

분류오차유발 패턴벡터 학습을 위한 학습네트워크

이 용 구*, 최 우 승**

Learning Networks for Learning the Pattern Vectors causing Classification Error

Yong-Gu Lee*, Woo-Seung Choi **

요약

본 논문에서는 분류오차를 추출하고 학습하여 분류성능을 개선하는 LVQ 학습 알고리즘을 설계하였다. 제안된 LVQ 학습 알고리즘은 초기기준벡터의 학습을 위해 SOM을 이용하고, LVQ 출력뉴런의 부류지정을 위하여 out-star 학습법을 사용하는 학습네트워크이다. 분류오차가 발생되는 패턴벡터로 추출하기 위하여 오차유발조건을 제안하였고, 이 조건을 이용하여 분류오차를 유발시키는 입력패턴벡터로 구성되는 패턴벡터공간을 구성하여 분류오차가 발생되는 패턴벡터를 학습시키므로 분류오차수를 감소시키고, 패턴분류성능을 개선하였다.

제안된 학습알고리즘의 성능을 검증하기 위하여 Fisher의 Iris 데이터와 EMG 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 designed a learning algorithm of LVQ that extracts classification errors and learns ones and improves classification performance. The proposed LVQ learning algorithm is the learning Networks which is use SOM to learn initial reference vectors and out-star learning algorithm to determine the class of the output neurons of LVQ. To extract pattern vectors which cause classification errors, we proposed the error-cause condition, which uses that condition and constructed the pattern vector space which consists of the input pattern vectors that cause the classification errors and learned these pattern vectors, and improved performance of the pattern classification.

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 EMG 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 : (학습벡터양자화)LVQ, (오차유발조건)error causing condition, (패턴분류)pattern classification

*제1저자 : 이용구

• 접수일 : 2005.10.12, 심사완료일 : 2005.11.07

* 한림성심대학 의용정보과 부교수, ** 경원전문대학 정보통신과 교수

I. 서 론

최근에 인공신경회로망을 이용한 영상신호 및 생체신호 처리 기법에 관한 연구가 활발히 진행되고 있다[1, 2]. 특히 클러스터링 알고리즘을 기반으로 하는 지도학습 및 비지도학습 알고리즘을 갖는 신경회로망을 이용한 패턴인식 기법에 대한 연구가 활발히 진행되고 있다[3, 4].

지도 및 비지도 학습 알고리즘을 갖는 인공신경회로망으로는 1987년 Hecht-Nielsen이 제안한 in-star 경쟁 학습법과 1974년 S. Grossberg가 제안한 out-star 학습법을 기반으로 Counter propagation networks 이 1987년 Hecht-Nielsen에 의해 제안되었다[5].

또한 같은 해인 1987년 Carpenter와 Grossberg는 패턴벡터의 유사도가 경계파라미터 이상의 패턴벡터는 분류시키고 그렇지 못한 패턴벡터는 분류대상에서 제외시키는 비지도학습 알고리즘을 갖는 신경회로망인 ART(Adaptive Resonance Theory)를 제안하였다[6, 7]. 1989년에는 in-star 경쟁 학습법을 기반으로 SOM(Self-Organizing Map)과 LVQ(Learning Vector Quantization)가 Kohonen에 의해 제안되었다[8, 9].

이들 중 SOM은 차원이 높은 패턴벡터를 2차원 특징 맵(feature map)으로 차원을 감소시키는 전 처리용으로 많이 사용되고, 실제의 패턴분류 알고리즘으로는 LVQ가 주로 사용된다. LVQ의 학습알고리즘은 지도학습과 비지도학습을 동시에 사용한다. LVQ에 가해지는 패턴벡터와 기준벡터(reference vector)와의 유사도를 측정하여 가장 유사성이 일치하는 출력뉴런이 승리뉴런이 되고, 승리뉴런이 갖는 부류와 입력벡터의 부류가 같으면 입력뉴런과 승리뉴런사이의 연결강도를 입력벡터의 방향으로 증가시키고, 부류가 다르면 연결강도는 입력벡터와 반대방향으로 학습시킨다. 이러한 학습과정을 통해 LVQ는 하나의 부류에 여러 개의 중속부류를 포함시켜서 학습을 진행하므로 정밀한 패턴분류특성을 갖는다.

그러나 LVQ의 학습에는 이웃반경이 고려되지 않고 오직 승리뉴런에 연결된 연결강도 만의 학습이 이루어지므로 패턴분류의 성능은 연결강도의 초기값 설정에 매우 민감하게 반응하고, 학습과정에서 어떠한 방식으로 종속부류인 출력

뉴런 각각을 어떤 부류에 지정하는가에 따라 분류성능에 영향을 미치게 된다[10, 11].

본 저자들은 이러한 LVQ 학습알고리즘을 개선하기 위하여 LVQ의 초기기준벡터를 학습시켜서 학습의 안정도를 개선하고, 출력뉴런이 속해야 할 부류를 학습에 의하여 지정되는 LVQ 학습알고리즘을 제안한 바 있다[2, 4]. 본 저자들이 제안한 LVQ 학습알고리즘은 Fisher의 Iris 데이터와 EMG 데이터에 적용시켜 기존의 LVQ 학습알고리즘보다 좋은 학습결과를 얻었지만 부류 간의 겹침이 심한 패턴벡터의 학습에는 여전히 분류오차가 발생하였다.

