

적응적 자기 조직화 형상지도

Adaptive Self Organizing Feature Map

이 형 준*, 김 순 협*
(Hyung Jun Lee*, Soon Hyob Kim*)

요 약

본 논문에서는 코호넨(Kohonen)의 SOFM(Self-Organizing Feature Map) 알고리즘의 단점을 해결하기 위한 새로운 학습 알고리즘 ASOFM(Adaptive Self-Organized Feature Map)을 제안한다.

코호넨의 학습 알고리즘은 초기화된 연결 벡터에 대하여 극소점에 빠지는 경우도 있다. 그러나 제안된 알고리즘에서는 학습과정중에 네트워크의 상태를 평가할 수 있는 목적함수(object function)을 사용하였고, 이 함수의 출력에 따라 학습의 각 시점에서 적응적으로 학습률의 재조정이 가능하였다. 이 결과, 네트워크의 상태가 최소점에 수렴함이 보증 되고 학습률의 적응성에 의해 임의의 학습패턴에 대한 학습의 일반화 능력이 보장되었다.

또한 제안된 알고리즘은 코호넨의 알고리즘보다 약 70%이상의 학습시간을 단축한다.

ABSTRACT

In this paper, we propose a new learning algorithm, ASOFM(Adaptive Self Organizing Feature Map), to solve the defects of Kohonen's Self Organizing Feature Map.

Kohonen's algorithm is sometimes stranded on local minima for the initial weights. The proposed algorithm uses an object function which can evaluate the state of network in learning and adjusts the learning rate adaptively according to the evaluation of the object function. As a result, it is always guaranteed that the state of network is converged to the global minimum value and it has a capacity of generalized learning by adaptibility.

It is reduce that the learning time of our algorithm is about 30% of Kohonen's.

I. 서 론

음성인식 분야는 고도의 기술과 응용이 집약되어 야하는 분야로써 많은 연구가 진행되어 왔고 다양한 식별기(discriminator)들이 제안되어져 왔다. 그것들

을 살펴보면 DP(Dynamic Programming), VQ(Vector Quantization), HMM(Hidden Markov Model), 신경회로망(NN: Neural Net.)등이 있다. 특히 최근에는 HMM과 신경회로망을 적용한 연구가 활발히 진행되고 있다[11][12]. 신경망모델은 학습방법에 따라 크게 지도학습(supervised learning)모델과 비지도학습(unsupervised learning) 모델의 두 형태로 나누어진다. 지도학습 모델은 학습과정에서 주어진 데

*광운대학교전자계산기공학과

*Department of Computer Engineering, Kwang Woon University

접수일자: 1994년 8월 20일

이타의 클래스(class)에 대한 정확한 정보가 지도신호로 제시되어 그것에 의해서 학습이 이루어지게 된다. 이 모델에는 전향네트워크(feedforward network)인 퍼셉트론(perceptron), 후향네트워크(feedback network)인 홉필드 네트워크(hopfield network) 등이 있다[5]. 자율학습 모델은 학습과정시 학습데이터에 대한 정보가 주어지지 않고 자기조직화로 집단화(clustering)를 하게 된다. 이 모델에는 대표적으로 코호넨이 제안한 SOFM이 있다[5][6]. 이 SOFM 모델은 학습되는 데이터의 기하학적인 2차원의 출력층에 경쟁학습을 통해 사상(mapping)함으로써 학습환경의 확률밀도를 형상지도(feature map)로 회복하게 된다. 이 모델에 의해서 얻어진 출력층의 형상지도는 뇌의 경우와 같은 국소 해부학적 정렬이다. 이 네트워크의 장점은 다른 신경망과는 달리 여러 단계의 후향전달이나 전향전달이 아닌 단 하나의 전향전달을 사용하기 때문에 구조상 수행 속도가 상당히 빠르다는 것과 지도학습에서와 같은 지도신호가 없기 때문에 지도신호의 추정시 생기는 왜곡을 막을 수 있다는 점, 그리고 학습 후 출력층에 형성된 형상지도를 통해서 입력패턴의 분포를 알 수 있다는 점, 경쟁학습을 통해서 연속학습이 가능하다는 점등이다[7]. 이 네트워크의 단점은 비지도 학습을 한다 할지라도 학습시 요구되는 시간과 최소점으로서의 수렴이 실험자의 주관적 관점에서 결정해야 하는 요소, 학습률의 변화패턴과 측면제어(lateral inhibition)에 의존한다는 점이다.

