

## 코호넨의 자기조직화 구조를 이용한 클러스터링 망에 관한 연구

이지영\*

### 목 차

- I. 서론
- II. 자기조직화 신경회로망의 기본이론
- III. 학습효율 개선을 위한 자기조직화 신경회로망
- IV. 실험 및 고찰
- V. 결론
- 참고문헌
- Abstract

### I. 서론

신경회로망 이론은 인공지능의 한 분야로써 인간의 신경 기능과 유사한 동작을 수행하는 로봇이나 컴퓨터에 대한 연구가 진행되어 왔으며, 영상처리 분야와 패턴인식 및 적응 제어 등 여러 응용분야에 그 우수성을 인정받고 있다.[1,2]

신경회로망의 알고리즘으로는 교사신호가 있는 지도학습과 교사신호가 없는 자율학습으로 나뉘어 진다. 지도학습 알고리즘으로는 역전파 알고리즘이 널리 이용되고, 자율학습 알고리즘으로는 인간의 자율신경과 유사한 처리를 수행하는 자기조직화(Kohonen Networks)신경회로망이 널리 이용된다.[1,2,3,4]

자기조직화 신경회로망의 학습규칙은 승자독점(winner take all)의 원리를 이용한다. 즉, 승자

뉴런만이 출력을 낼 수 있으며, 승자와 그 이웃한 뉴런들만이 연결강도를 조정할 수 있다. 생물학적 모델로 고안된 자기조직화 신경회로망은 층내에서 경쟁하는 복잡한 구조를 갖으며, 멕시칸 모자 형태인 측면제어(lateral inhibition)를 사용한다. 이 측면제어에 의한 자기조직화 신경회로망의 학습수행과정은 승리뉴런과 일정한 범위의 이웃하는 뉴런들이 모두 학습을 수행한다. 시간이 지나고 학습 횟수가 점차 증가하면서 이웃 뉴런들의 범위는 점차로 줄어들어 최적화된 승리뉴런만이 남게 된다.[3,4,5,6]

그러나, 기존의 자기조직화 학습알고리즘은 승자 뉴런과 이웃하는 뉴런의 연결강도 수정시 발생한 오차에 상관없이 시간의 함수인 학습계수에 따라서 연결강도를 조정하는 불합리성을 지니고 있다.[3,4] 이 학습계수를 부적절하게 선택할 경우, 필요 이상의 반복횟수를 요하거나 주어진 입력패턴에 대하여 올바른 분류를 수행하지 못하는 문제점이 발생한다. 따라서 이러한 문제점을 해

\* 세명대학교 소프트웨어학과 교수

결하고 학습알고리즘을 빠르게 처리할 수 있는 알고리즘에 대한 연구가 요구된다.[3,4]

위의 문제점을 해결하기 위하여 Martin A. Kraaijveld 와 Jianchang Mao는 비선형함수인 가우시안(Gaussian)함수를 이용하여 학습계수를 가변적으로 개선하는 알고리즘을 제안하였다.[5] 이 알고리즘은 기존의 자지조직화 신경회로망에 비해 학습효율이 향상되었지만, 많은 부가적인 계산이 필요하고 학습에 관여하는 학습 상수 값들의 설정에 많은 시간이 소요되는 문제점을 갖는다.

본 논문에서는 자지조직화 신경회로망의 연결 강도 개선과정에 영향을 미치는 학습계수를 입력 벡터와 연결가중치 벡터의 차에 따라서 가변적으로 개선할 수 있는 알고리즘을 제안하였다. 제안한 알고리즘은 부가적인 계산없이 반복횟수와 학습효율을 향상시켰다.

## II. 자지조직화 신경회로망의 기본이론

자지조직화 신경회로망은 1980년경 핀란드의 헬싱키 공과대학(Helsinki Technology University)의 튜보 자지조직화(Teuvo Kohonen)에 의해 제안된 자율 신경회로망으로 Fig.1과 같은 구조를 갖는다.[3,4]

Fig. 1에 나타낸 자지조직화 신경회로망은 여러 단계의 피드백이 아닌 단 하나의 전방패스 (feed-forward flow)를 사용하므로 구조상 수행이 상당히 빠르고, 입력 데이터의 통계적 분포 변화에 자지조직화 신경회로망이 자동적으로 적응하므로 연속적인 학습이 가능하다. 자지조직화 신경회로망의 학습규칙은 식 (1)에 따라서 수행

된다.

