

뇌파의 입력패턴벡터 추출 및 패턴인식

이 용 구*, 이 선엽**, 최 우승***

Input Pattern Vector Extraction and Pattern Recognition of EEG

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

요 약

본 논문에서는 뇌파인식을 위한 입력패턴벡터를 추출하고 패턴인식을 위한 뇌파 학습 알고리즘을 설계하였다. 입력패턴벡터의 구성을 위해 알파리듬과 베타리듬의 주파수와 진폭이 사용되었고, 뇌파패턴인식을 위한 알고리즘은 초기 참조벡터의 학습을 위해 SOM을 이용하고, 종속 부류층의 출력뉴런의 부류지정을 위하여 out-star 학습법을 사용하였다. 제안된 알고리즘의 입력 층과 종속 클래스 층 사이의 연결강도는 SOM과 LVQ 알고리즘을 이용하여 초기 참조벡터의 설정 및 학습이 가능하게 하였고, 패턴벡터를 종속 부류층의 뉴런에 의해 종속 클래스로 분류하고, 종속 클래스 층과 출력 층 사이의 연결강도는 분류된 종속 부류를 클래스로 지정하는 학습을 하게 된다. 뇌파 패턴 분류를 위하여 제안된 학습알고리즘을 이용하여 시뮬레이션 되었고 기존의 LVQ 학습방식 보다 우수한 분류성공률을 확인하였다.

Abstract

In this paper, the input pattern vectors are extracted and the learning algorithms is designed to recognize EEG pattern vectors. The frequency and amplitude of alpha rhythms and beta rhythms are used to compose the input pattern vectors. And the algorithm for EEG pattern recognition is used SOM to learn initial reference vectors and out-star learning algorithm to determine the class of the output neurons of the subclass layer. The weights of the proposed algorithm which is between the input layer and the 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 between subclass layer and output layer is learned to classify the classified subclass, which is enclosed a class. To classify the pattern vectors of EEG, the

• 제1저자 : 이용구

• 접수일 : 2006.10.13, 심사일 : 2006.10.20, 심사완료일 : 2006.11.18

* 한림성심대학 의료기기정보과 부교수 ** 한림대학교 부속 춘천성심병원 방사선과 부기사장

*** 경원전문대학 정보통신과 교수

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 : 뇌파(EEG), 패턴벡터추출(Pattern vector extraction), 학습벡터양자화(LVQ), 패턴분류(Pattern classification)

I. 서 론

1929년 오스트리아 의사 Han Burger는 인간의 머리가 죽 위에 전극을 배치하여 여러 형태의 전기활동을 측정하여 기록하였고, 이 기록을 EEG(뇌파)라 부른다[1, 2, 3]. 뇌파 중 알파리듬은 눈을 감고 편안하게 쉬고 있는 성인에게서 우세하게 나타나는 EEG 파형이고, 대뇌피질의 occipital lobe와 parietal lobe에서 가장 커다란 진폭을 갖는 파형이 기록된다. 눈을 뜨고 정신을 바짝 차리고, 외부자극에 주의를 기울이거나 정신적인 계산을 하는 것과 같이 연속적으로 정신적인 노력을 기울일 때 알파리듬은 진폭이 작고 주파수가 큰 베타리듬으로 바뀌게 된다. 이러한 베타리듬은 눈을 감은 상태에서 눈꺼풀 밑에서 눈동자가 빠르게 움직이는 REM(Rapidly Eye Movement) 수면 동안에도 나타나며, 대뇌피질의 frontal lobe에서 가장 잘 기록된다. 또한 사람이 꾸벅꾸벅 졸게 됨에 따라 알파리듬은 점차 낮은 주파수를 갖는 세타리듬으로 바뀌게 된다. 이 세타리듬은 잠이 깊어지면서 델타리듬이 우세하게 된다[3]. 이러한 뇌파는 주파수와 진폭으로 특징을 나타내는데, Han Burger의 기록이 후에 과학자들은 뇌파를 연구하기 시작하였고, 오늘날까지도 EEG는 뇌기능을 의학적으로 유용하게 기록하고 있다. 뇌파와 같이 인체에서 발생되는 다양한 생체신호를 계측하고, 생체신호처리 및 패턴인식기법을 적용함으로써 사용자의 뜻대로 팔 또는 다리를 자유롭게 움직이게 하는 것을 지능형 인공의지라 한다. 이러한 인공의지를 위해서 주로 많이 사용되는 생체신호가 뇌파, 근전도 등이며 이러한 생체신호를 측정하여 증폭, 필터에 의한 신호처리과정 및 패턴분류기를 설계한 후 자동 측정되는 생체신호를 패턴인식에 의해 분류하여 본인의 의지대로 손과 팔 운동을 할 수 있게 된다[4,5,6]. 이러한 경향에 발맞추어 최근에는 신경회로망과 같은 인공지능알고리즘을 사용하여 생체신호에 대한 첨단 신호처리 및 패턴인식 기법의 연구가 진행되고 있다[6-9]. 또한 대부분의 생체신호 패턴인식에 LVQ(Learning Vector Quantization)가 많이 사용되고 있으나 학습하는 동안 참조벡터의 안정성과 출력뉴런의 부류지정에 어려움을 갖는다.

