

SOM의 출력 뉴런의 승리 기대값을 이용한 LVQ 네트워크의 최적 설계

정 경 권, 엄 기 환, *이 용 구, **손 동 설
동국대학교 전자공학과, *한림정보산업대학 전자통신과, **유한대학 전자과
전화 : 02-2260-3332 / 핸드폰 : 016-704-7707

Optimal Design of LVQ Network using the Winning Expectation of Output Neurons of SOM

Kyung Kwon Jung, Ki Hwan Eom, *Yong Gu Lee, **Dong Seol Son
Dept. of Electronic Eng., Dongguk University
Dept. of Electronic Communication, Hallym College of Electronic Information & Industry
Dept. of Electronic Eng., Yuhan College
E-mail : kwon@dongguk.edu

Abstract

In this paper, we propose a optimal design method of the LVQ network. The proposed method determines the initial reference vectors and optimal network structure using the winning expectation of output neurons of SOM. In order to verify the effectiveness of the proposed method, we performed experiments on the Fisher's IRIS data. The experimental results showed that the proposed method improves considerably on the performance of the conventional LVQ networks.

I. 서론

LVQ(Learning Vector Quantization) 네트워크는 1989년 Kohonen이 패턴분류에 적용하기 위해 제안한 신경회로망 이론이다. LVQ 네트워크는 경쟁 네트워크를 근간으로 하고, 지도 학습(supervised learning)과 비지도 학습(unsupervised learning)이 동시에 존재하는 하이브리드(hybrid) 형태이며, 연결벡터(weight vector)를 원형벡터(prototype vector)로 하여 학습하는 알고리즘을 사용한다. LVQ 네트워크의 학습은 입력과 출력 사이의 연결벡터인 기준벡터(reference vector)와

입력벡터와의 거리를 비교하여, 기준벡터와의 거리가 가장 가까운 입력벡터가 승리벡터가 되고, 기준벡터와 승리벡터가 같은 클래스(class)로 분류되면 연결벡터를 증가시키고, 다른 클래스로 분류되면 연결벡터를 감소시킨다. 이러한 과정을 통해 입력패턴은 분류가 되고 연결벡터는 학습하게 된다. 최근 들어 LVQ 네트워크는 음성인식, 문자인식, 지문인식 등과 같은 패턴인식 분야뿐만 아니라, 제어 분야 등에서도 널리 활용되고 있다[1-3].

그러나 우수한 성능에도 불구하고 LVQ 네트워크는 여러 가지 문제점을 가지고 있다. 첫 번째는 기준벡터의 초기값을 선정하는 것이다. LVQ 네트워크의 기준벡터는 LVQ 네트워크의 카테고리 경계(category boundary)를 결정하고 그것의 수렴에 영향을 미치기 때문에 기준벡터의 초기값을 선정하는 것은 중요한 문제이다. 일반적으로 기준벡터를 정하는 방법은 입력패턴의 학습 데이터 중에서 임의로 선택하거나 혹은 랜덤하게 선택하는 방법이 사용된다. 그러나 이러한 방법에 의한 선택은 정확한 분류에는 적합하지 않은 방법이다. LVQ 네트워크의 또 다른 문제점은 뉴런의 미사용(underutilization)이다. 데드(dead) 뉴런의 문제는 경쟁 네트워크의 공통적인 문제점으로, 이것은 기준벡터의 초기 분포에 기인한다. 패턴의 분포가 다른 패턴과 확연히 구분되는 데이터의 경우 적은 수의 뉴런으로도 분류가 가능하나 초기에 너무 많은 뉴런을 할당

했을 경우 분류에 가담하지 않는 데드 뉴런이 발생하게 되는 것이다. 이외에도 LVQ 네트워크는 중복(overlapping) 되거나 복잡하고 다차원인 입력패턴의 경우 그 데이터를 정확하게 분류하지 못하는 문제가 있다[4-5].

