

동적 근사곡선을 이용한 자기조직화 지도의 수렴속도 개선

길민욱[†] · 김귀정^{††} · 이 극^{†††}

요 약

기존 Kohonen의 자기조직화 지도(self-organizing feature map)는 학습시 많은 입력 패턴이 필요하며 이에 따른 학습 시간 역시 증가하는 단점이 있다. 이러한 단점을 보완하기 위해 B.Bavarian은 위상학적 위치에 따라 각기 다른 학습률(learning rate)을 갖도록 하였으나 자기조직화가 정밀하게 되지 않는 단점을 갖고 있다. 본 논문에서는 자기조직화 지도의 학습시 계산량이 많은 가우시안 함수를 근사곡선(approximate curve)으로 변형하여 수렴속도를 향상시켰고 학습 횟수에 따라 근사곡선의 폭을 동적으로 변화시킴으로써 자기조직화지도의 수렴도를 개선하였다.

Improved Speed of Convergence in Self-Organizing Map using Dynamic Approximate Curve

Minwook Kil[†], Guijoung Kim^{††} and Geuk Lee^{†††}

ABSTRACT

The existing self-organizing feature map of Kohonen has weakpoint that need too much input patterns in order to converge into the learning rate and equilibrium state when it trains. Making up for the current weak point, B.Bavarian suggested the method of that distributed the learning rate such as Gaussian function. However, this method has also a disadvantage which can not achieve the right self-organizing. In this paper, we proposed the method of improving the convergence speed and the convergence rate of self-organizing feature map converting the Gaussian function into dynamic approximate curve used in when trains the self-organizing feature map.

1. 서 론

인공 신경망 모델들중 Kohonen이 제안한 자기조직화 지도(self-organizing feature map)는 경쟁층에서 한 뉴런과 다른 뉴런들간의 유 кл리디안 거리(Euclidean distance)에 따른 경쟁 관계를 설정하고, 이러한 뉴런들이 자기조직에 의하여 자율 학습한다. 이 신경망은 구조상 수행이 상당히 빠른 모델로써 단

하나의 전방 패스(feed forward flow)를 사용하여 잠재적으로 실시간 학습 처리를 할 수 있는 모델이다 [1-3]. 또한 다수의 입력 벡터에 대한 본질적인 특성들을 1차원 또는 2차원 특징 지도로 형성하여 그에 따른 입력 벡터들의 분류 문제를 자동으로 해결한다. 이 모델은 로봇의 모타제어, 패턴인식 및 영상처리를 포함하는 여러 적용 분야에서 유용한 것으로 입증되었다[4,5]. 이러한 자기 조직화 지도의 학습 방법은 느린 학습률(learning rate)과 평형상태(equilibrium state)로 수렴하기 위하여 학습시 많은 입력 패턴이 필요하다는 단점이 있다. 이러한 문제점을 개선하기 위하여 학습 법칙에 퍼지 개념을 도입한 방법[6], 가우시안 함수(Gaussian function)의 형태로 학습률을

본 논문은 1999년 한남대학교 연구비 지원에 의한 결과임

[†] 문경대학 정보전자기계계열 인터넷정보관리전공 조교수

^{††} 경희대학교 전산과 박사과정

^{†††} 종신회원, 한남대학교 컴퓨터전자통신공학부 컴퓨터공학전공 교수

분포시키는 방법[7,8]등이 제안되었다. B.Bavarian에 의해 제안된 가우시안 함수의 형태로 학습률을 분포시키는 방법은 기존의 자기 조직화 지도보다 높은 수렴도를 얻을 수 있었지만 계산이 복잡한 가우시안 함수를 사용하기 때문에 만족할 만한 수렴속도를 얻지는 못하였다.

본 논문에서는 자기조직화 지도의 학습시 이웃 상호작용 함수(neighborhood interaction function)로 사용된 가우시안 함수를 근사곡선으로 변형하여 수렴 속도를 높이고, 학습 회수에 따라 폭이 감소하는 동적 성질 즉, 승자 뉴런으로부터의 위상학적 위치에 따라 각기 다른 학습률을 갖도록 하여 자기조직화 지도의 수렴도를 개선하였다.

2. 이웃 상호작용 함수

2.1 Kohonen의 자기조직화 지도(1-3,9)

자기조직화 지도는 2개 층의 단순한 구조로 이루어져 있는데 첫 번째 층은 입력층이고 두 번째 층은 경쟁층으로 2차원의 격자(grid)로 되어 있다. 이때 모든 연결들은 첫 번째 층에서 두 번째 층의 방향으로 되어 있으며 층 사이가 완전 연결(fully connected)되어 입력 패턴을 모든 출력층 뉴런이 소유한다.