본 논문에서는 SOM(Self Organizing Maps), LVQ 알고리즘을 혼합으로 사용하여 구조적 측면에서 CP-Net.(Counter Propagation Networks)과 동일한 LVQ 네트워크를 설계하여 측정된 뇌파에 대한 패턴분류를 하였다. 제안된 알고리즘에서 SOM을 이용하여 LVQ의 초기 참조벡터를 학습시켜서 학습의 안정도를 가지게 하였다. 또한 LVQ의 출력뉴런이 속해야 할 클래스의 지정을 위하여 out-star 학습규칙을 사용하였다. 뇌파의 획득을 위하여 BIO PAC사의 MP35 데이터획득 장비와 BSL 3.7.0 소프트웨어를 사용하였고, BSL 3.7.0 소프트웨어 상에서 측정된 뇌파의 주파수와 진폭을 측정하여 특징벡터를 추출하였다.

또한 지능형 인공의지의 적용가능성을 진단하기 위하여 몇 가지 정신상태에 대한 뇌파를 인식하게 하여 제안된 학습알고리즘과 기존의 클러스터링 학습알고리즘과의 패턴인식의 성능을 비교분석한다.

이러한 연구를 수행하기 위하여 2장에서 EEG의 특징과 신호획득방법을 기술하고, 3장에서는 뇌파분류알고리즘을 제안하였으며, 4장에서는 MP 35 장비를 사용한 데이터획득과 특징벡터추출 및 패턴분류실험을 하였고, 이를 기반으로 제안된 방식의 유용함을 5장에서 결론짓는다.

II. 뇌파 및 신호의 획득

1. 뇌파 데이터

대뇌의 외곽 세포층은 회백질이라 불리는 대뇌피질을 형성하고, 이 대뇌피질은 많은 신경세포를 포함한다. 이러한 신경세포들은 서로 기능적으로 연결되고 뇌의 다른 부분들과 연결되어있다. 대뇌피질이 하는 기능은 추상적인 사고, 추론, 기억, 골격근의 자발적 및 비자발적인 수축, 육체, 내장, 특별한 감각 자극들의 인식 및 식별 등이다. 뇌파는 환자들마다 복잡하고 다르게 측정되지만 어떤 확실한 조건아래서는 보다 단순하고 규칙적인 활동을 나타낸다. 알파리듬은 눈을

감고 편안하게 쉬고 있는 성인에게서 우세하게 나타나는 EEG 패형이고, 대뇌피질의 occipital lobe와 parietal lobe에서 가장 커다란 진폭을 갖는 패형이 기록된다. 눈을 뜨고 정신을 바짝 차리고, 외부자극에 주의를 기울이거나 정신적인 계산을 하는 것과 같이 연속적으로 정신적인 노력을 기울일 때 알파리듬은 진폭이 작고 주파수가 큰 베타리듬으로 바뀌게 된다. 이러한 베타리듬은 눈을 감은 상태에서 눈꺼풀 밑에서 눈동자가 빠르게 움직이는 REM 수면 동안에도 나타나며, 대뇌피질의 frontal lobe에서 가장 잘 기록된다. 또한 사람이 꾸벅꾸벅 졸게 될 때 따라 알파리듬은 점차 낮은 주파수를 갖는 세타리듬으로 바뀌게 된다. 이 세타리듬은 잠이 깊어지면서 델타리듬이 우세하게 된다.

EEG는 환자의 정신 상태에 따라서 알파리듬의 주파수와 진폭이 변화한다. 일반적으로 알파리듬은 눈을 감은 성인이 긴장을 풀고 편안하게 주의를 집중하지 않을 때 우세하게 나타나는 EEG 패형이다. 그러나 정상보다 빠르고 깊은 호흡을 하면 대뇌피질 신경세포들의 전기활동을 증가시켜서 알파리듬의 진폭을 크게 하고, 남성보다 여성의 알파리듬의 주파수가 큰 경향이 있다. 또한 기억력이 높은 사람은 낮은 사람보다 알파리듬의 주파수가 크게 측정되며, 외향적인 사람의 주파수는 내성적인 사람의 주파수보다 더 크게 나타나는 경향이 있다. 또한 사람이 눈을 뜨고 외부 자극에 주의를 기울일 때 알파리듬의 진폭은 줄어들며, 사람이 나른해지는 오후 1시 30분에서 4시 30분 사이에 알파리듬의 진폭이 가장 커지는 경향이 있다[3].

2. 뇌파 신호의 획득

본 연구에서는 뇌파 신호의 획득은 BIO PAC 사의 MP35 데이터 획득 장비와 USB 케이블로 장비에 연결되고 BSL 3.7.0 소프트웨어를 내장한 PC를 사용하여 측정하였다. 뇌파 데이터의 획득을 위한 신호 측정 시스템의 블록도는 그림 1과 같다.