본 논문에서는 LVQ 네트워크의 문제를 해결하기 위해서 SOM의 출력 뉴런의 승리 기대값을 이용하는 방법을 제안한다. 제안한 설계 방식은 LVQ의 학습에 앞서 SOM을 이용하여 1차 가분류를 수행하고, 분류된 결과에서 어느 출력 뉴런이 훈련 데이터에 대해서 승리하는 횟수를 가지고 기대값을 계산한 후에, 그 기대값이 높은 뉴런과 연결 강도를 가지고 LVQ 네트워크의 출력 뉴런 수와 서브 클래스 수를 정하고, 기준 벡터를 초기화 시키는 방법이다. 제안한 방식의 유용성을 확인하기 위하여 Fisher의 IRIS 데이터를 대상으로 실험을 수행한 결과 LVQ 네트워크의 설계가 용이하고, 동일한 설계 상황에서 LVQ1이나 LVQ2의 방식보다 분류 성능이 우수함을 확인한다.

II. LVQ 네트워크

Kohonen이 제안한 LVQ 알고리즘은 클래스를 잘 구분 할 수 있도록 경계를 형성하는 것이 목적이다. Kohonen은 LVQ를 SOM (Self-rganizing Map) 에 분류 성능을 향상시키기 위해 제안하였으나, 단독으로 그림 1과 같은 LVQ 경쟁 신경회로망을 학습하는 데에 사용되기도 한다[2-3].

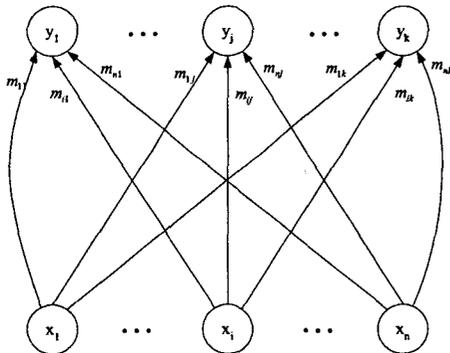


그림 1. LVQ 네트워크

경쟁 학습 신경회로망 중에서 음성 인식, 문자 인식, 지문 인식 등과 같은 패턴 인식뿐만 아니라, 제어, 통신 분야 등에서 널리 활용되고 있는 LVQ는 지도 학습과 비지도 학습이 동시에 존재하는 형태로 구성되어 있다. LVQ의 학습은 입력과 출력 사이의 연결 벡터인

기준 벡터(reference vector)와 입력 벡터의 거리를 비교하여, 기준 벡터와의 거리가 가장 가까운 입력 벡터가 승리 벡터가 되고, 기준 벡터와 승리 벡터가 같은 클래스(class)로 분류되면 연결 벡터를 증가시키고, 다른 클래스로 분류되면 연결 벡터를 감소시킨다. 이러한 과정을 통해 입력 패턴은 분류가 되고 연결 벡터는 학습하게 된다[2-3][6].

LVQ는 잘못 분류된 출력 뉴런의 가중치 벡터에 대해서 결정 경계의 반대 방향으로 밀어냄으로써 분류 성능을 향상시키는 방법이다.

1. 입력 벡터를 $x \in \mathbb{R}^n$ 이라 하고, LVQ 네트워크의 기준 벡터를 $m_i \in \mathbb{R}^n$ 이라 하면 LVQ 네트워크는 입력 x 에 가장 근접한 m_c 를 찾는 것이다.

$$\begin{aligned} \|x - m_c\| &= \min \|x - m_i\| \\ c &= \arg \min \|x - m_i\| \end{aligned} \quad (1)$$

입력 벡터 x 에 대해서 승리 뉴런이 i 이고 그 기준 벡터를 $m_i(t)$ 라고 할 때, 입력 벡터 x 와 출력 뉴런 i 의 클래스가 같은 경우에는 다음 식에 의해 기준 벡터를 조정한다.

$$m_i(t+1) = m_i(t) + \alpha(t)(x - m_i(t)) \quad (2)$$

입력 벡터 x 와 출력 뉴런 i 의 클래스가 다른 경우에는 아래 식에 의해 조정된다.

$$m_i(t+1) = m_i(t) - \alpha(t)(x - m_i(t)) \quad (3)$$

승리 뉴런 i 를 제외한 모든 출력 뉴런의 가중치 벡터는 갱신되지 않는다. $\alpha(t)$ 는 학습율이다.

$$m_j(t+1) = m_j(t) \quad \text{for } j \neq i \quad (4)$$

III. 제안한 설계 방식

제안한 방식은 훈련 데이터에 대해서 SOM의 출력 뉴런이 승리하는 횟수를 살펴서 기대값이 큰 뉴런만을 이용하여 LVQ를 최적 설계한다.

