

근전도 패턴인식을 위한 혼합형 LVQ 학습 알고리즘

이용구*, 최우승**

The Hybrid LVQ Learning Algorithm for EMG Pattern Recognition

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

요 약

본 논문에서는 근전도 패턴인식을 수행하기 위한 혼합 LVQ 학습 알고리즘을 설계하였다. 제안된 혼합 LVQ 학습 알고리즘은 초기 참조벡터의 학습을 위해 SOM을 이용하고, LVQ 출력뉴런의 부류지정을 위하여 out-star 학습법을 사용하는 변형된 C.P. Net.이다.

제안된 C.P. Net.의 입력 층과 종속 클래스 층 사이의 연결강도는 SOM과 LVQ 알고리즘을 이용하여 초기 참조벡터의 설정 및 학습이 가능하게 하였고, 패턴벡터를 종속 클래스 층의 뉴런에 의해 종속 클래스로 분류하고, C.P. Net.의 종속 클래스 층과 클래스 층 사이의 연결강도는 분류된 종속 클래스를 클래스로 지정하는 학습을 하게 된다.

근전도 패턴 분류를 위하여 제안된 학습알고리즘을 이용하여 시뮬레이션 되었고 기존의 LVQ 학습방식보다 우수한 분류성공률을 확인하였다.

Abstract

In this paper, we design the hybrid learning algorithm of LVQ which is to perform EMG pattern recognition. The proposed hybrid LVQ learning algorithm is the modified Counter Propagation Networks(C.P. Net.) which is use SOM to learn initial reference vectors and out-star learning algorithm to determine the class of the output neurons of LVQ.

The weights of the proposed C.P. Net. which is between input layer and subclass layer can be learned to determine initial reference vectors by using SOM algorithm and to learn reference vectors by using LVQ algorithm, and pattern vectors is classified into subclasses by neurons which is being in the subclass layer, and the weights which is between subclass layer and class layer of C.P. Net. is learned to classify the classified subclass, which is enclosed a class.

To classify the pattern vectors of EMG, the proposed algorithm is simulated with ones of the conventional LVQ, and it was a confirmation that the proposed learning method is more successful classification than the conventional LVQ.

▶ Keyword : EMG, SOM, LVQ, C.P. Networks, pattern classification

• 제1저자 : 이용구

• 접수일 : 2005.04.21, 심사완료일 : 2005.05.20

* 한림성심대학 의용정보전공(과) 부교수, ** 경원전문대학 정보통신과 교수

1. 서론

근전도(ElectroMyoGram : EMG)는 골격근이 수축할 때 생기는 활동전위를 기록한 것으로 근육의 활성화 정도에 따라서 실효치(RMS)의 변화를 가지며, 근육의 피로도의 증가에 따라서 주파수의 감소를 나타낸다[1]. 이러한 근전도 측정에 사용되는 전극에는 침전극과 표면전극이 있는데 사용의 편리함으로 주로 표면전극이 사용되고 있다. 근전도의 적용분야로는 주로 근육이나 말초신경의 이상을 검사하는데 사용되어왔으나 최근에는 전기생리학으로 그 활용범위가 다양해지고 있다[2].

그 중에서 지능형 인공지능은 인체에서 발생하는 다양한 생체신호를 측정하고, 생체신호처리 및 패턴인식기법을 적용함으로써 사용자의 뜻대로 인공지능이 팔 또는 다리를 자유롭게 움직이게 한다. 이러한 인공지능을 위해서 주로 많이 사용되는 생체신호가 근전도이며, 특히 전환 및 상완이 절단된 장애인을 위한 인공지능은 상완근육의 근전도를 측정하여 증폭, 필터에 의한 신호처리과정 및 패턴분류기를 설계한 후 자동 측정되는 근전도를 패턴인식에 의해 분류하여 본인의 의지대로 손과 팔 운동을 할 수 있게 된다[3].

또한 인공지능은 노화에 의하여 근 골격계가 손상을 입거나 퇴화되어 운동기능이 손실되었을 경우에도 운동기능 손실을 보상할 것으로 기대되므로 생체공학을 기반으로 한 실버형 지능형 인공지능의 연구가 진행되고 있다.

이러한 경향에 발맞추어 최근에는 퍼지 및 신경회로망 등의 인공지능기법을 사용하여 근전도에 대한 첨단 신호처리 및 패턴인식 기법의 연구가 진행되고 있다[3].

