

論文2002-39CI-3-3

웨이블릿 신경망을 이용한 패턴 분류 시스템 설계 및 EEG 신호 분류에 대한 연구

(A Study of Pattern Classification System Design Using
Wavelet Neural Network and EEG Signal Classification)

林成吉 * , 朴贊虎 ** , 李顯洙 *

(Sung-Kil Lim, Chan-Ho Park, and Hyon-Soo Lee)

요약

본 논문에서는 신경망에 기반한 디지털 신호를 위한 패턴분류 시스템을 제안한다. 제안하는 시스템은 두 가지 신경망 모델로 구성된다. 첫 번째 부분은 특징 추출의 역할을 하는 웨이블릿 신경망이다. 이 부분을 위해 기존의 웨이블릿 신경망 모델들을 비교한 후, 특징 추출을 위한 새로운 웨이블릿 신경망 모델을 제안한다. 다른 부분은 패턴 분류를 위한 웨이블릿 신경망이다. 패턴 분류에 적용하기 위해 기존의 웨이블릿 신경망 구조를 수정하고 학습 방법을 제안한다. 패턴 분류 웨이블릿 신경망의 입력은 특징 추출 신경망의 은닉노드의 연결강도, 확장 및 이동 파라미터로 구성되었다. 또 출력은 특징 추출 신경망의 입력 신호가 속한 부류를 나타낸다. 제안한 시스템을 EEG 신호를 주파수에 따라서 분류하는 문제에 적용하였다.

Abstract

In this paper, we propose a pattern classification system for digital signal which is based on neural networks. The proposed system consists of two models of neural network. The first part is a wavelet neural network whose role is a feature extraction. For this part, we compare existing models of wavelet networks and propose a new model for feature extraction. The other part is a wavelet network for pattern classification. We modify the structure of previous wavelet network for pattern classification and propose a learning method. The inputs of the pattern classification wavelet network is connection weights, dilation and translation parameters in hidden nodes of feature extraction network. And the output is a class of the signal which is input of feature extraction network. The proposed system is applied to classification of EEG signal based on frequency.

Key Words : Wavelet Neural Network, Pattern Classification, EEG, Feature Extraction

* 正會員, 慶喜大學校 컴퓨터工學科

(Department of Computer Engineering, Kyung-Hee University)

** 正會員, 富川大學 인터넷應用科

(Department of Internet Information Science, Bucheon College)

※ 이 논문은 1998년 한국학술진흥재단의 학술연구비
에 의하여 지원되었음(과제번호 : 1998- 001-E01032)

接受日字:2001年12月5日, 수정완료일:2002年4月25日

I. 서론

신경망(Neural Network)은 기존의 방법으로는 해결하기 어려운 문제뿐만 아니라 이미 잘 알려진 해결책이 존재하는 문제에서도 적용되고 있다. 신경망을 이용한 해결 방법이 주목받고 있는 이유는 실세계의 문제가 수학적으로 잘 정의된 경우보다는 문제 자체가 모호한 경우가 많아 기존의 해결 방법들이 정확히 적용

되기 어렵고, 기존의 방법들이 비규칙적인 잡음에 상당한 영향을 받는다는 사실에 기인한다.

이에 반해 신경망을 이용한 접근은 학습을 통해 문제를 해결함으로써, 문제가 정확히 정의되지 않은 경우는 물론, 문제의 해결책이 알려지지 않은 경우에도 적용될 수 있다. 신경망은 일반적으로 기존의 최적해를 구하는 방법보다 빠르게 동작하며 본질적으로 병렬성을 가지고 있기 때문에 필요한 경우 병렬처리를 구현하기도 쉽다는 장점을 가지고 있다.

패턴 인식 및 분류 문제에서 가장 널리 사용되고 있는 오차 역전파 신경망(Error Backpropagation Neural Network, EBP) 모델은 많은 응용 분야에서 성공적으로 적용되고 있지만, 은닉층의 노드의 수를 결정하기 어렵고 지역해에 빠지는 수가 많으며 학습 과정이 매우 길다는 단점을 가지고 있다. 1992년 Q. Zhang에 의해 제안된 웨이블릿 신경망(Wavelet Network)은 EBP의 이러한 단점을 보완할 수 있는 모델이다[3].

웨이블릿 신경망은 웨이블릿 이론 중 프레임 특성(frame property)에 의해 은닉층 노드의 구성을 결정하고 은닉 노드의 활성화 함수로서 지역성을 가진 웨이블릿 함수를 사용함으로써 전체적인 학습이 빠르며, 다중 해상도(multiresolution)를 사용함으로써 지역해에 빠지는 것을 회피하는 특성을 가지고 있다.^[2] 특히 함수 근사 문제를 위한 웨이블릿 신경망은 웨이블릿 변환 과정과 동일한 수식을 사용함으로서 은닉층과 출력 층의 연결 가중치가 웨이블릿 계수로 학습되도록 한다. 이 사실은 웨이블릿 신경망을 이용하여 입력신호의 특징을 추출 할 수 있음을 의미한다. 그러나 기존의 웨이블릿 신경망은 필요 이상으로 많은 은닉층의 노드로 구성됨으로써 자원의 낭비뿐만 아니라 학습 속도에도 영향을 미치고 있다.^[3,4]

본 논문에서는 신호의 특징을 추출하기 위해 기존의 웨이블릿 신경망을 비교 분석하여 특징 추출에 적합한 신경망의 구조를 제안하고, 더 나아가서 웨이블릿 신경망을 패턴 분류 문제에 적용하여, 학습의 속도가 빠르고 지역해에 수렴할 가능성이 적은 신호 분류 시스템을 제안한다.

II. 시스템 개요

일반적인 신호 분류 시스템은 그림 1과 같이 실세계의 대상 신호를 패턴 인식 시스템에 적합한 형태의 입

력으로 변환해 주는 센싱(Sensing), 입력되는 데이터를 하나의 대상으로 나누어주는 역할을 하는 분할(Segmentation), 입력 데이터를 분류하는데 적합한 특성 및 속성을 선택하는 특징 추출(Feature Extraction), 특징 벡터를 이용하여 입력되는 대상을 여러 개의 부류 중 하나로 결정하는 주처리-분류(Main Processing-Classification), 문맥적인 검사 등을 이용하여 분류된 결과를 보다 정제하는 후처리(Post Processing)로 구성된다. 본 논문에서 제안하는 신호 분류 시스템은 특징 추출 부분과 주 처리 부분(패턴 분류 부분)만을 포함한다.

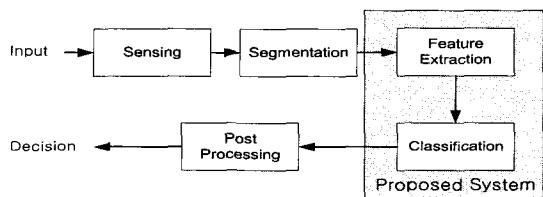


그림 1. 제안하는 신호 분류 시스템의 범위
Fig. 1. The Scope of Proposed Signal Classification System.

