

고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map

論 文

52D-5-3

Using Higher Order Neuron on the Supervised Learning Machine of Kohonen Feature Map

鄭 鍾 秀* · 萩原 將文**

(Jong Soo JUNG · Masafumi HAGIWARA)

Abstract - In this paper, we propose Using Higher Order Neuron on the Supervised Learning Machine of the Kohonen Feature Map. The architecture of proposed model adopts the higher order neuron in the input layer of Kohonen Feature Map as a Supervised Learning Machine. It is able to estimate boundary on input pattern space because of the higher order neuron. However, it suffers from a problem that the number of neuron weight increases because of the higher order neuron in the input layer. In this time, we solved this problem by placing the second order neuron among the higher order neuron. The feature of the higher order neuron can be mapped similar inputs on the Kohonen Feature Map. It also is the network with topological mapping. We have simulated the proposed model in respect of the recognition rate by XOR problem, discrimination of 20 alphabet patterns, Mirror Symmetry problem, and numerical letters pattern problem.

Key Words : Kohonen Feature Map, Higher Order Neuron, XOR, Pattern, Mirror Symmetry, Numerical Letters.

1. 서 론

생물의 신경 조직 및 뇌의 정보처리 방식을 도용하여 인간과 같은 유연성이 있는 정보처리를 실현하고자 하는 시도가 인공적 신경회로망(뉴럴 네트워크)을 이용하여 활발하게 연구되고 있다. 이러한, 뉴럴 네트워크의 특징은 병렬 분산처리, 학습능력 및 범화능력이 있으며, 뉴럴 네트워크의 특성에 의해 교사 학습 모델과 교사 없는 학습으로 분리된다. 교사 학습기로서는 Back Propagation이 대표적인 모델이며 여러 분야에서 뛰어난 특성을 발휘하고 있다[1].

한편, 비 교사 학습으로는 대표적인 모델이 Topological Map를 도입한 Kohonen Feature Map이 있다[2][3][4]. Kohonen Feature Map는 입력 데이터의 유사 정도를 동적으로 찾아내어 유사한 입력들을 네트워크 상의 가까운 곳에 배치하는 특징이 있다. 즉, 입력 데이터에 대하여 선택적으로 반응하는 네트워크 구조이다. 또한, Kohonen Feature Map는 맵 내의 상호결합이 불필요한 동시에 미분 연산이 필요 없으므로 간결한 네트워크로 형성되는 것이 특징이다. 따라서, 이러한 특성들을 이용하기 위하여 Kohonen Feature Map에 교사 신호를 도입한 교사 학습기의 Kohonen Feature Map이 H. Ichiki, M. Hagiwara, 및 M. Nagakagawa 등에 의해 제안

되어 패턴인식 및 연상기억 등에서 뛰어난 특징들을 소개하였다[5][6]. 그러나, 기존의 모델은 일차 뉴런만으로 구성되어 있는 단순한 형태의 구성으로 이루어져 있어, 일차 뉴런에 의한 선형분리 기능만이 가능한 형태로 되어있다. 그러나, 실질적인 패턴인식의 문제에 있어서는 선형 분리문제 보다 비선형 분리 문제가 더 많이 요구된다. 이러한 문제를 해결하기 위한 방안으로 일차 다층형(Single Multi Layer)과 고차 단층형(Multiple Single Layer) 형태의 네트워크가 제안되었다. 특히, 고차 뉴런을 이용한 고차 뉴럴 네트워크의 경우, 간단한 네트워크 구조를 형성하고 있음에도 고차 뉴런에 의한 비선형 분리가 가능한 것이 특징이다. 그러나, 고차 뉴런을 도입함에 있어 뉴런의 방대한 증가를 근본적으로 해결 할 수 있는 대체방안이 없는 것이 가장 큰 문제점으로 지적되고 있으나 일정한 수의 뉴런을 형성하는 알고리즘이 제안되어 그 특성들을 확인하고 있다[7][11][12]. 더욱이, 이러한 특성을 계층형 네트워크에 적용한 결과 위치변형, 확대 및 축소 등에 대응되는 사실이 발표되었다[8][10][11]. 이러한 특성들을 더욱 활성화하기 위하여 본 논문에서는 고차 뉴런을 Kohonen Feature Map에 적용하여 그 특성을 비교한 결과, 비선형 분리 문제에 있어서 본 제안 모델이 종래의 모델 보다 뛰어난 성능을 발휘하여 국소(局所) 집중반응을 정확하게 추출할 수 있었다. 또한, 이러한 비선형 분리에 의한 복잡한 패턴 분리가 가능하여 여러 가지 응용이 가능한 사실 또한 알 수 있었다. 그러나, 고차 뉴런을 이용함에 있어 고차 뉴런의 근본적인 결점인 뉴런의 증가를 억제하기 위해 본 논문에서는 최적의 뉴런만을 형성하기 위해 2차 뉴런만을 생성하는 알고리즘을 도입하였다[7][8][11]. 본 모델은 비 교사 학습기인 Kohonen Feature Map의 알고리즘을 기초로 하여 교사 학습