본 논문은 신경망모델 중 코호넨이 제안한 SOFM 알고리즘의 단점을 수정보완한 학습방법을 제안했다. 이 논문의 구성은 II에서 기존의 코호넨의 알고리즘을 기술하고, III에서 제안된 ASOFM 알고리즘을 기술하였고, IV에서 실험 및 고찰을, V에서 결론을 기술하였다.

II. 코호넨의 SOFM(Self-Organizing Feature Map) 알고리즘

1. 코호넨의 알고리즘

자기 조직화 형상지도 알고리즘에서 출력층의 모든 셀(cell, output neuron)은 연결강도 벡터와 임의의 시점에섭 인가된 입력패턴간의 거리가 얼마나 되는지를 계산하고 각 셀들은 학습할 수 있는 특권을 부여받기위해서 서로 경쟁을 한다. 그들중 거리가 가

장 가까운 셀이 승리하게 된다. 이 승자(winner) 셀이 출력신호를 보낼 수 있는 유일한 셀이 되고 나머지 셀의 출력은 무시된다. 이와같은 방법을 경쟁학습이라고 한다. 그리고, 이 경쟁학습을 승자독점(winner take all)원칙이라고도 한다.

코호넨의 알고리즘은 이 경쟁학습과 경쟁학습에서 선택된 승리셀과 적당히 인접한 이웃 셀들만이 인가된 입력벡터에 대하여 학습이 허용된다[7][8].

2. 코호넨 알고리즘의 장점

코호넨의 SOFM 알고리즘의 장점은 자율학습과 인가되는 신호공간을 출력층상에 사상하여 형상지도를 형성함으로써 미지의 입력패턴분포를 분류(classification)을 통해서 시각적으로 표현할 수 있다는 점, 그리고 경쟁학습을 통해 연속적인 학습이 가능하다는 점이다.

자율학습을 함으로써 지도학습시 여러가지 문제점을 해결할 수 있다. 그 중 가장 대표적인 문제는 지도신호를 추정할때에 발생하는 추정오차이다. 지도신호를 주기위해서는 인위적으로 학습패턴의 분포공간을 분할하는 과정이 반드시 필요하게 된다. 이때, 주관적 평가에 의해서, 또는 주변환경에 의해서 생기는 왜곡은 상황에 따라서는 심각한 문제를 야기시킨다. 이와같은 문제는 지도신호가 필요없는 자율학습을 통해 해결될 수 있다. 자율학습은 경쟁학습을 이용하는 학습과 평가함수를 이용하는 학습으로 크게 구분될 수 있다. 코호넨의 SOFM은 경쟁학습을 통하여 학습하는 네트워크로서 지도학습에서 생기는 SOFM은 경쟁학습을 통하여 학습하는 네트워크로서 지도학습에서 생기는 문제점을 없앨 수 있다.

또한, 경쟁 학습과 측면제어를 하기 때문에 자주 인가되는 신호와 모든 연결강도 벡터들의 전체 거리는 감소하고 빈번히 인가되는 신호들을 표현하는데 많은 연결강도 벡터가 사용된다.

$$d(X_n, M_i(t+1)) \leq d(X_n, M_i(t)) \quad (2.1)$$

여기서, X_n 는 자주 인가되는 입력패턴들의 지수(index)이고, i 는 X_n 에 대한 승리셀의 연결강도 벡터의 인덱스이다. 다시말하면, 신호가 인가됨에 의해서 연결강도 벡터가 인가된 신호와의 오차를 줄이기 위해서 수정된다는 것이다. 그러므로, 시간에 따라 입력패턴공간의 확률밀도함수가 연속적으로 변한다 하더라도

연결강도 벡터는 변화하는 밀도하무늬를 근사화하는 방향으로 계속 수정된다. 즉, 연속적인 학습이 가능하다는 것이다. 이와같은 특성은, 일정한 학습패턴을 가지고 일단 학습을 하면 기존의 학습정보를 기반으로 재학습할 수 없는 대부분의 식별기에 비해서 이 알고리즘이 가지는 또하나의 장점이다.