따라서 본 논문에서 제안하는 시스템은 잡음 제거, 신호의 세기 조정 및 분할과 같은 전처리 과정이 수행되고 난 후의 신호를 샘플링과 양자화를 거쳐 생성된 디지털 신호를 입력받는다. 또한 시스템의 출력은 신호가 속하는 부류와 그에 해당하는 신경망의 출력 노드의 값이 된다. 그림 2는 본 논문에서 제안하는 신호 분류 시스템의 입력 및 출력을 나타낸다. 그림에서 $F(x)$ 는 부류가 알려지지 않은 디지털 신호를 n 개의 샘플로 구성된 프레임을 나타내며, y_1, y_2, \dots, y_M 은 M 개의 부류에 포함 여부를 코드화한 신경망의 출력 값을 나타낸다.



그림 2. 제안하는 시스템의 입·출력
Fig. 2. Input/Output of Proposed System.

제안하는 전체 분류 시스템은 학습의 단계와 분류 단계로 나뉘어 동작하는데 학습이 종료된 후의 분류기로서의 동작은 다음과 같다.

Step1. 신호가 M 개의 부류 $\omega_1, \omega_2, \dots, \omega_M$ 중 하나에 포함된다고 가정, t 시간에서 n 개의 신호 챔플 $F(t) = \{f(x)|x=t-n+1, t-n+2, \dots, t-1, t\}$ 을 시스템에 입력

Step2. 특징 추출 신경망에 의해 입력된 신호가 연결 가중치로 변환

Step3. 특징 추출 신경망의 연결 가중치를 패턴 분류 신경망에 입력

Step4. M 개의 부류를 코딩한 패턴 분류 신경망의 출력 y_1, y_2, \dots, y_M 을 계산

Step5. 신경망의 출력을 평가하여 부류에 포함 여부를 판단

알고리즘 1. 신호 분류 시스템의 전체 동작
Algorithm 1. Processing of Signal Classification System.

제안하는 신호 분류 시스템의 학습 과정은 다음과 같다.

Step1. 부류가 알려진 신호 챔플 $F_p(t) = \{f_p(x)|x=t-n+1, t-n+2, \dots, t-1, t\}$ 와 그에 해당하는 부류코딩 값 $\bar{\mathbf{y}}_p = [\bar{y}_1, \bar{y}_2, \dots, \bar{y}_M]^T$ 로 구성된 훈련 집합 $T = \{(F_p(t), \bar{\mathbf{y}}_p)|p=1, 2, \dots, t\}$ 의 모든 신호에 대하여

Step2. 특징 추출 신경망을 $(x, f_p(x)), x=1, \dots, n$ 에 대하여 학습

Step3. 특징추출 신경망의 연결 강도의 집합 $X_p = \{w_k|k \in \text{set of hidden nodes}\}$ 과 교사신호 $\bar{\mathbf{y}}_p$ 의 순서쌍 $(X_p, \bar{\mathbf{y}}_p)$ 에 대하여 패턴 분류 신경망을 학습

Step4. 모든 훈련 패턴에 대하여 에너지 함수 E 가 충분히 작으면 학습 종료, 그렇지 않다면 Step1부터 반복

알고리즘 2. 신호 분류 시스템의 학습
Algorithm 2. Learning Process of Signal Classification System.

그림 3은 제안하는 신호 분류 시스템의 내부 구조도이다. 제안하는 신호 분류 시스템은 크게 두 부분, 특징 추출 웨이블릿 신경망과 패턴 분류 웨이블릿 신경망으로 구성된다. 특징 추출 웨이블릿 신경망은 입력되는

신호를 근사하도록 학습하며, 그 연결 강도를 신호의 특징으로서 신호 분류기의 입력으로 사용한다. 그럼에서 $F(x)$ 는 시스템의 입력을 나타내고 $f'(x)$ 는 특징 추출 웨이블릿 신경망에서 생성되는 임시 출력이다. x 는 특징 추출 신경망의 학습을 위해 임시로 생성되는 변수로써 입력 신호 $F(x)$ 의 패턴 번호에 해당한다.

패턴 분류 웨이블릿 신경망은 학습된 특징 추출 신경망의 연결 강도를 패턴으로 하여 분류 작업을 수행하며, 전체 시스템의 교사신호 $\bar{y}_1, \bar{y}_2, \dots, \bar{y}_M$ 을 교사 신호로 하여 학습된다.

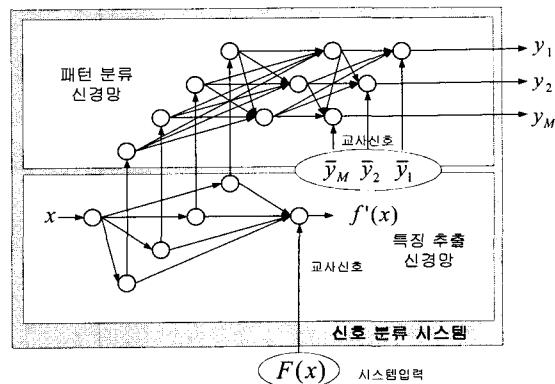


그림 3. 신호 분류 시스템의 구조
Fig. 3. Structure of Signal Classification System.

III. 특징 추출 웨이블릿 신경망

웨이블릿 신경망은 웨이블릿 변환을 기존의 전방향 다층 신경망의 구조에 적용한 신경망 모델로 다음과 같은 성질을 갖는다.

1. 웨이블릿 신경망의 출력 (식1)은 웨이블릿 역변환의 (식2)와 동일하다.

$$\hat{y}(t) = \sum_{k=1}^K w_k \psi_{a_k, b_k}(t) \quad (1)$$

$$f(t) = \frac{1}{C_\phi} \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} W_f(a, b) \psi_{a, b}(t) \quad (2)$$

2. 웨이블릿 신경망의 연결강도는 웨이블릿 변환의 계수로 학습하게 된다.

3. 웨이블릿 신경망의 은닉노드를 프레임을 이루도록 네트워크 구조를 결정하면 L^2 상의 모든 임의의 신호를 표현 할 수 있다.

4. 웨이블릿 신경망은 각 은닉 노드가 원도우를 가지

므로 지역학습이 가능하다.

본 논문에서는 웨이블릿 신경망의 동작이 웨이블릿 역변환과 동일한 수식을 사용하므로 웨이블릿 신경망의 학습이 웨이블릿 변환의 역할을 한다는 것에 착안하여 웨이블릿 신경망을 신호처리의 전처리 과정에 해당하는 특징 추출기로 사용한다.

웨이블릿 신경망의 학습 알고리즘은 크게 네트워크의 구조를 결정하는 부분과 네트워크의 출력 에러를 최소화하는 두 부분으로 나눌 수 있다.