출력층의 각 뉴런들은 연결 강도 벡터와 입력 벡터의 차를 계산하여 서로 경쟁을 통해 승자 뉴런을 결정한다. 또한 이 뉴런과 이와 인접한 이웃 뉴런들만이 제시된 입력 벡터에 대하여 학습이 허용되는데

그림 1은 승자 뉴런과 그 뉴런 주위에 정의된 이웃 뉴런들을 나타낸다. 이웃의 크기 $N_i(t_k)$ 는 시간 t_k 가 경과함에 따라 서서히 축소된다.

승자 뉴런과 일정한 이웃 집합 안에 있는 뉴런들

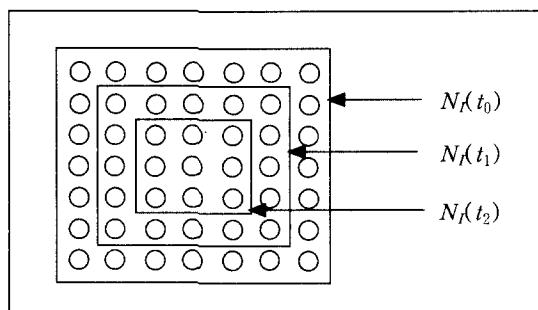


그림 1. 이웃 뉴런의 크기 조정

에 대해서는 측면 활성화(activity)값이 존재하는데 이 값은 멕시칸 모자의 형태를 취하며 활성화 법칙은 식 (1)과 같다.

$$\dot{Y}_i = -R_i(Y_i) + NET_i + \sum_j Z_{ij} Y_j \quad (1)$$

여기서 $R_i(Y_i)$ 는 누수 효과(leakage effect)를, Z_{ij} 는 뉴런 사이의 측면 연결 가중치를 나타낸다.

승자 뉴런을 결정하는 법칙으로 출력층의 뉴런과 입력층의 차원이 같이 때문에 유클리디안 거리로 측정하며 가장 거리가 짧은 뉴런을 식 (2)와 같이 승자 뉴런으로 결정한다.

$$\text{승자} = \min(\|\text{입력 벡터} - \text{출력층 뉴런의 가중치}\|) \quad (2)$$

학습 법칙은 입력과 가중치간의 거리에 학습 상수를 곱해줌으로써 반경 안에 속하는 뉴런들의 가중치가 입력 패턴에 점진적으로 가까이 가는 형태를 취한다. 이에 대한 법칙은 식 (3)과 같다.

$$\begin{aligned} M_i(t_{k+1}) &= M_i(t_k) + \alpha(t_k)[X(t_k) - M_i(t_k)], \\ &\quad \text{for } i \in N_i(t_k) \\ M_i(t_{k+1}) &= M_i(t_k), \quad \text{for } i \notin N_i(t_k) \end{aligned} \quad (3)$$

여기서 $X(t_k)$ 는 입력 벡터, $M_i(t_k)$ 는 출력층 i 뉴런의 가중치, $N_i(t_k)$ 는 이웃 집합, $\alpha(t_k)$ 는 학습 상수를 나타낸다. 학습 상수는 0과 1사이의 값을 가지는 이득항(gain term)으로서 학습 회수가 증가함에 따라 점차 감소하여 출력층 뉴런 가중치들의 입력력을 향한 유동을 완화시켜 신경망이 평형 상태에 도달하도록 하는 역할을 한다.

자기조직화 지도는 2개 층으로 이루어진 단순한 구조를 가지고 있으며 구조상 수행이 상당히 빠르고 모호한 특징들 사이의 관계를 자기 조직화 시켜주는 장점을 가지고 있다. 그러나 느린 학습률과 평형 상태로 수렴하기 위하여 다수의 입력 패턴이 필요하고, 신경망의 크기가 충분히 크지 못할 경우 좋은 성능을 발휘할 수 없다. 또한 가중치들의 값을 임의로 초기화시켜 주어야 하는 단점을 가지고 있다.

2.2 이웃 상호작용 함수(6,8,10,11)

자기 조직화 지도의 수렴도를 높이기 위해 B.Bavarian은 상호작용 함수를 정의하여 이웃 집합 안에 있는 뉴런들에 대하여 승자 뉴런과의 거리에 따라 각기

다른 학습률을 갖게 하는 방법을 제안하였다. 따라서 이웃 집합 안에서 승자 뉴런과의 거리에 관계없이 일정한 학습률을 가지는 Kohonen의 자기조직화지도는 그림 2와 같은 이웃 상호 작용 집합을 이용하여 학습을 행하는 신경망이다.