III. 제안된 ASOFM(Adaptive Self-Organizing Map) 알고리즘

1. 코호넨 알고리즘의 단점

경쟁학습 과정에서 연결강도 벡터의 변화량 δM_i 은 다음식과 같이 인위적으로 조정되어지는 학습률 $\alpha(t)$ 의 함수가 된다.

$$\delta M_i(t) = \alpha(t)[X(t) - M_i(t)] \quad (3.1)$$

그러므로, 연결강도 벡터 M_i 의 변화패턴은 학습률의 변화패턴에 의존하게 된다. 학습률의 변화패턴을 결정하는 단계에서 고려해야 할 두가지 문제가 있다. 첫째는 대략적 조정부(rough tuning part)에서 학습률을 얼마의 값까지 감소시킬 것인가 이고, 둘째는 미세조정부(fine tuning part)에서 학습률의 감소폭을 얼마쯤 잡을 것인가이다.

먼저, 대략적 조정구간에서 학습률이 너무 작은 값까지 감소되면, 미세한 조정구간에서 네트워크의 상태가 최소점에 도달하기까지는 너무 많은 시간이 소요된다. 그림 1에서 원의 크기는 학습률의 크기를 나타낸다. 대략적 조정이 끝났을 때 네트워크의 상태는 그림 1의 A상태에 놓이게 되었고 학습률의 크기는 가장 작은 원까지 감소되었다고 하면, A상태와 최소점과의 차이를 미세 조정에서 학습률이 작기때문에 조금씩 학습되어진다. 이때, 학습률이 너무 작으면 A상태로부터 최소점까지 네트워크의 상태가 이동하는데 많은 시간이 필요하게 된다. 이러한 상태에서 학습의 종료는 학습횟수에 의해서 결정되기 때문에 최소점에 수렴하지 않은 상태로 학습이 종료될 수도 있다.

이제, 미세 조정부에서 학습률의 감소폭을 선택하는데 따른 문제에 대해알아보자. 이단계에서 네트워크가 최소점에 도달하는데 가장 크게 영향을 미치는 요소는 학습률 $\alpha(t)$ 의 감소폭이다. 학습되는 패턴공간의 분포에 대하여 학습률 $\alpha(t)$ 이 너무 급격히 감소하면 네트워크의 상태가 최소상태까지 수렴하지 못




그림 1. 네트워크의 상태변화(학습률의 변화가 급격히 감소할 경우)

Fig 1. The change of network state. (In case that learning rate steeply decrease)

하고 임의의 상태에서 머무르게 된다.

그러므로, 학습률의 감소가 지나치게 완만하면 네트워크는 중복학습을 하게되는 문제가 발생한다. 이와같은 상태에서 학습의 반복(iteration) 횟수에 의해서 결정되므로 네트워크의 상태가 최소상태에 도달하기 전에 학습이 종료될 수도 있다. 이러한 경우, 네트워크의 상태변화는 그림 2에서 잘 보여주고 있다.




그림 2. 네트워크의 상태변화(학습률의 변화가 지나치게 완만할 경우)

Fig 2. The change of network state. (In case that learning rate slowly decrease)

위와같이 학습률의 변화패턴에 따른 문제가 심각하므로 신중하게 그 변화패턴을 결정해야만 한다. 만일, 우리가 학습되는 패턴의 확률분포를 알고 있다면 그 분포에 가장 적당한 학습률의 변화패턴을 결정하

여 네트워크를 쉽게 학습시킬 수 있다. 그러나 불행히도 실제 상황에서는 그 분포를 알 수 없기 때문만 아니라 경우에 따라 각기 고유한 분포특성을 갖고 있기 때문에 많은 실험에 의해 결정해야만 한다. 또한, 아무리 신중하고 많은 실험에 의해 선택된 학습률의 변화패턴이라 할지라도 그것이 학습패턴에 최적인지는 보장할 수 없다.