* 正 會 員 : 경인여자대학교 兼任教授

** 非 會 員 : 日本 KEIO大學 情報工學科 助教授 · 工博

接受日字 : 2001年 9月 25日

最終完了 : 2003年 3月 17日




그림 1 교사 학습기의 Kohonen Feature Map.
 Fig. 1 Kohonen Feature Map as a Supervised Learning Machine.

기로 구축된 Kohonen Feature Map에 교사 뉴런을 적용하여 패턴 분류 문제를 중심으로 시뮬레이션 하였다.

2. 교사 학습기의 Kohonen Feature Map 구조.

Kohonen Feature Map는 입력층과 출력층인 2차원 뉴럴 시트(Neural Sheet)의 구조로 형성되어 있으며 동작은 입력 벡터에 대하여 2차원의 뉴럴 시트 상에서 거리 관계를 구하여 학습되어진 뉴런이 각각 반응하는 특징을 갖고 있는 즉, 토폴로지 맵을 실행하는 네트워크이다[2]. 따라서, 교사 학습기로서 Kohonen Feature Map는 입력 벡터와 교사 벡터를 하나의 학습 벡터로 학습하는 방식이다[5][6]. 교사 학습기의 Kohonen Feature Map 구조는 그림 1과 같고 비 교사 학습 뉴럴 네트워크의 대표적인 모델인 Kohonen Feature Map의 특징을 유지하면서 교사 학습기로 변형하기 위한 입력 벡터 I_n 는

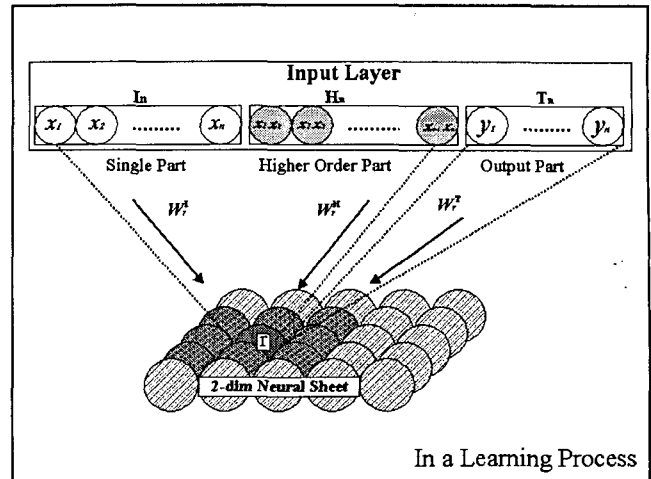
$$I_n = (x_1, x_2, \dots, x_n) \tag{1}$$

