는 실제 포함된 패턴의 수를 나타낸다. 위의 수식(1),수식(3)에서 만약 하나의 패턴이 갖는 Dis_i 이 승자뉴런 $i(x)$ 의 D_i 보다 작으면 이 패턴을 안전하다라고 결정한다. 그러나 반대의 경우에는 이 패턴을 안전하지 않다고 결정하고 새로운 군집을 만들어 이 패턴을 할당 한다. 그림2에서는 제안한 패턴분할 신경망의 구조를 나타낸다. 그림2에서 출력뉴런은 학습도중 제거와 생성을 동적으로 진행한다. 즉, 패턴분할신경망에서의 출력뉴런은 SOSL신경망에 존재하는 모듈화된 CBP신경망 수를 나타내며 각 출력뉴런에 할당된 패턴의 수는 CBP신경망의 수와 동일하다.

위의 신경망에서 하나의 출력뉴런이 추가될 때 가중치연결이 자동적으로 추가되며 이때 각 가중치의 값은 입력패턴의 값 X_i 로 초기화된다. Dis_i 의 초기값은 상한과 하한의 중간에서 임의로 결정할 수 있으며 이때 하한은 입력 X_i 와 W_{ij} 의 최소 유클리디안 거리로 상한은 X_i 와 X_j 의 최대 유클리디안 거리로 결정한다.

패턴군집화 신경망의 안정조건을 만족하면 각 출력뉴런의 값이 PCA영역으로 전파되어 원 입력패턴의 차원감소 단계를 거치게된다. 패턴군집화 신경망의 학습단계를 표현하면 다음과 같다.

- 단계1) 초기화 : 학습 가중치에 대한 임의값 설정 및 학습 파라메터 초기화
- 단계2) 샘플링 : 입력패턴의 전파
- 단계3) 유사도 계산 : 유클리디안 거리 계산에 의한 승자 뉴런의 결정
- 단계4) 결정 : if $Dis_i < D_i$ of 승자뉴런 $i(x)$ goto 단계5) else goto 단계6)
- 단계5) 개신 : 가중치 및 Dis_i 개신
- 단계6) 새로운 군집생성 : 새로운 출력뉴런의 생성 및 주어진 패턴의 할당
- 단계7) 판단 : 신경망안정조건판단 if 조건만족 goto 단계8) else goto 단계2)
- 단계8) 개신 : 각 뉴런의 가중치 개신
- 단계9) 판단 : 각 뉴런가중치가 안정될때까지 단계2로 돌아가서 계속

$$y = Wx \quad (4)$$

$$W = [w_1, w_2, \dots, w_m]^T \in R^{m \times n} \quad (5)$$

행렬 W 의 열들은 상관행렬 R_{XX} 의 고유벡터이다.

$$R_{XX} = \frac{1}{N} \sum_{k=1}^N x_k x_k^T = \frac{1}{N} XX^T \quad (6)$$

최초의 주성분 y_1 과 R_{XX} 의 주성분 고유벡터 w_1 그리고 다중성분해석을 위하여 Sanger는 GHA(Generalized Hebbian Algorithm) 보다 빠른 수렴속도와 보다 세밀한 성분들을 추출하는 SGA(Stochastic Gradient Algorithm)을 제안하였다.

CBP의 입력으로 사용되는 입력데이터의 차원을 감소시키기 위하여 본 연구에서는 하나 또는 몇 개의 주 성분들만을 (y_1, y_2, \dots, y_m ($m < n$) n : 입력벡터)추출하는 단일 신경망을 사용하였다. 그리고 군집화된 원 입력벡터를 지역투영 시키기 위하여 SGA방법을 이용한 가중치개신 방법을 사용한다. 이를 수식으로 나타내면 다음과 같다.

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w g_i \quad (7)$$

$$\Delta w = \eta y_i(k) [y_i(k) - w_{ij}(k) y_i(k) - \alpha \sum_{h=1}^{i-1} w_{ih}(k) y_h(k)] \quad (8)$$

2.2. PCA를 이용한 지역투영.

PCA에서 주어진 확률 입력벡터 x 에 관한 m 주성분은 다음의 선형변환 식에 의하여 정의된다.