2. ASOFM알고리즘

이와같은 단점을 해결하기 위해 ASOFM알고리즘을 제안한다. 제안된 알고리즘은 연결강도 벡터들을 최적위치로 이동시키는데 결정적인 영향을 미치는 학습률을 적응적으로 적용함으로써 문제를 해결하였다. 기존의 방법은 학습률을 학습이 진행됨에 따라 단조 감소시키면서 학습을 진행하였다. 그러나, 여기서 제안한 알고리즘은 네트워크의 상태를 평가할 수 있는 목적함수를 정의하고 학습시 이것을 이용하여 네트워크의 상태변화를 분석한다. 그리고, 그 분석을 통하여 네트워크의 상태가 최소점으로 수렴하기 위한 최적의 변화패턴을 적응적으로 결정하면서 학습을 진행한다.

본 논문에서 정의한 목적함수는 학습패턴들에 대한 네트워크의 오차함수(error function)이다. 이 함수는 다음과 같은 거리함수(distance function)을 사용하여 네트워크의 상태를 평가한다[2].

$$\frac{1}{N} \sum_j d^2(X_j, M_i) \tag{3.2}$$

j: 학습패턴의 인덱스

i: 각 학습패턴에 대한 승리셀의 인덱스

여기에서, 학습패턴의 수가 적을 경우는 학습패턴 전체에 대하여 네트워크의 상태를 평가할 수 있다. 그러나, 그 수가 많을 경우에는 전체패턴에 대한 평가는 오히려 학습시간의 지나친 증가를 보여준다. 그러므로, 학습패턴이 많을 경우에는 학습패턴의 분포를 나타낼 수 있는 표본(sample)을 추출하여 그 표본에 대한 네트워크의 상태를 분석함으로써 목적함수와 평가를 정당화시킬 수 있다[13][14]. 그리고, 학습률은 목적함수의 분석결과에 따라 변화되어진다. 대략적 분석구간에서 학습률은 어느정도 큰 값(이때, 네트워크의 출력층에는 어느정도 형성저도가 형성된 상태이어야 함)까지 단조감소하면서 학습한다. 이때, 학습률은 코호넨의 알고리즘에서 $(\alpha(t) < 0.01)$ 보다

큰 값이어야 한다[5]. 그 이유는 대략적 조정을 통해서 코호넨의 네트워크보다 학습패턴의 분포를 잘 나타내진 못하지만 좀더 폭넓게 미세조정구간에서 좀더 빨리 최소점에 도달할 수 있기 때문이다.

그리고, 미세조정에서의 학습률은 일정하게 유지되면서 학습이 진행된다. 이때, 목적함수의 출력은 점점 감소하게 된다. 그리고, 그 학습률에 대한 네트워크의 상태가 가장 안정되었을 때 학습률을 감소시킨후 감소된 학습률을 일정하게 유지하면서 학습을 진행한다. 이와같은 방법으로 미세조정구간의 학습은 학습률이 영(0)에 가까워질때까지 계속 진행된다. 그림 3은 이와같은 학습이 진행시 네트워크의 상태변화와 그 상태에 따른 학습률의 변화를 보여주고 있다. 그림 3에서 원의 크기는 학습률의 크기를 나타낸다. 그리고, 그림 4는 제안된 알고리즘의 학습률의 변화패턴을 보여주고 있다. 미세조정구간에서의 네트워크의 상태는 그림 3에서와 같이 초기에 큰 학습률로 빠르게 최소점을 향하여 감소한다. 그리고, 어느정도 학습이 진행되면 학습률은 감소하고 네트워크의 상태는 최소점에 근접하게 된다. 그러므로, ASOFM 알고리즘은 학습이 진행됨에 따라 하나의 학습률로 학습할 시간은 감소하게 되어 그림 4와 같은 학습률의 변화패턴을 갖게 된다. 그리고, 학습률의 감소폭은 학습이 불가능한 상태가 되지않는 한계내에서 임의적으로 선택해도 거의 상관이 없다. 그러나 학습시간을 단축하기 위해서 학습률의 감소폭을 제시할 수도 있다.