이다. 여기서, x_n 는 입력 벡터이고, n 은 입력 벡터 수이다. 입력 벡터에 대응하는 교사 벡터 T_n 는

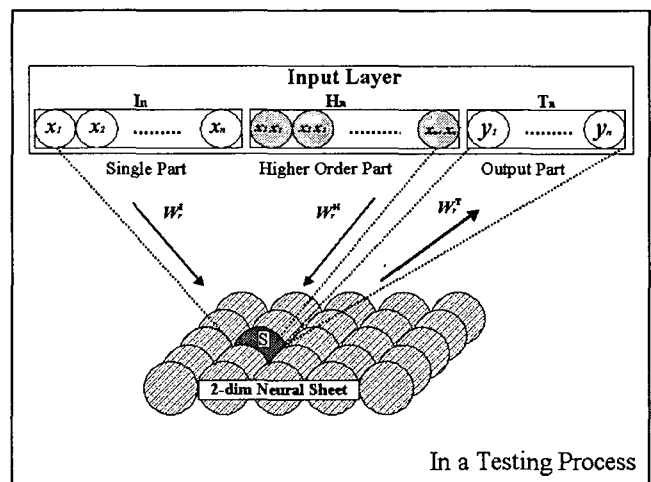
$$T_n = (y_1, y_2, \dots, y_n) \tag{2}$$

이며 여기서, y_n 는 교사 벡터이고, n 은 교사 벡터 수이다. 네트워크 상에서 학습을 하기 위해서는 입력 벡터와 교사 벡터를 하나로 결합된 학습 벡터 X_n 는

$$X_n = \alpha \begin{bmatrix} I_n \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ T_n \end{bmatrix} \tag{3}$$



In a Learning Process



In a Testing Process

그림 2 고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map.

Fig. 2 Using Higher Order Neuron on the Supervised Learning Machine of Kohonen Feature Map.

이다. 단, 입력 벡터의 크기에 의해 맵이 형성 되도록 입력 벡터에 대하여 가중치를 적용하여 $\alpha \gg 1$ 로 한다. 그러므로, 입력 벡터의 가중치에 의한 교사 벡터의 연결강도가 투형 되는 형태의 맵이 형성된다. 따라서, 연결강도는 다음과 같이 분리하여 표현된다.

$$W_r = \begin{bmatrix} W_r^I \\ W_r^T \end{bmatrix} \tag{4}$$

여기서, r 은 맵 상에서 뉴런의 위치를 나타내는 2차원 위치 벡터이고, W_r^I 는 입력 벡터에 해당하는 연결강도이며, W_r^T 는 교사벡터에 대한 연결강도 이다.

3. 제안모델의 네트워크 구조 및 알고리즘.

본 논문에서 이용된 고차 뉴런의 특징은 고차 뉴런에 의한

비선형 분리가 가능함에 있어 일차 뉴런이 갖고 있는 구조적 결합, 즉 선형분리 기능만이 가능한 기능을 개선하여 실질적인 패턴인식의 문제에 있어 비 선형 분리 문제의 많은 한계를 극복하는데 있다. 따라서, 이러한 문제를 해결하기 위해 심플한 네트워크 구조를 갖고 있는 특징과 고차 뉴런에 의한 비선형 분리가 원활히 이루어지는 특징 등을 갖고 있는 고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map을 제안한다. 본 제안 모델의 구조는 종래형의 모델 즉, 교사 학습기의 Kohonen Feature Map의 입력 층에 고차 뉴런을 도입하는 형태로 고차 뉴런은 (1)식의 입력 벡터에 대하여 각각 자신의 입력 벡터를 대입하는 형태로 고차 뉴런을 복합적으로 산출하는 방정식으로 입력 부분에서 고차 뉴런을 형성하였다. 따라서, 고차 뉴런의 입력 벡터 H_n 는

$$H_n = (x_1 x_2, x_1 x_3, \dots, x_{n-1} x_n) \quad (5)$$

이다. 또한, 고차 뉴런을 포함하고 있는 입력 벡터를 교사 학습 데이터로 학습하기 위해서는 고차 뉴런을 포함하고 있는 입력 벡터와 교사 벡터를 하나로 형성된 학습 벡터로 형성할 필요가 있다. 따라서, 고차 뉴런을 갖고 있는 입력 벡터 X_n^p 는

$$X_n^p = \alpha \begin{bmatrix} I_n \\ H_n \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ T_n \end{bmatrix} \quad (6)$$