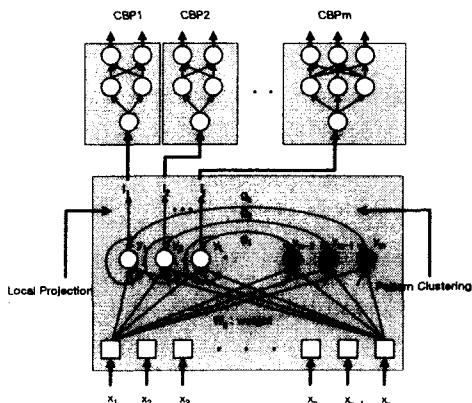
위의 수식에서 학습상수 η 는 학습횟수 k 가 증가할 수록 지수적으로 감소하며 α 의 값은 1 이상으로 한다. PCA영역에서는 다중성분 출력이 생성되므로 CBP신경망의 크기를 결정하는데

있어서 큰 역할을 담당하는 출력패턴의 차원이 충분히 감소될 수 있다. 그러나 PCA영역이 비교사학습을 수행하므로 학습종료 조건인 SSV(상태 안정 조건)을 결정해 주어야 하며 이를 수식으로 나타내면 다음과 같다.

$$SSV = \frac{1}{m} \left(\sum_{i=1}^m y_i(k+1) - \sum_{i=1}^m y_i(k) \right) < \gamma \quad (9)$$

III. SOSL 신경망 구조 및 학습

SOSL 신경망은 여러개의 CBP신경망과 하나의 지역투영신경망으로 구성된다. 지역 투영 신경망은 CBP신경망으로 전파되는 입력패턴의 차원을 감소시키기 위하여 PCA역활을 담당하며 또한 PCA영역에서 사용되는 주성분 추출에 있어서 지역적인 군집화를 만들어낸다. 이를 그림으로 나타내면 다음 그림3과 같다.



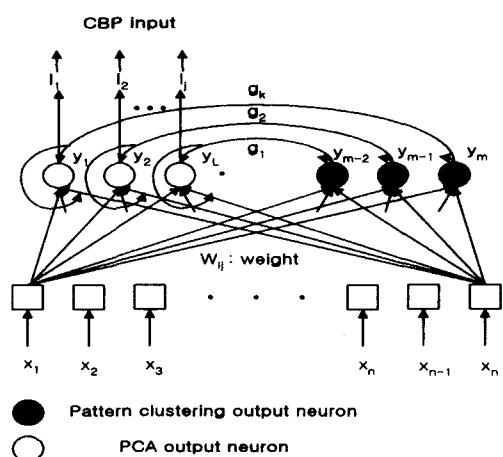
(그림 3) SOSL 신경망 구조

그림3에서 CBP 신경망의 수는 전체 패턴을

지역분할한 군집의 수와 동일하며 각 CBP신경망으로 전파되는 패턴은 하나의 군집에 속한 패턴군이다.

3.1. 지역투영신경망

지역투영 신경망은 2개의 영역으로 구분되며 비교사학습을 수행하는 2층 완전연결신경망이다. 이때 군집화 영역과 PCA영역의 출력뉴런 또한 완전 연결구조를 가진다. 이를 그림으로 나타내면 아래 그림4와 같다.



(그림 4) 지역 투영 신경망 구조

패턴 군집화 영역에서는 입력패턴에 대한 군집화 작업이 이루어 지며 학습단계는 2-1절에서 설명하였다. 그러나 이때 출력뉴런의 값이 실수 값을 가지게 되므로 PCA영역에 존재하는 출력뉴런과 서로 사상시키기 위하여 실수값을 이진값으로 변화시켜주어야 하며 이를 위하여 두 영역간의 가중치값 $G = \{g_{m-l+1}, g_{m-l+2}, \dots, g_m\}$ 를 계산하기 위하여 다음의 수식을 사용한다.