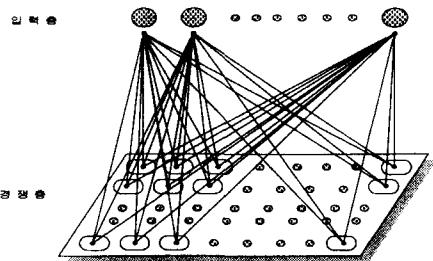


Fig. 1. The structure of Kohonen neural networks.

$$W_{\text{new}} = W_{\text{old}} + a(t)(X - W_{\text{old}}) \quad (1)$$

식 (1)에서  $W_{\text{old}}$ 는 조정되기 이전의 연결강도 벡터이고  $W_{\text{new}}$ 는 조정된 후의 새로운 연결강도 벡터이며,  $a(t)$ 는 학습상수이고  $X$ 는 입력벡터이다.

학습규칙은 승자 뉴런과 이웃한 뉴런들의 연결 강도 벡터를 개선하여 입력벡터에 접근하는 과정으로 이루어진다. 이 경우, 학습의 진행은 승자 뉴런과 일정한 범위의 이웃하는 뉴런들이 모두 학습에 참여한다. 시간이 경과함에 따라 이웃 뉴런들의 범위는 점차로 줄어들어 최적화된 승리 뉴런만이 남게 되며, 시간의 경과에 따른 최적화 과정은 Fig.2와 같다.

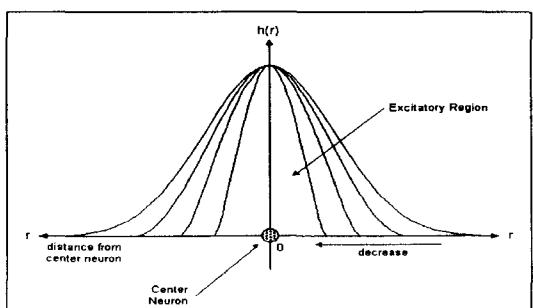


Fig. 2. The decreasing of neighborhood neuron for winner take all.

Fig.2와 같이 최적화된 뉴런의 산출은 식(1)에 의해 이루어지며, 식(1)은 학습계수( $\alpha(t)$ )에 따라서 1회의 학습량이 결정된다.

### III. 학습효율 개선을 위한 자자 조직화 신경회로망

2장에서 언급된 문제를 해결하기 위하여 Martin A. Kraaijveld 와 Jianchang Mao<sup>[5]</sup> 아래와 같은 알고리즘을 제안하였다.[5]

$$w_i(t+1) = w_i(t) + h_c(t)[x_i(t) - w_i(t)] \quad (2)$$

식 (2)에서  $h_c(t)$ 는 가우시안 연결가중치 함수로써 식 (3)과 같다.

$$h_c(t) = h_0(t) \exp\left(\frac{\|r_i - r_c\|^2}{\sigma(t)^2}\right) \quad (3)$$

식 (3)에서  $r_i$  와  $r_c$  는 각각 중심 클러스터와 이웃하는 클러스터를 의미한다. 또한,  $h_0(t)$ 와  $\sigma(t)$ 는 시간함수로써 적절히 감소되어 선택된다. 그러나, 위의 알고리즘은  $\sigma(t)$ 의 부가적인 계산이 필요하며  $h_0(t)$  와  $\sigma_0(t)$ 의 초기값 설정이 잘못되었을 경우, 학습을 올바르게 수행하지 못하는 문제점이 발생한다.

본 논문에서는 발생한 오차(유클리디언 거리) 값에 따라 가변적으로 학습계수를 변화시킬 수 있는 알고리즘들을 제안하였다. 즉, 식(4)와 같이 학습률  $\alpha(t)$ 를 입력패턴(X)과 승자 뉴런의 연결강도( $W_c$ )의 차를 이용하여 가변적으로 생성함으로써, 신경회로망의 단점인 과다한 학습으로 인

한 속도지연 및 분류를 제대로 수행하지 못하는 문제를 해결할 수 있다.

$$\begin{aligned} w_{ij}(t+1) - w_{ij}(t) &= \alpha(t)[x_i(t) - w_{ij}(t)] \\ \Delta w_{ij}(t) &= \alpha(t)d_j \\ \alpha(t) &= \frac{\Delta w_{ij}(t)}{d_j} \\ (\text{단}, d_j &= x_i(t) - w_{ij}(t)) \end{aligned} \quad (4)$$

