

## Forward C.P. Net.을 이용한 3단 LVQ 학습알고리즘

이용구\*, 최우승\*\*

### 3 Steps LVQ Learning Algorithm using Forward C.P. Net.

Yong-gu Lee \*, Woo-seung Choi \*\*

#### 요약

본 논문에서는 LVQ 네트워크의 분류성능을 향상시키기 위하여 F.C.P. Net.을 이용하여 LVQ 학습알고리즘을 설계하였다. F.C.P. Net.의 입력층과 부류층 사이의 연결강도는 SOM과 LVQ 알고리즘을 이용하여 초기 참조벡터의 설정 및 학습이 가능하게 하였다. 마지막으로 패턴벡터를 부류층의 뉴런에 의해 종속부류로 분류하고, F.C.P. Net.의 부류층과 출력층 사이의 연결강도는 분류된 종속부류를 부류로 지정하는 학습을 하게 된다. 또한 부류의 수가 결정되기만 하면 입력층, 부류층, 출력층의 뉴런의 수를 결정할 수 있도록 하였다. 제안된 학습알고리즘의 성능을 검증하기 위하여 Fisher의 Iris 데이터를 학습벡터 및 시험 벡터로 사용하여 시뮬레이션 하였고, 제안된 학습방식의 분류 성능은 기존의 LVQ와 비교되어 기존의 학습방식보다 우수한 분류성공률을 확인하였다.

#### Abstract

In this paper, we design the learning algorithm of LVQ which is used Forward Counter Propagation Networks to improve classification performance of LVQ networks. The weights of Forward Counter Propagation Networks which is between input layer and cluster layer can be learned to determine initial reference vectors by using SOM algorithm and to learn reference vectors by using LVQ algorithm. Finally, pattern vectors is classified into subclasses by neurons which is being in the cluster layer, and the weights of Forward Counter Propagation Networks which is between cluster layer and output layer is learned to classify the classified subclass, which is enclosed a class. Also, if the number of classes is determined, the number of neurons which is being in the input layer, cluster layer and output layer can be determined. To prove the performance of the proposed learning algorithm, the simulation is performed by using training vectors and test vectors that are Fisher's Iris data, and classification performance of the proposed learning method is compared with ones of the conventional LVQ, and it was a confirmation that the proposed learning method is more successful classification than the conventional classification.

▶ Keyword : SOM, LVQ, F.C.P. Networks, in-star learning rule, out-star learning rule, pattern classification

• 제1저자 : 이용구

• 접수일 : 2004.10.15, 심사완료일 : 2004.11.13

\* 한림성심대학 전자정보통신과 부교수

\*\* 경원전문대학 네트워크정보과 교수

## 1. 서론

전방향 카운터 프로퍼게이션 네트워크(Forward only Counter Propagation Networks : F.C.P Net.)은 입력층, 부류층, 출력층으로 구성된 3층 구조의 신경회로망이다. 입력층과 부류층 사이의 학습은 in-star 학습법이 사용되어 부류층의 승리뉴런을 결정하고, 이 승리뉴런과 출력층의 뉴런들 사이의 연결강도의 학습에는 out-star 학습법이 사용된다. 이러한 학습알고리즘을 갖는 F.C.P Net.은 주로 많은 량의 입력-출력 데이터 쌍(X, Y)을 부류층의 뉴런 수 정도의 적은 데이터 쌍(X\*, Y\*)으로 축소할 수 있다[1].

또한 비지도학습 신경회로망인 SOM은 패턴공간상에서 유사한 부류의 패턴을 하나의 부류로 분류하는 데 우수한 분류성능을 갖는다. 이러한 SOM의 학습은 거리 측정법에 기반을 둔 방식으로 일반적으로 거리측정 방법에는 성능 면에서 우수하고, 정규화가 필요 없는 유클리드 방식을 이용하고 있다[2~6].

또한 패턴을 보다 정밀하게 분류하기 위하여 하나의 부류에 여러 개의 종속부류를 포함시키고, 학습을 통하여 패턴벡터를 종속부류로 분류하므로서 부류로 분류하는 보다 정밀하고 우수한 분류성능을 갖는 신경회로망이 바로 LVQ이다[7-9]. 그러나 LVQ의 학습에는 이웃반경이 고려되지 않고 오직 승리뉴런에 연결된 연결강도 만의 학습이 이루어지므로 입력패턴벡터공간에서 특성화 지도를 형성하지 않으므로, 이로 인하여 패턴분류의 성능은 연결강도의 초기값 설정에 매우 민감하게 반응한다. 또한 LVQ 학습에서 분류 성능에 영향을 미치는 것은 종속 부류를 지정하는 출력뉴런 각각을 어떤 부류에 지정하는가 하는 문제이다.