그러나 B.Bavarian은 상호 작용 집합 대신 그림 3과 같은 형태의 이웃 상호작용 함수를 사용한다.

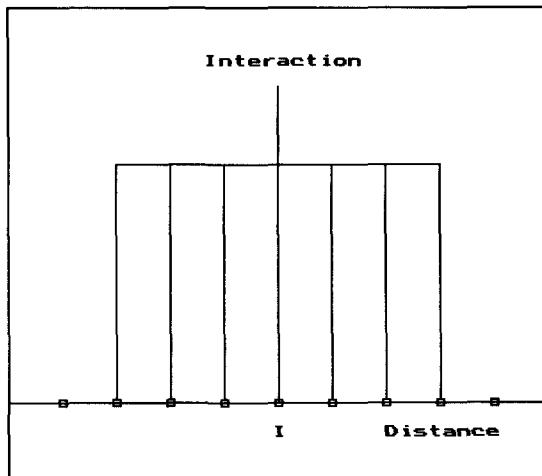


그림 2. 이웃 상호작용 집합

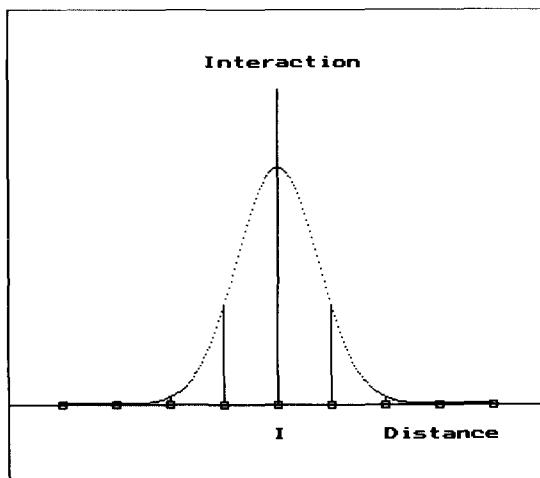


그림 3. 이웃 상호작용 함수

B.Bavarian은 이웃 상호작용 함수로 가우시안 함수를 사용하며 그 수식은 식 (4)와 같다.

$$A_I(i, t_k) = c + d \cdot e^{-\frac{H(i-d)^2}{2\sigma^2}}, \text{ for } i \in N_I(t_k)$$

$$\sigma = |N_I(t_k)| \quad (4)$$

여기서 가우시안 함수의 평차와 폭을 의미하는 c, d, H 는 상수이며, I 는 승자 뉴런을 나타내고, σ 인 $|N_I(t_k)|$ 는 시간에 따라 감소하는 시간 t_k 에서 이웃의 크기를 나타낸다.

식 (4)에서 상수 c, d, H 를 적당히 선택하면 변위는 항상 $[0,1]$ 의 범위를 갖게되고, 그래프가 그림 3과 같은 형태를 취하게 되어 학습 시 이웃 집합 안에 속하는 뉴런들 중 승자 뉴런에서 멀리 떨어져 있는 뉴런 일수록 비례적으로 작은 값의 학습 상수를 갖게 된다.

상호작용 함수를 사용한 신경망의 학습 법칙은 자기조직화 지도의 학습 법칙에 $A_I(i, t_k)$ 를 첨가한 식 (5)와 같다.

$$M_i(t_{k+1}) = M_i(t_k) + \alpha(t_k) A_I(i, t_k) [X(t_k) - M_i(t_k)], \\ \text{for } i \in N_I(t_k)$$

$$M_i(t_{k+1}) = M_i(t_k), \text{ for } i \notin N_I(t_k) \quad (5)$$

이웃 집합의 크기와 학습 상수는 학습 회수가 증가함에 따라 단조 감소한다. 이 신경망은 기존의 자기조직화 지도보다는 세밀한 수렴도를 얻을 수 있으며 그에 따른 입력 벡터의 양을 줄일 수 있다는 장점이 있다. 그러나 이웃 상호작용 함수로서 계산이 복잡한 가우시안 함수를 사용하기 때문에 Kohonen 방법에 비해 수렴속도가 느려지는 단점이 있다.(그림 9 참조)

3. 근사곡선

3.1 동적 이웃 상호작용 함수

본 논문에서는 그림 4처럼 자기조직화 지도의 이웃 상호작용 함수를 학습 횟수에 따라 폭이 감소하는 동적 성질과 승자 뉴런으로부터의 위상적 위치에 따라 각기 다른 학습률을 갖도록 하여 세밀한 자기조직화가 이루어지도록 하였다.