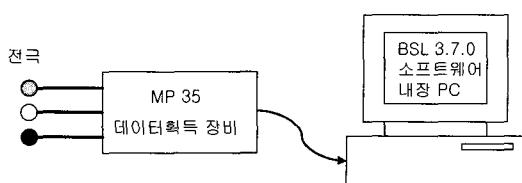
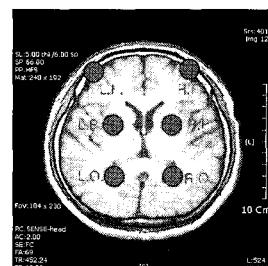


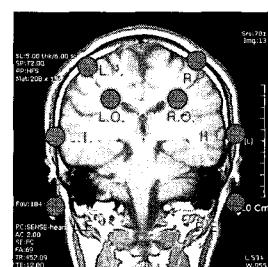
그림 1. 뇌파 측정 시스템
Fig. 1 EEG measurement systems

그림 1에서 MP 35 데이터 획득 장비는 3개의 전극을 가지며 3개의 전극을 통하여 측정된 뇌파는 MP 35에서 USB

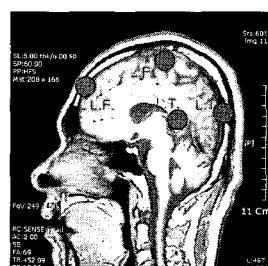
케이블을 통하여 소프트웨어 BSL 3.7.0이 내장된 PC로 전송된다. 3개의 전극 중 하나는 공통전극이며 나머지는 양(+)과 음(-)을 나타내는 전극이다. 그러므로 공통전극을 기준으로 양(+)과 음(-)사이의 차만큼의 신호가 측정된다. 전극의 부착 위치는 머리가죽의 영역 아래의 뇌의 영역인 frontal, parietal, temporal, occipital의 이름을 따서 지어졌다.



(a) Superior



(b) Posterior



(c) Lateral

● 전극의 부착 위치

R : Right	L : Left
F : Frontal	P : Parietal
T : Temporal	O : Occipital
E : Ear	

그림 2. 표준 EEG 전극 배치(3)
Fig. 2. EEG standard electrode positions

EEG를 기록할 때 전극 부착 위치는 단극 기록 방식과 양극 기록 방식 두 가지 방법이 있다. 단극 기록 방식은 활성화 전극은 그림 2와 같이 관심을 갖는 대뇌피질 위에 배치시키고 기준전극은 귱불 또는 신체의 보다 먼 부분에 부착하는 방식이다. 또한 양극 기록 방식은 측정하고자 하는 대뇌피질 위에 배치된 두개의 전극 사이의 전위차가 세 번째 기준전극을 기준으로 신호를 측정한다. 본 논문에서는 양극 기록 방식을 사용하여 뇌파를 측정하였다.

III. 뇌파 분류 알고리즘

본 논문에서는 각각의 다른 정신상태에서 각각 다르게 발생되는 뇌파를 측정하여 입력패턴벡터로 사용한다. 이 입력패턴벡터를 사용하여 네트워크를 학습시킨 후 임의의 정신상태에서 발생되는 뇌파가 네트워크에 가해졌을 때 어떠한 정신상태인지를 역으로 분류하는 학습네트워크를 설계한다.

본 논문에서 제안된 학습네트워크는 SOM의 학습 알고리즘을 이용하여 LVQ 네트워크의 초기 참조벡터를 학습하여 안정도를 향상시키고, out-star 학습규칙을 사용하여 LVQ 출력뉴런이 속해야 할 클래스를 학습하는 네트워크를 설계하여 뇌과 분류 알고리즘으로 사용된다.

1. 뇌파 학습네트워크

본 논문에서 사용된 뇌파 학습네트워크의 구조는 그림 3과 같다.