본 논문에서는 이러한 LVQ의 분류성능에 영향을 미치는 중요한 요인인 초기값 설정과 출력뉴런의 부류지정 설정이 신경회로망으로 자동 학습되는 방식을 제안하였다. 사용된 신경회로망은 3층 전방향 구조를 가지며, in-star 와 out-star 학습법을 사용하는 F.C.P. Net.을 사용하였고, LVQ 초기 참조벡터의 학습, 정밀한 참조벡터의 학습, 종속 부류가 속할 부류지정학습으로 이루어지는 3단계 학습알고리즘을 제안하였다.

제안된 학습네트워크의 분류성능의 타당성을 입증하기

위하여 Fisher의 Iris 데이터에 적용하여 패턴분류 성능을 시뮬레이션하고 기존의 LVQ와 성능을 비교하였다.

## II. SOM과 LVQ 및 F.C.P. Net.

### 2.1 SOM과 LVQ 학습 네트워크

(그림 1)과 같이 SOM과 LVQ는 같은 구조의 학습 네트워크를 갖는다.

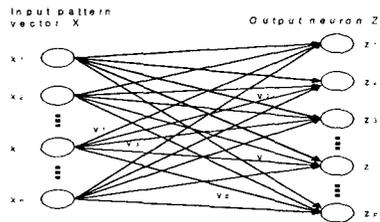


그림 1. SOM과 LVQ 학습네트워크  
Fig. 1 Learning networks of SOM and LVQ

(그림 1)에서  $x_1, x_2, \dots, x_n$  은  $n \times 1$  입력패턴벡터,  $z_1, z_2, \dots, z_p$  각각  $p$ 개의 출력뉴런,  $v_{ji}$ , ( $i=1, 2, \dots, n, j=1, 2, \dots, p$ )는 학습될 SOM 또는 LVQ의 weight 이다. 다음의 식 (1), (2)는 각각 SOM과 LVQ의 학습알고리즘이다.

$$v_{ji}^{k+1} = v_{ji}^k + \alpha_S [ x_i - v_{ji}^k ] \dots\dots\dots (1)$$

$$v_{ji}^{k+1} = v_{ji}^k + \alpha_L [ x_i - v_{ji}^k ] \dots\dots\dots (2-a)$$

$$v_{ji}^{k+1} = v_{ji}^k - \alpha_L [ x_i - v_{ji}^k ] \dots\dots\dots (2-b)$$

여기서  $v_{ji}$  는 입력패턴벡터의  $i$  번째 요소  $x_i$  에서  $j$  번째 출력 뉴런  $z_j$  사이의 연결강도이며,  $\alpha_S, \alpha_L$  는 각각 SOM과 LVQ의 학습률이다. 식 (1)은 SOM의 학습은 승리뉴런과 이웃한 뉴런들 까지도 학습을 하게 되지만, 식 (2)의 LVQ의 학습에서는 승리뉴런 만이 학습을 하게 된다. 식(2-a)와 (2-b)는 각각 입력패턴의 부류와 승리뉴런의 부류가 같은 경우와 다른 경우의 학습알고리즘이다.

## 2.2 F.C.P. Net.의 학습구조

그림 2는 F.C.P. Net.의 구조이다.

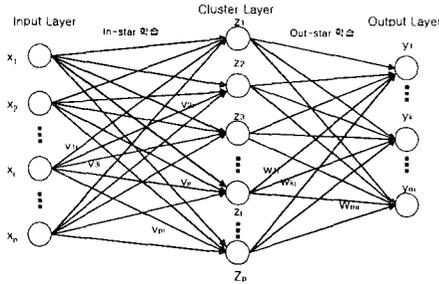


그림 2. F.C.P. Net.