이다. 교사 벡터에 있어 종래의 교사 학습기의 Kohonen Feature Map과 동일하게 입력 벡터의 가중치를 부가, 입력 벡터에 의해 맵이 형성 되도록 한다. 따라서, 고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map 상의 연결강도 W_r^p 는 다음과 같다.

$$W_r^p = \begin{bmatrix} W_r^I \\ W_r^H \\ W_r^T \end{bmatrix} \quad (7)$$

여기서, r 은 맵 상에서 뉴런의 위치를 나타내는 2차원 위치 벡터이고, W_r^H 는 고차 뉴런 벡터에 해당하는 연결강도이다. 본 제안 모델의 구조는 그림 2와 같다.

본 제안 모델의 학습은 입력 벡터 X_n^p 을 네트워크에 입력하여 y_r 출력을

$$y_r = X_n^p \cdot W_r^p \quad (8)$$

으로 계산되며, 식별기구로서는 2차 뉴럴 시트, 즉 맵 상에서 가장 발화하고 있는 뉴런의 출력 y_{max} ,

$$y_{max} = \max(\sum I_n W_n^I + \sum H_n W_n^H + \sum T_n W_n^T) = \max[X_n^p \cdot W_r^p]$$

$$= \max[y_r] \quad (9)$$

이다. 여기서 최대치를 나타내는 뉴런의 위치를 S 라고 하며, 최대로 발화된 뉴런의 출력 값을 1로 하고 나머지는 0으로 한다. 그리고, 각 뉴런에 대한 연결강도는

$$W_n^{(new)} = W_n^{(old)} + \epsilon h_{rs} (X_n^p \cdot W_n^{(old)}) \quad (10)$$

으로 변경되며 여기서, ϵ 는 결합강도의 변환 계수이고 h_{rs} 에 의해 학습하는 연결강도의 범위가 정하여 진다. 여기서, h_{rs} 는

$$h_{rs} = \exp \frac{-||r-s||^2}{\sigma^2} \quad (11)$$

이며, σ 는 근접학습의 범위를 결정하는 파라메타이다. σ 가 크면 클수록 학습 범위가 넓어진다. 통상 σ 는 초기단계에서는 큰 범위에서 학습을 하며 점차 감소시킨다. 또한, 변경된 연결강도를 절대값화 한다. 상기 알고리즘을 반복함으로써 토 폴로지 맵이 형성되며, 형성된 맵의 특징으로 입력 데이터간의 거리 관계가 정확하게 맵 상에 이미지화되어 보존되며 빈번한 입력 값은 그렇지 않은 입력 값에 비하여 넓은 범위로 형성된다. 따라서, 고차 뉴런을 이용함으로써 국소 집중반응 및 특징 유출이 용이하여 기존의 일차 뉴런 구조의 모델이 갖고 있는 문제점들을 해결 할 수 있으며 더욱이, 여러 응용분야에 적용이 가능하도록 학습회수의 절감 및 인식율의 향상을 얻을 수 있었다.

4. 실험 및 결과분석.

제안된 고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map의 유효성을 검사하기 위해 본 논문에서는 4가지 시뮬레이션의 결과를 비교하였다. 본 제안 모델은 비 교사 학습기의 대표적인 모델인 Kohonen Feature Map에 교사 학습을 적용한 교사 학습기의 Kohonen Feature Map에 고차 뉴런을 적용한 형태의 네트워크 구조로 Kohonen Feature Map의 기본적인 학습 알고리즘을 변형없이 사용하였다. 따라서, Kohonen Feature Map의 특성인 심플한 네트워크 구조인 단층형태의 네트워크 구조를 갖고 있으며 맵 내의 상호결합과 미분연산이 필요 없는 간결한 네트워크로 형성되는 특징을 갖고 있다. 상기 이러한 특징들 위에 고차 뉴런의 특징인 비 선형 분리 기능이 부가되어 한층 특징 유출이 용이한 형태로 네트워크 구조가 개선되었다. 여기서, 본 제안 모델의 특징을 알아보기 위해 아래 4가지 형태의 시뮬레이션을 가지고 결과 분석을 했으며 각 시뮬레이션의 목적과 필요성 및 시뮬레이션 방법에 대하여 해당란에 자세히 기술한다.