본 논문에서는 저자들이 제안하였던 LVQ 학습알고리즘에서 발생되는 분류오차를 줄이기 위한 학습알고리즘을 제안한다. 제안된 LVQ 학습알고리즘은 인접한 부류가 겹쳐서 분류오차가 주로 발생되는 부분의 패턴벡터를 별도로 추출하고, 추출된 패턴벡터들로 구성되는 패턴벡터공간에 대한 학습이 진행될 수 있는 학습네트워크를 설계한다.

제안된 학습알고리즘의 유용성을 입증하기 위하여 Fisher의 Iris 데이터와 EMG 데이터를 학습 및 시험 데이터로 시뮬레이션 하여 기존의 LVQ 학습방식과 패턴분류성능을 비교 검토하였다.

II. LVQ 학습알고리즘

(그림 1)은 Kohonen에 의하여 제안된 LVQ 네트워크의 구조이다.

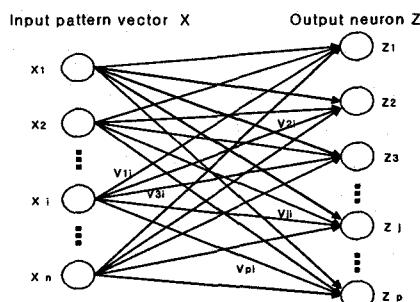


그림 1. LVQ의 구조
Fig. 1 The architecture of the LVQ

(그림 1)에서 x_1, x_2, \dots, x_n 은 $n \times 1$ 입력패턴벡터이고 z_1, z_2, \dots, z_p 각각 p 개의 출력뉴런이다. 입력패턴벡터와 출력뉴런 사이의 연결강도는 v_{ji} , ($j=1, 2, \dots, p$)는 학습될 LVQ의 기준벡터이다. 이 기준벡터의 학습에는 입력 패턴과 가장 유사한 연결강도를 갖는 출력뉴런이 승리뉴런이 되고, 그 승리뉴런이 속하는 부류와 입력패턴벡터가 속하는 부류가 동일할 때는 식(1)과 같이 입력패턴벡터와 동일한 방향으로 학습이 이루어진다.

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

만일 승리뉴런의 부류와 입력패턴벡터의 부류가 같지 않을 때는 식(2)와 같이 기준벡터의 학습은 입력패턴벡터의 방향과 반대 방향으로 이루어진다.

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

여기서 v_{ji} 는 입력패턴벡터 x_i 에서 j 번째 출력 뉴런 z_j 사이의 연결강도이고 α_L 은 학습률이다. 문제는 LVQ 네트워크의 분류성능에 영향을 미치는 초기기준벡터 v_{ji} 의 설정과 종속부류 $1, 2, \dots, p$ 를 지정하는 출력 뉴런 z_1, z_2, \dots, z_p 각각에 대한 부류의 지정이다. (그림 1)의 LVQ는 학습할 때 이웃반경을 고려하지 않고, p 개의 출력뉴런 $1, 2, \dots, p$ 각각은 입력패턴벡터가 속해야 할 종속부류를 지정하게 된다. 그러므로 LVQ는 SOM보다 정밀한 패턴분류특성을 갖지만 학습할 때에 이웃반경이 고려되지 않고 오직 승리뉴런에 연결된 기준벡터 만의 학습이 이루어지므로 입력패턴벡터공간에서 특성화 지도를 형성하지 않으므로 학습되지 않는 뉴런이 발생할 수 있고, 이로 인하여 패턴분류의 성능은 기준벡터의 초기값 설정에 매우 민감하게 반응한다. 또한 종속부류를 나타내는 p 개의 출력뉴런 각각을 어떤 부류에 포함시키는가 하는 문제는 LVQ의 분류 성능에 영향을 미치는 중요한 요소이다.

최근에 LVQ의 문제점들을 부분적으로 해결하기 위하여 저자들이 제안했던 LVQ 네트워크의 구조는 입력층, 종속부류층, 부류층으로 구성된 3층 구조의 신경회로망은 (그림 2)와 같다.

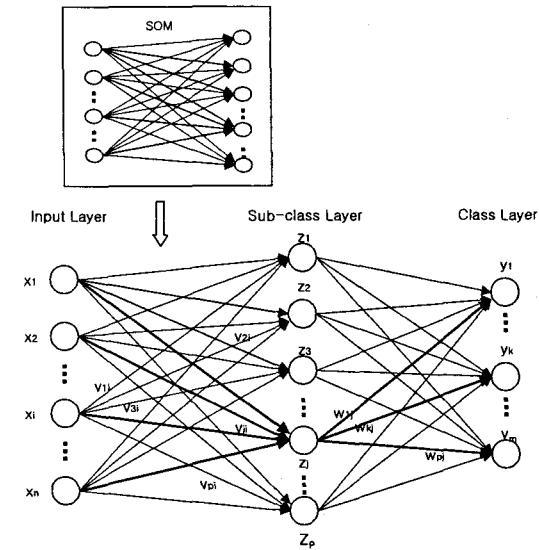


그림 2. LVQ 학습 네트워크
Fig. 2 The LVQ learning networks

입력층과 종속부류층 사이의 학습은 먼저, 온라인 또는 오프라인으로 SOM으로 학습이 진행되어 입력패턴벡터의 차원을 감소시킨다. 감소된 입력 패턴벡터를 사용하여 학습된 연결강도를 LVQ 학습 네트워크의 입력 층과 종속부류층 사이의 초기기준벡터로 사용한다. SOM의 학습알고리즘은 식(3)이다.