Fig. 2 Forward only Counter Propagation Networks

(그림 2)의 F.C.P. Net.에서 입력층과 부류층 사이의 연결강도  $v_{ji}$  ( $i=1,2,\dots,n, j=1,2,\dots,p$ )의 학습은 in-star 학습법을 사용하고, 부류층과 출력층 사이의 연결강도  $w_{kj}$  ( $j=1,2,\dots,m, k=1,2,\dots,p$ )의 학습은 out-star 학습규칙을 이용한다. 학습의 정확성은 부류층의 뉴런 수에 의존하고, 학습의 단계는 in-star 학습법을 사용하는 1 단계학습과 in-star 학습법과 out-star 학습법을 동시에 사용하는 2 단계의 학습으로 학습이 이루어진다. in-star 학습법을 사용하는 1 단계의 학습과정에서 승리뉴런을 계산하기 위하여 유클리드거리에 의한 방식을 사용하고, 부류층의  $j$ 번째 뉴런이 승리뉴런이 되었을 때 연결강도의 학습규칙은 식(3)으로 된다.

$$v_{ji}^{k+1} = v_{ji}^k + \beta [ x_i - v_{ji}^k ] \dots\dots\dots (3)$$

식(3)에서  $\beta$ 는 학습률이며, 학습률의 초기값  $\beta(0)$ 는  $0.5 < \beta(0) < 0.8$ 로 설정되고 학습이 진행되면서 서서히 감소된다. 1단계의 학습이 종료되면, 식(3)의 in-star 학습에서 학습률  $\beta$ 는 매우 작은 값으로 되고, 이 값을  $\beta_{final}$ 로 고정시키고 2단계의 학습을 시작한다. in-star와 out-star 학습규칙을 모두 사용하는 2단계의 학습규칙은 식(4)와 식(5)로 된다.

$$v_{ji}^{k+1} = v_{ji}^k + \beta_{final} [ x_i - v_{ji}^k ] \dots\dots\dots (4)$$

$$w_{kj}^{k+1} = w_{kj}^k + \gamma [ y_k - w_{kj}^k ] \dots\dots\dots (5)$$

학습에 이용되는 각 패턴벡터는 (입력벡터 : 출력벡터)

로 구성되는 2개의 데이터벡터를 갖는다. 입력벡터는  $x_1, x_2, \dots, x_n$ 로 구성되는  $n \times 1$  벡터, 출력벡터는  $y_1, y_2, \dots, y_m$ 으로 구성되는  $m \times 1$  벡터,  $\gamma$ 는 out-star 학습규칙의 학습률이며  $[0,1]$ 의 초기값으로 설정되고 학습이 진행되면서 감소한다.

## III. F.C.P. Net.을 이용한 LVQ 학습

본 논문에서는 LVQ 학습네트워크의 분류성능을 향상시키기 위한 LVQ 학습네트워크를 설계한다. 제안된 설계방식에서는 SOM의 학습 알고리즘을 이용하여 LVQ 네트워크의 초기 참조벡터를 학습하고, F.C.P. Net.을 이용하여 LVQ 네트워크의 참조벡터를 정밀하게 학습하는 한편, 동시에 출력뉴런이 속해야 할 부류를 학습하기 위한 학습네트워크를 설계한다.

### 3.1 SOM에 의한 LVQ 초기 참조벡터의 학습

충분히 학습된 SOM의 연결강도를 LVQ 초기 참조벡터로 이용되면, 국소적 점근 안정 평형점에 가까이 존재하고, 학습이 진행되면서 참조벡터가 평형점으로 부터 멀리 이동되지 않게 되어 LVQ의 참조벡터는 수렴하고 LVQ 네트워크는 우수한 분류성능을 갖는다(7-9).

(그림 2)의 F.C.P. Net.에서 입력층과 부류층 사이의 네트워크의 구조는 SOM과 LVQ의 학습네트워크의 구조와 동일하다. 그러므로 LVQ 초기 참조벡터를 학습하기 위한 1 단계의 학습으로, F.C.P. Net.에서 입력층과 부류층 사이의 연결강도의 학습은 식 (1)과 같이 이웃반경을 고려한 SOM의 학습규칙에 의해 학습된다. 즉, F.C.P. Net.의 입력층과 부류층 사이의 학습은 SOM 알고리즘이 사용된다. 충분히 학습된 SOM의 연결강도는 다시 F.C.P. Net.의 입력층과 부류층 사이의 연결강도로 설정된다.