4.1. XOR의 문제.

본 제안 모델의 동작을 조사하기 위해 비교적 간단한 문제이며, 선형분리 불가능한 표 1의 XOR의 문제를 가지고 시뮬레이션을 하였다. 고차 뉴런을 이용한 Kohonen Feature Map

표 1 XOR 문제.

Table 1 XOR Problem.

입력 벡터	교사 신호
[-1, -1]	-1
[-1, +1]	+1
[+1, -1]	+1
[+1, +1]	-1

은 정규화 했으며, 고차 뉴런을 포함하고 있는 입력 벡터와 교사 벡터는 각각 같은 2진수인 -1과 1을 가지고 시뮬레이션을 하였다. Kohonen Feature Map은 종래형과 비교하기 위해 5X5개의 2차원 뉴런 시트 맵을 사용하였으며, 입력 벡터의 가중치는 5.0, 결합강도의 변환 계수는 0.4, 근접학습 범위의 초기 값을 4.0에서 최종 값 0.4로 하여 시뮬레이션을 하였다. 학습 회수에 의한 학습 인식율은 그림 3과 같다. 이 결과에서 알 수 있듯이 고차 뉴런을 이용함으로써 학습에 따르는 인식에 있어 종래의 학습 회수를 삭감할 수 있었으며, 종래 모델의 학습 인식율을 보다 높은 인식율을 얻을 수 있었다. 이것은 국소 집중반응 및 특징 유출을 산출함에 있어 고차 뉴런이 일차 뉴런보다 월등한 성능을 발휘하고 있으며, 고차 뉴런을 도입함으로써 비선형 분리 능력이 한층 향상됨을 보여주는 좋은 결과이다.

4.2. Alphabet 식별문제.

본 논문에 있어서, 15Pixel로 이루어진 20개의 Alphabet에 대한 식별을 목적으로 식별에 관한 시뮬레이션을 하였다. 상기 20개의 Alphabet는 가장 적은 픽셀로 이루어진 패턴으로 패턴 식별문제에 있어서 일반적으로 사용되는 패턴이다. 또한, 고차 뉴런의 생성은 본 논문에 기초한 2차 뉴런을 생성하였으며, (5)식에 의해 중복되는 뉴런의 생성을 억제하였다. 특히, 종래형과 비교를 위해 2차원의 뉴런 시트 맵의 크기를 5X5로 하였으며 입력 벡터에 대한 가중치를 5.0으로 하였다. 결합강도의 변환 계수는 0.4이고, 근접학습 범위의 초기 값을 4.0에서 최종 값 0.4를 가지고 시뮬레이션을 하였다. 입력 벡터인 20개의 Alphabet는 그림 4와 같다. 그림 5는 2000회에 이르는 학습 회수에 대한 종래형과 제안 모델의 인식율을 나타낸 것이다. 이 결과에서 알 수 있듯이 복잡한 패턴 인식문제에 대하여 고차 뉴런을 이용함이 보다 효율적이라는 것을 알 수 있다. 이것은 고차 뉴런을 사용함으로써 한층 비선형




그림 4 20개의 Alphabet 문자.
Fig. 4 20 Pattern of Alphabet Letters.




그림 3 XOR의 결과.
Fig. 3 Result of XOR.

분리 능력이 향상됨으로 복잡한 패턴 인식문제에 대하여 종래형 보다 높은 인식율을 얻을 수 있었다.

4.3. Mirror Symmetry 문제.

본 제안 모델의 범화 능력을 알아보기 위해 그림 6과 같은 4X4 Mirror Symmetry를 사용하여 시뮬레이션을 하였다[10]. 4X4 Mirror Symmetry 문제는 입력 벡터의 2진수 값의 대칭 축을 학습 후, 인식하는 형태로 4X4 Mirror Symmetry 인식




그림 5 20개의 Alphabet 문자 인식율.
Fig. 5 Result of 20 Pattern Recognition.