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

여기서 α_S 는 SOM 학습알고리즘의 학습률이다. 식 (3)으로 충분히 학습된 SOM의 연결강도를 초기기준벡터로 사용하는 LVQ 알고리즘은 국소적 접근 안정 평형점에 가까이 존재하고, 학습이 진행되면서 기준벡터가 평형점에서 멀리 이동되지 않게 되어 기준벡터는 수렴하고 우수한 분류성을 갖는다[10,11].

이렇게 안정된 초기기준벡터를 가지고 식(1) 및 식(2)를 사용하여 LVQ의 학습을 진행하여 입력패턴벡터가 속할 종속부류로 학습된다.

입력패턴벡터가 속하는 종속부류는 식(4)의 out-star 학습규칙에 의해 종속부류층과 부류층 사이의 연결강도가 조정된다.

$$w_{kj}^{k+1} = w_{kj}^k + b[y_k - w_{kj}^k] \dots \dots \dots (4)$$

여기서, b 는 학습률, w_{kj} 는 종속부류층의 j 번째 승리뉴런과 부류층에 있는 m 개의 출력뉴런 y_i , $i = 1, 2, \dots, m$ 사이에 연결강도, y_k 는 학습에 사용되는 패턴벡터 쌍 중 출력벡터로 입력벡터가 속할 부류를 나타내는 $m \times 1$ 벡터이다.

III. 분류오차개선을 위한 LVQ 학습 알고리즘

Ⅱ장에서 논의된 (그림 2)의 LVQ 학습알고리즘은 SOM의 사용으로 패턴벡터공간의 차원이 감소되고, 학습되는 기준벡터는 초기에 안정된 기준벡터를 사용하므로 기준벡터는 수렴하고 우수한 분류성능을 갖는다. 그러나 이러한 방식의 학습으로도 인접한 두개의 부류가 약간 겹치는 경우에는 패턴벡터를 올바르게 분류하지만, 겹침이 심한 경우에는 여전히 분류오차가 발생하였다. 이러한 현상은 유кли드 거리를 기반으로 유사도를 측정하고 네트워크를 학습시키는 알고리즘의 한계로 생각된다.

따라서 본 논문에서는 인접한 부류가 겹쳐서 분류오차가 주로 발생되는 입력패턴벡터들을 별도로 추출하여 추출된 패턴벡터들로 구성되는 패턴벡터공간을 구성하고 이 공간에서 LVQ 학습알고리즘에 의해 오차가능성이 큰 입력패턴벡터들을 학습시켜서 전반적으로 분류성능을 개선할 수 있는 LVQ 학습네트워크를 설계한다.

제안된 네트워크의 학습알고리즘은 먼저, Ⅱ장에서 논의된 알고리즘으로 입력패턴벡터의 차원이 높은 경우 차원을 감소시키고, 감소된 패턴벡터를 사용하여 LVQ의 초기기준벡터를 학습시킨 후 입력패턴벡터가 속할 종속부류 및 종속부류가 속할 부류를 지정하는 학습을 진행한다.

두 번째로는 학습된 네트워크에 입력패턴벡터를 가하여 패턴분류를 진행하면서 오차를 유발시키는 패턴벡터를 추출하여 패턴공간을 구성한다.

세 번째로 부류간의 겹침이 발생되어 오차를 유발시키는 패턴벡터들로 구성된 추출된 패턴공간에서 변형된 LVQ 알고리즘을 이용하여 학습을 한다.

식(1), 식(2) 및 식(4)의 학습알고리즘으로 (그림 2)의 LVQ 네트워크를 학습한 후 분류오차를 갖는 입력패턴공간의 구성을 위하여 (그림 3)의 변형된 LVQ 네트워크를 고려한다.

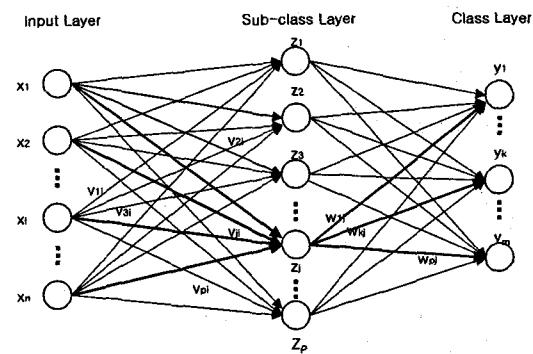


그림 3. 변형된 LVQ 네트워크
Fig. 3 The modified LVQ Networks

(그림 3)의 변형된 LVQ 네트워크의 학습을 위해서 입력벡터 X 와 출력벡터 Y 가 입력뉴런에 각각 가해진다. 본 논문에서 입력벡터 X 는 학습에 사용될 패턴벡터이고, 출력벡터 Y 는 입력벡터가 속하는 부류를 지정한다.