위 방법의 상호작용 함수는 B.Bavarian 방법에서 사용된 식 (4)를 식 (6)과 같이 변형하여 학습 횟수가 증가함에 따라 가우시안 함수의 폭을 변화시켜 승자뉴런의 위상학적 위치에 따라 각기 다른 학습률을 갖도록 하고, 또한 초기의 시간 영역에서 승자뉴런에 집중적으로 몰려있는 가중치 개선 효과를 위하여 평차 σ 를 이웃 크기보다 넓게 선택하여 시간이 지남에

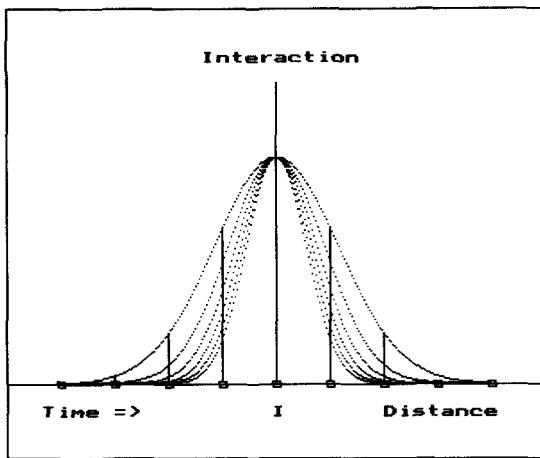


그림 4. 동적 이웃 상호작용 함수

따라 모든 이웃 집합 안의 뉴런에 완만하게 적용되도록 하였다.

$$A_f(i, t_k) = c + d \cdot e^{-\frac{(H + \frac{t_k}{f})(i - D)^2}{2\sigma^2}}, \text{ for } i \in N_f(t_k)$$

$$\sigma = |N_f(t_k)| \quad (6)$$

여기서 c, d, f, H 는 상수이다. 제안한 방법은 B. Bavarian 방법보다 세밀한 자기조직화 지도를 형성할 수 있으나 가우시안 함수가 지수 함수(exponential function)를 사용하여 복잡한 계산 과정을 거친으로 신경망이 평형 상태에 도달하여 수렴하기까지 오랜 시간이 요구되는 문제점을 갖고 있다.

3.2 가우시안 함수의 근사곡선

계산량이 많은 가우시안 함수를 근사곡선으로 변형하여 수렴속도를 향상시키고 학습 횟수에 따라 근사곡선의 폭을 동적으로 변화시킴으로써 자기조직화지도의 수렴도를 개선하고자 한다.

이 방법은 B.Bavarian이 이웃 상호 작용 함수로 사용한 가우시안 함수를 대칭적으로 3구간을 잡아 선형방정식으로 표현한다. 이것은 식 (4)에서 보는 바와 같이 가우시안 함수가 지수 함수를 사용하여 복잡한 계산 과정을 거친으로서 신경망이 평형 상태에 도달하여 수렴하기까지 오랜 시간이 요구되는 문제점을 해결하고자 한 것이다. 또한 배열(array)을 사용하여 선형방정식의 기울기 값을 저장시켜 수렴 속도를 2배 이상 향상시킬 수 있다.

그림 5는 가우시안 함수를 근사곡선으로 변형하기 위하여 대칭적으로 3구간(s_1, s_2, s_3)으로 나누어 선형방정식으로 표현한 것을 나타내며, 그림 6은 본 논문에서 제안한 함수로서 Kohonen 방법과 B.Bavarian 방법의 특징을 모두 수용한다. 즉 이 함수는 학습 횟수에 따라 폭이 감소하는 동적 성질과 승자 뉴런으로부터의 위상학적 위치에 따라 각기 다른 학습률을 갖는 상호작용 함수이다.