먼저, 웨이블릿 네트워크의 구조는 은닉 노드의 수와 각 노드의 확장(dilation), 이동(translation) 파라미터의 분포로 특정 지울 수 있다. 확장과 이동 파라미터는 이산적인 방법에 의해 결정 될 수도 있고 학습을 통하여 적응적으로 결정 될 수도 있다. 은닉 노드의 수를 결정하는 방법은 주로 시간-주파수 공간에서 훈련 패턴의 분포를 사용한다. 이것은 각각의 은닉 노드에 해당하는 윈도우에 훈련 패턴이 존재하지 않으면 그 은닉 노드의 연결 강도가 0이 된다는 성질을 이용한 방법이라 할 수 있다.

웨이블릿 신경망은 은닉 노드가 프레임을 이루도록 구성하면 임의의 신호를 근사할 수 있는데, 이렇게 구성된 신경망은 필요 이상의 은닉 노드를 가짐으로써, 학습의 성능을 저하시키고, 자원을 낭비하게 된다. 따라서 웨이블릿 신경망의 구조를 최적화 시키는 연구는 주로 은닉 노드의 수를 결정하는 방법을 연구하는 것이다. 웨이블릿 신경망 구조의 최적화 방법으로는 다중 해상도(Multi resolution)를 이용하여 은닉층을 단계적으로 추가시키며, 하나의 해상도 층이 추가 할 때마다 최급 강하 학습과 은닉 노드를 제거(prune)하는 방법을 반복적으로 사용하는 방법[4], 프레임 조건(frame condition)을 만족하도록 네트워크를 구성한 후, 각각의 은닉 노드에 해당하는 윈도우에 시간-주파수 공간으로 변환된 훈련 패턴이 속하는 은닉 노드만을 선택하여 네트워크를 재구성하여 에러를 최소화하는 학습을 수행하는 방법^[5], 훈련 패턴을 시간-주파수 공간으로 변환한 후, 시간-주파수 공간에서 변형된 SOFM (Modified Self Organize Feature Map)을 이용하여 은닉 노드의 수와 적절한 위치를 결정하는 방법^[6], 훈련 패턴의 변환 없이 은닉 노드의 추가와 에러 최소화 학습을 반복적으로 수행하여 은닉 노드의 수를 최적화 하는 방법^[7] 등이 있다.

본 논문에서는 전처리 과정이 필요 없도록 수정한 이산 웨이블릿 신경망(DWN)과, 연속 웨이블릿 신경망(CWN), 은닉 노드의 수를 대상 신호에 따라 가변적으로 결정하는 자기 성장 웨이블릿 신경망(SGWNN)에 대하여 근사 성능을 비교하고 특징 추출기로서의 적합성을 분석한다.

1. 이산 웨이블릿 신경망 (DWN)

DWN은 입력, 은닉, 출력층으로 구성된 3층의 전방향 네트워크로, 입력층과 출력층은 선형 유닛을 사용하며, 은닉층은 웨이블릿 함수를 활성화 함수로 사용하는 웨이블릿 유닛으로 구성되어 있다. 각 층의 노드들은 완전 연결되어 있다. 입력층과 은닉층의 연결은 연결강도가 1로 고정되어 있으며, 은닉층과 출력층의 연결의 연결강도는 학습 과정을 통해 웨이블릿 계수로 학습하게 된다.

DWN의 은닉 노드는 다중해상도(multiresolution)의 형태로 구성되어 있으며, 확장 파라미터 a_k 는 j 가 해상도를 나타내는 정수 일 때 2^j ($j \in \mathbb{Z}$)의 값을 가지고, 이동 파라미터 b_k 는 정수가 된다. DWN에서 a_k 와 b_k 는 학습에 참여하지 않으며 초기의 값을 유지하고 있다.

DWN의 출력은 (식 3)과 같이 결정된다.

$$\hat{y}(t) = \sum_{k=1}^K w_k \psi_{a_k, b_k}(t) \quad (3)$$

where $a_k = 2^j$, $j \in \mathbb{Z}$, $b_k \in \mathbb{Z}$

DWN의 학습 과정은 확장 파라미터와 이동 파라미터가 이진(dyadic) 방법에 의해 초기화된 후, 학습 과정에서 값이 변경되지 않는다는 점을 제외하면 일반적인 웨이블릿 네트워크 학습과 동일하게 학습된다. DWN의 구체적인 학습 과정은 다음의 알고리즘 3과 같다.

- Step1.** 각 리졸루션별 은닉 노드 초기화 및 연결강도 초기화
- Step2.** 학습 패턴 적용 및 출력 계산
- Step3.** 연결 강도 변화량 계산
- Step4.** 연결강도 갱신
(확장, 이동 파라미터는 갱신하지 않음)
- Step5.** 학습 종료조건을 만족하지 않으면 step2-step4 반복

알고리즘 3. DWN의 학습과정

Algorithm 3. Learning Process of DWN

Step1의 네트워크 초기화 단계에서 은닉 노드의 확장 파라미터는 2^j ($j=1,2,\dots,m$, m 은 해상도의 단계)로 초기화하고, 이동 파라미터는 각 해상도 r 에 대하여 $i \times (\text{학습패턴의 수}/2^r)$ ($i=0 \text{ to } 2^r$)로 초기화한다. 연결 강도는 0으로 초기화한다. Step2에서 출력은 (식 3)에 의해 계산되며, Step5의 학습 종료 조건은 각 훈련 패턴에 대하여 네트워크의 출력 오차의 제곱이 일정한 상수 보다 작을 때로 결정한다.

2. 연속 웨이블릿 신경망 (CWN)

CWN은 DWN과 동일한 구조를 가지고 있으며, DWN의 은닉 노드가 이진 구조를 가지고 있는 반면, CWN의 은닉 노드는 확장과 이동이 임의의 실수 형태를 취하고 있다는 차이점을 가지고 있다.

CWN의 출력은 (식 4)와 같이 결정된다.

$$\hat{y}(t) = \sum_{k=1}^K w_k \phi_{a_k, b_k}(t) \quad (4)$$

where $a_k \in R(>0)$, $b_k \in R$

CWN의 학습 과정은 일반적인 웨이블릿 네트워크 학습과 동일하다. CWN의 구체적인 학습 과정은 다음의 알고리즘4와 같다.

- Step1. 은닉 노드 초기화 및 연결강도 초기화
- Step2. 학습 패턴 적용 및 출력 계산
- Step3. 연결 강도 변화량 계산
- Step4. 연결강도, 확장 및 이동 파라미터 생성
- Step5. 학습 종료조건을 만족하지 않으면 step2-step4 반복

알고리즘 4. CWN의 학습 알고리즘

Algorithm 4. Learning Process of CWN.

Step1의 네트워크 초기화 단계에서 은닉 노드의 확장 파라미터는 0보다 큰 임의의 실수로 초기화하고, 이동 파라미터는 임의의 실수로 초기화한다. 연결강도는 0으로 초기화한다. Step2에서 출력은 (식 4)에 의해 계산되며, Step5의 학습 종료 조건은 각 훈련 패턴에 대하여 네트워크의 출력 오차의 제곱이 일정한 상수 보다 작을 때로 결정한다.