식(1)과 식(2)의 in-star 경쟁학습에 의해서 종속부류층의 승리뉴런이 결정되고, 식(4)의 out-star 학습에 의해서 부류층의 승리뉴런이 속하게 되는 부류가 학습된다. 결국 out-star 학습법에 의하여 학습되는 종속부류층과 부류층 사이의 연결강도 W 는 입력패턴벡터가 속하게 될 부류를 나타낸다. 종속부류층의 승리뉴런에서 부류층으로 학습된 연결강도 w_{kj} 는 식(5)와 같은 고정된 문턱치 Θ 를 갖는 활성화함수를 통과한다.

$$f(w_{kj}) = \begin{cases} 1, & \text{if } w_{kj} \geq \Theta \\ -1, & \text{if } w_{kj} < \Theta \end{cases} \dots \dots \dots (5)$$

식(5)는 종속부류층의 j 번째 승리뉴런에서 부류층에 있는 m 개의 출력뉴런 각각에 대하여 계산된다.

소속될 부류 Y 를 갖는 학습에 사용되는 입력패턴벡터 X 는 이미 자신이 학습되어 소속될 목표벡터가 Y 이므로 학습이 잘되어 오차가 유발되지 않고 정확한 패턴분류가 수행되면, 식(6-a)의 조건을 만족한다.

$$|Y - W| = 0 \quad \dots \dots \dots \quad (6-a)$$

$$|Y - W| \neq 0 \quad \dots \dots \dots \quad (6-b)$$

식(6-a)가 의미하는 것은 학습에 의해서 학습된 입력패턴벡터 X 의 부류 W 는 입력패턴벡터 X 의 목표 부류 Y 와 정확히 일치함을 나타낸다. 식(6-b)과 같이 학습에 의해서 학습된 입력패턴벡터 X 의 부류 W 는 입력패턴벡터 X 의 목표 부류 Y 와 일치하지 않는 경우에는 입력패턴벡터는 부적절한 부류로 분류된다. 그러므로 식(6-b)를 패턴벡터의 오차유발 조건이라 하고, 식(6-b)의 조건을 만족하는 패턴벡터들로 구성된 공간을 오차유발 패턴벡터 공간이라 한다.

식(6-b)의 조건을 만족하는 입력패턴벡터들 만의 공간을 새로운 벡터공간으로 설정하고 식(1), 식(2) 및 식(4)로 학습을 별도로 진행한다. (그림 4)는 본 논문에서 제안된 오차유발 패턴벡터 공간에서 학습네트워크를 갖는 제안된 학습네트워크이다.

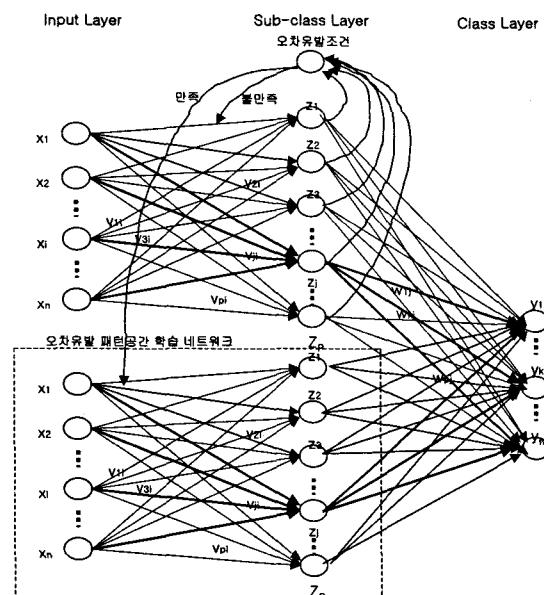


그림 4. 제안된 LVQ 네트워크
Fig. 4 The proposed LVQ networks

IV. 시뮬레이션

본 연구에서 제안된 알고리즘의 유용성을 확인하기 위해서 Fisher의 Iris 데이터와 EMG 데이터에 적용시켜 패턴분류에 대한 시뮬레이션 하였다. 제안된 알고리즘(LVQ-D)과 비교하기 위해서 기존의 LVQ 방식으로는 초기기준벡터를 무작위로 발생시킨 방식(LVQ-A), 학습용 패턴벡터를 초기기준벡터로 사용한 경우(LVQ-B) 및 (그림 2)의 LVQ 학습알고리즘(LVQ-C)에 대한 패턴분류성능을 비교하였다. LVQ-A 방식에서 Iris 데이터에 적용한 경우에는 초기기준벡터의 설정을 [0.7] 사이의 값을 무작위로 발생시켰고, EMG 데이터에 적용한 경우에는 [0,10] 사이의 값을 무작위로 발생시켰다. 제안된 LVQ-D에서 부류지정학습을 위한 out-star 학습에서 활성화 함수의 고정된 문턱치 Θ 는 0을 사용하였다.

4.1 Fisher의 Iris에 적용한 경우

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 4×1 벡터로 표시된다.