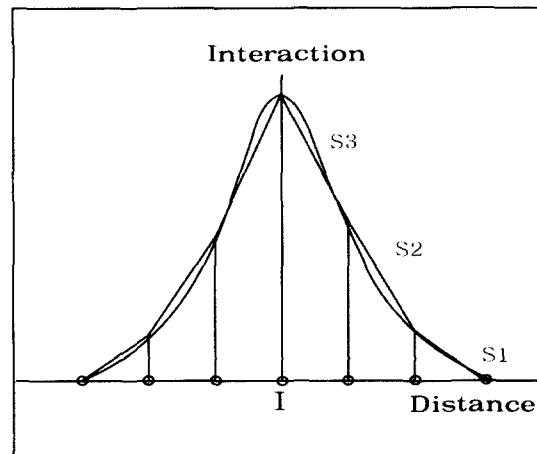


그림 5. 근사곡선의 3구간

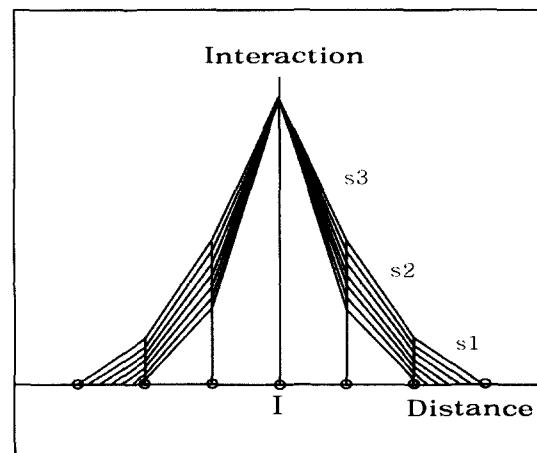


그림 6. 동적 근사곡선

이 선형방정식의 기울기는 가우시안 함수를 이용하여 얻어지며, 이웃 집합의 크기가 변함에 따라 기울기 값도 변할 수 있도록 각각의 이웃 집합에 대하여 기울기 값을 구한다. 이웃 집합의 크기가 결정되면

절편의 값에 상관없이 방정식의 시작점은 ($-N_I(t_k)$, 0.0302)가 되어 기울기 값을 누적시킴으로써 선형적인 근사곡선이 계산되어 진다.

3.3 근사곡선의 일반화

본 장에서는 이웃 집합의 크기에 따라 변하는 가우시안 함수의 근사곡선을 일반화시키는 방법을 제안한다. 제안한 방법은 그림 5에서와 같이 3부분으로 표현한 선형방정식의 기울기 값을 구간별로 나누어 새로운 3개의 함수를 유도하고 이웃 집합의 크기를 변수로 하여 각각의 구간에 해당하는 기울기 값을 갖도록 만들어진다. 본 논문에서는 가우시안 함수를 근사곡선으로 변형하기 위하여 이웃 집합의 크기에 따른 기울기 값을 구간별로 일반화하여 다음과 같은 수식을 제안하였다.

$$\begin{aligned} A1 &= 0.430048 \cdot \sigma^{-0.937354} \quad (a) \\ A2 &= 1.0009 \cdot \sigma^{-0.893198} \quad (b) \\ A3 &= 1.07716 \cdot \sigma^{-1.02494} \quad (c) \end{aligned} \quad (7)$$

여기에서 σ 는 이웃 집합의 크기를 나타내며, A1, A2, A3은 각 구간별 기울기 값을 나타낸다.

식 (7)에 의해서 계산된 기울기 값은 계산 속도를 증가시키기 위하여 배열에 저장되고 이웃 상호 집합의 크기에 따라 저장되어 있는 값을 사용한다. 본 논문에서 제안한 가우시안 함수의 근사곡선을 사용한 신경망의 학습 법칙은 다음과 같다.

$$\begin{aligned} M_i(t_{k+1}) &= M_i(t_k) + \alpha(t_k)(a + A1 \cdot l)[X(t_k) \\ &\quad - M_i(t_k)], \quad \text{for } i \in S1 \\ M_i(t_{k+1}) &= M_i(t_k) + \alpha(t_k)(a + A1 \cdot \frac{\sigma}{3} + A2 \cdot l) \\ &\quad [X(t_k) - M_i(t_k)], \quad \text{for } i \in S2 \\ M_i(t_{k+1}) &= M_i(t_k) + \alpha(t_k)(a + A1 \cdot \frac{\sigma}{3} + A2 \\ &\quad \cdot \frac{\sigma}{3} + A3 \cdot l)[X(t_k) - M_i(t_k)], \\ &\quad \text{for } i \in S3 \\ M_i(t_{k+1}) &= M_i(t_k), \quad \text{for } i \notin N_I(t_k) \end{aligned} \quad (8)$$

$$\alpha = 0.0302, \quad l = 1, 2, \dots, \frac{\sigma}{3}, \quad \sigma = |N_I(t_k)|$$

여기에서 l 은 각 구간에서 정의한 구간별 기울기 A1,A2,A3의 누적 횟수를 나타내며, 출력층 뉴런 i 의 값에 따라 1에서 최대 $\frac{\sigma}{3}$ 까지의 값을 갖는다.

4. 실험결과

위상적인 순서화의 평가와 자기 조직화 정도를 분석하기 위하여 60×60 신경망을 만들어 2차원 위상에 적용시켜 실험하였다. 2차원의 입력 벡터와 사각형 위상을 가진 2차원 신경망을 채택하였으며 입력 벡터는 사각형 위상 위에서 평등 분포되도록 선택하였다.