최근 이러한 패턴인식을 위하여 널리 연구되고 있는 인공신경회로망으로는 1989년 Kohonen에 의해 제안된 LVQ (Learning Vector Quantization) 이 있다. LVQ 학습의 기반이 되는 경쟁 학습은 1987년 R. Hecht-Nielsen이 제안한 in-star 학습법과 1974년 S. Grossberg가 제안한 out-star 학습법이 있다[4-7].

이러한 경쟁 학습 중 in-star 학습을 기반으로 한 LVQ는 지도학습(supervised learning)과 비지도학습(unsupervised learning)을 동시에 사용한다. LVQ의 입력벡터와 기준벡터(reference vector)와의 유사도를 측정하여 가장 유사성

이 일치하는 출력뉴런이 승리뉴런이 되고, 승리뉴런이 갖는 클래스와 입력벡터의 클래스가 같으면 입력뉴런과 승리뉴런 사이의 연결강도를 입력벡터의 방향으로 증가시키고, 클래스가 다르면 연결강도는 입력벡터와 반대방향으로 학습시킨다.

LVQ와 같은 클러스터링 알고리즘에는 LVQ를 비롯하여 SOM(Self Organizing Map), CP Net.(Counter Propagation Networks), ART(Adaptive Resonance Theory) 등이 있다[8-10].

SOM과 ART는 in-star 학습을 기반으로 한 비지도학습을 하며 목표출력을 갖지 않는다. SOM은 차원이 높은 벡터의 패턴분류를 위한 전 처리 과정에서 패턴벡터를 2차원 특징 맵(feature map)으로 하는 데에 많이 사용되고, ART는 경계파라미터를 두어 입력패턴벡터를 클래스로 분류하는 경계치의 조절이 가능하여 원하는 유사도를 갖는 입력벡터를 클래스로 분류시키고, 유사도가 작은 입력벡터는 분류하지 않는다.

반면에 in-star 학습규칙과 out-star 학습규칙을 모두 사용하는 CP. Net.은 입력 층, 클러스터 층, 출력 층으로 구성된 3층 구조의 신경회로망이다. 입력 층과 클러스터 층 사이에는 in-star 학습규칙이 사용되어 클러스터 층의 승리뉴런을 결정한다. 클러스터 층에서 승리뉴런과 출력 층 사이의 연결강도의 학습에는 out-star 학습규칙이 사용된다.

본 논문에서는 지능형 인공지능 알고리즘의 일종으로 SOM, CP. Net, LVQ 알고리즘을 혼합으로 사용하여 LVQ의 패턴인식 성능을 향상시키고, 근전도의 패턴인식에 사용하였다. 제안된 알고리즘에서 SOM을 이용하여 근전도 패턴벡터의 차원을 감소시켜서 학습을 간소화하고, LVQ의 초기 참조벡터를 학습시켜서 학습의 안정도를 가지게 하였다. 또한 LVQ의 출력뉴런이 속해야 할 클래스의 지정을 위하여 CP. Net.의 out-star 학습규칙을 이용하여 패턴인식의 성능을 개선하였다. 근전도 신호의 획득은 정경권 님의 박사학위 논문에서 제작하여 사용된 동일한 장비를 사용하여 획득하였다[11].

또한 지능형 인공지능의 적용가능성을 진단하기 위하여 한글 자음 'ㄱ', 'ㄴ', 'ㄷ', 'ㅇ', 'ㅍ'에 대한 수화동작에 따른 근전도에 대한 패턴인식을 하여, 제안된 학습네트워크와 기존의 LVQ 학습방식과의 패턴인식의 성능을 비교분석하였다.




그림 1. 근전도 신호 측정 시스템
Fig. 1 EMG measuring system

II. 근전도 및 신호의 획득

2.1 근전도 데이터

근전도는 골격근이 수축할 때 생기는 활동전위를 기록한 것으로 근육의 활성화 정도에 따라서 신호전압 실효치의 변화를 가지며, 근육의 피로도의 증가에 따라서 주파수의 감소를 나타낸다.

근육이 수축 및 이완이 되기 위해서는 뇌에서 척수로 명령이 전달되고, 척수에 있는 운동 피질에서 신경 임펄스 열이 발생되어 각 운동 신경단위에 가해질 때 각 근육섬유의 표면에서 일어나는 탈분극과 재분극에 의하여 운동신경단위 열이라는 운동 활동전위의 열이 발생되는 데 이 전위들을 합쳐져서 근전도 신호를 형성한다.

이와 같이 골격근은 기능면에서 운동신경단위를 기본으로 이루어져 있다. 단일운동신경과 그 운동신경이 지배하고 있는 골격근의 그룹들을 단일운동신경단위(SMU : single motor unit)라 한다. 이때 신경이 흥분되어서 SMU가 활성화 될 때, 골격근에서 측정되는 전기신호를 근전도라 한다. 다시 말하면, 신경이 흥분되어서 신경이 지배하는 근육의 수축이 일어날 때 발생하는 전기적인 현상을 기록하는 것을 근전도라 한다.

