

고차 뉴런을 이용한 KOHONEN 자기 조직화 맵의 연결강도 특성

정 종 수, 김 성 일, 전 병 훈
네파아(주), 서울대학교, 중부대학교

Control Weights On Supervised Kohonen Feature Map For Using Higher Order Neuron

Jong Soo JUNG, Sung il Kim, Byung Hoon Jeon
Netpia Co. Ltd, Seoul National University, JoogBu University.

Abstract - 본 논문은 고차 뉴런의 문제점으로 지적되고 있는 뉴런이 방대하게 증가하는 문제를 해결하고자, 최적의 뉴런을 생성하고 생성되어진 고차 뉴런 중 일정 비율로 뉴런의 연결강도를 도태시켜 감에 따라 네트워크 상에 나타나는 특성을 비교하였다. 본 논문은 고차 뉴런을 이용한 Kohonen의 자기 조직화 맵의 고차 뉴런부에 일정 비율로 연결강도를 도태한 후 인식률을 얻는 형태로 시뮬레이션을 하였다. 특히, 종래 형태의 고차 뉴런을 이용한 Kohonen 자기 조직화 맵의 알고리즘을 변형 없이 사용하였으며 중복되는 뉴런을 최대한 억제하기 위해 2차 뉴런만을 생성한 네트워크 구조 위에 입력 데이터의 특징을 유지하고 고차 뉴런의 특징을 더욱 활성화하기 위해 일정한 양의 연결강도를 도태시킴으로써 출력면에서 국소집중 반응에 의한 정확한 인식을 향상 등을 조사하는 시뮬레이션을 하였다. 본 제안 모델의 특성을 살펴보기 위해 60개의 데이터로 이루어진 금속 소나 음 데이터와 암석 소나 음 데이터를 이용하여 금속인지 암석인지를 판별하는 시뮬레이션을 하였다.

안 모델인 결합강도 조절에 관한 고차 뉴런의 Kohonen 자기 조직화 맵은 종래 모델의 특징인 고차 뉴런의 특성을 개선시키고 고차 뉴런의 적용에 따르는 결합강도의 계산 양이 증가되는 것을 억제할 수 있으며 아울러 공헌도가 적은 결합강도를 도태시킴으로써 더욱 국소 집중반응을 정확하게 추출할 수 있으리라고 사려 되어진다. 그러므로 이러한 시뮬레이션은 입력층과 출력층의 2차원 뉴럴 시트(Neural Sheet)의 간단한 구조를 갖고 있는 Kohonen Feature Map에 적용, 고차 뉴런의 특성 및 네트워크에 미치는 영향 등을 관찰 할 수 있는 귀중한 자료가 될 것이다.

1. 서 론

뉴럴 네트워크의 특징으로는 병렬 분산처리, 학습능력 및 범화능력 등을 말할 수 있으며 뉴럴 네트워크의 특성에 따라 교사 학습 모델과 비 교사 학습 모델로 분리된다. 비 교사 학습의 대표적인 모델이 Topological Map을 도입한 Kohonen Feature Map이 있다[1][2][3]. Kohonen Feature Map의 일반적인 특징으로는 입력 데이터의 유사성을 자동적으로 탐색하여 유사성이 있는 신호를 출력면(Kohonen Feature Map) 내의 특정한 위치에 집중하는 메커니즘으로 국소집중 반응을 구하는 구조이다[3]. 즉, 입력 데이터에 대하여 선택적으로 반응하는 네트워크 구조이다. 또한, Kohonen Feature Map는 맵 내의 상호결합이 없는 동시에 미분 연산이 필요 없이 간결한 형태의 네트워크로 구성되는 것이 큰 특징이다. 특히, 고차 뉴런을 이용한 Kohonen의 자기 조직화 맵은 일차 뉴런의 문제점인 비 선형 분리 문제를 해결하고자 교사 학습기의 Kohonen Feature Map의 입력 층에 고차 뉴런을 적용하여 한층 향상된 형태의 네트워크 구조를 갖고 있다[6][7]. 그러나 방대한 양의 결합강도의 증가로 인해 계산 양이 증가하고 입력 데이터가 많은 경우에는 결합강도의 증가에 의한 유사성의 혼란을 초래하는 점 등이 일반적인 고차 뉴런의 문제점으로 지적되고 있다[4]. 따라서 이러한 사항들을 보완하기 위해 계층형 구조의 뉴럴 네트워크에서 대부분 2차 뉴런만을 생성하는 형태의 네트워크 구조와 생성된 결합강도 중에 공헌도가 적은 뉴런 및 결합강도를 삭감하는 모델인 M. Hagiwara에 의해 제안되어 그 특징을 소개한바 있다[5]. 그러나 본 논문에서는 이러한 특성을 계층형 구조가 아닌, 단순한 형태의 네트워크 구조를 갖고 있는 고차 뉴런을 이용한 Kohonen 자기 조직화 맵에 적용하여 연결강도에 따르는 Kohone Feature Map의 특성을 비교하고자하는데 그 목적이 있다. 특히, 본 제