Iris 데이터에 대한 시뮬레이션 조건은 LVQ-A, LVQ-B 방식에서는 출력층의 뉴런을 25개 사용하였고, 이 중 5개의 뉴런은 Setosa의 부류로 포함시켰고, 나머지 20개 중에서 Versicolor와 Virginica의 부류로 각각 10개의 뉴런을 포함시켰다. 또한 LVQ-C 방식에서는 LVQ-A, LVQ-B 방식의 출력뉴런에 해당하는 종속 부류층의 뉴런을 동일하게 25개를 사용하였고, 각각의 부류(Setosa, Versicolor, Virginica)는 out-star 학습규칙에 의해 자동 학습되게 하였으며, 부류층 뉴런 수는 2개로 사용하였다. 부류 'Setosa', 'Versicolor', 'Virginica'에 대한 각각의 부류층의 뉴런의 설정값은 각각 $(-1, -1)$, $(-1, 1)$, $(1, -1)$ 로 하여 종속부류층의 승리뉴런과 부류층의 출력 뉴런 사이의 연결강도를 학습하였다.

제안된 LVQ-D 방식에서는 패턴벡터의 오차유발 조건을 만족될 때 LVQ-C 방식에서와 같은 조건이며, 오차유발 조건이 만족 될 경우에는 오차유발 패턴공간에서 오차유발 패턴벡터 들만 별도로 학습을 진행시킨다. LVQ-A, LVQ-B, LVQ-C 및 LVQ-D 방식에서 학습되는 기준벡터 또는 연결강도는 학습이 진행되면서 식(7)로 감소된다.

$$a = a(0) \cdot \frac{ITER_{num} - k}{ITER_{num}} \quad \dots \dots \dots \quad (7)$$

식(7)에서 $ITER_{num}$ 는 학습횟수, $a(0)$ 는 학습률의 초기값을 나타낸다. 또한 LVQ-C 및 LVQ-D 학습방식에서 종속 부류총과 부류총 사이의 연결강도 역시 식(4)를 사용하여 학습이 진행되면서 감소된다. 식(7)에 의해 감소되는 학습률의 초기값을 각각 0.7, 0.5, 0.3, 0.1로 놓고 패턴분류성능을 시뮬레이션 한 결과는 각각 <표 1, 2, 3, 4>이다.

표 1. 훈련 데이터의 분류에러 수($a(0) = 0.7$)
Table. 1 The number of the classification errors of training datas($a(0) = 0.7$)

the number of iterations	1000	2000	5000	10000	에러율 (%)
LVQ-A	11	11	10	10	7
LVQ-B	7	7	7	7	4.7
LVQ-C	4	3	3	3	2.2
LVQ-D	3	3	3	3	2.0

표 2. 훈련 데이터의 분류에러 수($a(0) = 0.5$)
Table. 2 The number of the classification errors of training datas($a(0) = 0.5$)

the number of iterations	1000	2000	5000	10000	에러율 (%)
LVQ-A	12	12	11	11	7.7
LVQ-B	1	10	10	9	6.7
LVQ-C	4	4	4	4	2.7
LVQ-D	2	2	2	2	1.3

표 3. 훈련 데이터의 분류에러 수($a(0) = 0.3$)
Table. 3 The number of the classification errors of training datas($a(0) = 0.3$)

the number of iterations	1000	2000	5000	10000	에러율 (%)
LVQ-A	12	12	10	9	7.2
LVQ-B	16	16	16	13	10.2
LVQ-C	4	4	4	4	2.7
LVQ-D	3	3	3	3	2.0

표 4. 훈련 데이터의 분류에러 수($a(0) = 0.1$)
Table. 4 The number of the classification errors of training datas($a(0) = 0.1$)

the number of iterations	1000	2000	5000	10000	에러율 (%)
LVQ-A	11	10	10	10	6.8
LVQ-B	24	24	23	22	15.5
LVQ-C	3	3	3	3	2.0
LVQ-D	0	0	0	0	0.0

다음의 <표 5>는 <표 1, 2, 3, 4>를 평균한 분류오차수와 오차율이다.

표 5. 분류오차수와 분류오차율
Table. 5 Number and Ratio of classification errors

the number of iterations	1000	2000	5000	10000	평균
LVQ-A	오차수	11.5	11.25	10.25	10.0
	오차율(%)	7.7	7.5	6.8	6.7
LVQ-B	오차수	14.5	14.25	14.0	12.75
	오차율(%)	9.7	9.5	9.3	8.5
LVQ-C	오차수	3.75	3.5	3.5	3.5
	오차율(%)	2.5	2.3	2.3	2.3
LVQ-D	오차수	2	2	2	2
	오차율(%)	1.3	1.3	1.3	1.3

<표 5>에서 기준의 LVQ-A, LVQ-B, LVQ-C에서는 각각 150개의 시험벡터 중에 각각 평균 10.75개, 13.88 개, 3.56개의 분류오차를 나타내었고, 제안된 LVQ-D에서는 평균 2개의 분류오차를 가졌다. 이것을 분류오차율로 계

산하면, LVQ-A, LVQ-B, LVQ-C는 각각 7.18(%), 9.25(%), 2.35(%)의 분류오차율을 가지며, 제안된 LVQ-D에서는 1.3(%)의 분류오차율을 갖는다.

