

## 자기조직화 신경회로망의 학습능률 향상에 관한 연구

홍봉화\* · 허윤석\*\*

### 요약

신경회로망의 학습은 신경사이의 연결강도 개선과정으로 이루어진다. 이때, 학습계수를 잘못 설정하였을 경우, 과도한 학습 횟수를 요하거나, 올바른 학습을 수행하지 못하게 된다. 패턴분류에 자주 이용되는 코호넨 신경회로망의 경우 고정된 학습계수를 사용하여 연결강도를 일률적으로 개선하는 방식을 취함으로서 학습효율을 저하시키는 문제점이 발생한다. 본 논문에서는 코호넨 신경회로망의 학습효율을 향상시키기 위하여 학습계수를 입력벡터와 연결강도 벡터의 차에 따라 가변적으로 적용하는 자율학습 알고리즘을 제안하였다. 제안된 학습 알고리즘의 검증을 위하여 온라인 필기체의 표준 획 분류에 적용하였다. 그 결과 약 1.44~3.65% 정도의 학습 효율이 향상됨을 고찰하였다.

### I. 서론

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

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

코호넨 신경회로망의 학습규칙은 승자독점(winner take all)의 원리를 이용한다. 즉, 승자뉴런만이 출력력을 낼 수 있으며, 승자와 그 이웃

한 뉴런들만이 연결강도를 조정할 수 있다. 생물학적 모델로 고안된 코호넨 신경회로망은 층 내에서 경쟁하는 복잡한 구조를 갖으며, 멕시칸 모자 형태인 측면제어(lateral inhibition)를 사용한다. 이 측면제어에 의한 코호넨 신경회로망의 학습수행과정은 승리뉴런과 일정한 범위의 이웃하는 뉴런들이 모두 학습을 수행한다. 시간이 지나고 학습 횟수가 점차 증가하면서 이웃 뉴런들의 범위는 점차로 줄어들어 최적화된 승리 뉴런만이 남게 된다<sup>[3][4][5][6]</sup>.

그러나, 기존의 코호넨 학습알고리즘은 승자뉴런과 이웃하는 뉴런의 연결강도 수정시 발생한 오차에 상관없이 시간의 함수인 학습계수에 따라서 연결강도를 조정하는 불합리성을 지니고 있다.<sup>[3,4]</sup> 이 학습계수를 부적절하게 선택할 경우, 필요 이상의 반복횟수를 요하거나 주어진 입력패턴에 대하여 올바른 분류를 수행하지 못하는 문제점이 발생한다. 따라서 이러한 문제점을 해결하고 학습알고리즘을 빠르게 처리할 수 있는 알고리즘에 대한 연구가 요구된다.<sup>[3,4]</sup>

\* 경희사이버대학교 정보통신학과 조교수

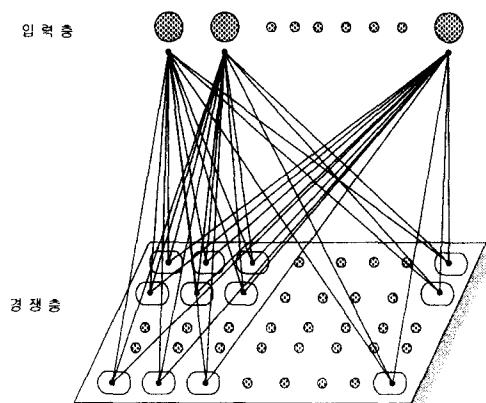
\*\* 충청대학 전자과 교수

위의 문제점을 해결하기 위하여 Martin A. Kraaijveld와 Jianchang Mao는 비선형함수인 가우시안(Gaussian)함수를 이용하여 학습계수를 가변적으로 개선하는 알고리즘을 제안하였다<sup>[5]</sup>. 이 알고리즘은 기존의 코호넨 신경회로망에 비해 학습효율이 향상되었지만, 많은 부가적인 계산이 필요하고 학습에 관여하는 학습 상수값들의 설정에 많은 시간이 소요되는 문제점을 갖는다.