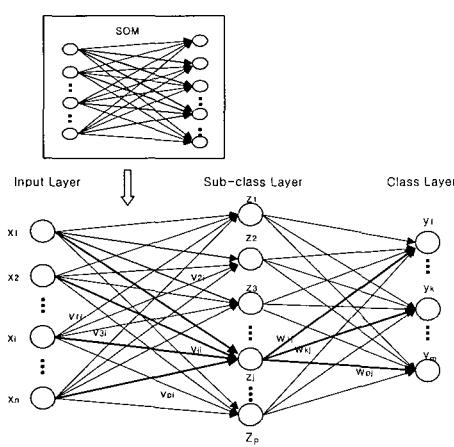


그림 3. 뇌파 학습 네트워크
Fig. 3. EEG learning networks

그림 3에서 x_1, x_2, \dots, x_n 은 $n \times 1$ 입력패턴벡터, z_1, z_2, \dots, z_p 는 각각 p 개의 출력뉴런 v_{ji} , ($i=1, 2, \dots, n$, $j=1, 2, \dots, p$)로 in-star 학습규칙에 의해 학습될 SOM 또는 LVQ의 연결강도이고, 또한 in-star 학습규칙에 의해 학습될 p 개의 클러스터 층의 뉴런이다. 만일 그림 3의 제안된 학습네트워크에서 종속 클래스 층과 클래스 층을 각각 클래스 층과 출력 층으로 고치고, 입력 층과 클래스 층 사이 및 클래스 층과 출력 층 사이의 연결강도를 각각 in-star 와 out-star 학습규칙으로 학습을 진행하면 CP. Net.과 동일하게 된다[7]. 그러나 제안된 학습 네트워크에서는 학습의 안정성을 위하여 SOM을 사용하여 입력 층과 종속 클래스 층 사이의 초기 참조벡터를 학습하였다. 입력 층과 종속 클래스 층 사이의 네트워크는 LVQ의 구조와 같으며 이렇게 학습된 초기 참조벡터를 사용하는 LVQ의 참조벡터는 학습하는 도중에 국소적 접근 안정 평형점에 가까이 존재하고, 학습이 진행되면서 참조벡터가 평형점으로 부터 멀리 이동되지 않게 되어 LVQ의 참조벡터는 수렴하고 LVQ 네트워크는 우수한 분류성능을 갖는다[10,11]. 이렇게 안정된 초기 참조벡터를 가지고 시작되는 LVQ의 학습은 입력패턴벡터와 가장 일치하는 유사도를 갖는 종속 클래스 층의 뉴런과 입력 층 뉴런과 연결된 연결강도를 학습한다. 이것은 입력패턴 벡터가 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 클래스가 지정된다.

2. 뇌파 분류 알고리즘

뇌파 학습네트워크는 알고리즘의 측면에서 성능향상을 갖는 LVQ 네트워크이다. 먼저, LVQ의 참조벡터가 안정적으로 수렴하는 학습능력을 갖기 위해서식 (1)의 SOM 학습규칙으로 온라인 또는 오프라인으로 학습을 진행한다.

$$v_{\pm}^{k+1} \equiv v_{\pm}^k + \alpha_s [x_{\pm} - v_{\pm}^k] \dots \dots \dots (1)$$

여기서 v_{ji} 는 입력패턴벡터의 i 번째 요소 x_i 에서 j 번째 출력 뉴런 z_j 사이의 연결강도이며, a_s 는 SOM의 학습율이다. SOM의 학습이 완료되면, 학습된 연결강도를 LVQ 네트워크의 초기 참조벡터로 설정한다. 이것은 그림 3의 학습 네트워크의 입력 층과 종속 클래스 층의 사이의 연결강도를 학습된 SOM의 연결강도로 대체하여 된다. 즉, 그

럼 3의 뇌파 학습 네트워크의 입력 층과 종속 클래스 층 사이의 네트워크는 LVQ 네트워크로 사용된다. 두 번째의 학습으로 안정된 초기 참조벡터를 가지고 식 (2)를 이용하여 LVQ의 학습을 수행한다.

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

여기서 a_L 은 LVQ의 학습률이며, 승리뉴런의 클러스터와 입력벡터의 클러스터가 같은 경우가 +로, 다른 경우는 -로 학습된다. 세 번째로, 작은 학습률 a_{CP} 로 고정된 값을 가지고 식 (3)으로 정밀 학습을 진행한다.

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

식 (1)의 SOM과 식 (3)의 입력 층과 클러스터 층 사이의 네트워크의 학습은 승리뉴런과 이웃한 뉴런들을 동시에 학습하거나 승리뉴런 만의 학습이 가능하다. 네 번째로, 종속 클래스 층의 승리뉴런을 결정하고, 그 승리뉴런이 속할 클래스는 식 (4)로 학습된다. 즉 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)로 된다.

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

식 (4)에서 β 는 학습률이며 학습이 진행되면서 서서히 감소된다

IV. 데이터 획득 및 패턴인식 실험

1. 데이터 획득

그림 4는 뇌파 데이터를 측정하기 위한 실험장치의 사진이다.



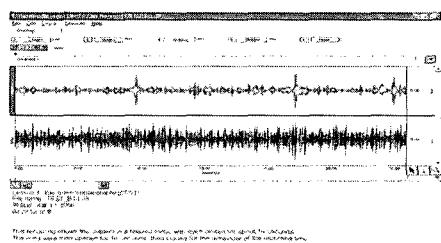
그림 4. 실험장치
Fig. 4 Experimental setup

또한 그림 5는 2쌍의 전극과 하나의 공통접지 전극을 사용한 3개의 전극으로 1개의 채널을 구성하여 측정한 실물에 대한 사진이다.