〈표 5〉에서 정리된 시뮬레이션 결과에 대한 분류오차율을 그래프로 나타낸 것이 (그림 5)이다.

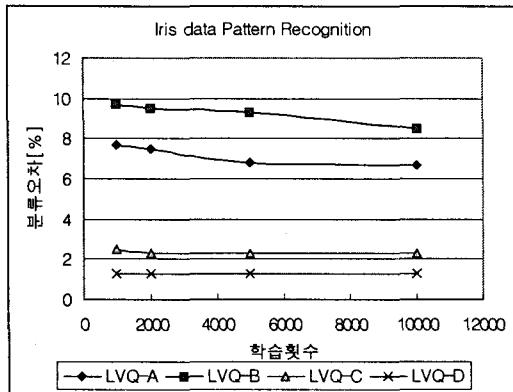


그림 5. 분류오차율
Fig. 5 The ratio of classification error

〈표 5〉와 (그림 5)의 결과를 보면, 제안된 학습방식인 LVQ-D는 기존의 LVQ-A, LVQ-B, LVQ-C의 학습방식보다 평균 5.88(%), 7.95(%), 1.05(%)의 평균 분류 오차율이 개선되었음을 확인하였다.

4.2 EMG 신호의 패턴인식에 적용한 경우

시뮬레이션에 사용된 EMG 데이터는 한글 자음을 수화로 표현할 때 발생되는 14개의 자음 중 'ㄱ', 'ㄹ', 'ㅁ', 'ㅇ', 'ㅍ' 5개의 한글 자음에 대한 수화동작 시에 발생되는 신호를 4개의 채널에서 100개의 데이터를 측정하여 400차원의 균전도 데이터를 획득하였다.[2] 그러므로 1번의 측정은 400×1 의 균전도 패턴벡터를 얻고, 각각의 동작마다 25번을 측정하였다.

400×1 의 균전도 패턴벡터는 SOM 알고리즘에 의해 〈표 6〉과 같이 2×1 패턴벡터로 차원이 감소시킨 후 감소된 패턴벡터를 사용하여 시뮬레이션을 하였다.

표 6. 감소된 균전도 데이터
Table. 6 The reduced EMG datas

수화 신호 번호 분류	ㄱ	ㄹ	ㅁ	ㅇ	ㅍ
(11, 19)	(19, 2)	(14, 0)	(2, 18)	(7, 13)	
(14, 14)	(19, 10)	(15, 0)	(5, 8)	(6, 4)	
(18, 17)	(11, 1)	(11, 5)	(0, 13)	(8, 12)	
(19, 14)	(19, 6)	(12, 7)	(5, 10)	(8, 10)	
(18, 17)	(19, 0)	(12, 7)	(0, 19)	(8, 12)	
(14, 14)	(7, 2)	(15, 0)	(2, 4)	(6, 4)	
(18, 17)	(19, 6)	(11, 5)	(5, 8)	(7, 13)	
(19, 14)	(13, 0)	(14, 0)	(2, 4)	(8, 12)	
(14, 14)	(19, 0)	(12, 7)	(5, 10)	(8, 10)	
(14, 14)	(7, 2)	(11, 5)	(2, 18)	(8, 10)	
(18, 17)	(19, 6)	(14, 0)	(5, 8)	(8, 12)	
(19, 14)	(13, 0)	(15, 0)	(0, 13)	(8, 10)	
테스트 벡터 (25개)	(18, 17)	(19, 2)	(0, 19)	(7, 13)	
(14, 14)	(19, 10)	(14, 0)	(2, 18)	(8, 12)	
(18, 17)	(11, 1)	(12, 7)	(5, 8)	(6, 4)	
(19, 14)	(19, 6)	(11, 5)	(0, 13)	(7, 13)	
(18, 17)	(11, 1)	(11, 5)	(0, 19)	(8, 10)	
(14, 14)	(19, 6)	(15, 0)	(2, 4)	(7, 13)	
(18, 17)	(13, 0)	(14, 0)	(5, 10)	(8, 12)	
(19, 14)	(19, 2)	(12, 7)	(2, 18)	(6, 4)	
(11, 19)	(19, 0)	(14, 0)	(2, 18)	(6, 4)	
(14, 14)	(19, 6)	(15, 0)	(5, 8)	(7, 13)	
(18, 17)	(13, 0)	(14, 0)	(0, 13)	(8, 12)	
(19, 14)	(19, 2)	(12, 7)	(5, 10)	(8, 10)	
(18, 17)	(11, 1)	(15, 0)	(0, 19)	(8, 12)	

EMG 데이터에 대한 시뮬레이션 조건은 LVQ-A, LVQ-B 방식에서는 입력층 뉴런 2개, 출력층 뉴런을 25개 사용하였고, 25개의 출력 뉴런 중 각각 5개씩을 'ㄱ', 'ㄹ', 'ㅁ', 'ㅇ', 'ㅍ'에 해당하는 부류에 포함되는 종속 부류를 지정하였다.