본 논문에서는 코호넨 신경회로망의 연결강도 개선과정에 영향을 미치는 학습계수를 입력벡터와 연결가중치 벡터의 차에 따라서 가변적으로 개선할 수 있는 알고리즘을 제안하였다. 제안한 알고리즘은 부가적인 계산 없이 반복횟수와 학습효율을 향상시켰다.

## II. 코호넨 신경회로망의 기본이론

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



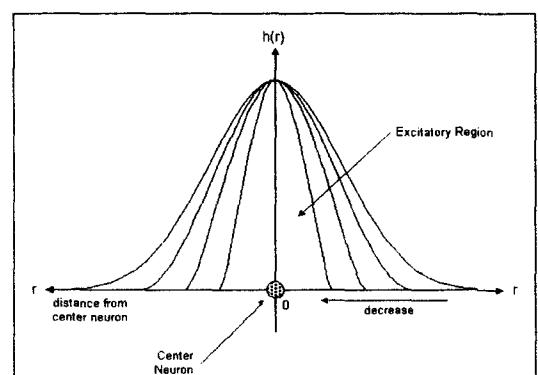
(그림 1) 코호넨 신경회로망 구조

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

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

식 (1)에서  $W_{\text{old}}$ 는 조정되기 이전의 연결강도 벡터이고  $W_{\text{new}}$ 는 조정된 후의 새로운 연결강도 벡터이며,  $\alpha(t)$ 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 그림 2와 같다.



(그림 2) 승자뉴런에 대한 이웃 뉴런의 감소

그림 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 코호 네 신경회로망

II 절에서 언급된 문제를 해결하기 위하여 Martin A. Kraaijveld 와 Jianchang Mao이 아래와 같은 알고리즘을 제안하였다.[5]

$$w_i(t+1) = w_i(t) + h_{ci}(t)[x_i(t) - w_i(t)] \quad (2)$$

식 (2)에서  $h_{ci}(t)$ 는 가우시안 연결가중치 함수로써 식 (3)과 같다.

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

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(유clidean 거리) 값에 따라 가변적으로 학습계수를 변화시킬 수 있는 알고리즘들을 제안하였다. 즉, 학습율  $\alpha(t)$ 를 입력패턴(X)과 승자 뉴런의 연결강도( $W_c$ )의 차를 이용하여 가변적으로 개선함으로써, 신경회로망의 단점인 과다한 학습으로 인한 속도지연 및 분류를 제대로 수행하지 못하는 문제를 해결 할 수 있다.

시그모이드 함수의 성질을 이용하여 학습계수 ( $\alpha(t)$ )를 가변적으로 개선하는 알고리즘은 식 (1)을 정리하여 식 (4)와 같이 나타낼 수 있다.

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

(단,  $d_j = |(x_i(t) - w_{ij}(t))|$ )

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

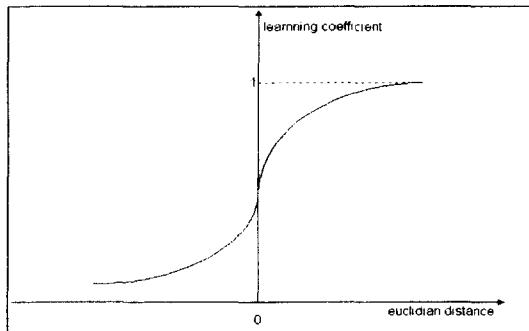
$$\begin{aligned} \alpha(t+1) &= \alpha(t) + \Delta\alpha(t) \\ \Delta\alpha(t) &= A\left(\frac{1}{1 + \exp(-d_j + \theta(t))}\right) \\ (\text{단, } \theta(t) &= -\exp\left(\frac{1}{1+t}\right) d_j = [x_i(t) - w_{ij}(t)]) \end{aligned} \quad (5)$$