식 (4)에서 알 수 있듯이 학습계수  $\alpha(t)$ 는 연결강도 공간상에서 기울기의 변화량과 같다. 따라서, Fig.3과 같이 기울기가 점차 증감하는 성질을 이용하는 시그모이드( sigmoid )함수를 적용한 학습계수의 생성 과정을 나타내면 식 (5)와 같이 기술할 수 있다.[1,2]

$$\begin{aligned} \alpha(t+1) &= \alpha(t) + \Delta\alpha(t) \\ \Delta\alpha(t) &= A\left(\frac{1}{1 + \exp(d_j + \theta_j)}\right) \quad (5) \\ (\text{단}, d_j &= (x_i - w_{ij})) \end{aligned}$$

식 (5)에서 A는 초기 상수값을 나타내고,  $d_j$ 는 입력패턴과 연결강도의 차를 나타내며,  $\theta_j$ 는 임계값을 나타낸다. 식 (5)을 식 (1)에 대입하면 식 (6)과 같다.

$$\begin{aligned} w_{ij}(t+1) - w_{ij}(t) &= \alpha(t)[x_i(t) - w_{ij}(t)] \\ \alpha(t) &= A\left[\frac{1}{1 + \exp(d_j + \theta_j)}\right] \\ d_j &= [x_i(t) - w_{ij}(t)] \end{aligned} \quad (6)$$

식 (6)은 입력벡터와 연결강도 벡터의 차에 따라 학습계수를 비선형적으로 생성함으로써 연결강도를 효율적으로 생성한다.

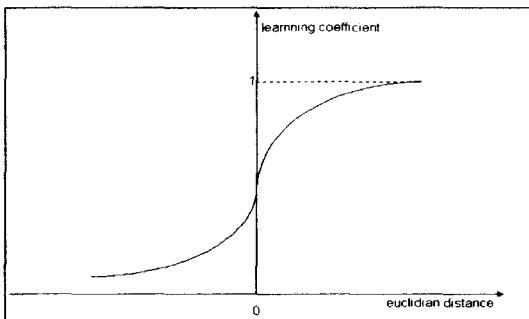


Fig. 3. The change of learning coefficient for sigmoid function.

#### IV. 실험 및 고찰

본 논문에서는 자기조직화의 학습알고리즘을 개선하기 위하여 학습계수를 입력패턴과 연결강도의 차에 따라 가변적으로 갱신하는 알고리즘을 제안하였다. 제안한 알고리즘의 타당성을 검증하기 위하여 Fig.4와 같은 임의 값을 갖는 40개의 연결강도 클러스트링에 적용하였다.

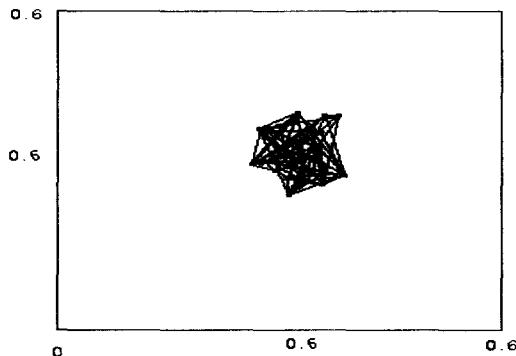


Fig. 4. The initial state with connecting weight of random value

자기조직화 신경회로망의 훈련 패턴들은 Fig.4에 나타낸 바와 마찬가지로 0과 1사이의 균등하

게 분포된 값을 임의적으로 선택하였다.

Fig.5는 본 논문에서 제안한 적용 자기조직화 신경회로망이 1,350번 학습하였을 경우 연결강도의 클러스트링의 상태를 나타 내며, Fig. 6은 14,500번 학습후의 연결 강도의 클러스트링 상태를 나타낸다. 본 실험에서 기존의 자기조직화 신경회로망에 적용한 결과 같은 결과를 얻는데 Fig.5의 상태에서 3000번의 반복횟수를 보였으며, Fig.6의 상태에 이르기 까지는 25000번의 반복횟