또한 LVQ-C 방식에서는 LVQ-A, LVQ-B 방식과 동일하게 입력 뉴런 2개, 종속 부류층의 뉴런 25개, 부류층의 뉴런은 3개를 사용하였다. 부류 'ㄱ', 'ㄹ', 'ㅁ', 'ㅇ', 'ㅍ'에 대한 각각의 부류층의 뉴런의 설정값은 [-1,-1,-1], [-1,-1,1], [-1,1,-1], [-1,1,1], [1,-1,-1]로 하여 종속 부류층의 승리뉴런과 부류층의 출력 뉴런사이의 연결강도를 학습하였다.

LVQ-A, LVQ-B, LVQ-C 및 LVQ-D 방식에서 학습되는 기준벡터 또는 연결강도는 학습이 진행되면서 식 (7)로 감소된다.

또한 LVQ-D 방식에서 종속 부류층과 부류층 사이의 연결강도 역시 식(4)를 사용하여 학습이 진행되면서 감소된

다. 식(7)에 의해 감소되는 학습률의 초기값을 각각 0.7, 0.5, 0.3, 0.1로 설정하고 근전도 데이터 패턴분류를 시뮬레이션 한 결과는 각각 〈표 7, 8, 9, 10〉이다.

표 7. 훈련 데이터의 분류 오차 수($a(0) = 0.7$)

Table. 7 The number of the classification errors of training datas($a(0) = 0.7$)

the number of iterations	1000	2000	5000	10000	오차율 (%)
LVQ-A	41	41	41	35	31.6
LVQ-B	20	17	17	18	14.1
LVQ-C	6	6	6	6	4.8
LVQ-D	6	6	4	4	4.0

표 8. 훈련 데이터의 분류 오차 수($a(0) = 0.5$)

Table. 8 The number of the classification errors of training datas($a(0) = 0.5$)

the number of iterations	1000	2000	5000	10000	오차율 (%)
LVQ-A	40	40	38	35	30.6
LVQ-B	31	31	27	22	21.9
LVQ-C	6	6	6	6	4.8
LVQ-D	6	6	6	6	4.8

표 9. 훈련 데이터의 분류 오차 수($a(0) = 0.3$)

Table. 9 The number of the classification errors of training datas($a(0) = 0.3$)

the number of iterations	1000	2000	5000	10000	오차율 (%)
LVQ-A	22	22	22	22	17.6
LVQ-B	20	21	22	22	16.9
LVQ-C	9	9	9	9	7.2
LVQ-D	6	6	6	6	4.8

표 10. 훈련 데이터의 분류 오차 수($a(0) = 0.1$)

Table. 10 The number of the classification errors of training datas($a(0) = 0.1$)

the number of iterations	1000	2000	5000	10000	오차율 (%)
LVQ-A	45	50	50	47	38.4
LVQ-B	21	22	20	19.0	16.2
LVQ-C	9	9	9	9	7.2
LVQ-D	6	6	6	6	4.8

위의 〈표 7, 8, 9, 10〉의 각 시뮬레이션은 'ㄱ', 'ㄹ', 'ㅁ', 'ㅇ'의 각 부류 별로 25번의 측정에 의해 각 부류 별로 25개의 근전도 데이터를 학습 및 분류테스트 용으로 사용하므로 전체 125개의 벡터가 학습 및 분류테스트를 위해 사용되었다.

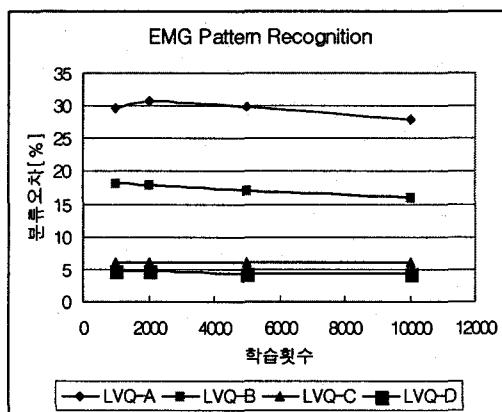
다음의 〈표 11〉은 〈표 7, 8, 9, 10〉을 평균한 분류오차수 및 오차율이다.

표 11. 분류 오차수와 분류오차율

Table. 11 Number and Ratio of classification error

the number of iterations	1000	2000	5000	10000	평균
LVQ-A	오차 수	37	38.25	37.35	34.75
	오차율 (%)	29.6	30.6	29.9	27.8
LVQ-B	오차수	22.63	22.5	21.25	20
	오차율 (%)	18.1	18.0	17.0	16.0
LVQ-C	오차수	7.5	7.5	7.5	7.5
	오차율 (%)	6.0	6.0	6.0	6.0
LVQ-D	오차수	6	6	5.5	5.5
	오차율 (%)	4.8	4.8	4.4	4.6

〈표 11〉의 평균분류 오차율을 그래프로 나타낸 것이 (그림 6)이다.

그림 6. 분류오차율
Fig. 6 The ratio of classification errors

(그림 6)에서 기존의 LVQ-A, LVQ-B, LVQ-C에서는 각각 125개의 EMG 벡터 중에 각각 평균 36.84개, 21.6개, 7.5개의 분류오차를 나타내었고, 제안된 LVQ-D에서는 평균 5.75개의 분류오차를 가졌다. 이것을 분류오차율로 계산하면, LVQ-A, LVQ-B, LVQ-C는 각각 29.5[%], 17.3[%], 6.0[%]의 분류오차율을 가지며, 제안된 LVQ-D에서는 4.6[%]의 분류오차율을 갖는다.