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

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

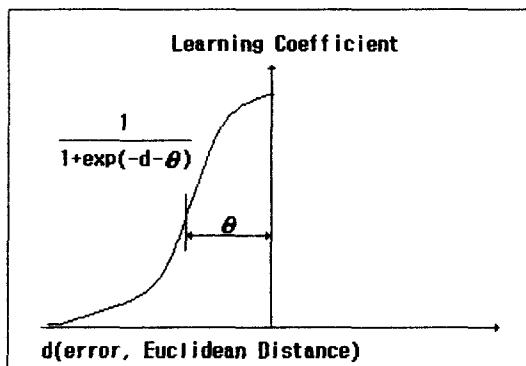
식 (6)은 입력벡터와 연결강도 벡터의 차에 따라 학습계수를 비선형적으로 개선함으로써 연결강도를 효율적으로 개선한다.  $\theta(t)$ 는 학습이 반복됨에 따라 점진적으로 감소되는 함수로서 측면

제어의 효과를 나타낼 수 있도록 한다.



(그림 3) 시그모이드 함수에 의한 학습변수의 변화

따라서 그림 3의 시스모이드 함수의 기울기 변화를 식 (4)를 이용하여 측면제어 형태로 다시 표현하면 그림 4와 같다.

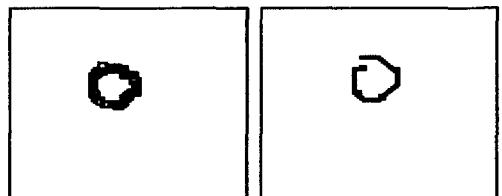


(그림 4) 시그모이드에 의한 학습계수의 변화

## IV. 실험 및 고찰

본 논문에서는 코호넨의 학습알고리즘을 개선하기 위하여 학습계수를 입력패턴과 연결강도의 차에 따라 가변적으로 갱신하는 알고리즘을 제안하였다. 제안한 알고리즘의 타당성을 검증하기

위하여 그림 5와 같은 온라인 필기체의 표준 획(41개의 획)에 적용하였다.



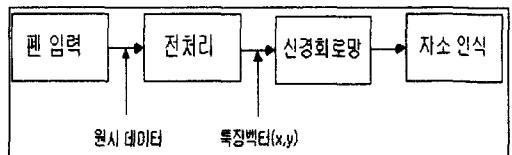
(그림 5) 실험에 사용한 표준 획 스트로크의 예

그림 6은 온라인 필기체 패턴의 표준 획의 원시데이터와 전처리후의 데이터에 대한 예를 나타낸다



(그림 6) 온라인 필기체 표준 획에 대한 원시데이터와 전처리 후 데이터의 예

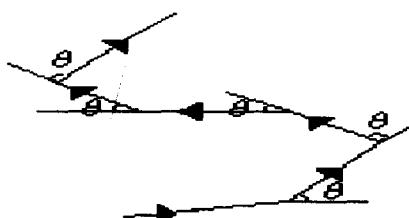
그림 7은 온라인 필기체 패턴의 분류과정을 나타낸다.



(그림 7) 온라인 필기체 표준 획의 분류과정

그림 7에서 펜 입력으로 그림 5에 나타낸 "o"를 입력할 경우 전처리 한 결과 추출된 4 개의 특징점을 나타낸다. 이 특징 점은 시점(starting point)으로부터 종점(ending point)까지 필기 진행 중 굴곡점으로 하며, 굴곡점이 필기 진행 방

향으로 누적된 각도가  $90^{\circ}$ 이하일 때 특징 점으로 추출한다. 추출된 특징점으로부터 코호넨 신경회로망의 입력으로 이용되는 입력벡터의 추출은 그림 8과 같다.



(그림 8) 온라인 필기체에 대한 입력벡터 추출

그림 8의 과정을 거쳐 코호넨 신경회로망의 입력으로 이용되는 입력벡터를 표현하면 식 (10)과 같다.

$$x = \cos(\theta), \quad y = \sin(\theta) \quad (10)$$

$$(\theta = 0^{\circ} \sim \pm 180^{\circ})$$

식 (10)에서  $\theta$ 는 온라인 필기체 획의 방향을 나타내며 온라인 필기체 표준 획 41자는 표 1과 같다.