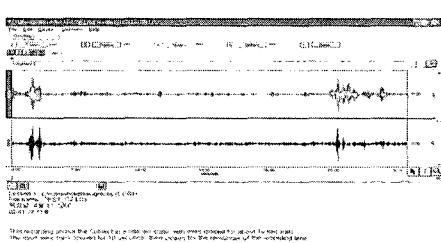


그림 5. 뇌파 측정 사진
Fig. 5 Photograph of EEG measurements

그림 5의 뇌파 측정 사진에서 보이는 바와 같이 뇌파의 측정을 위해 1회용의 Ag/AgCl 표면전극을 사용하여 측정을 하였다. 측정한 뇌파 신호는 알파리듬과 베타리듬이다. 환자의 정신적인 상태는 눈을 뜨고 편안하게 있는 상태, 가쁘게 호흡하고 있는 상태, 암산을 하고 있는 상태에서 각각 알파리듬과 베타리듬을 측정하였다.



(a) 눈을 뜨고 편안하게 있는 상태



(b) 가쁘게 호흡하고 있는 상태

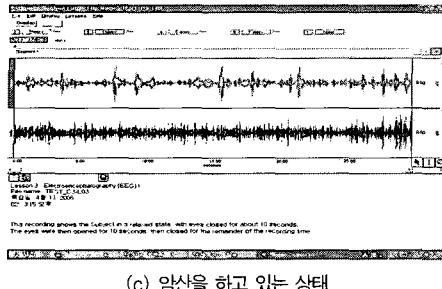


그림 6. EEG 측정(알파리듬과 베타리듬)

Fig. 6 EEG measurements(alpha rhythm and beta rhythm)

그림 6은 각각 (a), (b), (c)와 같은 정신상태에서 MP35를 사용하여 그림 5와 같이 3개의 전극을 뇌에 부착하여 알파리듬(위)과 베타리듬(아래)을 30초 동안 측정하여 BSL 3.7.0 소프트웨어를 통하여 PC 모니터에 표시된 뇌파이다.

각각의 정신상태에서 동일 시간에 발생된 알파리듬과 베타리듬의 주파수와 진폭을 측정하여 4×1 특징벡터를 만들어 4차원의 특징공간을 구성하였다. 데이터의 측정은 각각의 정신상태에서 30개의 데이터를 측정하여 90개의 4차원의 뇌파 데이터를 획득하였다. 그러므로 1번의 측정은 4×1 의 뇌파 패턴벡터를 얻고, 각각의 정신상태마다 30개의 데이터를 측정하여 부록의 표 1과 같이 모두 90개의 데이터를 획득하였다.

2. 패턴인식 실험결과

제안된 알고리즘의 유용성을 확인하여 위하여 획득된 뇌파 데이터를 학습 및 테스트용 데이터로 사용하여 시뮬레이션 하였다.

먼저, 제안된 네트워크의 초기참조벡터를 얻기 위하여 5×5 형상지도를 갖는 SOM 네트워크를 구성하였다.

SOM네트워크의 초기 학습률은 0.9, 초기 이웃반경은 학습이 진행되면서 단계적으로 감소되게 하였다. 초기 연결강도는 [0, 20]의 값으로 무작위로 발생시켰고, 학습 횟수는 10,000번 수행하였다.

제안된 학습알고리즘을 뇌파의 패턴인식에 시뮬레이션하고, 기존의 LVQ 학습알고리즘과의 패턴분류성능을 비교하였다. 기존의 LVQ의 초기참조벡터의 설정은 [0, 20] 사이의 값을 무작위로 발생시킨 경우와 학습용 패턴벡터를 초기 참조벡터로 사용한 경우로 나누어 시뮬레이션하고, 각각의 패턴분류특성을 비교하였다.

실험조건에서 눈을 뜨고 편안히 쉴 때를 상태 A, 가쁜

호흡을 할 때를 상태 B, 암산을 할 때를 상태 C로 고려한다. 기존의 LVQ 네트워크는 입력 뉴런 4개, 출력 뉴런 25개를 사용하였고, 25개의 출력 뉴런 중 9개, 9개, 7개를 각각 상태 A, B, C로에 속하도록 종속클래스를 지정하였다. 또한 제안된 학습네트워크의 입력 뉴런 4개, 종속 클래스 총의 뉴런 25개, 클래스 총의 뉴런은 2개를 사용하였다. 클래스 A, B, C에 대한 각각의 클래스 총의 뉴런의 설정값은 [-1, 1], [1, -1], [1, 1]로 하여 종속 클래스 총의 승리뉴런과 클래스 총의 출력 뉴런사이의 연결강도를 학습하도록 하였다.

SOM, LVQ의 연결강도 및 제안된 방식의 입력 총과 종속 클래스 총 사이의 연결강도를 학습하기 위하여 사용된 학습율은 학습이 진행됨에 따라 서서히 감소하며 식(5)와 같이 학습이 진행됨에 따라 감소된다.