그림 3. ASOFM알고리즘에 의한 학습시 네트워크의 상태
Fig 3. The state of network during the learning of ASOFM algorithm.




그림 4. ASOFM 알고리즘의 학습률의 변화
Fig 4. The change of learning rate of ASOFM

이와같이, 제안된 네트워크는 학습시 평가함수를 도입함으로써 임의의 학습패턴에 대하여 네트워크의 상태를 스스로 진단하고 학습률의 변화시점을 찾아내어 스스로 최적의 학습을 진행한다. 그러므로, ASOFM 알고리즘은 최소점까지의 수렴이 보장될 뿐만 아니라 학습시간 단축할 수 있다.

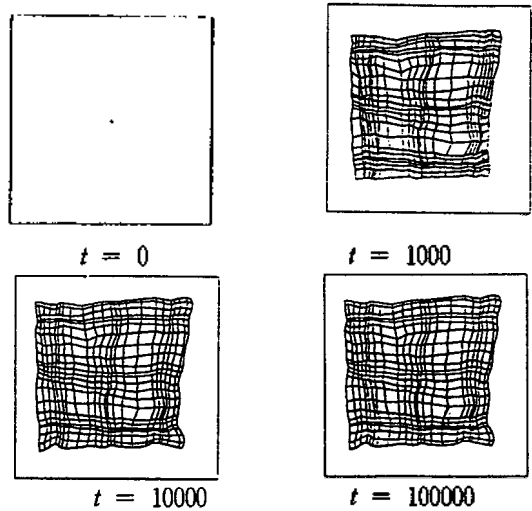
IV. 실험 및 고찰

제안된 ASOFM 알고리즘의 객관적 성능평가를 위하여 코호넨 네트워크와 ASOFM 네트워크를 구성하여 동일한 학습패턴을 가지고 실험하였다. 본 실험에서는 2차원의 일정한 확률분포를 가진 데이터에 대하


여 실시되었다. 학습패턴은 컴퓨터로 무작위 값을 발생시켜 사용하였다. 두 네트워크의 초기 연결강도 벡터는 같은 값을 사용하였다.

1. 실험 I


실험 I은 코호넨의 학습알고리즘에서 발생할 수 있는 문제점들에 대한 실험이다. 그림 5은 코호넨 네트워크가 최소점까지 도달하지 못하는 경우의 학습상태를 보여준다.




$$(b) \alpha(t)_{t=1000} \doteq 0.01, \delta\alpha(t+1)_{t>1000} = \alpha(t) \times 0.99999 \text{ 일 경우}$$



$$(a) \alpha(t)_{t=1000} \doteq 0.01, \delta\alpha(t+1)_{t>1000} = \alpha(t) \times 0.9995 \text{ 일 경우}$$



$$(c) \alpha(t)_{t=1000} \doteq 0.01, \delta\alpha(t+1)_{t>1000} = \alpha(t) \times 0.99999999999 \text{ 일 경우}$$



(d) = 네트워크가 최소점에 수렴한 형상지도
 (t=1000: 대략적 조정구간, t>1000: 미세 조정 구간)

그림 5. 코호넨 알고리즘에서 학습시 최소점에 도달하지 못하는 경우의 형상지도
 Fig 5. Feature map that can't arrive at minimum point in Kohonen's algorithm