3. 자기성장 웨이블릿 신경망(SGWNN)

SGWNN은 CWN이 고정된 수의 은닉 노드를 가진다는 단점을 보완한 신경망 모델로, CWN과 동일한 구조

를 가지고 있다. CWN이 신경망의 초기화 과정에서 은닉 노드의 수를 결정하는 반면, SGWNN은 학습과정 중에 은닉 노드를 추가함으로써 은닉 노드 수를 결정한다. SGWNN의 학습과정은 알고리즘 5와 같다.

- Step1. 은닉 노드 초기화 및 연결강도 초기화
- Step2. 은닉 노드의 추가 및 삭제
- Step3. 학습패턴 적용 및 출력 계산
- Step4. 연결 강도 변화량 계산
- Step5. 연결강도, 확장 및 이동 파라미터 생성
- Step6. 에러의 변화율이 충분히 작지 않다면 step3-step5 반복, 충분히 작다면 step7 수행
- Step7. 학습 종료조건을 만족하지 않는다면 step2부터 반복

알고리즘 5. SGWNN의 학습과정

Algorithm 5. Learning Processing of SGWNN.

Step1에서 은닉 노드의 수는 임의의 적은 수로 결정 한다. 은닉 노드의 확장은 5-6개의 훈련 패턴이 포함되도록 임의의 상수로 결정하며, 이동은 전체 패턴 공간에서 평등 분포(Uniform distribution)을 따르도록 결정 한다. Step2에서 추가된 은닉 노드는 에러 최소화 학습이 실행되기 전에 신경망의 출력에 영향을 주지 않도록 연결 강도를 0으로 초기화하며, 확장은 신경망 초기화에 사용한 상수를 그대로 사용한다. 이동은 이전 학습에서 에러가 가장 많이 발생한 패턴의 위치 값으로 초기화한다.

Step2에서 은닉노드를 삭제하는 경우는 에러 최소화 학습의 결과 연결강도가 0에 가까운 값이 될 때, 그 은닉 노드는 신경망 전체의 학습에 영향을 거의 주지 않으므로 삭제하게 된다. Step6에서 에러의 변화율은 (식 5)와 같이 결정한다.

$$\frac{\text{이전 에러} - \text{현재 에러}}{\text{이전 에러}} < C \quad (5)$$

이때 C 는 에러의 변화율이 얼마나 작을 때 은닉 노드를 추가 할 것인지를 결정하는 상수로써 C 의 값이 크면 추가되는 은닉 노드의 수가 많아지고, 작으면 적은 수의 은닉노드가 추가된다.

4. 연속 이산 웨이블릿 신경망(CDWN)

CWN, DWN, SGWNN을 이용하여 여러 가지 주기의 사인파, 여러 가지 주기의 구형파, 가변 주기의 사인

파에 대한 근사 실험을 수행 한 결과 세 가지 모델을 비교해 보면 CWN의 경우가 대체적으로 일반화 성능이나 학습 속도 면에서 가장 좋은 성능을 나타내고 있었다. SGWNN은 은닉 노드의 수를 신호의 복잡한 정도에 따라 가변적으로 결정하므로 대상 신호의 변화에 따라 은닉 노드의 수를 결정해 줘야하는 불편을 없앨 수 있었다. DWN의 경우는 확장 및 이동 파라미터가 학습되지 않으므로 정확한 근사가 어려웠다.

그러나 본 논문에서 고려하고 있는 특징 추출 신경망은 신경망의 연결 강도와 확장 및 이동 파라미터를 대상 신호의 특징으로 사용함을 목적으로 하기 때문에 CWN이나 SGWNN의 경우는 적합하지 않다고 할 수 있다. 왜냐하면 SGWNN의 경우는 은닉 노드의 수가 가변적이기 때문에 대상 신호의 특징으로 사용할 차원이 고정되지 않기 때문이다. CWN의 경우는 은닉 노드의 수는 결정이 되어 있어 특징 벡터의 차원은 고정되어 있으나 각 노드의 확장과 이동이 임의로 생성되기 때문에 특징 벡터의 순서를 결정하기가 어렵기 때문이다.

따라서 본 논문에서는 특징 벡터로 사용하기에 적합한 DWN과 성능이 가장 우수하게 나온 CWN을 결합한 형태인 CDWN(Continuous Discrete Wavelet Network)을 특징 추출 신경망으로 사용하기로 한다. CDWN은 은닉 노드의 초기화를 DWN의 방식으로 하고 각 은닉 노드의 확장과 이동 파라미터를 연결 강도와 함께 학습함으로써 DWN에서 은닉 노드의 개수 및 순서가 고정되어 연결강도를 특징으로 사용하기 적합하다는 장점과 CWN의 우수한 근사 성능을 모두 살릴 수 있다. CDWN의 학습 과정은 알고리즘6과 같다.

- Step1.** DWN과 동일하게 은닉 노드를 이진 방법에 의해 초기화, 연결강도 초기화
- Step2.** 학습 패턴 적용 및 출력 계산
- Step3.** 연결 강도 변화량 계산
- Step4.** 연결강도, 확장 및 이동 파라미터 갱신
- Step5.** 학습 종료조건을 만족하지 않으면 step2-step4 반복

알고리즘 6. CDWN의 학습 알고리즘

Algorithm 6. Learning Process of CDWN

표 1은 여러 가지 신호에 대한 각 모델별 근사 실험

의 일반화 에러를 나타낸 것이다. 사용된 모델은 DWN과 CWN은 69개의 은닉 노드를 사용하였으며 SGWNN은 학습에 의하여 은닉 노드 수를 결정하도록 하였다. 학습률은 모든 파라미터에 대하여 0.1로 하였으며 각 훈련 패턴에 대한 에러 제곱이 0.001이하 일때 학습을 종료하였다. 일반화 에러는 학습된 패턴과 학습되지 않은 패턴으로 구성된 테스트 집합에 대한 에러의 평균을 구한 것이다. CDWN의 일반화 에러를 살펴보면, 5주기 사인파를 제외한 나머지 신호에 대해서는 다른 모델 보다 뛰어난 성능을 보이고 있다.

표 1. 각 모델별 일반화 에러

Table 1. Generalized Error of Each Models.

신경망 모델	CWN	DWN	SGWNN	CDWN
5주기 사인파	0.000741	0.001294	0.000242	0.000547
10주기 사인파	0.001498	0.001529	0.001476	0.001182
15주기 사인파	0.000521	0.001402	0.000601	0.000137
가변주기사인	0.004688	0.009022	0.004822	0.004672
5주기 구형파	0.025903	0.040684	0.019023	0.020131
10주기 구형파	0.047028	0.062250	0.058999	0.045721

표 2는 각 모델별 학습 회수를 비교한 것인데, 가변주기 사인파를 제외한 모든 신호에서 매우 뛰어난 성능을 보이고 있다. 이렇게 뛰어난 학습 속도를 보이는 것은 은닉 노드의 초기값이 다른 모델에 비하여 균등하게 위치하고 있기 때문으로 생각된다.