$$Y_i = WX = \sum_{k=1}^m w_k x_k \quad (m-l+1 \leq i \leq m) \quad (10)$$

$$\text{if } y_i = \max(y_i) \text{ then } g_i = 1 \\ \text{else } g_i = 0 \quad (11)$$

PCA영역에서의 학습은 2-1절의수식(6)과 수식(7)에 의하여 수행된다. PCA영역에서의 출력값은 군집화 영역으로부터 전파되어온 신호 g 와 곱하여 새로운 값 I_i^l 로 출력되며 이는 j번째 CBP신경망의 i번째 입력뉴런의 값으로 나타낸다. 이를 수식으로 표현하면 다음과 같다.

$$I_i^l = \sum_{j=m-l+1}^m g_j y_i \quad (12)$$

CBP신경망으로 전파되는 모든 패턴은 군집화되어 각자 다른 영역에서 병렬학습되므로 빠른 학습수렴속도를 얻을 수 있으며 학습의 복잡도 또한 크게 감소할 수 있다.

3.2. CBP신경망

CBP신경망은 여러 역전파 학습알고리즘을 수행하는 다중퍼셉트론 신경망 구조이다. 여러 역전파 신경망에서 학습의 성과는 입력된 패턴과 교사신호에 따른 해공간에서의 복잡도에 따라 달라지며 실제 응용에 있어서 패턴의 수가 많고 패턴의 차원수가 증가할수록 비 선형함수로 표현되는 신경망의 복잡도가 증가하는 것으로 알려져 있다. 이를 해결하기 위하여는 충분한 크기의 중간 뉴런이 존재하여야 하나 이는 네트워크의 크기를 크게 증가시켜야 한다는 단점을 가지고 있다. 본 연구에서는 중간뉴런의 크기를 고려하는 기존의 연구에서 탈피하여 입력뉴런의 수를 줄임으로서 기하학적 공간의 크기를 감소

시키고 또한 하나의 모듈화된 신경망으로 입력되는 패턴의 수를 전체 패턴이 아닌 군집화된 부류패턴들로 제한 함으로써 전체 학습속도 및 복잡도를 낮출 수 있었으며 각 모듈화된 CBP 신경망의 병렬화 구조에 의한 하이브리드 형태의 신경망을 제안하였다. CBP신경망에서 사용된 학습알고리즘은 널리 알려져 있으며 이를 수식으로 나타내면 다음과 같다.

$$O_j^k = f \left(\sum_{i=1}^l w_{ji}^k I_i^{k-1} + \Theta_j^k \right) = f(\text{net}_j) \quad (13)$$

$$w(t+1) = \lambda w(t) + \Delta w = \lambda w(t) + \theta \delta_j I_i \quad (14)$$

δ : error rate , θ : learning rate, λ : momentum

수식(14)에서 δ 는 다음과 같이 표현 가능하다.

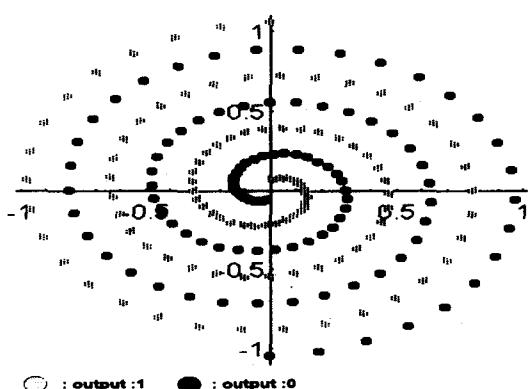
$$\delta_j = (d_j - o_j) f'(\text{net}) \text{ if } j: \text{output unit} \quad (15)$$

$$\delta_j = f'(\text{net}) \sum_i \delta_i w_{ij} \text{ if } j: \text{hidden unit} \quad (16)$$