운동신경단위에 연결된 근육섬유들이 수축 및 이완작용을 할 때 발생하는 전위의 지속시간은 3-15ms 정도이며, 20-2000 μ V의 진폭으로 초당 6-30회 정도로 발생된다. 일반적으로 근전도 신호의 전압은 10 μ V-15mV의 크기와 10-2000Hz의 주파수를 갖는다.

이러한 근전도 측정에 사용되는 전극에는 침전극과 표면전극이 있는데 본 연구에서는 사용의 편리함으로 표면전극이 사용되었다.

2.2 근전도 신호의 획득

본 연구에서는 근전도 신호의 획득은 정경권 님의 박사학위 논문에서 제작하여 사용된 동일한 장비를 사용하여 획득하였다[11]. 근전도 데이터의 획득을 위한 신호 측정 시스템의 블록선도는 (그림 1)과 같다.

(그림 1)에서 I.A.는 계측증폭기(Instrumentation Amplifier), HPF는 고역통과필터(High Pass Filter), LPF는 저역통과필터(Low Pass Filter), M.A.는 주 증폭기(Main Amplifier), NF는 노치필터(Notch Filter)를 나타내는 약어이다.


I.A.는 스위치를 사용하여 이득을 10, 100, 200, 400까지 단계적으로 조정 가능하고, HPF와 LPF를 사용하여 5-1200Hz의 대역통과필터가 구성된다. M.A.의 이득은 8-1600의 범위에서 조정가능하고, I.A.와 함께 80-640,000의 범위의 이득을 조정 가능하다. 또한 60Hz의 전원 잡음을 제거하기 위하여 NF가 구성되었고, 필터를 통과한 신호는 A/D 변환기로 샘플링 되어 디지털 화 된 근전도 데이터를 얻는다.

III. 경쟁학습을 갖는 클러스터링 알고리즘


경쟁학습을 기반으로 하는 클러스터링 알고리즘을 갖는 신경회로망으로 SOM, LVQ, CP Net.의 구조 및 학습규칙의 유사성을 논의하고 이를 기반으로 향상된 패턴분류 성능을 갖는 혼합형 LVQ 알고리즘을 제안하고자 한다.

3.1 학습 네트워크의 유사성

SOM, LVQ 그리고 CP Net.의 입력 층과 클러스터 층 사이의 네트워크는 동일한 구조를 갖는다.



(a) Learning networks of SOM and LVQ



(b) Forward only Counter Propagation Networks
 그림 2. 네트워크의 유사성
 Fig. 2 Similarity of the networks

(그림 2)에서 x_1, x_2, \dots, x_n 은 $n \times 1$ 입력패턴벡터, z_1, z_2, \dots, z_p 는 (a)에서는 각각 p 개의 출력뉴런, (b)에서는 F.C.P. Net.의 p 개의 클러스터 층의 뉴런이고, v_{ji} , ($i=1, 2, \dots, n, j=1, 2, \dots, p$)는 in-star 학습규칙에 의해 학습될 SOM, LVQ 및 F.C.P. Net.의 연결강도이다. F.C.P. Net.의 입력 층과 클러스터 층 사이의 네트워크의 구조는 SOM과 LVQ의 네트워크의 구조와 같다. 그러므로 F.C.P. Net.의 입력 층과 클러스터 층 사이의 네트워크의 학습은 SOM이나 LVQ의 네트워크의 구조를 사용하여 학습될 수 있다.

3.2 학습 알고리즘

다음의 식 (1), (2), (3)은 각각 SOM, LVQ 및 C.P. Net.의 학습알고리즘이다.

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

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

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

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

여기서 v_{ji} 는 입력패턴벡터의 i 번째 요소 x_i 에서 j 번째 출력 뉴런 z_j 사이의 연결강도이며, $\alpha_S, \alpha_L, \alpha_{CP}$ 는 각각 SOM, LVQ 및 C.P. Net.의 학습률이다. 식 (1)의 SOM과 식 (3)의 C.P. Net.의 입력 층과 클러스터 층 사이의 네트워크의 학습은 승리뉴런과 이웃한 뉴런들을 동시에 학습하거나 승리뉴런만의 학습이 가능하다. 또한 식

(2)의 LVQ의 학습에서는 승리뉴런의 클러스터와 입력패턴의 클러스터가 같은 경우가 식(2-a)이고, 다른 경우의 학습이 (2-b)이다.