따라서 제안된 학습방식에서는 기존의 LVQ-A, LVQ-B, LVQ-C의 학습방식 보다 평균 24.9[%], 12.7[%], 1.4[%]의 평균 분류 오차율이 개선되었음을 확인하였다.

VI. 결론

본 논문에서는 인접한 부류가 겹쳐서 분류오차가 주로 발생되는 입력패턴벡터들을 별도로 추출하였고, 추출된 패턴벡터들로 구성되는 패턴벡터공간을 구성하였고, 이 공간에서 분류오차를 유발시키는 입력패턴벡터들을 별도로 학습시켜 전반적으로 분류성능을 개선할 수 있는 LVQ 학습네트워크를 설계하였다.

이러한 오차유발 패턴벡터를 추출하기 위하여 입력패턴벡터 X 와 입력패턴벡터가 속하게 될 학습된 부류 W 와 실제의 입력패턴벡터 X 의 목표 부류 Y 가 일치하지 않게 되어 오차를 유발시키는 패턴벡터를 분류할 수 있는 패턴벡터의 오차유발 조건을 제안하였다.

제안된 알고리즘의 유용성을 확인하기 위해서 Fisher의 Iris 데이터와 EMG 데이터에 적용시켜 패턴분류에 대한 시뮬레이션 하였다. 제안된 알고리즘(LVQ-D)과 비교되기 위한 기존의 LVQ 방식으로는 초기기준벡터를 무작위로 발생시킨 방식(LVQ-A), 학습용 패턴벡터를 초기기준벡터로 사용한 경우(LVQ-B) 및 최근에 저자들에 의해 제안되었던 LVQ 학습알고리즘(LVQ-C)에 대한 패턴분류성능을 하여 각각 분류오차수 및 분류오차율을 비교하였다.

Iris 데이터를 학습 및 시험데이터로 사용하였을 때, 제안된 학습방식 LVQ-D는 기존의 LVQ-A, LVQ-B, LVQ-C의 학습방식 보다 평균 5.88[%], 7.95[%], 1.05[%]의 평균 분류 오차율이 개선되었음을 확인하였다.

또한 EMG 데이터를 학습 및 시험데이터로 사용하였을 때, 제안된 학습방식에서는 기존의 LVQ-A, LVQ-B, LVQ-C의 학습방식에 비하여 각각 평균 24.9[%], 12.7[%], 1.4[%]의 평균 분류 오차율이 개선되었음을 확인하였다.

참고문헌

- [1] 임승린, “내용기반 복합 영상 검색시스템을 위한 적용적 특징 자가선택과 다중 SOFM 신경망”, 한국컴퓨터정보학회논문집, 5권, 2호, 2000.
- [2] 이용구, 최우승, “근전도 패턴인식을 위한 혼합형 LVQ 학습 알고리즘”, 한국컴퓨터정보학회논문집, 제10권, 제 2호, pp.113-121, 2005. 5.
- [3] 이정훈, 정경권, 이현관, 엄기환, “가상로봇 팔 제어를 위한 퍼지-SOFM 방식의 근전도 패턴인식”, 대한전자공학회논문지, 제 40권 CI편 제 2호, 2003.
- [4] 이용구, 최우승, “Forward C.P. Net.을 이용한 3단 LVQ 학습알고리즘”, 한국컴퓨터정보학회논문집, 제9 권제 4호, pp.33-39, 2004.
- [5] Hecht-Nielsen, “Counterpropagation networks”, IEEE International Conference on Neural Networks, II, pp.19-32, 1987.
- [6] Carpenter, G. A., & S. Grossberg, “A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine.”, Computer Vision, Graphics, and Image Processing, 37, pp.54-115, 1987.
- [7] Carpenter, G. A., & S. Grossberg, “ART2 : Self-organization of Stable Category Recognition Codes for Analog Input Patterns.”, Applied Optics, 26, pp.151-162, 1987.
- [8] T. Kohonen, Self-organization and Associative Memory, Springer-Verlag, Berlin, 1989.
- [9] T. Kohonen, “The Self-Organizing Maps.”, Proceedings of the IEEE, 78(9), pp.1464-1480, 1990.

- [10] Baras, J.S. and LaVigna, A., "Convergence of Kohonen's Learning Vector Quantization", IJCNN, pp.17-20, Vol. 3, June, 1990.
- [11] 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).

저자소개



이용구

1987년 동국대학교 공학사
1993년 동국대학교 공학석사
1997년 동국대학교 공학박사
1998년~2005 현재 한림성심대학
의용정보과 부교수
〈관심분야〉 지도 및 비지도학습
신경회로망, 퍼지논리시스템,
폐턴인식, 생체신호처리



최우승

1977년 동국대학교 공학사
1981년 동국대학교 공학석사
1994년 동국대학교 공학박사
1998년~2000년 한국컴퓨터정보학회
학회장
2000년~현재 한국컴퓨터정보학회
고문
1981년~2005년 현재 경원전문대학
정보통신과 교수
〈관심분야〉 비지도학습 신경회로망,
폐턴인식