IV. 시뮬레이션 및 검토

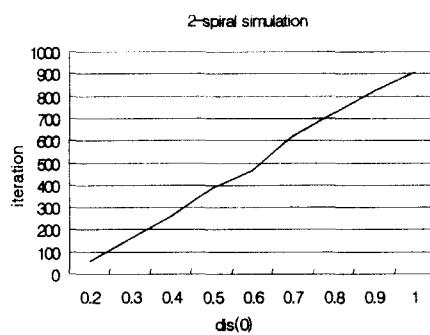
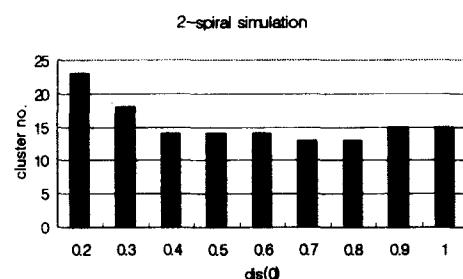
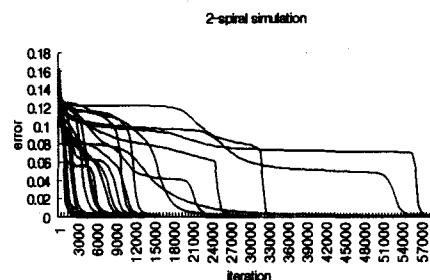
제안한 하이브리드 신경망의 유효성을 검토하기 위하여 문제의 복잡도가 높은 2중 나선형태를 가지는 함수를 실험대상으로 하였다. 그림5에서는 사용된 2중 나선 문제를 보여준다. 그림6은 이중나선 문제에서 사용된 패턴의 군집화 결정 함수인 $Dis(0)$ 값의 변화에 따른 학습반복 횟수를 보여준다. $Dis(0)$ 의 값이 0.2일때는 전체 23개의 군집을 형성하면서 70회 미만의 반복 횟수로 학습을 종료하였으며 군집의 영역을 확대하기 위하여 $Dis(0)$ 의 값을 1로 하였을 경우에는 907회의 학습반복횟수를 나타냈다. 그림7은 $Dis(0)$ 값의 변화에 따른 원 입력패턴의 군집

화된 수를 나타낸다. 전체 200개의 패턴이 Dis 값의 변화에 따라 23개에서 15정도로 분류됨을 볼 수 있다. 각 군집에 포함된 패턴의 수는 최대 20개에서 4개정도로 나타났는데 그 이유는 이중나선 문제가 좌표상에서 (0,0)의 값에 가까울수록 패턴이 밀집되어 있으므로 해당되는 군집의 Dis 값이 달라지기 때문이다. 전체적으로는 이중나선 문제에서 바깥쪽에 위치한 패턴의 Dis 값이 상대적으로 큼을 알 수 있었다. 이중나선 문제의 경우 입력패턴의 차원은 2차원이다. 따라서 CBP 신경망으로 전파되는 패턴의 차원은 PCA신경망에서 처리하지 않았으며 군집화된 패턴은 바로 CBP신경망으로 전파되어진다.

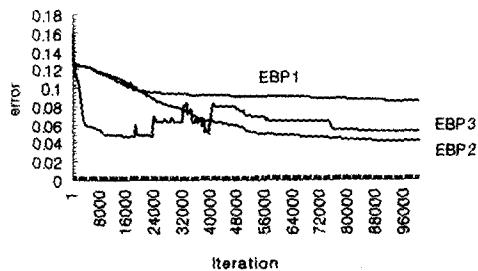


(그림 5) 이중나선(2-spiral)문제

그림8에서는 23개의 군집으로 분류된 CBP신경망의 학습에러를 보여준다. 그림9에서는 동일한 이중나선 문제에 대한 일반 에러 역전파 신경망의 학습에러를 보여준다. 그림8에서 제안한 방법에서는 55,000의 반복횟수안에 수렴됨을 보여주고 있으나 그림9의 에러역전파 신경망에서는 학습이 수행되지 않고 있음을 보여준다.