다음과 같은 3가지 신경망의 성능을 각각 비교 분석하였다.

1. 자기 조직화 지도 (Kohonen의 방법)
2. 상호 작용 함수로서 가우시안 함수 사용 (B. Bavarian의 방법)
3. 상호 작용 함수로서 가우시안 함수의 근사곡선 사용 (제안한 방법)

위의 각 경우에 대하여 입력 벡터, 이웃 집합의 크기, 이웃 집합의 감소되는 반경이 같도록 하여 실험하였다.

2번의 신경망은 상호 작용 함수의 변위가 항상 $[0,1]$ 에 속하도록 정적인 가우시안 함수를 사용하였고, 3번의 신경망은 가우시안 함수를 근사곡선으로 변형하여 이를 상호 작용 함수로 사용하였다. 2번과 3번의 신경망에서 사용된 가우시안 함수의 수식은 식 (6)에서 $c=0, d=1$ 로 설정한 식 (9)와 같으며 초기 H 의 값은 7로 하였다.

$$A_f(i, t_k) = e^{-\frac{(H + \frac{t_k}{f})(i-l)^2}{2\sigma^2}}, \quad \text{for } i \in N_I(t_k)$$

$$\sigma = |N_I(t_k)| \quad (9)$$

본 실험에서 사용된 학습 상수 $\alpha(t_k)$ 는 시간이 지남에 따라 단조 감소하게 했으며 그 수식은 다음과 같다.

$$\alpha(t_k) = A(1 - \frac{t_k}{T_1}) \quad (10)$$

여기에서 A는 초기 학습 상수로서 0.3을 사용하였고 T_1 은 최대 학습 회수이다.

위의 조건을 토대로 신경망의 성능을 평가하기 위하여 식 (11)의 오차 함수(error function)를 사용하였다.

$$\text{error}(t_k) = \sum_i (M_{il}(t_k) - \mu_{il})^2 + (M_{2l}(t_k) - \mu_{2l})^2 \quad (11)$$

여기서 μ_1 , μ_2 는 각 뉴런의 가장 이상적인 수렴점(convergence point)을 나타낸다.

4.1 각 신경망 성능의 비교·분석

그림 7은 신경망의 성능을 식 (11)을 이용하여 시간 영역(time domain)에 대해서 평가한 결과이다. 훈련 횟수를 독립 변수로 한 수렴도를 나타낸 것으로써 Kohonen의 방법과 제안한 방법은 작은 오차 값에 수렴하지만 B.Bavarian의 방법은 큰 오차 값을 가짐을 알 수 있다. 그리고 그림 8은 시간의 변화에 따른 신경망의 성능을 비교한 것으로 제안한 방법이 동일한 시간에 가장 적은 오차 값을 가지고 자기 조직화가 이루어짐을 보여 주고 있다.

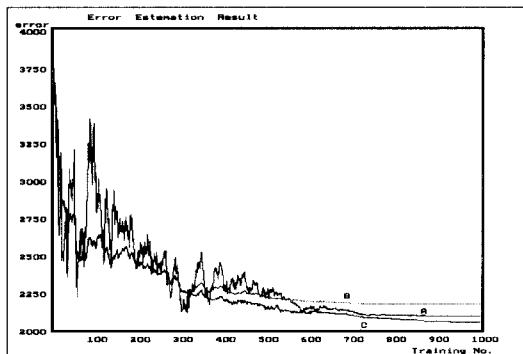


그림 7. 훈련 횟수에 따른 신경망의 성능 비교

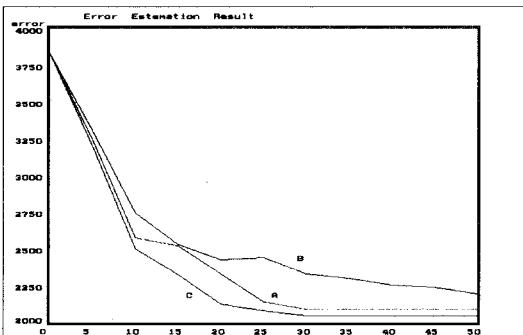


그림 8. 시간의 변화에 따른 신경망의 성능비교
(A: Kohonen의 방법 B: B.Bavarian의 방법 C: 제안한 방법)

그림 9는 훈련 횟수를 독립 변수로 하여 각 신경망의 훈련 횟수를 표시한 것이다. 같은 1000회 훈련하는 동안 소요되는 시간이 Kohonen의 방법은 30초,