반면에 C.P. Net.의 클러스터 층의 승리뉴런과 출력 층 사이의 연결강도 w_{kj} ($j=1, 2, \dots, m, k=1, 2, \dots, p$)의 학습은 out-star 학습규칙에 의해 학습된다. 클러스터 층의 j 번째 뉴런이 승리뉴런이 되었을 때 연결강도의 학습규칙은 식(4)으로 된다.

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

식(4)에서 β 는 학습률이며, 학습률의 초기값 $\beta(0)$ 는 $0.5 < \beta(0) < 0.8$ 로 설정되고 학습이 진행되면서 서서히 감소된다

IV. 학습알고리즘의 제안

본 논문에서는 각각의 다른 움직임이나 다른 자세로 있을 때 활성화 또는 비활성화 되는 근육에서 각각 다르게 발생하는 전기신호인 근전도를 측정하여 입력패턴벡터로 사용한다. 이 입력패턴벡터를 사용하여 네트워크를 학습시킨 후 임의의 자세에서 발생하는 근전도가 네트워크에 가해졌을 때 어떠한 자세인지를 역으로 분류하는 학습네트워크를 설계한다.

본 논문에서 제안된 학습네트워크는 SOM의 학습 알고리즘을 이용하여 400×1 의 근전도 데이터를 2×1 의 데이터로 간소화시키고, LVQ 네트워크의 초기 참조벡터를 학습시켜서 학습 안정도를 향상시키고, C.P. Net.의 클러스터 층과 출력 층 사이의 학습에는 out-star 학습규칙을 사용하여 LVQ 출력뉴런이 속해야 할 클래스를 학습하는 네트워크를 설계한다.

4.1 제안된 학습네트워크의 구조

본 논문에서 제안된 학습네트워크의 구조는 (그림 3)과 같다.

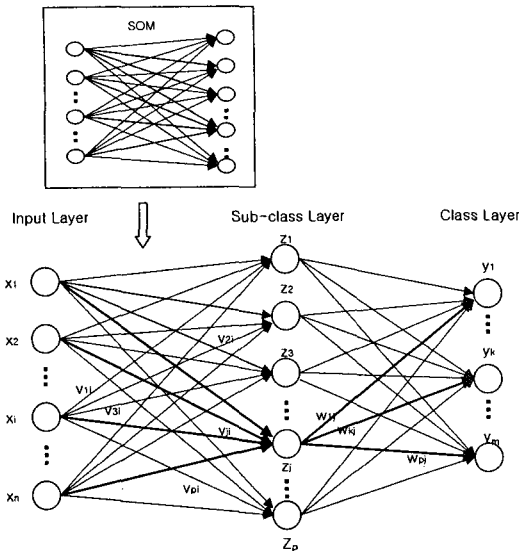


그림 3. 제안된 학습 네트워크
Fig. 3 Proposed learning network

(그림 3)의 제안된 학습네트워크는 구조적인 측면에서 입력 층, 종속 클래스 층, 클래스 층으로 구성된 3층 구조의 신경회로망으로 변형된 C.P. Net.의 형태를 갖는다. 입력 층과 종속 클래스 층 사이는 SOM과 LVQ의 구조와 동일하다. 따라서 입력 층과 종속 클래스 층 사이의 학습은 먼저, 온라인 또는 오프라인으로 SOM으로 학습이 진행되어 근전도 패턴벡터의 차원을 감소시키고, 감소된 근전도 패턴벡터를 학습벡터로 사용하여 학습된 연결강도를 제안된 학습 네트워크의 입력 층과 종속 클래스 층 사이의 초기 연결강도로 사용한다. 입력 층과 종속 클래스 층 사이의 네트워크가 알고리즘 측면에서 개선된 패턴분류성능을 갖는 LVQ 네트워크가 된다. 그러므로 SOM으로 학습된 연결강도를 입력 층과 종속 클래스 층의 연결강도로 사용한다는 것은 결국 LVQ의 초기 참조벡터 또는 코드북 벡터로 사용된다는 것을 의미한다. 이러한 방식으로 충분히 학습된 SOM의 연결강도를 LVQ 초기 참조벡터로 이용되면, 국소적 접근 안정 평형점에 가까이 존재하고, 학습이 진행되면서 참조벡터가 평형점에서 멀리 이동되지 않게 되어 LVQ의 참조벡터는 수렴하고 LVQ 네트워크는 우수한 분류성능을 갖는다[12,13].