〈표 1〉 온라인 필기체의 표준 획

번호	획	번호	획	번호	획	번호	획	번호	획	번호	획
1	*	9	2	15	~	25	2	35	h	36	—
2	—	10	3	16	C	26	S			37	↓
3	/	11	5	17	)	27	U			38	≤
4	\	12	6	18	C	28	W			39	≥
5	1	13	8	19	F	29	Y			40	＼
6	7	14	9	20	J	30	Z			41	Γ
7	L			21	<	31	V				
8	O			22	N	32	O				
				23	m	33	ø				
				24	P	34	Q				

본 논문에서 제안한 알고리즘의 타당성을 검증하기 위한 실험조건으로는 2개의 입력단과 50개의 선형적인 경쟁단으로 구성된 코호넨 신경회로망을 사용하였으며, 연결가중치는 0~1사이 값 을 초기 발생하여 실험하였다. 또한, 반복횟수를 25000번으로 제한하여 각 알고리즘의 성능을 비교 분석하여 표2에 나타내었다.

〈표 2〉 온라인 필기체 표준획에 대한 반복횟수의 비교

알고리즘	Kohonen	Mao	제안한 알고리즘
반복 횟수	25000	17521	11296

표 2에서 알 수 있듯이 본 논문에서 제안된 알고리즘이 코호넨 알고리즘에 비하여 약 54.82% 정도 반복횟수를 줄일 수 있었으며, Mao에 의해 제안된 알고리즘에 비해서도 약 35.53%정도의 반복횟수가 개선되었다.

실험 결과, 코호넨 알고리즘은 초기 학습계수를 잘못 설정 ( $\alpha_0(0) = 0.9$ )하였을 경우, 올바른 학습이 수행되지 못하였으며, Mao에 의해 제안된 알고리즘 또한, 초기상수 설정 값이 잘못되었을 경우 올바르게 학습을 수행하지 못하는 문제가 발생하였다.(즉, 참고문헌 [5]에서  $h_{ci}(0) = 0.5$ ,  $\sigma_0(0)=16.66$ ) 표 3은 필기체 표준 획에 대한 코호넨 알고리즘 및 Mao에 의해 제안된 학습알고리즘 과 본 논문에서 제안한 학습알고리즘의 분류율을 나타낸다.

표 3에서 알 수 있듯이 표준 코호넨 알고리즘은 온라인 필기체 표준획 41자의 평균 분류율은 98.1%를 나타내었고 Mao에 의해 제안된 알고리즘은 97.38%분류율을 나타내었다. 반면 본 논문에서 제안한 알고리즘을 적용한 결과 98.82%의 높은 분류율을 나타내었다. 따라서, 분류율면에서

〈표 3〉 온라인 필기체 표준획에 대한 분류율의  
비교

획 번호 \ 알고리즘	Kohonen	Mao	제안한 알고리즘
1	93.2	96.8	98.4
2	93.1	96.7	98.3
3	94.3	96.8	98.5
4	94.5	97.3	98.8
5	96.5	98.4	99.2
6	96.2	97.5	98.2
7	91.1	95.1	98.4
8	91.3	96.5	98.2
9	96.5	98.3	99.2
10	94.2	96.8	97.6
11	97.9	98.3	99.2
12	93.2	95.7	97.5
13	92.5	96.1	97.5
14	94.6	96.2	98.2
15	96.2	98.8	99.6
16	96.3	97.2	98.8
17	96.3	97.2	98.8
18	96.8	97.6	98.7
19	96.6	98.6	99.2
20	93.3	96.4	98.3
21	97.1	98.2	99.8
22	96.7	97.6	98.4
23	95.4	96.6	98.6
24	96.2	97.5	98.8
25	96.4	98.1	99.7
26	92.3	96.2	98.1
27	96.1	98.3	99.2
28	96.3	98.2	99.4
29	96.2	98.4	99.6
30	92.3	94.5	98.3
31	96.5	98.6	99.7
32	92.1	94.5	98.6
33	96.3	98.6	99.6
34	96.3	98.8	99.6
35	96.5	98.6	99.8
36	96.2	98.4	99.2
37	96.2	98.4	99.2
38	96.1	97.2	98.6
39	96.1	98.2	99.2
40	94.3	96.8	98.5
41	97.2	98.5	99.2
평균	95.20	97.38	98.82

기존의 코호넨 알고리즘과 Mao에 의해 제안된 알고리즘에 비하여 우수함을 알 수 있다.