2. 본 론

2.1 고차 뉴런을 이용한 Kohonen 자기 조직화 맵의 구조

고차 뉴런의 Kohonen 자기 조직화 맵의 구조는 입력 층과 출력층의 2차원 뉴럴 시트(Neural Sheet)의 구조로 되어 있다. 동작은 입력 벡터에 대하여 2차원의 뉴럴 시트 상에서 거리 관계를 구하여 학습하며 이에 뉴런이 각각 반응하는 특징을 갖고 있는 즉, 토폴로지 맵을 형성하는 네트워크이다[1]. 따라서 입력 벡터와 입력 벡터의 복합적 산출 방정식으로 형성된 고차 뉴런과 교사 벡터를 하나의 학습 벡터로 하여 동작하는 방식이다 [6][7]. 고차 뉴런의 Kohonen 자기 조직화 맵의 구조는 그림 1과 같다. 고차 뉴런의 Kohonen 자기 조직화 맵은 비 선형분리가 한층 향상되고 비 교사 학습기인 Kohonen Feature Map의 특징을 유지하기 위해 주어 진 입력 벡터 I 는

$$I = (x_1, x_2, \dots, x_n) \quad (1)$$

이다. 여기서, x_n 는 입력 벡터이고, n 은 입력 벡터 수이다. 한편, 비 선형분리가 한층 용이하도록 형성된 교차 뉴런은 (1)식의 입력 벡터를 자신의 입력 벡터에 대입하여 복합적 산출 방정식으로 결정되며 이러한 고차 뉴런의 입력 벡터 H 는

$$H = (x_1 x_2, x_1 x_3, \dots, x_{n-1} x_n) \quad (2)$$

이다. 여기서, 고차 뉴런의 생성을 최대한 억제하기 위해 2차 뉴런만을 형성하였으며 중복 뉴런 형성 또한 억제하였다. 상기, 입력 벡터에 대응하는 교사 벡터 T 는

$$T = (y_1, y_2, \dots, y_m) \quad (3)$$

이고 여기서, y_m 는 교사 벡터이고, m 은 교사 벡터 수이다. 네트워크 상에서 학습을 하기 위해서는 입력 벡터와 고차 뉴런 및 교사 벡터를 하나로 결합된 학습 벡터 X , 가 필요하며 다음과 같이 표현된다.

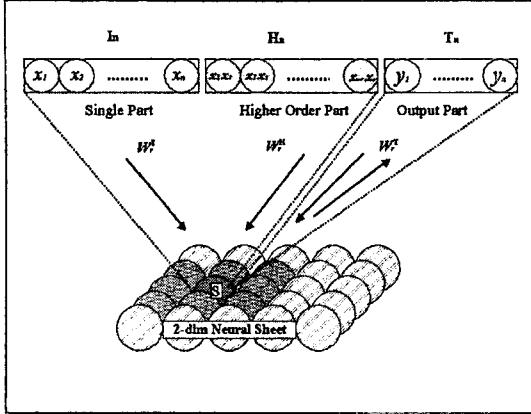


그림 1. 고차뉴런을 이용한 Kohonen 자기 조직화 맵

$$X_p = a \begin{bmatrix} I \\ H \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ T \end{bmatrix} \quad (4)$$

단, 입력 벡터의 크기에 의해 맵이 형성 되도록 입력 벡터에 대한 가중치로써 $a \gg 1$ 인 값으로 한다. 그러므로 입력 벡터의 가중치에 의해 교사 벡터의 연결강도가 투영되는 형태의 맵이 형성된다. 따라서 연결강도는 다음과 같이 분리하여 표현된다.

$$W_r^P = \begin{bmatrix} W_r^I \\ W_r^H \\ W_r^T \end{bmatrix} \quad (5)$$

여기서, r 은 맵 상에서 뉴런의 위치를 나타내는 2차원 위치벡터, W_r^I 는 입력 벡터에 해당하는 연결강도, W_r^H 는 입력 벡터에 의해 형성된 고차 뉴런에 해당하는 연결강도, W_r^T 는 교사벡터에 대한 연결강도이다. 고차 뉴런의 Kohonen 자기 조직화 맵의 학습은 입력 벡터 X_p 을 네트워크에 입력하였을 때 나오는 출력 값으로 결정되며 다음과 같이 표현된다.