표 2. 각 모델별 학습 회수

Table 2. Learning Iteration of Each Models.

신경망 모델	CWN	DWN	SGWNN	CDWN
5주기 사인파	73	5,000	1,388	7
10주기 사인파	59	5,000	1,632	11
15주기 사인파	64	5,000	2,210	18
가변주기 사인파	150	5,000	2,378	212
5주기 구형파	344	5,000	2,919	231
10주기 구형파	4,712	5,000	5,000	1,427

IV. 패턴 분류 웨이블릿 신경망

패턴을 분류하는 접근 방법으로는 Bayes 결정 이론

에 기반한 분류기와 같은 통계적인 방법, 마르코프 체인 모델과 같은 구문론적인 방법, 인공 신경망 모델을 이용한 방법 등이 사용되고 있다. 특히 인공 신경망을 이용한 패턴 분류기는 비교적 간단한 계산 요소들의 상호 연결을 통하여 구현되고, 구현이 상대적으로 용이 하며, 이론적으로 Bayes 분류기와 유사한 분류 성능을 가질 수 있어 새로운 분류기로서 활발히 연구되고 있다.

대표적인 인공 신경망 분류기로는 흡필드 네트워크 (Hopfield Network), 퍼셉트론 (Perceptron), 다층 퍼셉트론 (Multilayer Perceptron : MLP), 코호넨의 SOFM, 시간지연 신경망 (Time Delay Neural Network) 등이 있다. 본 논문에서는 웨이블릿 신경망을 패턴 분류에 적합하도록 수정하여 다층 퍼셉트론과 분류 성능을 비교한다.

웨이블릿 신경망의 초기 모델은 주로 1차원의 입력과 1차원의 출력을 가진 형태, 즉 1개의 입력 노드와 1개의 출력 노드를 가진 모델이 주를 이루었다. 이러한 모델은 함수의 근사나 비선형 시스템의 모델링 후에 제어에 매우 유용하게 응용되고 있다. 본 논문에서는 웨이블릿 신경망과 다층 퍼셉트론이 가지는 구조적인 유사점에 착안하여 다층 퍼셉트론이 패턴 분류를 위해 사용되었을 때와 유사한 구조를 갖는 웨이블릿 신경망 구조를 이용하여 웨이블릿 신경망을 패턴 분류 문제에 적용한다.

일반적으로 패턴 분류 문제는 M 개의 부류 $\omega_1, \omega_2, \dots, \omega_M$ 가 존재 할 때, 알려지지 않은 n 차원의 패턴 x ($x = [x_1, x_2, \dots, x_n]^T$)가 속하는 부류는 조건부 확률 $P(\omega_i | x)$, ($i = 1, 2, \dots, M$)을 최대로 하는 i 값을 찾아냄으로써 결정 할 수 있다. 이러한 확률을 사후확률(Posterior Probability)이라 한다. 그러나 대부분의 경우 사후확률은 직접적인 방법으로 구할 수가 없다. 따라서 이미 그 부류가 알려진 패턴 집합 X 를 이용하여 분류 오류가 가장 작도록 패턴 분류기를 구성하게 된다.

1. 패턴 분류 웨이블릿 신경망의 구조

패턴 분류를 위한 웨이블릿 신경망(PCWN)은 입력층(선형 노드)과 하나의 은닉층(웨이블릿 노드), 그리고 하나의 출력층(시그모이드 노드)의 3층 구조를 사용한다. 각 층간의 연결은 완전 연결을 사용하며, 은닉층과

출력층에서는 편향(bias)을 사용한다. M 개의 부류 $\omega_1, \omega_2, \dots, \omega_M$ 에 대한 n 차원의 입력 패턴 x 를 분류하기 위한 웨이블릿 신경망의 구조는 그림 4와 같다.

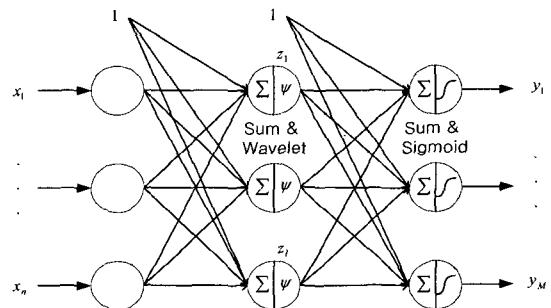


그림 4. 패턴 분류를 위한 웨이블릿 신경망의 구조
Fig. 4. Structure of Wavelet Network for Pattern Classification (PCWN).

그림 4에서 입력 $x = [x_1, x_2, \dots, x_n]^T$ 은 n 차원의 특징 벡터를 나타내며, $z = [z_1, z_2, \dots, z_l]^T$ 은 l 개의 은닉노드의 출력, $y = [y_1, y_2, \dots, y_M]^T$ 은 M 개의 부류에 포함 여부를 코딩한 값을 나타낸다. 그림 4 의 신경망 출력 수식은 (식 6)과 같다.

$$\begin{aligned} z_k &= \psi_{a_k, b_k} \left(\sum_{i=1}^n w_{ki} \cdot x_i \right) \\ y_j &= f \left(\sum_{k=0}^l w_{jk} \cdot z_k \right) \end{aligned} \quad (6)$$

이때, w_{ki} 는 은닉 노드 k 와 입력 노드 i 사이의 연결강도를 나타내며, w_{jk} 는 출력 노드 j 와 은닉 노드 k 사이의 연결 강도를, w_{j0} 은 출력 노드의 편향을 나타낸다. 은닉 노드에는 활성화 함수로 웨이블릿 함수를, 출력 노드의 활성화 함수는 시그모이드 함수를 사용하며, 시그모이드 함수는 (식 7)의 양극성 시그모이드 함수를 사용하고 웨이블릿 함수는 (식 8)의 시그모이드 함수로부터 유도된 함수를 사용한다.

$$f(x) = \frac{1 - \text{Exp}(-x)}{1 + \text{Exp}(-x)} \quad (7)$$

$$\psi_{a_k, b_k}(NET_{h_k}) = -\frac{1}{\sqrt{a_k}} (\text{temp}) \text{Exp}(-\text{temp}^2/2) \quad (8)$$

$$\text{temp} = \frac{NET_{h_k} - b_k}{a_k}$$

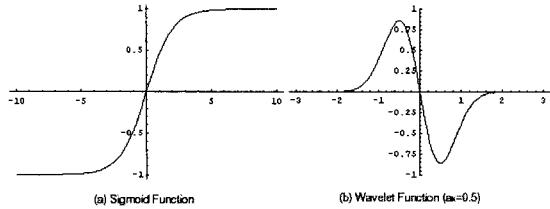


그림 5. 출력 노드 및 은닉 노드에서 사용된 활성화 함수

Fig. 5. Activation Functions of Output Node(a) and Hidden Node(b).