### 3.2 LVQ학습알고리즘에 의한 F.C.P. Net.의 정밀한 참조벡터 학습

두 번째의 학습 단계에서의 F.C.P. Net.의 입력층과 부류층 사이는 LVQ 학습알고리즘으로 학습된다. 그러므로 SOM 알고리즘으로 학습된 F.C.P. Net.의 입력층과 부류

층 사이의 연결강도가 다시 초기값으로 이용되고 F.C.P. Net.의 입력층과 부류층 사이를 LVQ 알고리즘으로 학습된 다면 LVQ의 초기 참조벡터는 SOM 학습알고리즘에 의해 학습된 것이고, LVQ 학습알고리즘으로 학습이 진행되는 동안 SOM으로 학습된 LVQ의 초기 참조벡터는 정밀하게 학습된다. 즉, SOM에 의해 개략적으로 패턴벡터를 분류하고, LVQ에 의해 패턴벡터를 정밀하게 분류하는 것이다. 패턴벡터를 정밀하게 분류하기 위한 LVQ 학습 알고리즘을 수행하기 위하여 다시 학습용 패턴벡터를 F.C.P. Net.의 입력 층에 인가하여 식 (2-a), (2-b)의 LVQ 학습알고리즘으로 입력층과 부류층 사이의 연결강도를 학습시킨다.

### 3.3 LVQ의 Class 지정 학습

전 절에서와 같이 LVQ의 초기 참조벡터를 정밀하게 학습한 후에 다시 학습용 패턴벡터를 F.C.P. Net.의 입력 층에 인가하여 패턴벡터를 부류층에 존재하는 뉴런들의 중속 부류로 분류함과 동시에 부류층에 존재하는 뉴런들의 중속 부류를 특정한 부류로 지정하는 학습을 수행한다. 이러한 출력뉴런이 속해야 할 부류를 지정하기 위한 학습알고리즘의 수행은 중속부류로의 분류와 동시에 진행된다. 즉, 학습용 패턴벡터를 F.C.P. Net.의 입력층에 가하여 부류층의 승리뉴런을 결정하고, 결정된 승리뉴런이 속해야 할 부류의 학습은 식(6)의 out-star 학습규칙을 사용하여 F.C.P. Net.의 부류층과 출력층의 연결강도를 학습한다.

$$w_{kj}^{k+1} = w_{kj}^k + b[y_k - w_{kj}^k] \dots\dots\dots (6)$$

여기서,  $w_{kj}$ 는 부류층의  $j$ 번째 승리뉴런과 출력층의  $m$ 개의 출력뉴런  $y_i, i = 1, 2, \dots, m$  사이에 연결된 연결강도이고,  $y_k$ 는 학습에 사용되는 패턴벡터 쌍 중 출력벡터로 입력벡터가 속할 부류를 나타내는  $m \times 1$  벡터이다.

### 3.4 제안된 LVQ 네트워크의 구조 설계

제안된 학습알고리즘을 갖는 LVQ네트워크의 구조는 (그림 2)에서와 같이 입력층, 부류층 및 출력층의 3층 구조의 신경회로망이다. 입력층의 뉴런 수는 학습하고자 하는 패턴 벡터의 차원과 동일하고, 부류층의 뉴런 수는 설계하고자 하는 뉴런의 수와 동일하다. 마지막으로 출력층의 뉴런 수  $m$ 은 분류하고자 하는 부류의 수가 최대  $n$ 이면, 다음의 식 (8)로 된다.

$$2^m = n, \text{ if } n > 2^{m-1} \text{ and } n < 2^m \dots\dots\dots (8)$$

식(8)의 F.C.P. Net.의 출력층 뉴런수를  $m$ 에 대하여 정리하면 식(9)로 된다.

$$m = \log_2 n \dots\dots\dots (9)$$

식(9)에 의하여 설계하고자 하는 LVQ의 부류가  $n$ 개 일 때, F.C.P. Net.의 출력층의 뉴런수  $m$ 을 나타낸 것이 (표 1)이다.