이렇게 안정된 초기 참조벡터를 가지고 시작되는 LVQ의 학습은 입력패턴벡터와 가장 일치하는 유사도를 갖는 종속 클래스 층의 뉴런과 입력 층 뉴런과 연결된 연결강도를 학습한다. 이것은 입력패턴벡터가 종속 클래스 층의 종속 클래스에 속하게 되는 것을 의미하고, 이 종속 클래스는 out-star

학습규칙에 의해 종속 클래스 층과 클래스 층 사이의 연결강도를 조정하여 가장 적합한 클래스로 지정된다. 따라서 입력패턴벡터는 in-star 경쟁학습에 의해 종속 클래스가 지정되고, 그 패턴벡터가 속하는 종속 클래스는 다시 out-star 경쟁학습에 의해 클래스로 지정된다.

4.2 제안된 네트워크의 알고리즘

제안된 학습네트워크는 알고리즘의 측면에서 성능향상을 갖는 LVQ 네트워크이다.

먼저, SOM의 학습으로 측정된 고차원 패턴벡터의 차원을 감소시키고, 감소된 근전도 패턴벡터를 사용하여 식 (1)의 SOM 학습규칙으로 온라인 또는 오프라인으로 학습을 진행한다.

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

SOM의 학습이 완료되면, LVQ의 참조벡터가 안정적으로 수렴하는 학습능력을 갖도록 하기 위해서 학습된 연결강도를 LVQ 네트워크의 초기 참조벡터로 설정한다. 이것은 (그림 3)의 제안된 학습 네트워크의 입력 층과 종속 클래스 층의 사이의 연결강도를 학습된 SOM의 연결강도로 대체하면 된다. 즉, (그림 3)의 제안된 학습 네트워크의 입력 층과 종속 클래스 층 사이의 네트워크는 알고리즘 측면에서 LVQ로 사용된다.

두 번째의 학습으로 안정된 초기 참조벡터를 가지고 식 (2-a) 및 (2-b)을 사용하여 LVQ의 학습을 수행한다.

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

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

세 번째로, 작은 학습률로 가지고 식 (2-a) 및 (2-b)로 정밀 학습을 진행한다. (그림 3)의 제안된 네트워크에서와 같이 종속 클래스 층의 승리뉴런을 결정하고, 그 승리뉴런이 속할 클래스는 식 (4)로 학습된다.

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

V. 데이터 획득 및 패턴인식

(그림 4)는 근전도 데이터를 측정하기 위한 실험장치의 사진이다.




그림 4. 실험장치
Fig. 4 Experimental set-up

또한 (그림 5)는 4쌍의 전극과 하나의 공통접지 전극을 사용한 9개의 전극으로 4개의 채널을 구성하여 측정한 실물에 대한 사진이다.




그림 5. 근전도 측정 사진
Fig. 5 The picture of EMG measurement

(그림 5)의 근전도 측정 사진에서 보이는 바와 같이 근전도의 측정을 위해 1회용의 Ag/AgCl 표면전극을 사용하여 측정을 하였다. 측정된 근전도 신호는 한글 자음을 수화로 표현할 때 발행되는 14개의 자음 중 'ㄱ', 'ㄴ', 'ㅇ', 'ㅇ', 'ㅇ' 5개의 한글 자음에 대한 수화동작에서 4개의 채널을 사용하여 신호를 측정하였다. 각 채널에서 신호를 측정할 때 두개의 Ag/AgCl 전극을 한 쌍으로 사용하고, 접지 전극이 별도로 부착하였다.

데이터의 측정은 4개의 채널에서 100개의 데이터를 측정하여 400차원의 근전도 데이터를 획득하였다. 그러므로 1번의 측정은 400×1의 근전도 패턴벡터를 얻고, 각각의 동작마다 25번을 측정하였다.

각각의 수화신호에 대한 25개의 근전도 데이터를 학습 및 테스트 벡터로 사용하였다.

먼저, 각각의 수화신호에 대한 25개의 400×1의 근전도 패턴벡터의 전 처리를 위하여 20×20 형상지도를 갖는 SOM 네트워크를 구성하였다.

SOM네트워크의 초기 학습률은 0.1, 초기 이웃반경은 19로 하였고, 학습이 진행되면서 단계적으로 감소되게 하였다. 초기 연결강도는 [0,1]의 값으로 무작위로 발생시켰고, 학습 횟수는 10,000번 수행하였다. 따라서 400×1의 근전도 패턴벡터는 <표 1>과 같이 2×1 패턴벡터로 차원이 감소되게 하였고, 이 차원이 감소된 패턴벡터를 사용하여 패턴 분류를 수행하였다.