2. 패턴 분류 웨이블릿 신경망의 학습

패턴 분류 웨이블릿 신경망이 분류기로서 동작하기 위한 학습은 이미 부류가 알려진 패턴과 그에 대응하는 목표 출력값의 순서쌍으로 이루어진 훈련집합 $T = \{(x_p, \bar{y}_p) | p=1, 2, \dots, t\}$ 를 이용하여 LMS (Least Mean Square) 알고리즘을 적용한다. 학습 방법은 일반화된 델타 학습법을 사용하여 최급강하 학습 (Steepest Descent Method)을 하도록 한다.

신경망의 출력을 $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$, 목표 출력값을 $\bar{\mathbf{y}} = [\bar{y}_1, \bar{y}_2, \dots, \bar{y}_M]^T$ 라 할 때 최소화하는 목적 함수, 혹은 에너지 함수 E 는 (식 9)과 같다.

$$E = \frac{1}{2} (\bar{\mathbf{y}} - \mathbf{y})^2 = \frac{1}{2} \sum_{k=1}^M (\bar{y}_k - y_k)^2 \quad (9)$$

Step1. 은닉 노드의 수 결정

v_{ki}, w_{jk}, a_k 초기화

학습률 a_w, a_a 결정

Step2. 훈련 집합 $T = \{(x_p, \bar{y}_p) | p=1, 2, \dots, t\}$ 의 모든 패턴에 대하여

Step3. 신경망의 출력 계산

Step4. 파라미터 갱신량 계산

Step5. 각 파라미터 갱신

Step6. 모든 훈련 패턴에 대하여 에너지

함수 E 가 충분히 작으면 학습 종료

그렇지 않다면 Step2부터 반복

알고리즘 6. 패턴 분류 신경망의 학습 과정

Algorithm 6. Learning Process of Pattern Classification Wavelet Network

학습되는 파라미터는 입력층과 은닉층 사이의 연결 강도 v_{ki} , 은닉층과 출력층 사이의 연결강도 w_{jk} , 은닉

층 웨이블릿 함수의 확장 파라미터 a_k 이다. 패턴 분류 웨이블릿 신경망의 전체 학습 알고리즘은 알고리즘 6와 같다.

V. 실험 및 결과

신호 분류 시스템의 성능을 평가하기 위하여 사인파와 구형파를 분류하는 문제, 사인파의 주기에 따른 부류를 분리하는 문제에 대하여 실험을 수행하였다. 특징 추출 웨이블릿 신경망은 CDWN을 사용하고, 패턴 분류 신경망은 PCWN과 MLP모델을 사용하여 두 모델을 비교 평가한다.

사인파와 구형파를 구분하는 실험에서 첫 번째 부류인 사인파는 5주기, 10주기, 15주기의 사인파를 위상변화를 주어 각각 10개의 신호로 구성되었고, 두 번째 부류인 구형파는 5주기, 10주기 구형파를 위상변화를 주어 각각 10개의 신호로 구성되었다. 신호 분류 시스템의 훈련을 위해 첫 번째 부류에서 15개의 신호를 임의로 선택하였고, 두 번째의 부류에서 10개의 신호를 임의로 선택하여 훈련 집합을 구성하였다. 훈련에 사용하지 않은 신호 25개와 훈련에 사용된 신호 25개를 합하여 테스트 패턴을 구성하였다. 각 신호는 125Hz로 샘플링하였다.

특징 추출에 사용된 CDWN의 은닉 노드는 69개를 사용하였고, 학습률은 0.1 최대 반복 학습 회수는 5,000회로 제한하였다. 패턴 분류에 사용된 MLP와 PCWN은 모두 10개의 은닉 노드를 가지며 0.1의 학습률을 사용하였고, 연결강도의 초기값은 -0.5에서 0.5 사이의 임의의 값으로 하였다.

학습 결과 패턴 분류 신경망으로 PCWN을 사용한 신호 분류 시스템은 1,214회 학습만에 수렴하였고, 학습된 신호 50%와 학습되지 않은 신호 50%로 구성된 50개의 테스트 신호에 대하여 오분류 신호 0개로 100% 인식률을 보였다. MLP를 분류기로서 사용한 신호 분류 시스템은 153회 학습만에 수렴하였고 동일한 테스트 신호에 대하여 오분류 신호 0개로 100% 인식률을 보였다.

주파수가 다른 사인파를 3개의 부류로 나누어 분류하는 실험에서 3개의 부류는 각각 5주기 사인파, 10주기 사인파, 15주기 사인파를 위상 변화를 주어 10개의 신호로 구성하였다. 총 30개의 신호 중, 각 부류에서 임의로 5개의 신호를 선택하여 총 15개의 훈련 집합을 구성하였고, 테스트 집합은 훈련된 신호 15개와 훈련되

지 않은 신호 15개를 합하여 총 30개의 신호를 사용하였다.

특정 추출에 사용된 CDWN은 이전 실험과 동일한 조건을 사용하였으며, 패턴 분류에 사용된 MLP와 PCWN은 모두 5개의 은닉 노드를 가지며 0.1의 학습률을 사용하였고, 연결강도의 초기값은 -0.5에서 0.5 사이의 임의의 값으로 하였다.

학습 결과 패턴 분류 신경망으로 PCWN을 사용한 신호 분류 시스템은 평균 2,531회 학습만에 수렴하였고, 학습된 신호 50%와 학습되지 않은 신호 50%로 구성된 30개의 테스트 신호에 대하여 오분류 신호 평균 4개로 87%의 인식률을 보였다. MLP를 분류기로서 사용한 신호 분류 시스템은 평균 2,773회 학습만에 수렴하였고 동일한 테스트 신호에 대하여 오분류 신호 평균 3개로 90% 인식률을 보였다. 주기가 다양한 부류의 분류 문제에서는 비교적 오분류율이 높게 나타나는데 이는 훈련패턴이 비교적 적기 때문에 훈련패턴을 어떻게 선택하는가에 따라 패턴 분류 신경망이 신호의 주파수 특징보다는 신호의 위상의 특징을 학습하기 때문에 생각된다. 분류 성능이 가장 좋은 경우는 PCWN과 MLP를 사용한 시스템 모두 1개의 신호를 오분류하여 3%의 오분류율을 보였다.

VI. EEG 신호 분류

실험의 대상이 되는 EEG신호는 하나의학사의 '뇌파학 입문'^[8]에 수록된 파형을 수집하여 사용하였다. α 파는 정상인의 각성, 안정, 폐안 상태의 뇌파와 57세 남자의 diffuse α 파, 파킨스씨 질환을 앓고 있는 64세 여성의 뇌파에서, Olivopontocerebellar degeneration을 앓고 있는 47세 여성의 뇌파 등에서 수집하였고 β 파는 정상 성인의 개안 상태에서의 뇌파에서 수집하였다. δ 및 θ 파는 Liver cirrhosis 증세가 있는 52세 여성의 뇌파 및 Lung carcinoma의 brain metastasis 증세가 있는 50세 남성의 뇌파에서 수집하였다.