표 1. 부류가  $n$ 개에 대한 출력층의 뉴런수  $m$   
Table. 1 Number of Output Layer with respect to Classes  $n$

n	m	n	m	n	m	n	m
2	2	7	3	12	4	17	5
3	2	8	3	13	4	...	...
4	2	9	4	14	4	31	5
5	3	10	4	15	4	...	...
6	3	11	4	16	4	33	6

## IV. 시뮬레이션

Fisher's Iris 데이터는 3가지 품종 'Setosa', 'Versicolor', 'Virginica'의 붓꽃(iris)으로부터 각각 50개씩 측정변수를 추출하여 생성된 150개의 개체들에서 측정된 데이터이다. 측정 변수는 꽃받침 조각의 길이(Sepal Length), 꽃받침 조각의 폭(Sepal Width), 꽃잎의 길이(Petal Length), 꽃잎의 폭(Petal Width)이다. 따라서 1개의 패턴벡터는 3가지 품종 중의 하나를 나타내며, 각각의 패턴벡터는 4개의 측정변수를 갖는  $4 \times 1$  벡터로 표시된다. 그러므로 패턴분류를 위한 실험 목적은 4가지 측정변수로 이루어진 훈련 패턴 벡터를 이용하여 충분히 학습된 네트워크는 4가지 측정변수로 이루어진 임의의 패턴 벡터가 어떤 품종에 속하는지를 정확하게 분류하는 것이다.

기존의 LVQ의 초기참조벡터의 설정은 [0.7] 사이의 값을 무작위로 발생시킨 경우와 학습용 패턴벡터를 초기 참조 벡터로 사용한 경우로 나누어 시뮬레이션하고, 각각의 패턴 분류특성을 제안한 방식과 비교하였다. 기존의 LVQ의 출력 뉴런과 제안된 방식의 부류층의 뉴런은 모두 25개를 사용하였고, 기존의 LVQ 학습에서 5개의 출력뉴런은 Setosa, 나

머지 20개 중에서 Versicolor와 Virginica를 분류하기 위하여 각각 10개의 출력뉴런을 할당하였다. SOM, LVQ의 연결강도 및 제안된 방식의 입력층과 부류층 사이의 연결강도를 학습하기 위하여 사용된 학습율은 학습이 진행됨에 따라 서서히 감소하며 식(10)과 같이 학습이 진행됨에 따라 감소된다.

$$a = a(0) \cdot \frac{ITER_{num} - k}{ITER_{num}} \dots\dots\dots (10)$$

식 (10)에서  $ITER_{num}$ 는 학습횟수,  $a(0)$ 는 학습률을 나타낸다. 학습률  $a$ 는 설정된 초기값  $a(0)$ 로부터 학습이 진행되면서 서서히 감소된다. 또한 제안된 학습방식에서 부류층과 출력층 사이의 연결강도 역시 식(9)를 사용하여 학습이 진행되면서 감소된다. 식(10)에 의해 감소되는 학습률의 초기값을 각각 0.7, 0.5, 0.3, 0.1로 놓고 제안된 학습방식을 갖는 LVQ와 기존의 LVQ와의 패턴분류성능을 시뮬레이션 한 결과는 각각 <표 2>, <표 3>, <표 4>, <표 5> 이다.

표 2. 훈련 데이터의 분류성능(a(0) = 0.7)  
Table. 2 Classification performance of training datas

the number of iterations	1000	2000	5000	10000	분류율 (%)
LVQ(Random)	139	139	140	140	93.0
LVQ(Learning vector)	143	143	143	143	95.3
the proposed method	146	147	147	147	97.8

표 3. 훈련 데이터의 분류에러 수(a(0) = 0.5)  
Table. 3 Classification performance of training datas

the number of iterations	1000	2000	5000	10000	분류율 (%)
LVQ(Random)	138	138	139	139	92.3
LVQ(Learning vector)	139	140	140	141	93.3
the proposed method	146	146	146	146	97.3

표 4. 훈련 데이터의 분류에러 수(a(0) = 0.3)  
Table. 4 Classification performance of training datas

the number of iterations	1000	2000	5000	10000	분류율 (%)
LVQ(Random)	138	138	140	141	92.8
LVQ(Learning vector)	134	134	134	137	89.8
the proposed method	146	146	146	146	97.3

표 5. 훈련 데이터의 분류에러 수(a(0) = 0.1)  
Table. 5 Classification performance of training datas

the number of iterations	1000	2000	5000	10000	분류율 (%)
LVQ(Random)	139	140	140	140	93.2
LVQ(Learning vector)	126	126	127	128	84.5
the proposed method	147	147	147	147	98.0

다음의 <표 6>은 <표 2>, <표 3>, <표 4>, <표 5>를 평균한 분류오차 수 및 오차율이다.