그림 5(a)는 미세조정구간에서의 학습률 $\alpha(t)$ 이 너무 급격히 감소할 경우에 대한 실험결과이다. 그림 5(b)는 대략적 조정구간에서 학습률 $\alpha(t)$ 을 크게 감소시켰을 경우에 대한 실험결과이다. 대략적 조정이 끝난후($t=10000$ 에서) 출력층에 형성된 형상지도는 일정한 확률분포를 가진 학습패턴을 대략적으로 나타내고 있음을 알 수 있다. 그러나, $t=10000, t=100000$ 에서의 형상지도는 $t=1000$ 일때의 형상지도가 거의 차이가 없다. 즉, 미세조정 구간에서의 학습은 거의 이루어지지 않았음을 알 수 있다. 그림 5(a)(b)의 실험에서, 우리는 학습률 $\alpha(t)$ 가 지나치게 급격히 감소할 경우 네트워크의 상태는 최소상태에 수렴하지 못하고 임의의 상태에서 머무르게 되는 것을 확인할 수 있었다. 그림 5(c)는 미세조정구간에서 학습률의 감소가 지나치게 완만할 경우에 대한 실험결과이다. 이 실험에서도 역시 대략적 조정이 끝난 후 출력층에 형성된 형상지도는 학습패턴의 확률분포를 대략적으로 나타내고 있다. 그리고, 그림 5(a)(b)와는 달리 $t=10000, 100000$ 에서의 형상지도는 $t=1000$ 에서의 형상지도 보다 실제 학습패턴의 확률분포를 훨씬 잘 나타내고 있음을 알 수 있다. 그러나, 그림 5(d)와 비교해보면 네트워크의 상태가 최소점에 수렴하지 못했음을 알 수 있다. 다시말해서, 그림 2에서 설명한 중복된 학습이 존재했음을 알 수 있다.

2. 실험 II


실험 II는 두 학습알고리즘에 대한 성능평가실험이다. 코호넨 네트워크의 경우 학습의 준비작업으로 학

습패턴에 대한 최적의 학습률의 변화패턴을 결정하기 위하여 많은 실험이 선행되었다. 그림 6은 코호넨의 알고리즘과 본 논문에서 제안된 ASOFM 알고리즘의 성능을 비교 실험한 결과이다. 물론, 두 실험의 초기화는 동일하게 하였다.

그리고, 그림 6(a)는 실험자의 주관적 판단에 의해서 선택된 학습률의 변화패턴을 적용한 실험결과이다. 대략적 조정, $t=1000$ 에서의 결과에서 (a)의 결과가 (b)의 결과보다 학습패턴의 확률분포(일정한 분포)를 잘 나타내고 있다. 그러나 (b)의 결과가 학



(b) 제안된 ASOFM 알고리즘을 이용한 실험



(c) 코호넨 알고리즘의 학습 (d) (c)같은 초기조건의 제안된 학습

그림 6. 코호넨 알고리즘과 제안된 ASOFM 알고리즘의 비교 실험
 ($t = 1000$: 대략적 조정구간, $t > 1000$: 미세 조정구간)
 Fig 6. The comparison of Kohonen's algorithm and proposed ASOFM

습패턴의 확률분포특성(네모안에서 일정한 분포)을 (a)의 결과 보다 폭넓게 나타내는 것을 알 수 있다. 그리고, $t = 10000$ 에서의 결과를 보면 ASOFM 알고리즘이 훨씬 학습패턴의 확률밀도를 잘 나타냄을 알 수 있다. 그리고, 제안된 알고리즘은 30000회의 학습만에 최소점에 수렴하였음을 확인할 수 있다. 그림 6(c)는 동일한 학습패턴공간과 학습물의 변화패턴에 대하여 초기 연결강도가 변화되었을 때 발생한 경우이다. 이것은 코호넨의 네트워크가 초기 연결강도에 의해 국소점에 빠지는 경우로 볼 수 있다. 그림 6(d)는 (c)와 동일한 연결강도로 초기화한 후 제안된 알고리즘에 의해 학습한 결과이다.

이 실험에서 주목할 것은 코호넨의 네트워크에서는 적당한 학습물의 변화패턴을 인위적으로 선택하기 위해서 약 1주일 이상의 실험을 계속해야 했는데 반해서 ASOFM 알고리즘의 실험에서는 이러한 시간이 필요없었다는 점이다. 제안된 알고리즘은 학습물의 변화패턴을 인위적으로 선택하지 않으므로 학습패턴에 대한 최적의 학습물의 변화패턴을 선택하는 시간을 단축할 수 있었다. 뿐만아니라, 최적의 학습물의 변화시기를 네트워크 스스로 선택하여 학습물을 조정함으로써 빠른시간안에 네트워크의 상태가 최소점에 수렴하는 것을 확인할 수 있었다.