뇌파는 12 전극법에 의해 각 채널 별로 측정되었으며, 데이터 변환을 통해 250Hz로 샘플링하였다. 진폭은 최대 $300\mu V$ 로 측정하여 $200\mu V$ 가 1의 값을 갖도록 조정하였으며, 신호의 평균값을 0이 되도록 표준화하여 사용한다. 수집된 데이터는 α 파 456초, 서파 240초, 속파 52초로 구성되어 있다. 수집된 데이터 중 α 파의 대표적인 파형은 그림 6과 같다. 그림에서 신호의 길이는 8초이며 진폭은 최대 값이 약 $40\mu V$ 이다.

적인 파형은 그림 6과 같다. 그림에서 신호의 길이는 8초이며 진폭은 최대 값이 약 $40\mu V$ 이다.

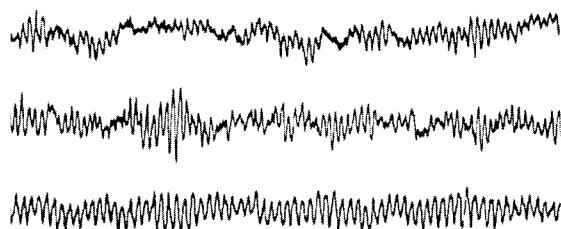


그림 6. α 파의 대표적인 파형

Fig. 6. Typical α wave.

그림 7은 수집된 데이터 중 속파를 포함한 신호이다. 역시 신호의 길이는 8초이며, 최대 진폭은 약 $40\mu V$ 이다. 그림의 신호 중 초반 2초구간은 α 파로, 중반 4초구간은 속파로, 후반 2초는 다시 α 파로 구분하였다.

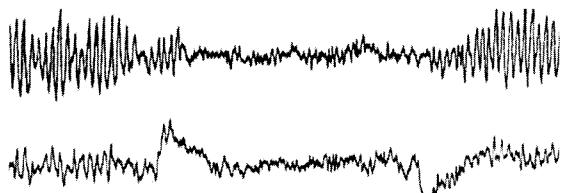


그림 7. 속파의 대표적인 파형

Fig. 7. Typical fast wave.

그림 8은 수집 된 데이터 중 서파 신호이다. 신호의 길이는 8초이며, 최대 진폭은 약 $240\mu V$ 이다.

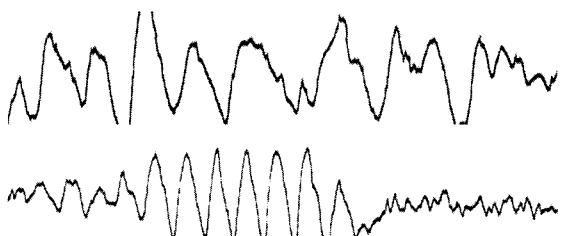


그림 8. 서파의 대표적인 파형

Fig. 8. Typical slow wave.

제안한 신경망 신호 분류 시스템의 성능을 평가하기 위하여 수집한 뇌파 신호에 대하여 α 파, 속파(β 파), 서파(θ 파, δ 파)로 구분하는 실험을 수행하였다. 실험에 사용한 신호 분류 시스템은 CDWN을 신호의 특징 추출기로써 사용하였고, 분류기로는 MLP와 PCWN을 사

표 3. EEG 신호 분류 실험 결과
Table 3. Simulation Result of EEG Signal Classification.

분류기의 종류	MLP를 사용한 시스템			PCWN을 사용한 시스템		
	온녁 노드 수	20	30	50	20	30
학습회수	13,610	16,000	20,000	20,000	20,000	20,000
오분류 신호	171	190	180	172	186	173
α파를 오분류	81	88	85	80	86	77
α파를 속파로 오분류	29	30	28	33	24	30
α파를 서파로 오분류	39	37	37	27	32	40
속파 오분류	17	20	20	21	21	22
속파를 α파로 오분류	10	14	13	10	14	16
속파를 서파로 오분류	5	5	5	8	7	5
서파 오분류	73	80	75	71	79	74
서파를 α파로 오분류	41	40	35	41	24	45
서파를 속파로 오분류	22	28	24	17	20	19

용한 두 가지 시스템을 사용하였다.

신호 분류 시스템의 입력은 250Hz로 챔플링 된 뇌파 신호 1초구간을 125Hz로 다운 챔플링하여 입력신호를 구성하고, 실험 데이터를 수집한 하나의 학사의 '뇌파학 입문'에 의거하여 α , 속파, 서파의 구분을 코드화 하여 교사신호로 사용하였다. 훈련 데이터는 α 파 228개 (228초구간), 속파 128개 (32초구간을 4회 반복 사용), 서파 120개 (120초구간)으로 구성하였다. 테스트 데이터는 훈련에 사용된 α 파 228초구간과 훈련에 사용되지 않은 32초구간과 훈련에 사용되지 않은 20초구간을 합하여 총 52초, 서파는 훈련에 사용된 120초구간과 훈련에 사용되지 않은 120초구간을 합하여 총 240초로 구성하여 전체 사용된 신호는 748초구간의 뇌파로 구성하였다. 따라서 테스트 데이터는 훈련된 데이터 51%와 훈련되지 않은 데이터 49%로 구성되어 있다.

CDWN의 온녁층은 6개의 resolution으로 구성하여 총 69개의 온녁노드를 사용하여, CDWN의 구조는 $1 \times 69 \times 1$ 로 하였다. 온녁노드와 출력노드 사이의 연결강도를 조정하기 위한 학습률은 0.1을, 온녁 노드의 dilation을 조정하기 위한 학습률은 0.5를 사용하였고, 최대 허용에러는 0.001, 최대 반복 학습 회수는 각 신호마다 5,000회로 하였다.

패턴 분류기로는 오류역전파 알고리즘을 사용하는 일반적인 MLP와 본 연구에서 제안한 PCWN 두 가지

모델을 모두 실험하였다. MLP와 PCWN 모두 입력 노드는 69개이며 출력 노드는 3개이다. 온녁노드는 20개, 30개, 50개에 대하여 실험하였고, 각 노드의 연결강도를 조정하는 학습률은 0.05로 하였다. 표3은 두 모델에 대한 EEG신호 분류 실험 결과이다.

CDWN과 MLP를 이용한 신호 분류 시스템에서 온녁 노드의 수 20개, 학습률 0.05를 사용한 모델의 경우, 13,610회의 학습만에 수렴하였고 α 파는 81개의 신호를 오분류하여 82.3%의 인식률을 보였으며, 속파는 17개를 오분류하여 67.4%의 인식률을 보였다. 서파의 경우 73개를 오분류하여 69.6%의 인식률을 보였다. 전체적으로는 748개의 데이터 중에서 171개의 신호를 오분류하여 77.1%의 인식률을 보였다.