표 1. 감소된 근전도 데이터
Table. 1 reduced EMG data

신호 분류	수화 신호				
	ㄱ	ㄴ	ㄷ	ㅇ	ㅍ
학습 및 테스트 벡터 (25개)	(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)
	(18, 17)	(19, 2)	(15, 0)	(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)	(11, 5)	(0, 13)	(8, 12)
	(19, 14)	(19, 2)	(12, 7)	(5, 10)	(8, 10)
	(18, 17)	(11, 1)	(15, 0)	(0, 19)	(8, 12)

학습률은 학습이 진행됨에 따라 서서히 감소하며 식(5)와 같이 학습이 진행됨에 따라 감소된다.

$$a = a(0) \cdot \frac{ITER_{num} - k}{ITER_{num}} \dots\dots\dots (5)$$

식 (5)에서 $ITER_{num}$ 는 학습 횟수, $a(0)$ 는 학습률을 나타낸다. 학습률 a 는 설정된 초기값 $a(0)$ 로부터 학습이 진행되면서 서서히 감소된다. 또한 제안된 학습 네트워크에서 종속 클래스 층과 클래스 층 사이의 연결강도 역시 식(5)를 사용하여 학습이 진행되면서 감소된다.

식(5)에 의해 감소되는 학습률의 초기값을 각각 0.7, 0.5, 0.3, 0.1로 설정하고 제안된 학습방식을 갖는 LVQ와 기존의 LVQ와의 근전도 데이터 패턴분류를 시뮬레이션 한 결과는 각각 <표 2, 3, 4, 5> 이다.

표 2. 근전도 데이터의 분류 오차 수(a(0) = 0.7)
Table. 2 Classification error of EMG data

the number of iterations	1000	2000	5000	10000	오차율 (%)
LVQ(Random)	41	41	41	35	31.6
LVQ (Learning vector)	A	6	5	2	3.0
	B	34	28	31	25.2
	평균	20	16.5	16.5	17.5
the proposed method	6	6	6	6	4.8

표 3. 근전도 데이터의 분류 오차 수(a(0) = 0.5)
Table. 3 Classification error of EMG data

the number of iterations	1000	2000	5000	10000	오차율 (%)	
LVQ(Random)	40	40	38	35	30.6	
LVQ (Learning vector)	A	2	2	2	1.6	
	B	59	59	52	41	42.2
	평균	30.5	30.5	27	21.5	21.9
the proposed method	6	6	6	6	4.8	

표 4. 근전도 데이터의 분류 오차 수(a(0) = 0.3)
Table. 4 Classification error of EMG data

the number of iterations	1000	2000	5000	10000	오차율 (%)	
LVQ(Random)	22	22	22	22	17.6	
LVQ (Learning vector)	A	6	6	6	4.8	
	B	33	36	38	38	29.0
	평균	19.5	21	22	22	16.9
the proposed method	9	9	9	9	7.2	

제안된 학습알고리즘을 근전도의 패턴인식에 시뮬레이션 하고, 기존의 LVQ 학습알고리즘과의 패턴분류성능을 비교 하였다. 기존의 LVQ의 초기참조벡터의 설정은 (0, 10) 사이의 값을 무작위로 발생시킨 경우와 학습용 패턴벡터를 초기 참조벡터로 사용한 경우로 나누어 시뮬레이션하고, 각각의 패턴분류특성을 비교하였다.

기존의 LVQ 네트워크는 입력 뉴런 2개, 출력 뉴런 25개를 사용하였고, 25개의 출력 뉴런 중 각각 5개씩을 'ㄱ', 'ㄴ', 'ㄷ', 'ㅇ', 'ㅍ'에 해당하는 클래스에 해당되는 종속 클래스로 지정하였다.

또한 제안된 학습네트워크의 입력 뉴런 2개, 종속 클래스 층의 뉴런 25개, 클래스 층의 뉴런은 3개를 사용하였다. 클래스 'ㄱ', 'ㄴ', 'ㄷ', 'ㅇ', 'ㅍ'에 대한 각각의 클래스 층의 뉴런의 설정값은 [-1,-1,-1], [-1,-1,1], [-1,1,-1], [-1,1,1], [1,-1,-1]로 하여 종속 클래스 층의 승리뉴런과 클래스 층의 출력 뉴런사이의 연결강도를 학습하였다.