$$y_r = X_p \cdot W_r^P \quad (6)$$

식별기구로서는 2차 뉴런 시트 즉, 맵 상에서 가장 발화하고 있는 뉴런의 출력 y_{\max} 는

$$\begin{aligned} y_{\max} &= \max(\sum I W_n^I + \sum \sum I_{n-1} I_n W_n^H + \sum T W_n^T) \\ &= \max(\sum I W_n^I + \sum H W_n^H + \sum T W_n^T) \\ &= \max[X_p \cdot W_r^P] \\ &= \max[y_r] \end{aligned} \quad (7)$$

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

$$W_n^{(new)} = W_n^{(old)} + \epsilon h_n (X_p \cdot W_n^{(old)}) \quad (8)$$

으로 변경되며 여기서, ϵ 는 결합강도의 변환 계수이고 h_n 에 의해 학습하는 연결강도의 범위가 정하여진다. 여기서, h_n 는





그림 2. 고차 뉴런의 연결강도 특성

$$h_n = \exp \frac{-\|r-s\|^2}{\sigma^2} \quad (9)$$


이며, σ 는 근접학습의 범위를 결정하는 파라메타이다. σ 가 크면 클수록 학습 범위가 넓어진다. 통상 σ 는 초기 단계에서는 넓은 범위에서 학습을 하며 점차 감소시킨다. 또한, 변경된 연결강도를 절대값화 한다. 이와 같은 알고리즘을 반복함으로써 토폴로지 맵이 형성되며 형성된 맵의 특징으로 입력 데이터간의 거리 관계가 정확하게 맵 상에 이미지화되어 보존된다.

2.2 고차 뉴런을 이용한 Kohonen 자기 조직화 맵의 고차 뉴런의 연결강도 특성

Kohonen Feature Map의 일반적인 특징으로는 입력 데이터의 유사성을 자동적으로 탐색, 유사성이 있는 신호를 출력면(Kohonen Feature Map) 내의 특정한 위치에 집중하는 국소집중 반응을 구하는 구조이다. 즉, 입력 데이터에 대하여 선택적으로 반응하는 네트워크로 주어진 입력 뉴런에 의해 형성되어진 뉴런의 연결강도는 ϵ 인 결합강도의 변환 계수와 h_n 인 근접학습에 의해 그 범위가 결정된다. 따라서 새롭게 변경되는 연결강도는 토폴로지 맵을 형성하며 새로 생성되어진 뉴런들의 연결강도의 변화는 출력층의 2차 뉴런 시트에 절대적인 영향력을 부여한다. 그 결과, 생성되어진 연결강도의 크기에 따라 국소집중 반응을 구하는데 중요한 역할을 담당하게 된다. 이와 같은 사실을 토대로 연결강도의 특성을 비교 분석하기 위해 고차 뉴런을 이용한 Kohonen 자기 조직화 맵을 사용하여 생성되어진 고차 뉴런의 일정 비율의 연결강도를 도태하여 그 특성을 비교하기 위해 그림 2와 같이 시뮬레이션을 하였다. 상기, 고차 뉴런 부분은 (1)식의 입력 벡터에 대하여 자신의 입력 벡터를 대입, 반복적 산출 방식으로 형성되었고 형성되어진 고차 뉴런에 대응하는 연결강도는 (8)식에 의해 새롭게 형성되었다. 그러나 새롭게 형성되어지는 연결강도는 (8)식에서 알 수 있듯이 연결강도 값이 작은 것은 새롭게 형성되는 연결강도에 대한 공헌도가 낮으므로 이를 도태시킴으로써 계산량을 줄일 수 있으며, 이를 통해 2차 뉴런시트로 이루어져있는 출력면의 국소집중 반응을 구하는 작업을 용이하게 한다. 따라서 새롭게 형성되어진 고차 뉴런의 연결강도 중에 공헌도가 낮은 연결강도의 일정량을 $[W_n^{(old)}]=0$ 으로 치환한다.