CDWN과 PCWN을 이용한 신호 분류 시스템에서 온녁 노드의 수 20개, 학습률 0.05를 사용한 모델의 경우, 20,000회의 학습만에 수렴하지 못하였고, α 파는 80개의 신호를 오분류하여 82.4%의 인식률을 보였으며, 속파는 21개를 오분류하여 59.6%의 인식률을 보였다. 서파의 경우 71개를 오분류하여 70.4%의 인식률을 보였다. 전체적으로는 748개의 데이터 중에서 172개의 신호를 오분류하여 77%의 인식률을 보였다.

오분류된 신호를 분석해 보면 α 파와 속파의 경계에서 오분류된 신호가 전체 오분류 신호의 23.4%, α 파와 서파의 경계에서 오분류된 신호가 40.8%를 차지하고 있었다. 이에 반해 서파를 속파로 오분류하거나 속파

를 서파로 오분류 한 경우는 15.3%를 차지하고 있었다. 이는 주파수에 따른 뇌파의 분류가 명확한 경계를 가지고 있지 않기 때문에 학습 패턴의 교사 신호의 오류에 기인한 것으로 생각된다.

VII. 결 론

본 논문에서는 웨이블릿 신경망을 이용하여 디지털 신호에 대한 특징 추출 및 패턴 분류 신경망 모델을 제안하여 신경망 신호 분류 시스템을 구성하였다. 특징 추출 신경망은 기존의 웨이블릿 신경망 모델 중에서 기존의 웨이블릿 신경망 모델의 근사 성능 및 특징 추출기로서의 특징을 고려하였다. 실험 결과 DWN은 특징 추출기로서는 좋은 특성을 가지고 있으나, 근사 성능이 좋지 않았고, CWN과 SGWNN은 근사 성능은 좋지만 특징 추출기로 사용하기 힘들다는 단점을 가지고 있었다. 따라서 본 논문에서는 고정된 은닉 노드의 수를 가진 DWN의 특징과 뛰어난 근사 성능을 가진 CWN의 특징을 결합한 CDWN을 제안하여 특징 추출 기로 사용하였고, 패턴분류 신경망은 기존의 웨이블릿 신경망을 패턴 분류에 적합하도록 구조를 재구성하였다. 신호 분류 성능을 평가하기 위해 사인파와 구형파를 구분하는 실험에서는 100%의 분류 성능을 보였고, 주파수가 다른 사인파의 분류 실험에서는 평균 87%의 분류율을, 최고 97%의 분류 성능을 보였다. 제안한 신경망 신호 분류 시스템의 유용성을 검증하기 위하여 EEG 신호의 주파수의 특성에 따라 α 파, 속파, 서파로 구분하는 실험을 수행하였다. 실험 결과 MLP를 이용한 신호 분류 시스템은 평균 75.8%의 분류율을 보였고 PCWN을 이용한 신호 분류 시스템은 76.3%의 분류율을 보였다. 제안한 신호 분류 시스템을 실제 문제에 적용한 EEG 분류 문제의 경우 분류율이 예상보다 적게 나타났는데, 이는 EEG 파형을 편의상 주파수별로 구분하기는 하지만 실제의 데이터는 여러 주파수가 혼재하여 구분이 명확하지 않기 때문이라고 생각된다.

본 논문에서 제안한 신호 분류 시스템을 보다 실용적인 분야에 적용하기 위해서는 보다 많은 임상 데이-

터와 전문의의 의견을 참고한 훈련 집합을 이용하여 시스템을 학습시키는 연구가 필요하다. 또한 패턴 분류를 위한 웨이블릿 신경망의 동작 특성을 보다 명확하게 분석하고 기존의 MLP를 이용한 방법과 비교하여 패턴 분류기의 성능을 높이는 연구가 필요하다.

참 고 문 현

- [1] Ingrid Daubechies, "Orthonormal bases of compactly supported wavelets", *Communications on Pure and Applied Mathematics*, 41:909~996, November 1988.
- [2] H.Suz, B.Telfer, S.Kadambe, "Neural Network Adaptive Wavelets for Signal Representation and Classification", *Optical Engineering*, Vol. 31, pp. 1907~1916, 1992.
- [3] Q. Zhang, A. Benveniste, "Wavelet Networks", *IEEE Trans. Neural Networks*, Vol. NN-3, No 6, pp. 889~898, 1992.
- [4] B. Bakshi, G. Stephanopoulos, "Wavelets as Basis Functions for Localized Learning in a Multi-resolution Hierarchy", *IJCNN 92*, Vol 2, pp. 140~145, 1992.
- [5] Y.C. Pati and P.S. Krishnaprasad, "Analysis and Synthesis of Feedforward Neural Networks Using Discrete Affine Wavelet Transformations", *IEEE Trans. Neural Networks*, 4, (1), pp. 73~85, 1993.
- [6] K.Kobayashi, T. Torioka, "A Wavelet Neural Network for Function Approximation and Network Optimization", *Proc. of ANNIE 94*, Vol 4, pp. 505~510, 1994.
- [7] 임성길, 이현수, "은닉노드의 생성 소멸에 의한 웨이블릿 신경망 구조의 자기조직화", 전자공학회 논문지 제36권 C편 제12호, pp.78~89, 1999
- [8] 이창변, 노재영, 뇌파학입문, 하나의학사, 1997

저자소개

林 成 吉(正會員) 第36卷 C編 第12號 參照

1997년 경희대학교 수학과 졸업(이학사), 1999년 경희대학교 전자계산공학과 대학원 석사과정 졸업(공학석사), 1999년 - 현재 경희대학교 전자계산공학과 박사과정, <주관심분야 : 신경회로망, 패턴인식, 신호처리, Auditory Scene Analysis 등임>

李 顯 洊(正會員) 第33卷 B編 第10號 參照

1979년 경희대학교 전자공학과 졸업(공학학사), 1982년 일본 경응의숙대학 전기공학과 석사과정 졸업(공학석사), 1985년 일본 경응의숙대학 전기공학과 박사과정 졸업(공학박사), 1985년 - 현재 경희대학교 전자계산공학과 교수, <주관심분야 : Parallel Processing, VLSI architecture 설계 및 신경망 컴퓨터 등임>

朴 賢 虎(正會員) 第33卷 B編 第10號 參照

1991년 경희대학교 전자계산공학과 졸업(공학석사), 1993년 경희대학교 전자계산공학과 대학원 석사과정 졸업(공학석사), 1998년 경희대학원 전자계산공학과 대학원 박사과정 졸업(공학박사), 2000년 - 현재 부천대학 인터넷 응용과 전임강사, <주관심분야 : 신경회로망, 패턴인식, 컴퓨터구조, 병렬처리 등임>