SOM, LVQ의 연결강도 및 제안된 방식의 입력 층과 종속 클래스 층 사이의 연결강도를 학습하기 위하여 사용된

표 5. 근전도 데이터의 분류 오차 수(a(0) = 0.1)
Table. 5 Classification error of EMG data

the number of iterations		1000	2000	5000	10000	오차율 (%)
LVQ(Random)		45	50	50	47	38.4
LVQ (Learning vector)	A	6	6	6	5	4.6
	B	35	38	33	33	27.8
	평균	20.5	22	19.5	19.0	16.2
the proposed method		9	9	9	9	7.2

위의 <표 2, 3, 4, 5>에서 the proposed method가 제안된 학습방식을 나타내고, LVQ(Random)과 LVQ(Learning vector)는 기존의 LVQ의 학습방식이다. LVQ(Random)은 초기 참조벡터를 [0, 10] 사이로 무작위로 발생시킨 경우이다. LVQ(Learning vector)방식은 학습에 사용되는 패턴 벡터를 초기 참조벡터로 사용한 경우로 A와 B방식으로 분류하였다. A방식은 각 클래스에서 각 클래스를 가장 대표하는 5개씩의 패턴벡터를 뽑아 25x2 초기 참조벡터를 구성한 경우이고, B방식은 학습에 사용되는 패턴벡터를 앞에서부터 25개를 뽑아서 25x2 초기 참조벡터를 구성한 경우이다.

'ㄱ', 'ㄴ', 'ㅇ', 'ㅇ', 'ㅍ'의 각 클래스 별로 25번의 측정 에 의해 각 클래스 별로 25개의 근전도 데이터를 학습 및 분류테스트 용으로 사용하므로 전체 125개의 벡터가 학습 및 분류테스트를 위해 사용되었다.

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

표 6. 평균 분류오차 수 및 분류 오차율
Table. 6 Number and Ratio of classification error

the number of iterations		1000	2000	5000	10000	평균
LVQ (Random)	분류 오차 수	37	38.25	37.35	34.75	36.84
	분류오차율(%)	29.6	30.6	29.9	27.8	29.5
LVQ (Learning vector)	분류 오차수	22.63	22.5	21.25	20	21.6
	분류오차율(%)	18.1	18.0	17.0	16.0	17.3
the proposed method	분류 오차수	7.5	7.5	7.5	7.5	7.5
	분류오차율(%)	6.0	6.0	6.0	6.0	6.0

<표 6>의 평균분류 오차율을 그래프로 나타낸 것이 <그림 6>이다.

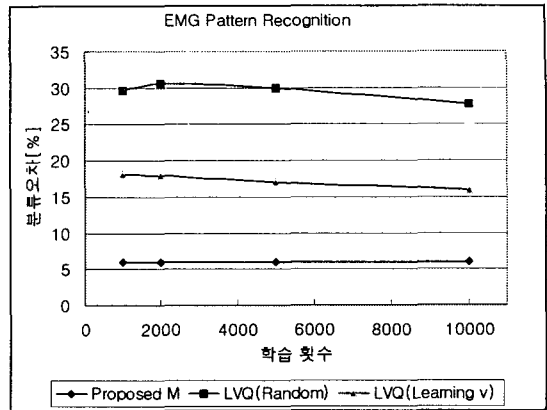


그림 6. 분류오차율
Fig. 6 Ratio of the error

분류성능 면에서 볼 때, 각 클래스에서 5개씩의 패턴 벡터를 뽑아 25x2 초기 참조벡터를 구성한 기존의 LVQ(Learning vector)-A 학습방식의 분류오차가 제안된 방식보다 상대적으로 적게 나타나 보다 좋은 분류성능을 갖는 것으로 나타났다. 그러나 같은 방식인 LVQ(Learning vector)-B 학습 방식은 제안된 학습방식보다 분류성능이 떨어지는 것으로 확인되었다.

전반적으로 LVQ(Learning vector)-A 방식과 같이 최적의 조건으로 LVQ의 초기 참조벡터를 설정하는 것은 어려우므로, 인공지능을 실현하는 면으로 볼 때 LVQ(Learning vector)-A와 B 방식을 평균하여 고려하는 것이 일반적이라 사료된다. 그러므로 제안된 EMG 데이터 학습방식은 LVQ(Learning vector)-A와 B의 평균보다 11.3(%)의 오차율이 개선되었고, LVQ(Random) 학습방식보다 평균 23.5(%)의 분류 오차율이 개선되었음을 확인하였다.

VI. 결론

본 연구에서는 인체에서 발생하는 다양한 생체신호를 계측하고, 생체신호처리 및 패턴인식기법을 적용함으로써 사용자의 뜻대로 인공지능이 팔 또는 다리를 자유롭게 움직이게 하는 지능형 인공지능의 구현을 위한 근전도 데이터의 획득 및 학습네트워크를 설계하였다.