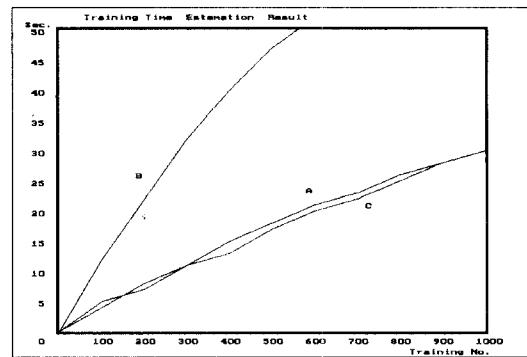


그림 9. 훈련 횟수에 따른 시간의 변화
(A: Kohonen의 방법 B: B.Bavarian의 방법 C: 제안한 방법)

B.Bavarian의 방법은 65초, 제안한 방법은 30초로 B.Bavarian의 방법에 비해 아주 짧은 시간에 훈련이 행하여짐을 알 수 있다. 즉, 세밀한 자기 조직화가 가능함과 동시에 훈련 시간은 B.Bavarian의 방법에 비해 $\frac{1}{2}$ 이상을 단축할 수 있다.

4.2 2차원 위상에의 적용

그림 10은 200회와 1000회를 훈련시킨 신경망의 상태를 2차원 평면상에 나타내었다. 입력 벡터와 같은 좌표 상에 각 뉴런들의 가중치 벡터의 좌표를 나타낸 것으로 가장 근접한 뉴런의 가중치 벡터끼리 연결한 것이다. 다시 말해서 격자상의 선의 교점은 가중치 벡터의 좌표를 나타내고, 두 개의 교점을 연결하는 선은 그 교점의 가중치 벡터를 갖는 뉴런들이 인접하고 있는 것을 나타낸다. 학습결과 제안한 방법이 Kohonen의 방법과 B.Bavarian의 방법보다 세밀한 자기 조직화가 이루어진다.

5. 결 론

Kohonen의 방법은 수렴도는 빠르나 세밀한 자기 조직화가 어렵고, B.Bavarian의 방법은 Kohonen의 방법에 비해 세밀한 자기 조직화가 가능하나 학습 시간이 오래 걸리는 단점이 있다. 본 논문에서는 이러한 Kohonen 방법의 장점인 빠른 수렴속도와 B.Bavarian 방법의 장점인 세밀한 자기 조직화가 가능하도록 동적 근사곡선 방법을 이용하여 소수의 입력 패턴을 가지고 빠른 시간내에 신경망을 학습시킬 수 있는 방법을 제안하였다.