그림 6 4X4 Mirror Symmetry 문제 및 패턴 예.
Fig. 6 4X4 Mirror Symmetry Problem and Pattern Samples.

카테고리에 대한 패턴의 인식을 하는 문제로 네트워크의 응용력, 즉 범화 능력을 측정하는 좋은 예제이다. 그림 6에 있어 좌측 순으로 좌우대칭, 상하대칭 및 사면대칭에 관한 예제를 나타낸 것이다. 상기 대칭 패턴에 있어 1200개의 학습 데이터를 가지고 학습 후, 각 일정한 미학습 데이터 패턴에 있어서 대칭축을 인식하는 시물레이션을 하였다. 또한, 본 논문에서는 종래형과 제안 모델의 특성을 비교하기 위해 10X10과 패턴 수 만큼의 2차 뉴런시트 맵을 사용하여 시물레이션을 하였다. 여기서, 입력 벡터의 가중치는 5.0으로 하였으며, 결합강도의 변환 계수는 0.4, 근접학습 범위는 초기 값을 4.0에서 최종 값 0.4를 가지고 시물레이션을 하였다. 그림 7은 2000회 학습 후, 일정 분포의 미지 테스트 패턴을 네트워크에 대입하여 각각의 패턴에 대한 인식율의 곡선이다. 이 결과에서 알 수 있듯이 고차 뉴런을 도입함으로써 미지 대칭축에 대한 인식율이 종래형 보다 높다는 결과를 알 수 있다. 따라서, 본 제안 모델이 종래형 보다 높은 범화 능력을 갖고 있어 여러 응용 분야에 있어서 종래형 네트워크 구조 보다 본 제안 모델이 한층 적용 가능함을 보여준 결과라고 할 수 있다.

4.4. 응용 패턴인식 문제

본 제안 모델의 일반적인 응용력의 특징을 알아보기 위해서 그림 8과 같은 숫자 형태의 문자 패턴인식 문제를 가지고




그림 8 100개의 픽셀로 이루어진 숫자 패턴 인식 문제.
Fig. 8 Numerical Letters Recognize Problem.

고차 뉴런을 이용한 교사 학습기의 Kohonen Feature Map




그림 7 4X4 Mirror Symmetry에 대한 인식률.
Fig. 7 4X4 Mirror Symmetry Recognition.

시물레이션을 하였다. 상기 5개의 숫자는 각각 100개의 픽셀로 이루어져 있으며 종래형과 본 제안 모델의 특징을 동일선상에서 비교하기 위해서 똑같은 조건하의 파라미터를 가지고 시물레이션을 실행했다. 즉, Kohonen Feature Map의 2차 뉴런 시트는 5X5를 사용하였으며 입력벡터의 가중치는 동일하게 5.0, 결합강도의 변환 계수는 0.4, 근접학습 범위는 초기값을 5.0에서 최종값 0.4로 하여 시물레이션을 하였다. 학습 회수에 의한 학습 인식률은 그림 9와 같다. 이 결과에서 알 수 있듯이 고차 뉴런을 도입함으로써 종래형의 선형분리 기능에 위에 고차 뉴런에 의한 비선형 분리 기능이 한층 향상되어 특징 유출이 더욱더 향상된 결과를 얻을 수 있었다. 이러한 사실을 토대로 본 제안 모델은 다양한 응용력에 적합한 형태의 네트워크 구조로 개선되었으며 정확한 인식률을 얻는데 종래형 보다 한층 향상된 기능을 얻을 수 있었다.




그림 9 숫자 패턴에 대한 인식률.
Fig. 9 Numerical Letters Recognition.