획득된 근전도는 'ㄱ', 'ㄴ', 'ㅇ', 'ㅇ', 'ㅍ'에 해당하는 수화동작에 따른 근전도 데이터이며, 측정된 근전도 데이터를 학습할 수 있도록 경쟁학습을 하는 클러스터링 알고리즘을 복합적으로 구현하여 학습네트워크를 설계하였다.

제안된 EMG 학습네트워크는 경쟁학습을 하는 SOM, LVQ, C.P. Net.의 구조상의 유사성과 학습의 상호 유사성에 착안하였다.

제안된 학습네트워크는 전체 구조는 변형된 C.P. Net. 구조를 갖고 알고리즘 측면에서 볼 때는 개선된 분류 성능을 갖는 LVQ 학습네트워크로 설계되었다.

전반적인 설계의 간소화를 위하여 SOM 네트워크를 사용하여 400×1의 패턴벡터를 2×1으로 벡터 차원을 감소시켰다.

LVQ와 SOM 네트워크의 구조상 같은 구조를 활용하여 온라인 또는 오프라인으로 SOM을 이용하여 LVQ의 초기 참조벡터를 학습하여 LVQ 네트워크의 수렴성과 학습의 안정성을 고려하였다.

또한 C.P. Net. 구조를 변형하여 LVQ의 종속 클래스를 클래스로 학습할 수 있도록 하였다.

제안된 학습네트워크를 설계하여 EMG 데이터의 분류 성능을 테스트 한 결과 제안된 학습네트워크는 기존의 LVQ 학습네트워크 보다 EMG 패턴 분류 오차율이 현저히 줄어든 패턴분류성능을 가짐을 확인하였다.

따라서 본 연구는 장애나 노화 등으로 인하여 근 골격계가 손상을 입거나 퇴화되어 운동기능이 손실되었을 경우 운동기능의 손실을 보상하는 실버형 지능형 인공의지의 구현에 활용 될 것으로 사료된다.

참고문헌

[1] 최화순, "휠체어 추진시 근전도 신호의 특성 변화", 대한물리치료학회지 논문집, 제 13권, 제 3호, pp.777-789, 2001.

[2] 김호봉, 박영환, 배성수, "근전도와 신경전도 검사의 임상적 응용", 대한물리치료학회지 논문집, 제 10권, 제 1호, pp.199-212, 1998.

[3] 이정훈, 정경권, 이현관, 엄기환, "가상로봇 팔 제어를 위한 퍼지-SOFM 방식의 근전도 패턴인식", 대한전자공학회논문지, 제 40권 CI편 제 2호, 2003.

[4] T. Kohonen, Self-Organizing Maps, Springer-Verlag, Berlin, 1995.

[5] 이용구, 최우승, "Forward C.P. Net.을 이용한 3단 LVQ 학습알고리즘, 한국컴퓨터정보학회논문집, 제9권제 4호, pp.33-39, 2004.

[6] Laurene Fausett, Fundamentals of Neural Networks, PRENTICE HALL, 1994.

[7] M. T. Hagan, H. B. Demuth and M. Beale, NEURAL NETWORK DESIGN, PWS Publishing Company, 1996.

[8] 임승린, "내용기반 복합 영상 검색시스템을 위한 적응적 특징 자가선택과 다중 SOFM 신경망", 한국컴퓨터정보학회논문집, 5권, 2호, 2000.

[9] R. Hecht-Nielsen, "Applications of counterpropagation network", Neural Networks, vol. 1, pp.131-139, 1988.

[10] T. Kohonen, "The Self-Organizing Map", PROCEEDING OF THE IEEE, VOL. 78, NO. 9, pp.1464-1480, 1990.

[11] 정경권, "확률 분포를 이용한 LVQ의 패턴 분류 성능 개선", 동국대학교 박사학위논문, 2002.

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

[13] 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).

저 자 소 개



이 용 구
 1987년 동국대학교 공학사
 1993년 동국대학교 공학석사
 1997년 동국대학교 공학박사
 1998년~2005년 현재 한림성심대학
 의용정보전공(과) 부교수
 <관심분야> 지도 및 비지도학습 신경
 회로망, 퍼지논리시스템, 패
 턴인식, 생체신호처리



최 우 승
 1977년 동국대학교 공학사
 1981년 동국대학교 공학석사
 1994년 동국대학교 공학박사
 1998년~2000년 한국컴퓨터정보 학
 회 학회장
 2000년~현재 한국컴퓨터정보학 고문
 1981년~2005년 현재 경원전문대
 학 정보통신과 교수
 <관심분야> 비지도학습 신경회로망,
 패턴인식