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

식 (5)에서 $ITER_{num}$ 는 학습횟수, $a(0)$ 는 학습율을 나타낸다. 학습률 a 는 설정된 초기값 $a(0)$ 로부터 학습이 진행되면서 서서히 감소된다. 또한 제안된 학습네트워크에서 종속 클래스 총과 출력 총 사이의 연결강도 역시 식(5)을 사용하여 학습이 진행되면서 감소된다. 식(5)에 의해 감소되는 학습율의 초기값을 각각 0.0, 0.7, 0.5로 설정하고 제안된 학습방식을 갖는 LVQ와 기존의 LVQ와의 뇌파 데이터 패턴분류를 시뮬레이션 한 결과는 각각 표 2, 3, 4이다.

표 2. 훈련 데이터의 분류오차($a(0) = 0.9$)
Table. 2 Classification errors of training data

the number of iterations	1000	2000	5000	10000
LVQ(Random)	60	60	60	60
LVQ(Learning vector)	25	23	23	21
the proposed method	21	21	19	19

표 3. 훈련 데이터의 분류오차($a(0) = 0.7$)
Table. 3 Classification errors of training data

the number of iterations	1000	2000	5000	10000
LVQ(Random)	55	55	55	55
LVQ(Learning vector)	21	21	21	21
the proposed method	18	17	19	18

표 4. 훈련 데이터의 분류오차($a(0) = 0.5$)

Table. 4 Classification errors of training data

the number of iterations	1000	2000	5000	10000
LVQ(Random)	59	59	59	58
LVQ(Learning vector)	21	21	21	21
the proposed method	20	20	20	20

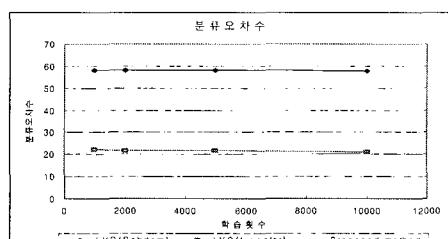
다음의 표 5는 표 2, 3, 4를 평균한 분류오차 수 및 오차율이다.

표 5. 평균 분류오차 및 분류 오차율

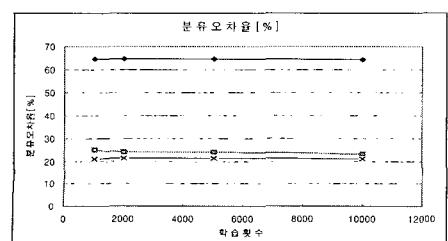
Table. 5 Number and ratio of classification errors

the number of iterations	1000	2000	5000	10000	평균
LVQ (Random)	오차수	58	58	58	57.7
	오차율[%]	64.4	64.4	64.4	64.1
LVQ (Learning vector)	오차수	22.3	21.7	21.7	21
	오차율[%]	25.1	24.1	24.1	23.3
the proposed method	오차수	19.7	19.3	19.3	19
	오차율[%]	21.2	21.4	21.4	21.1

그림 7은 표 5에 대한 평균 분류 오차 및 오차율을 그래프로 나타내었다.



(a) The number of the classification errors



(b) Ratio of the classification errors

그림 7. 분류오차비교
Fig. 7 Comparison of the classification errors

그림 7에서 LVQ(Random)은 초기 참조벡터를 무작위로 발생시킨 LVQ이고, LVQ(L vector)는 학습에 사용되는 패턴벡터를 초기 참조벡터로 설정된 LVQ 학습방식이다. LVQ(Random)은 64.3[%], LVQ(L vector)는 24.1[%]의 평균분류오차를 얻었지만, 제안된 알고리즘을 사용한 방식에서는 21.4[%]의 평균 분류 오차는 를 얻을 수 있었다.

따라서 제안된 방식은 LVQ(Random) 보다 평균 45[%], LVQ(L vector) 학습방식보다 평균 2.7[%]의 평균 분류 오차율이 개선되었음을 확인하였다.

V. 결론

본 논문에서는 BIO PAC 사의 MP35 데이터획득 장비와 BSL 3.7.0 소프트웨어가 내장된 PC를 사용하여 뇌파를 측정하였다. 측정된 뇌파는 3개의 정신상태 즉 눈을 뜨고 편안하게 있는 상태, 가쁘게 호흡하고 있는 상태, 암산을 하고 있는 상태의 조건에서 측정되었다. 측정된 뇌파는 알파리듬, 베타리듬, 델타리듬, 세타리듬 중 분류의 용이성을 위하여 알파리듬과 베타리듬 만을 사용하였다.

특징벡터의 추출은 PC 상에서 BSL 3.7.0 소프트웨어를 사용하여 같은 시간에 발생된 알파리듬과 베타리듬의 진폭과 주파수를 추출하여 4×1 특징벡터를 구성하였다. 학습 및 시험에 사용될 패턴벡터는 동일하며 각 정신상태에서 각각 30개의 특징벡터를 추출하여 모두 90개의 패턴벡터를 구성하였다. 추출된 뇌파 패턴벡터의 분류를 위해 제안된 뇌파 학습알고리즘은 학습하는 동안 안정적으로 수렴될 수 있도록 SOM으로 초기 참조벡터를 학습하였다. 그리고 학습된 초기 참조벡터를 사용하여 LVQ의 학습을 진행 한 다음, 다시 한번 더 작은 값으로 고정된 학습률로 정밀 학습을 하였다.