4. 결 론

본 제안 모델인 고차 뉴런을 이용한 교차 학습기의 Kohonen Feature Map는 교차 학습기임에도 Kohonen 자기 조직화 맵의 특징인 비 교차 학습의 기능 즉, 특징 유출의 능력을 유지 할 수 가 있었다. 또한, 입력층에 고차 뉴런을 도입하여 초기 단계에서 비선형 분리가 가능하게 되어 복잡한 문제에 대하여 더욱더 향상된 기능들을 확인할 수 있었다. 본 제안 모델의 특성을 알아보기 위해서 XOR, 20개의 Alphabet 문제, 4X4 Mirror Symmetry 문제, 그리고 100개의 픽셀로 이루어진 숫자형태의 패턴 인식문제를 사용하여 계산기 시뮬레이션을 하였다. 그 결과, 종래형 보다 높은 인식률을 얻을 수 있었으며 고차 뉴런에 의한 특징 유출이 한층 용이한 사실을 알 수 있었다. 이러한 결과들은 고차 뉴런에 의한 비 선형 분리가 가능함으로 실질적인 패턴 인식문제에 보다 적합한 네트워크 형태임을 잘 보여준 좋은 예라고 생각한다. 그러나, 본 제안 모델의 문제점으로 지적되는 고차 뉴런에 의한 방대한 양의 결합강도를 어느 적정 수준에서 억제할 수 있을 것인가 하는 문제가 아직도 남아 있는 과제이다. 따라서, 차기 문제해결을 위해 자기 조직화 맵 상에서 공현도가 적은 결합강도에 대하여 도태시키는 결합강도 삭감문제에 대하여 연구가 수행되어야 할 것이다.

참 고 문 헌

[1] Remelhart and McClelland, "Parallel Distributed Processing", MIT, Press, 1986
 [2] T. Kohonen, "Self-Organized formation of topographical correct feature map", Biol, Cybern, pp.59-69, 43, 1982
 [3] T. Kohonen, "Self-Organization and Associative Memory: second edition", Springer-Verlag, Press, 1988
 [4] T. Kohonen, "Self-Organizing Semantic Maps", Biol, Cyber, 61, pp.241-253, 198.
 [5] H. Ichiki, M.Hagiwara and M. Nakagawa, "Self-Organizing Multi-Layer Semantic Maps", IJCNN, Vol.1, pp.357-360, 1991.
 [6] H. Ichiki, M.Hagiwara and M. Nakagawa, "Kohonen Feature Map as a Supervised Learning Machine", ICNN, pp.1944-1948, 1993
 [7] Y. C. Shin and R. Sridhar, "Network Configurations and Training Speeds of Second-Order Neural Network", WCONN, Vol.1, pp.585-588, 1993
 [8] J. G. Taylor and S. Coonnber, "Learning Higher-Order correlation", Neural Network, Vol.6, pp.423-427, 1993

[9] T. J. Sejnowski and P. K. Kienker, "Learning Symmetry Groups with Hidden Unit: Beyond the perceptron", Physical, 22D, pp.260-275, 1986
 [10] Lilly Spirkovska and Max B. Reid, "Connectivity Strategies for Higher-Order Neural Network Applied to pattern Recognition", IJCNN, 90, San Diego, 1990.
 [11] 정 중수, 홍성찬, "위치 변환 패턴 인식을 위한 다항식 고차 뉴럴 네트워크", 한국정보처리학회 논문지, 제4권, 제12호, pp.3063-3068, 1997
 [12] 정 중수, 하기와라 마사후미, "고차 뉴런을 이용한 Kohonen의 자기 조직화 맵", 대한전기학회 하계학술대회 논문집(D), pp.2656-2659, 7월, 2001.

저 자 소 개



정 중수(鄭鍾秀)

1967년 3월 5일 생. 1992년 수원대학교 전기공학과 졸업. 1996년 일본 게이오 대학원 전기공학과 졸업(석사). (주)데이터박스 개발이사. (주)TNT Invest 시스템 개발이사. 경인여자대학교 겸임교수, 현 넷피아(주) 기술연구소.
 Tel: 016-236-6706
 E-mail: jsjung@netpia.com



하기와라 마사후미(萩原 將文)

1960년생, 1982년 게이오 대학교 전기공학과 졸업. 1984년 동 대학원 전기공학과 졸업(석사). 1987년 동 대학원 전기공학과 졸업(공학박). 미국 스탠포드 대학 방문연구원 현재 일본 게이오 대학교 전기공학과 조교수.
 Tel: 81-45-563-1151
 E-mail: hagiwara@soft.ics.keio.ac.jp