(a)



(b)

그림 3. (a)금속 소나 음과 (b)암석 소나 음의 예제

2.3. 실험 및 결과분석

고차뉴런을 이용한 Kohonen 자기 조직화 맵의 연결 강도의 특성을 알아보기 위해, 그림 3과 같은 50개의 0과 1사이의 소수점 데이터로 이루어진 금속과 암석에 대한 소나 음에 대한 데이터를 통해 금속과 암석을 판별하는 문제를 사용하여 시뮬레이션을 하였다. 상기에 사용된 소나 음은 총 208개로, 그중 104개는 학습 패턴 수이고 나머지 104개는 학습 후, 금속인지 암석인지를 판단하는 테스트 데이터로 사용하여 이를 인식을 하는 형태로 시뮬레이션을 하였다. 상기 시뮬레이션에서 고차 뉴런을 이용한 Kohonen 자기 조직화 맵의 연결 강도의 특성을 비교하기 위해서 똑같은 조건하의 파라메타를 가지고 일정비율의 연결강도를 도태시키는 방법을 이용하였다. 상기 파라메타로써, Kohonen Feature Map의 2차 뉴런 시트는 20×20를 사용하였으며 입력벡터의 가중치는 동일하게 5.0, 결합강도의 변환 계수는 0.4, 근접학습 범위는 초기값을 5.0에서 최종값 0.4까지 점차 감소시켜 가며 시뮬레이션을 하였다. 일정비율의 연결강도를 도태시 인식률에 대한 결과 값을 얻기 위해 학습 회수를 25회로 제한하여 시뮬레이션을 하였으며 그 결과 값은 표 1과 같다. 이 결과에서 알 수 있듯이 일정비율의 연결강도, 즉 공헌도가 낮은 연결강도를 도태시킴으로써 특징 유출이 더욱더 향상된 결과를 얻을 수 있는 것을 알 수 있다. 그러나 무리하게 뉴런에 연결되어있는 연결강도를 도태시키는 것은 네트워크에 악영향을 주는 사실 또한 알 수 있었다. 따라서 이러한 사실은 네트워크 형태에 따르는 구조 분석 및 네트워크 응용성에 있어 연결강도의 역할의 중요성을 잘 보여준 예제라고 할 수 있으며 고차 뉴런을 도입함으로써 발생하는 방대한 뉴런의 발생에 따르는 계산량 증가의 문제를 근본적으로 해결 할 수 있으며, 결과적으로 계산량의 감소를 통해 보다 실용적인 네트워크 구조로 개선 및 보다 정확한 인식을 얻는데 한층 향상된 기능을 얻을 수 있었다.

표 1. 고차 뉴런을 이용한 Kohonen 자기 조직화 맵의 고차 뉴런의 연결강도 특성 결과값

연결강도 도태 비율	인식률
10%	92.3%
12%	94.1%
50%	91.2%

3. 결 론

고차뉴런을 이용한 Kohonen 자기 조직화 맵의 연결 강도의 특성을 조사하기 위해 일정한 량의 연결강도를 도태하여 시뮬레이션을 하였다. 그 결과, 상기 표1의 소나 음에 대한 식별 결과에서 알 수 있듯이 고차 뉴런을 사용함에 있어 근본적인 문제로 지적되었던 방대한 뉴런의 증가에 따르는 계산량의 증가 문제를 고차 뉴런 중에 공헌도가 낮은 연결강도를 도태시킴으로써 계산량의 감소시키고 국소집중 반응을 향상 수 있었다. 이러한 결과 값은 고차 뉴런을 도입하고 싶어도 방대한 뉴런이 생성되는 문제점으로 인해 실제 적용에 많은 어려움이 있었으나 본 논문에서는 이러한 방대한 계산량에 대한 문제점을 극복할 수 있었다. 즉, 공헌도가 낮은 연결강도를 도태시킴으로써 인식률의 향상과 더불어 다양한 응용력을 가질 수 있는 네트워크 형태로 구성이 가능하다는 사실을 알 수 있다.

(참 고 문 헌)

- [1] T. Kohonen, "Self-Organized Formation of Topographically Correct Feature Map", Biol. Cybern, 43, pp.59-69, 1982
- [2] T. Kohonen, "Self-Organization and Associative Memory: second edition", Springer-Verlag, Press, 1988
- [3] T. Kohonen, "Self-Organizing Semantic Maps", Biol. Cybern, 61, pp.241-254, 1989.
- [4] J. G. Taylor and S. Coomber, "Learning Higher-Order Correlation", Neural Network, Vol.6, pp.423-427, 1993
- [5] M. Hagiwara, "Removal of Hidden Units and Weights for Back Propagation Network" ICNN, pp.351-354, 1993
- [6] 정중수, 하기와라 마사후미, "고차 뉴런을 이용한 KOHONEN의 자기 조직화 맵", 대한전기학회 하계학술대회 논문집, D, pp.2656-2659, 2001
- [7] 정중수, 하기와라 마사후미, "고차 뉴런을 이용한 교차 있는 학습기의 Kohonen Feature Map", 전기학회 논문지, D, 제52권 제5호 pp.277-282, 2003.