표 6. 평균 분류성공 수 및 분류 성공률  
Table. 6 Number and Ratio of classification performance

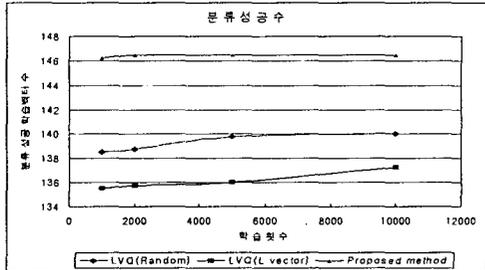
the number of iterations		1000	2000	5000	10000	평균
LVQ (Random)	분류 성공수	138.5	138.75	139.75	140.0	139.5
	분류성공률 (%)	92.3	93.2	93.2	93.3	93.0
LVQ (Learning vector)	분류 성공수	135.5	135.75	136.0	137.25	136.13
	분류성공률 (%)	90.3	90.5	90.7	91.5	90.75
the proposed method	분류 성공수	146.25	146.5	146.5	146.5	146.44
	분류성공률 (%)	97.5	97.7	97.7	97.7	97.63

(그림 3)은 <표 2>, <표 3>, <표 4>, <표 5> 및 <표 6>에서 수행된 시뮬레이션에 대한 평균 분류 성공 수 및 성공적인 분류율을 그래프로 나타내었다.

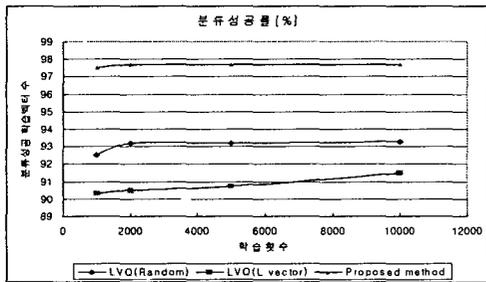
그림 3에서 LVQ(Random)은 기존의 LVQ 네트워크의 초기 참조벡터를 무작위로 발생시켜 설정하고 패턴분류성능을 시뮬레이션 한 결과이고, LVQ(L vector) 역시 기존의 LVQ 네트워크의 초기 참조벡터의 설정하는 데 있어서 학습에 사용할 패턴벡터를 초기 참조벡터로 사용한 경우이다. LVQ(Random), LVQ(L vector), 제안된 방식은 150개의 시험벡터 중에 각각 평균 139.5개, 136.13개, 146.44개의 분류성공수를 나타내었다. 이것을 분류성공률로 표기하면, LVQ(Random), LVQ(L vector), 제안된 방식은 각각 93.0(%), 90.75(%), 97.63(%의 분류성공률을 갖는다.

따라서 제안된 방식의 패턴분류성능은 무작위로 발생시킨 LVQ(Random) 보다 평균 4.63(%의 분류 성공률이 개선되었고, 패턴벡터를 초기 참조벡터로 사용한 LVQ(L

vector) 학습방식보다 평균 6.88(%)의 분류성공률이 개선되었음을 확인하였다.



(a) Number of the successful classification pattern vectors



(b) Ratio of the successful classification pattern vectors

그림 3. 분류성능비교

Fig. 3 Comparison of the classification performance

였다. 즉, LVQ 초기 참조벡터를 학습하기 위한 1 단계의 학습으로, F.C.P. Net.에서 입력층과 부류층 사이를 SOM 네트워크로 사용하여 LVQ의 초기 참조벡터를 학습하게 하였다.

두 번째의 학습 단계에서의 F.C.P. Net.의 입력층과 부류층 사이를 LVQ 학습네트워크로 사용하였고, 1 단계에서 학습된 연결강도를 초기 참조벡터로 사용하여 LVQ 학습 알고리즘에 의해 참조벡터를 정밀하게 학습가능하게 하였다.

마지막으로 3 단계학습에서는 다시 학습용 패턴벡터를 F.C.P. Net.의 입력 층에 인가하여 in-star 및 out-star 학습알고리즘으로 입력층과 부류층 사이의 LVQ의 참조벡터를 정밀하게 학습시키면서 부류층에 존재하는 뉴런들의 종속부류를 분류함과 동시에 부류층에 존재하는 뉴런들의 종속부류를 특정한 부류로 지정하는 학습을 수행하게 하였다.