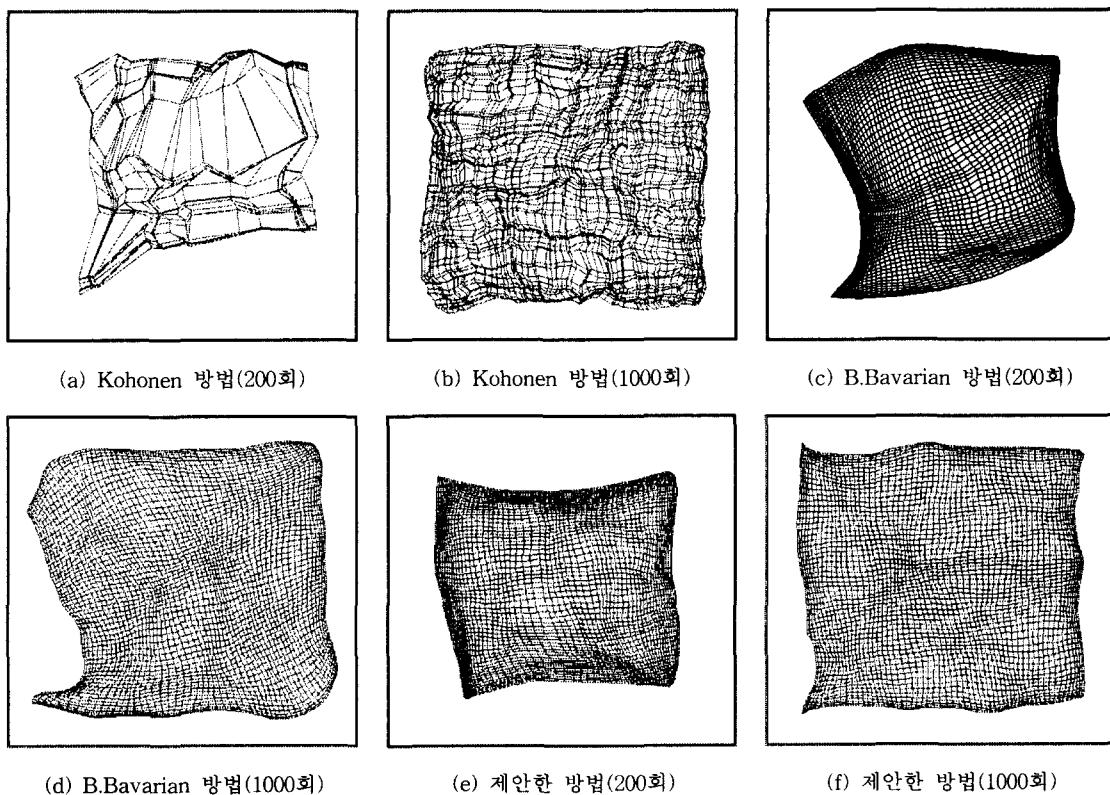


그림 10. 200회와 1000회를 훈련시킨 신경망

본 논문에서는 자기 조직화 지도의 학습시 이웃 상호작용 함수로 사용된 가우시안 함수를 근사곡선으로 변형하여 수렴속도를 증가시키고, 학습 회수에 따라 근사곡선의 폭을 변화시켜 수렴도를 개선하였다. 또한 제안한 방법이 동일한 시간에 가장 적은 오차 값을 가지고 자기 조직화가 이루어지며 짧은 시간에 학습이 행하여짐을 알 수 있다.

참 고 문 헌

- [1] Teuvo Kohonen, "The Neural Phonetic Type-writer", computer, Vol.21, No. 3, pp.11-22, 1988.
- [2] Teuvo Kohonen, Self-Organization and Associative Memory, Springer-Verlag, 1995.
- [3] Teuvo Kohonen, "The Self-Organizing Map", Proc. of the IEEE, Vol.78, pp.1464-1480, Sep. 1990.
- [4] Teubo Kohonen, E.Oja, A.Visa, O.Simula,
- "Engineering applications of self-organizing map", Proc. of the IEEE, pp.1358-1384, 1996.
- [5] P.Demartines and J.Herault, "Curvilinear component analysis: a self-organizing neural network for nonlinear mapping of data sets", IEEE trans. on neural network, Vol.8, pp.148-154, 1997.
- [6] Yong S. Kim, "An Unsupervised Neural Network Using a Fuzzy Learning Rule," 1999 IEEE International Fuzzy Systems Conference Proceedings, Vol. I, pp. 349-353, Seoul, Korea, August 1999.
- [7] Z.P.Lo and B.Bavarian, "Improved Rate of Convergence in Kohonen Neural Network", Proc. of IJCNN, Vol.2, pp.201-206, 1991.
- [8] Z.P.Lo, M.Fujita and B.Bavarian, "Analysis of Neighborhood in Kohonen Neural Network", Proc. of the 5th IPPS, pp.246-249, 1991.

- [9] Teuvo Kohonen, "Generalizations of the Self-Organizing Map", Proc. of IJCNN, Vol.1, pp.457-461, 1993.
- [10] Z.P.Lo and B.Bavarian, "Two Theorem for the Kohonen Mapping Neural Network", Proc. of IJCNN, Vol.4, pp.755-760, 1992.
- [11] Z.P.Lo Y.Yu and B.Bavarian, "Convergence Properties of Topology Preserving Neural Network", IEEE Trans. Neural Networks Vol.4, No. 2, March 1993.



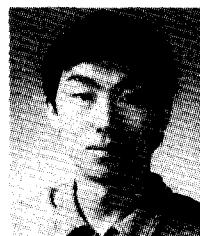
길 민 육

1989년 한남대학교 전자계산공학과(학사)
 1991년 한남대학교 대학원 전자계산공학과(석사)
 1994년 ~ 현재 한남대학교 대학원 전자계산공학과 박사과정
 1997년 ~ 현재 문경대학 정보전자기계계열 인터넷정보관리전공 조교수
 관심분야 : 신경회로망, 음성인식, 멀티미디어, 유전자 알고리즘



김 귀 정

1991년 한남대학교 수학과(학사)
 1996년 한남대학교 전자계산공학과(석사)
 1998년 8월 ~ 경희대학교 전산과 박사과정
 관심분야 : 신경회로망, 멀티미디어



이 극

1983년 경북대학교 전자공학과(전산모듈) 공학사
 1986년 서울대학교 컴퓨터공학과 공학석사
 1993년 서울대학교 컴퓨터공학과 공학박사
 1988년 ~ 현재 한남대학교 컴퓨터 전자통신공학부 컴퓨터공학전공 교수
 관심분야 : 인공지능, 신경회로망, 멀티미디어, 보안시스템, 음성인식