마지막으로 종속 클래스 층의 승리뉴런을 결정하고, 그 승리뉴런이 속할 클래스를 학습하기 위하여 out-star 학습 규칙을 사용하였다. 측정 및 특징벡터로 추출된 뇌파 데이터를 학습벡터 및 시험 벡터로 사용하여 제안된 학습방식과 기존의 LVQ 학습방식에 적용하여 시뮬레이션 하였다.

제안된 학습방식의 패턴분류 성능은 네트워크의 초기 참조벡터를 무작위로 발생시켜 설정한 LVQ(Random) 보다 평균 45[%]의 분류 오차율이 개선되었고, 패턴벡터를 초기 참조벡터로 사용한 LVQ(L vector) 학습방식보다 평균

2.7[%]의 분류오차율이 개선되었음을 확인하였다.

각 정신상태에서 뇌파의 변화는 일정한 상태로 변화되지만 불규칙적인 변화의 양도 무시할 수 없을 정도로 심하여 각 상태에서 뇌파의 겹침이 심하게 얻어졌다. 이로 인하여 제안된 방식의 알고리즘을 사용한 경우에도 21.4[%]의 평균 분류 오차를 나타내었다.

이 후 보다 우수한 뇌파의 패턴분류를 하기 위해서는 각 정신상태에서 패턴벡터의 겹침 정도가 완화될 수 있도록 특징벡터의 추출방식을 개선하는 것이 과제로 남는다.

참고문헌

- [1] 장남섭 외 5인, 생리학, pp.286-291, 수문사, 2005.
- [2] 의공학교육연구회, 의용계측공학, pp.212-237, 여문각, 2002.
- [3] Richard G. Planzer, Experimental Laboratory Physiology BIOPAC LAB Exercises, KENDALL/HUNT PUBLISHING COMPANY, 2004.
- [4] 김호봉, 박영환, 배성수, “근전도와 신경전도 검사의 임상적 응용”, 대한물리치료학회지 논문집, 제 10권, 제 1호, pp.199-212, 1998.
- [5] 이정훈, 정경권, 이현관, 엄기환, “가상로봇 팔 제어를 위한 퍼지-SOFM 방식의 근전도 패턴인식”, 대한전자공학회논문지, 제 40권 CI편 제 2호, 2003.
- [6] 이용구 외 2인, “EEG 패턴인식”, 2006년도 대한전자공학회 하계종합학술대회논문집 제29권 제1호, pp.1017-1018, 2006.
- [7] 이용구, 최우승, “근전도 패턴인식을 위한 혼합형 LVQ 학습 알고리즘”, 한국컴퓨터정보학회논문집, 제10권, 제 2호, pp.113-121, 2005. 5.
- [8] 이용구, 최우승, “Forward C.P. Net.을 이용한 3단 LVQ 학습알고리즘”, 한국컴퓨터정보학회논문집, 제9권제 4호, pp.33-39, 2004.
- [9] 이용구, 최우승, “분류오차율을 낮추는 LVQ 학습을 위한 학습네트워크”, 한국컴퓨터정보학회논문집, 제10권제 5호, pp.77-86, 2005.
- [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).

저자 소개



이 용 구

1987년 동국대학교 공학사

1993년 동국대학교 공학석사

1997년 동국대학교 공학박사

1998년 ~ 현재 한림성심대학
의료기기정보과 부교수

〈관심분야〉

지도 및 비지도학습 신경회로망,
퍼지논리시스템, 패턴인식,
생체신호처리



이 선 엽

1981년 신구대학 전문학사

1997년 연세대학교 보건학석사

2006년 강원대학교 공학박사(수료)

1985년 ~ 한림대학부속춘천성심병원
진단방사선과 부기사장

〈관심분야〉

비지도학습 신경회로망, 패턴인식,
방사선 영상, CAD.Export
System.



최 우 승

1977년 동국대학교 공학사

1981년 동국대학교 공학석사

1994년 동국대학교 공학박사

1998년 ~ 2000년 한국컴퓨터정보
학회 학회장

2000년 ~ 현재 한국컴퓨터정보학회
고문

1981년 ~ 2006년 현재 경원전문대학

정보통신과 교수

〈관심분야〉

비지도학습 신경회로망, 패턴인식

부 록

표 1. 측정된 EEG 데이터

Table 1. The measured EEG data
(alpha : Hz, μ V, beta : Hz, μ V)