(그림 6) 이중나선 문제에서 지역 투영 신경망에서의 $dis(0)$ 값 변화에 따른 학습 반복회수(그림 7) 이중나선 문제에서 지역투영 신경망의 $dis(0)$ 값 변화에 따른 군집의 수 변화

(그림 8) 이중나선 문제에 있어서 23개로 군집화된 CBP신경망의 학습에러



(그림 9) 이중나선 문제에 있어서
EBP신경망의 학습에러

V. 결론

본 연구에서는 하이브리드형 모듈화 신경망인 SOSL을 제안하고 시뮬레이션을 통하여 제안한 모델의 유효성을 검토하였다. SOSL 패턴인식 신경망은 기존의 방법과는 달리 입력되는 패턴의 분포와 수에 따라 적응적으로 자신의 구조를 변화시키는 동적 신경망 구조를 가지고 있다. 또한 전체 신경망의 크기를 감소시키기 위하여 주성분 추출 방법인 PCA를 이용하여 지역투영을 함으로써 각 모듈화 신경망의 입력뉴런수를 감소시키고 병렬학습을 수행시킬 수 있다는 장점이 있다. 제안한 신경망 구조가 가지는 문제점으로는 각 신경망 영역에서 학습이 종료되는 시점을 임의로 결정해야 한다는 점이다. 일반적으로 신경망의 학습종료는 원하는 학습반복횟수를 만족하거나 에러율 이하로 에러가 감소할 때 학습이 종료된다. 본 연구에서의 또 다른 고려사항으로는 군집화된 분할패턴을 학습할 때 사용되는 CBP신경망들의 학습종료가 학습이 가장 느린 CBP신경망에 의존된다는 점이다. 이를 해결하기 위해서는 각 CBP신경망에 할당된 문제

의 복잡도가 비슷한 신경망을 구성해야 한다. 따라서 이를 해결하기 위한 앞으로의 연구가 필요하다.

참고문헌

- [1] S. Haykin, *Neural Network A Comprehensive Foundation*, Mcmillan Publishing Co., 1993.
- [2] Y. Hirose, K.Y. Yamashita and S. Hijiya, "Back propagation algorithm with varies the number of hidden units," *Neural Networks*, vol.4, 1991, pp61-66.
- [4] A. Cichocki and R. Ubenhauen, *Neural Networks for Optimization and Signal Processing*, WILEY Publishing co., 1992.
- [5] T.D. Sanger, "An optimality principal for unsupervised learning," *Advances in Neural Information Processing Systems*, D.S., Touretzkey editor, Morgan Kaufman, 1989, pp11-19.
- [6] E. Oja, "Principal components, minor components and linear neural networks," *Neural Networks*, vol.5, 1992, pp.927-935.
- [7] E. Oja, "A simplified neuron model as a principal component analyzer", *J. Math Biology*, vol.15, 1982, pp267-273.
- [8] T. Kohonen, *Self-Organization and Associative Memory*, 3rd ed., Springer-Verlag, Berlin, 1989.
- [9] T. Kohonen, "Improved versions of learning vector quantization," *Int. Joint Conf. Neural networks I*, 1990, pp545-550.

- [10] C. Park, H. Lee, "Hybrid Multiple Component Neural Network Learning with efficient pattern partitioning and PCA", ICONIP'97, New Zealand, 1997, pp.774-779.
- [11] C. Park, H. Lee, "Self_Organized Supervised Learning with Local Projection and Pattern Clustering", ICONIP'98, Japan, 1998, pp.1616-1621.

A Study on Pattern Recognition with Self-Organized Supervised Learning

Chan-Ho Park*

Abstract

On this paper, we propose SOSL(Self-Organized Supervised Learning) and it's architecture. SOSL is hybrid type neural network. It consists of several CBP (Component Back Propagation) neural networks, and a modified PCA neural networks.

CBP neural networks perform supervised learning procedure in parallel to clustered and complex input patterns. Modified PCA networks perform it's learning in order to transform dimensions of original input patterns to lower dimensions by clustering and local projection.

Proposed SOSL can effectively apply to neural network learning with large input patterns results in huge networks size.

* Dept. of Internet Information Science, Bucheon College