SOM은 분류하고자 하는 클래스의 N배수 크기로 정한 후, 입력 패턴으로 충분히 학습을 시킨다. 학습이

끝난 후에 입력 패턴의 클래스와 출력 뉴런이 승리하는 횟수를 조사하여 클래스마다 평균을 계산하여 각각의 뉴런에 대하여 승리하는 기대값을 계산한다. 출력 뉴런마다 기대값이 큰 뉴런만을 이용하여 LVQ 네트워크의 서브 클래스를 설계하고, 그 뉴런들의 연결 강도를 이용하여 LVQ의 기준 벡터를 초기화 한다. 제안한 방식의 블록 선도는 그림 2와 같다.

제안한 방식은 기준 벡터의 초기값 문제나 출력 뉴런의 미사용 문제를 해결할 수 있다.

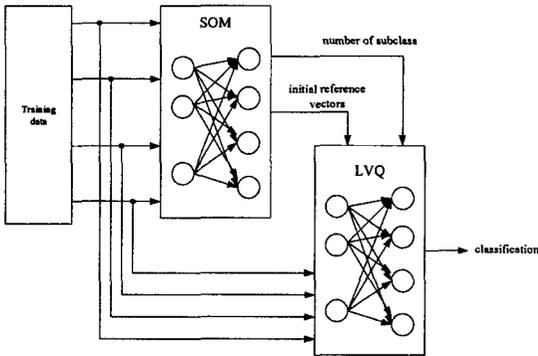


그림 2. 제안한 방식의 블록 선도

IV. 실험

제안한 방식의 유용성을 확인하기 위하여 Fisher의 IRIS 데이터 분류를 시뮬레이션한다. 패턴 데이터를 훈련용과 시험용으로 나누고 분류 어려움을 가지고 기존 LVQ1, LVQ2와 제안한 방식의 분류 성능을 비교하였다.

1936년 Fisher는 붓꽃(iris)의 꽃받침(sepal)과 꽃잎(petal)의 크기와 길이를 조사하여 이를 데이터로 만들었다. 이렇게 해서 만들어진 데이터가 Fisher의 IRIS 데이터이다[52-55]. IRIS 데이터는 붓꽃의 3 종류인 Setosa, Versicolor, Virginica에 대해서 꽃받침과 꽃잎의 크기 및 길이에 대해 각 종류마다 50개씩의 데이터로 구성되었다. 이러한 IRIS 데이터는 분류나 클러스터링 해석을 위한 데이터로 널리 사용되고 있다. 이 3개의 종류 중에서 Setosa는 나머지 두 종류 Versicolor, Virginica와 선형적으로 분리가 가능하지만 Versicolor와 Virginica는 데이터가 서로 겹쳐서 있다. 각각의 중에서 25개씩 75개의 데이터를 가지고 학습을 하였고, 나머지 75개의 데이터로 시험을 하여 LVQ1과 LVQ2와 분류 성능을 비교하였다.

SOM은 입력 뉴런 4개, 출력 뉴런은 20개로 설정하였고, 학습율은 0.9에서 학습을 하면서 감소하게 설정

하였다. 학습 횟수는 500번을 하였다. 훈련 데이터에 대한 SOM의 출력 뉴런의 승리 횟수와 기대값은 표 1과 같다.