학습 및 테스트 용(30개)	
상태 A	11.11111, 3.199941, 20.000000, 3.983619. 10.526316, 3.725089, 25.000000, 4.645598. 8.333333, 3.492327, 22.222222, 3.380573. 8.695652, 3.256549, 25.000000, 3.458147. 10.526316, 3.215334, 22.222222, 6.074407. 9.523810, 4.970682, 25.000000, 2.718833. 9.523810, 4.970682, 25.000000, 4.663848. 11.764706, 2.667023, 28.571429, 3.109077. 9.090909, 4.292401, 22.222222, 4.400172. 8.000000, 2.488072, 18.181818, 3.449570. 10.526316, 3.208888, 22.222222, 2.375675. 10.000000, 3.172038, 28.571429, 3.761401. 11.111111, 2.065737, 20.000000, 3.051960. 9.523810, 6.294753, 22.222222, 3.912883. 10.000000, 3.811185, 22.222222, 2.932860. 10.526316, 6.352690, 22.222222, 4.098877. 13.333333, 2.754468, 25.000000, 4.957147. 10.000000, 6.380018, 33.333333, 2.971468. 7.692308, 4.713866, 20.000000, 4.450525. 10.000000, 3.003726, 20.000000, 5.989013. 9.523810, 1.837600, 20.000000, 6.446720. 11.764706, 0.753420, 22.222222, 3.291241. 10.526316, 1.811456, 22.222222, 2.99759. 11.111111, 2.203540, 20.000000, 4.096501. 9.523810, 2.430592, 22.222222, 3.387489. 8.333333, 1.789818, 22.222222, 3.521337. 8.333333, 2.228090, 22.222222, 1.457079. 10.000000, 3.754062, 28.571429, 1.910406. 8.695652, 2.136479, 22.222222, 4.505058. 9.523810, 3.362392, 20.000000, 2.076412.
	9.523810, 4.298639, 20.000000, 3.581685. 10.526316, 3.245233, 22.222222, 2.851906. 8.695652, 3.804375, 16.666667, 1.920289. 10.000000, 3.488873, 20.000000, 2.687245. 9.523810, 2.342726, 22.222222, 3.164478. 8.000000, 2.321457, 25.000000, 1.934977. 10.000000, 2.506823, 20.000000, 1.707271. 10.000000, 4.645921, 22.222222, 1.314660. 9.523810, 3.752070, 22.222222, 2.219718. 10.000000, 4.300400, 25.000000, 1.827110. 10.000000, 4.314822, 20.000000, 3.239354. 10.000000, 4.064906, 20.000000, 3.390251. 10.526316, 4.294776, 16.666667, 2.524549. 9.523810, 3.010009, 20.000000, 2.653626. 10.000000, 5.343595, 18.181818, 3.050266. 9.523810, 1.926632, 20.000000, 1.937201. 10.000000, 5.530440, 28.571429, 1.334732. 9.523810, 5.870895, 25.000000, 2.452016. 11.111111, 2.252642, 22.222222, 1.659490. 9.090909, 4.983907, 25.222222, 2.807485. 10.000000, 3.680289, 22.222222, 8.896795. 9.523810, 5.140614, 25.000000, 1.598617. 9.523810, 5.053958, 22.222222, 3.571641. 10.526316, 3.919508, 18.181818, 1.790959. 9.090909, 4.241552, 22.222222, 2.375235. 8.695652, 4.788724, 18.181818, 4.202570. 8.333333, 5.575407, 25.000000, 2.932004. 9.523810, 4.436817, 20.000000, 2.886310. 9.523810, 3.691396, 15.384615, 3.691396. 11.111111, 2.398170, 18.181818, 1.327697.
	11.764706, 2.998534, 22.222222, 5.704110. 9.090909, 2.514655, 22.222222, 5.988368. 9.523810, 3.317213, 18.181818, 2.740729. 10.000000, 1.391616, 22.222222, 4.544400. 10.000000, 3.995442, 25.000000, 1.739957. 10.000000, 3.224081, 18.181818, 4.065017. 10.000000, 2.311580, 20.000000, 2.230758. 11.111111, 0.544943, 22.222222, 3.076986. 11.111111, 4.38348, 22.222222, 4.656562. 11.111111, 2.258438, 20.000000, 4.652079. 8.333333, 2.711317, 25.000000, 2.149587. 8.333333, 1.626814, 20.000000, 3.213800. 7.407407, 1.974963, 20.000000, 4.201336. 11.111111, 2.305744, 22.222222, 2.496264. 11.111111, 1.533293, 25.000000, 2.486291. 9.523810, 2.683461, 18.181818, 4.996634. 11.764706, 1.962736, 20.000000, 2.098657. 10.526316, 2.439337, 25.000000, 2.091025. 11.764706, 2.186243, 25.000000, 1.127649. 9.090909, 3.454971, 18.181818, 3.200976. 11.111111, 2.267379, 22.222222, 1.148303. 7.142857, 1.643100, 16.666667, 2.400426. 11.111111, 3.316617, 22.222222, 5.128374. 11.111111, 2.620538, 22.222222, 3.871029. 8.333333, 1.591015, 16.666667, 3.105800. 9.090909, 1.324110, 25.000000, 1.787841. 11.111111, 1.520951, 25.000000, 3.058833. 10.526316, 3.105963, 16.666667, 4.240512. 8.695652, 1.315800, 25.000000, 2.347653. 10.526316, 5.898002, 18.181818, 5.898002
	상태 C