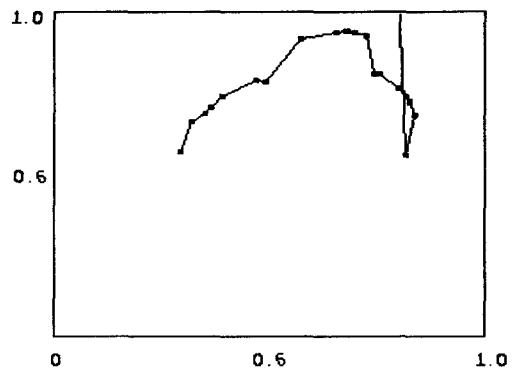


Fig. 5. The state of connecting weight after learning with the 1350 iteration

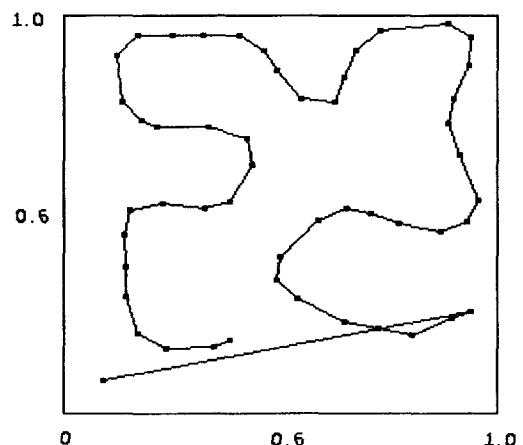


Fig. 6. The state of connecting weight after learning with the 14500 iteration

수를 보였다. 실험결과, 본 논문에서 제안한 알고리즘이 기존의 자기조직화 신경회로망에 비하여 약42%~55%정도 학습효율이 향상됨을 고찰하였다.

## V. 결론

오늘날 신경회로망 이론은 많은 연구를 거듭하여 여러 응용분야에서 적합성을 인정받고 있으나, 초기 학습계수를 잘못 설정하였을 경우(자기조직화 신경회로망 : 0.95이상) 필요이상의 학습횟수를 요하거나 분류를 제대로 문제점이 야기된다.

본 논문에서는 인간의 신경 처리와 유사한 동작을 하는 자율 신경회로망의 일종인 자기조직화 신경회로망의 알고리즘을 분석하여 학습효율을 향상시키기 위하여 연결강도 갱신에 중요한 역할을 수행하는 학습계수( $\alpha(t)$ )를 입력벡터와 연결강도의 차이에 따라서 가변적으로 갱신할 수 있는 알고리즘을 제안하였다. 제안된 알고리즘의 타당성을 검증하기 위하여 임의의 40개 연결강도 클러스터링에 적용하여 보았다. 적용한 결과, Fig.5, Fig.6과 같은 결과를 얻었다. Fig.5와 Fig.6에서 알 수 있듯이 기존의 자기조직화 학습알고리즘에 비하여 본 논문에서 제안한 방법이 약 42%~55% 정도의 반복횟수가 감소하여 학습효율이 향상되어짐을 고찰하였다. 앞으로의 연구방향은 본 알고리즘을 보완하여 필기체 한글 전체로의 확장과 하드웨어로의 구현이 요구된다.

*neural systems*, West Publishing Company, 1992

- [2] Gerald Tesauro David S. Touretzky & Todd K. Leen, *Advances in neural information processing systems 7*, The MIT Press, 1995.
- [3] J.C. Bezdek & N.R. Pal, A note on self-organizing semantic maps, *IEEE Transaction on Neural Networks*, Vol.6, No.5 Sept. 1995, pp.1029~1036.
- [4] N.R. Pal, J.C. Bezdek, & E.C.-K. Tsao, Generalized clustering networks and kohonen's self-organizing, *IEEE Transaction on Neural Networks*, Vol.4, No. 4, July 1993, pp.549~557.
- [5] Martin A. Kraaijveld, & Jianchang Mao, A nonlinear projection method based on kohonen's topology preserving maps, *IEEE Transaction on Neural Networks*, Vol.6, No.3, May 1995, pp.548~559.
- [6] Patrick Thiran, Vincent Peiris, Pascal Heim, & Bertrand Hochet, Quantization effects in digitally behaving circuit implementations of kohonen networks, *IEEE Transaction on Neural Networks*, Vol.5, No.3, May 1994, pp.450~458.

## 참고문헌

- [1] Jacek M. Zurada, *Introduction to artificial*

## On the Clustering Networks using the Kohonen's Elf-Organization Architecture

Ji-Young Lee\*

### Abstract

Learning procedure in the neural network is updating of weights between neurons. Unadequate initial learning coefficient causes excessive iterations of learning process or incorrect learning results and degrades learning efficiency.

In this paper, adaptive learning algorithm is proposed to increase the efficient in the learning algorithms of Kohonens Self-Organization Neural networks. The algorithm updates the weights adaptively when learning procedure runs. To prove the efficiency the algorithm is experimented to clustering of the random weight. The result shows improved learning rate about 42~55% ; less iteration counts with correct answer.

Key words: Network, Learning Algorithm, Neural Network, Elf-Organization Architecture

---

\* Professor, Dept. of software, Semyung University