LVQ 네트워크는 입력 뉴런 4개, 출력 뉴런은 기대값에 따라 Setosa는 1개의 서브 클래스(출력 뉴런)를 할당하고, Versicolor와 Virginica는 각각 4개의 서브 클래스가 할당되게 LVQ 네트워크를 설계하였다. 학습율은 0.9에서 학습을 하면서 감소하게 설정하였다. 제안한 방식에서 초기 기준 벡터는 선택된 뉴런의 연결 강도를 이용하였고, LVQ1과 LVQ2에서는 훈련 데이터의 최대값과 최소값의 평균으로 초기 기준 벡터를 정하였다.

훈련 데이터의 분류 결과는 와 시험 데이터의 분류 결과는 표 2, 3과 같다.

표 2. 훈련 데이터의 분류 결과

학습 횟수	0	100	200	300	400	500	600	700	800	900
LVQ1	29	10	7	6	9	6	6	5	5	6
LVQ2	29	8	6	9	6	4	4	6	4	4
제안	3	3	3	3	3	3	3	3	3	3

표 3. 시험 데이터의 분류 결과

학습 횟수	0	100	200	300	400	500	600	700	800	900
LVQ1	25	9	6	7	8	8	8	7	6	9
LVQ2	25	6	6	6	6	2	6	6	4	3
제안	1	1	1	1	1	1	1	1	1	1

제안한 방식은 SOM을 이용하여 데드(dead) 뉴런을 줄일 수 있는 최적 설계를 하였고, 분류 성능 면에서도 우수함을 확인하였다. 또한 SOM을 통한 학습이 선행되었기 때문에 결과 표에서처럼 SOM의 연결 강도를 LVQ의 초기 기준 벡터로 이용하면 LVQ의 학습 효과가 있음을 알 수 있었다.

표 1. SOM 출력 결과

	클래스																					
	Setosa				Versicolor										Virginica							
출력 뉴런	1	2	3	4	6	7	8	9	10	11	12	13	14	8	13	14	15	16	17	18	19	20
승리 횟수	11	6	4	5	2	2	3	1	3	3	5	1	1	1	2	6	2	4	4	3	1	5
평균	7				2										3							
기대값	1	0	0	0	0	0	1	0	1	1	2	0	0	0	0	1	0	1	1	0	0	1
선택	c						c		c	c	c					c		c	c			c

V. 결론

본 논문에서는 LVQ 네트워크의 문제를 해결하기 위해서 SOM의 출력 뉴런의 승리 기대값을 이용하는 방법을 제안하였다. 제안한 설계 방식은 LVQ의 학습에 앞서 SOM을 이용하여 학습을 하고, 출력 뉴런이 훈련 데이터에 대해서 승리하는 기대값을 계산한 후에, 기대값이 높은 뉴런과 연결 강도를 가지고 LVQ 네트워크의 출력 뉴런 수와 서브 클래스 수를 정하고, 기준 벡터를 초기화 시키는 방법이다. 제안한 방식의 유용성을 확인하기 위하여 Fisher의 IRIS 데이터를 대상으로 실험을 수행한 결과 동일한 설계 상황에서 LVQ1이나 LVQ2의 방식보다 분류 성능이 우수하고, LVQ의 초기 기준 벡터 선정 문제와 데드(dead) 뉴런 문제를 해결 할 수 있었다.

[5] S. C. Ahalt, A. K. Krishnamurthy, P. Chen, D. E. Melton, "Competitive Learning Algorithm for Vector Quantization," *Neural Networks*, vol. 3, pp. 277-290, 1990.

[6] T. Kohonen, "The self-organizing map," *Proceedings of the IEEE*, vol. 78, no. 9, pp. 1464-1480, 1990.

참고문헌

[1] Richard O. Duda, Peter E. Hart, David G. Stork, *Pattern Classification*, John Wiley & Sons, 2000.

[2] Fausett, Laurene, *Fundamentals of Neural Networks*, Prentice Hall, 1994.

[3] Hagan, Martin T., *Neural Network Design*, Thomson Learning, 1996.

[4] N. B. Karayiannis, "Soft learning vector quantization and clustering algorithms based on ordered weighted aggregation operators," *IEEE transactions on neural networks*, vol. 11, no. 5, pp.1093-1105, 2000.