## V. 결론

오늘날 신경회로망 이론은 많은 연구를 거듭하여 여러 응용분야에서 적합성을 인정받고 있으나, 초기 학습계수를 잘못 설정하였을 경우(코호넨 신경회로망: 0.95이상, Mao에 의해 제안된 알고리즘:  $h_{ci}(0)=0.5, \sigma_0(0)=16.666$ ) 필요이상의 학습 횟수를 요하거나 분류를 제대로 문제점이 야기된다.

본 논문에서는 인간의 신경 처리와 유사한 동작을 하는 자율 신경회로망의 일종인 코호넨 신경회로망의 알고리즘을 분석하여 학습효율을 향상시키기 위하여 연결강도 개선에 중요한 역할을 수행하는 학습계수( $a(t)$ )를 입력벡터와 연결강도의 차이에 따라서 가변적으로 개선할 수 있는 알고리즘을 제안하였다. 제안된 알고리즘의 타당성을 검증하기 위하여 온라인 필기체 기본 획 41자에 적용한 결과, 표2와 표3같은 결과를 얻었다. 표2에 알 수 있듯이 코호넨 학습알고리즘과 Mao에 의해 제안된 학습알고리즘에 비하여 본 논문에서 제안한 방법이 약 35.53%~54.82%정도의 반복횟수가 감소하여 학습효율이 향상되어짐을 고찰하였다. 또한 표3에서 알 수 있듯이 온라인 필기체 표준획 41의 분류율면에서도 본 논문에서 제안한 알고리즘이 기존의 코호넨 알고리즘과 Mao에 의해 제안된 알고리즘에 비하여 약 1.44%~3.62%정도 분류율이 향상하였다. 앞으로의 연구 방향은 본 알고리즘을 보완하여 필기체 한글 전체로의 확장과 하드웨어로의 구현이 요구된다.

## 참고문헌

파라메타 설정에 관한 연구,"『세명대학교 산업기술연구소 논문집』, 5, 1998, pp.127~133.

- [1] JACEK M. ZURADA, *Introduction to artificial neural systems*, West Publishing Company, 1992.
- [2] Gerald Tesauro David S. Touretzky and Todd K. Leen *advances in neural information processing systems 7*, The MIT Press, 1995.
- [3] J.C. Bezdek and N.R. Pal, A note on self-organizing semantic maps, *IEEE Transaction on Neural Networks*, 6(5), Sept. 1995, pp.1029~1036.
- [4] N.R. Pal, J.C. Bezdek, and E.C.-K. Tsao, Generalized clustering networks and kohonen's self-organizing, *IEEE Transaction on Neural Networks*, 4(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*, 6(3), May 1995, pp.548~559.
- [6] Patrick Thiran, Vincent Peiris, Pascal Heim, and Bertrand Hochet, Quantization effects in digitally behaving circuit implementations of kohonen networks, *IEEE Transaction on Neural Networks*, 5(3), May 1994, pp.450~458.
- [7] 이승주, "지수함수 및 시그모이드 함수를 이용한 신경회로망 학습효율 개선에 관한 연구," 경희대학교 대학원 박사학위논문, 1999. 8.
- [8] 홍봉화, 이승주, "코호넨 신경회로망의 학습

## On the enhancement of the learning efficiency of the self-organization neural networks

Bong-Hwa Hong\* · Yun-Seok Heo\*\*

### 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 Self-Organization Neural Networks. The algorithm updates the weights adaptively when learning procedure runs. To prove the efficiency the algorithm is experimented to classification of strokes which is the reference handwritten character. The result shows improved classification rate about 1.44~3.65% proposed method compare with Kohonan and Mao's algorithm, in this paper.

Key words : neural network, neurons, self-organization

---

\* Assistance Prof. Dept. of Information and Telecommunication, Kyunghee Cyber University

\*\* Professor, Dept. of Electronic Information, Chung Cheong University