또한 패턴벡터의 차원 및 그들을 몇 개의 부류로 분류할 것인지를 결정하기만 하면 입력층, 부류층, 출력층에 존재하게 되는 뉴런의 개수를 결정할 수 있도록 하였다.

제안된 학습방식의 타당성을 검증하기 위하여 Fisher의 Iris 데이터를 학습벡터 및 시험 벡터로 사용하여 시뮬레이션 한 결과, 제안된 학습방식을 이용한 LVQ의 패턴분류 성능은 기존의 LVQ 네트워크의 초기 참조벡터를 무작위로 발생시켜 설정한 LVQ방식 보다 평균 4.63(%)의 분류 성공률이 개선되었고, 패턴벡터를 초기 참조벡터로 사용한 LVQ 학습방식보다 평균 6.88(%)의 분류성공률이 개선되었음을 확인하였다.

## V. 결론

본 논문에서는 LVQ 학습네트워크의 분류성능을 향상시키기 위한 LVQ 학습네트워크를 설계하였다. 제안된 설계방식에서는 SOM의 학습 알고리즘을 이용하여 LVQ 네트워크의 초기 참조벡터를 학습하였고, F.C.P. Net.을 이용하여 LVQ 네트워크의 참조벡터를 정밀하게 학습하게하는 한편, 동시에 출력뉴런이 속해야 할 부류를 학습하기 위한 학습네트워크를 설계하였다.

F.C.P. Net.의 입력층과 부류층 사이의 네트워크의 구조가 SOM과 LVQ의 학습네트워크의 구조와 동일함을 기반으로 3 단계 학습 중 1, 2 단계의 학습알고리즘에 제안하

## 참고문헌

- [1] R. Hecht-Nielsen, "Applications of counter-propagation network", Neural Networks, vol. 1, pp.131-139, 1988.
- [2] T. Kohonen, Self-Organizing Maps, Springer-Verlag, Berlin, 1995.
- [3] T. Kohonen, "The Self-Organizing Map", PROCEEDING OF THE IEEE, VOL. 78, NO. 9, pp.1464-1480, 1990.
- [4] 길민욱, 이극, "동적 가우시안 함수를 이용한 Kohonen 네트워크 수렴속도개선", 한국컴퓨터정보학

회논문집, 7권, 4호, 2002.

- [5] 한광덕, "역사적 기록문서에서 효율적인 유사도 및 클러스터링 측정에 관한 연구", 한국컴퓨터정보학회논문집, 7권, 4호, 2002.
- [6] 임승린, "내용기반 복합 영상 검색시스템을 위한 적응적 특징 자가선택과 다중 SOFM 신경망", 한국컴퓨터정보학회논문집, 5권, 2호, 2000.
- [7] Baras, J.S. and LaVigna, A., "Conergence of Kohonen's Learning Vector Quantization", IJCNN, pp.17-20. Vol. 3, June, 1990.
- [8] Tanaka, T. Saito, M., Quantitative Properties of Kohonen's Self-Organizing Maps as Adaptive Vector Quantizers, IEICE transactions on information and systems, D-II, Vol. J75-D-II, No. 6, pp. 1085-1092, 1992(in Japanese).
- [9] T. Kohnen, "Improved versions of learning vector quantization", Proc. IEEE International Joint Conference on Neural Networks, San Diego, California, June 17-21, vol. 1, pp. 545-550, 1990.



## 저자 소개

### 이 옹 구

1987년 동국대학교 공학사  
 1993년 동국대학교 공학석사  
 1997년 동국대학교 공학박사  
 2004년 ~ 현재  
 대한전자공학회 전자기술소사이어티 이사  
 1998년 ~ 현재  
 한림성심대학 전자정보통신과 부교수  
 <관심분야>  
 지도 및 비지도학습 신경회로망,  
 퍼지논리시스템, 패턴인식,  
 생체신호처리



### 최 우 승

1977년 동국대학교 공학사  
 1981년 동국대학교 공학석사  
 1994년 동국대학교 공학박사  
 1998년 ~ 2000년  
 한국컴퓨터정보 학회 학회장  
 2000년~현재  
 한국컴퓨터정보학회 교문  
 1981년~ 2004년 현재  
 경원전문대학 네트워크정보과 교수  
 <관심분야>  
 비지도학습 신경회로망, 패턴인식