V. 결 론

제안된 ASOFM 알고리즘은 기존의 코호넨 알고리즘의 장점을 가지고 있으면서 학습시 일어나는 단점을 적응적 특성으로 보완하여 네트워크가 임의의 패

턴에 대하여 일반성을 갖게 되었다. 알고리즘의 가장 큰 단점은 학습물의 변화패턴을 실험자의 주관적 판단에 의해서 선택한다는 점이다. 그리고 그것에서 파생되는 문제는 학습시 네트워크의 상태가 최소점에 수렴하지 못하는 결과를 초래할 수도 있다는 것이다. 제안된 알고리즘은 이러한 문제를 해결하기 위해 평가함수를 사용하여 학습시 자기진단을 한다. 그리고, 그 진단의 결과에 따라 최적의 학습환경을 스스로 설정하여 학습을 진행하게 된다. 또한, 제안된 알고리즘은 코호넨 알고리즘의 다른 함수들은 그대로 사용함으로써 그 장점을 그대로 유지할 수 있다.

ASOFM 알고리즘의 특징을 알아보면 다음과 같다. 입력 패턴에 대한 자기조직화 형상지도를 2차원의 출력층에 국소해부학적으로 형성할 수 있다. 그리고, 이미 학습된 패턴에 대한 지식을 기반으로 새로운 학습데이터에 대하여 학습을 할 수 있기 때문에 연속 학습이 가능하다. 학습패턴이 확률밀도에 대하여 학습물이 적응적으로 변화하면서 학습을 진행되기 때문에 네트워크가 가장 효율적인 시간으로 최소점에 수렴할 수 있고 임의의 학습데이터에 대하여 일반성을 가진다.

참 고 문 헌

1. 김순협, "국내의 음성인식 기술의 연구동향 및 전망," 제 9회 음성통신 및 신호처리 워크샵, 한국음향학회, pp. 110~116, 1992, 8.
2. 김순협, 강명광외, "새로운 자율학습을 이용한 한국어 음소 인식," 전자공학회 하계종합학술대회 논문집, Vol. 17, No. 1, 1994.
3. X. D. Huang, Y. Ariki and M.A. Jack, *Hidden Markov Models for Speech Recognition*, Edinburgh University, 1990.
4. 진용옥, "음성정보처리 기술 및 음성정보 서비스의 발전과 전망," 제9회 음성통신 및 신호처리 워크샵, 한국음향학회, pp. 110~116, 1992, 8.
5. T. Kohonen, "The self-organizing map," *Proc. of the IEEE*, Vol. 78, No. 9, pp 1464-1477, 1990.
6. T. Kohonen, *Self-organized and associative memory*, Springer Verlag, 3d ed., New York, 312 p, 1989.
7. 김대수, "신경망 이론과 응용(1)," 하이테크정보, 1992.
8. D. P. Morgan and C. L. Scofied, *Neural Networks and Speech Processing*, Kluwer Academic, 1991.
9. T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological Cybernetics*,

Vol.43, No.62, pp 511-521, 1982.

10. T. Kohonen, "Generalizations of the Self-Organizing Map," *Proc. IJCNN '93*, pp 457-461, 1993.
11. K. Ozdemir, et al, "A Modified Kohonen's Neural Network Algorithm," *WCNN*, vol II, 1993.
12. P. D. Wasserman, *Neural Computing Theory and Practice*, Van Nostrand Reinhold, 1989.
13. J. L. Devore, *Probability & Statistics for Engineering and the Sciences*, Brooks/Cole, 1982.
14. 허문열 외, *수리 통계학*, 문운당, 1982.

▲이 형 준 : 제 13권 1호 참조

▲김 순 협 : 제 12권 3호 참조