

論文98-35S-2-8

웨이브렛과 신경 회로망을 이용한 EEG의 간질 파형 검출

(Detection of Epileptiform Activities in the EEG using Wavelet and Neural Network)

朴鉉錫 * , 李斗秀 * , 金先一 **

(Hyun-Seok Park, Doo-Soo Lee, and Sun-Il Kim)

요약

본 논문은 간질 진단을 위한 장시간 EEG 모니터링에 필요한 극파(Spike) 검출 알고리듬을 제안한다. 이 방법은 웨이브렛 전처리와 신경 회로망 그리고 전문가 시스템의 3단계로 구성된다. 먼저 간질 활동 파형과 정상 활동 파형으로 분류된 EEG의 세그먼트(segment)는 신경망의 입력노드를 줄이기 위해 다해상도 웨이브렛을 전개한다. 그리고 각 웨이브렛 레벨에서 단 채널 EEG 파형에 관한 중요 파라메터를 추출하게 된다. 또한 극파 발생 전과 발생 시의 파워비와 변이비가 부가 파라메타로 추가된다. 다음으로 앞 단계에서 구한 파라메타를 이용하여 역전파 학습 알고리듬을 적용한 신경 회로망의 학습과 테스트를 거친다. 실제 임상 적용에서, 학습된 단채널 신경망의 출력을 바탕으로 인접 채널들과의 문맥적 정보를 이용하는 전문가 시스템을 도입한다.

본 연구에서는 전체 32명의 환자로부터 EEG(간질환자: 12, 정상환자: 20)를 측정하고 2명의 판독사의 동의에 의한 간질 활동 파형과 정상 활동 파형으로 분류한 후 제시한 방법을 적용하였다. 결과적으로 웨이브렛 전처리는 신경망의 입력 노드를 줄일 수 있었고, 전처리를 통한 신경망은 원래 데이터의 같은 입력 개수로 학습된 신경망보다 높은 정확도를 나타내었다. 임상 적용에서 전문가 시스템은 EEG 기록에서 흔히 발생하는 아티펙트를 제거할 수 있었다.

Abstract

Spike detection in long-term EEG monitoring for epilepsy by wavelet transform(WT), artificial neural network(ANN) and the expert system is presented. First, a small set of wavelet coefficients is used to represent the characteristics of a single channel epileptic spikes and normal activities. In this stage, two parameters are also extracted from the relation between EEG activities before the spike event and EEG activities with the spike. Then, three-layer feed-forward network employing the error back propagation algorithm is trained and tested using parameters obtained from the first stage. Spikes are identified in individual EEG channels by 16 identical neural networks. Finally, 16-channel expert system based on the context information of adjacent channels is introduced to yield more reliable results and reject artifacts. In this study, epileptic spikes and normal activities are selected from 32 patient's EEG in consensus among experts. The result showed that the WT reduced data input size and the preprocessed ANN had more accuracy than that of ANN with the same input size of raw data. In a clinical test, our expert rule system was capable of rejecting artifacts commonly found in EEG recordings.

* 正會員, 漢陽大學校 工科大學 電子工學科
(Dept. of Elec. Eng., Hanyang University)

** 正會員, 漢陽大學校 醫科大學 醫用生體工學科
(Dept. of Biomedical Engineering, Hanyang

University)

※ 이 논문은 1997학년도 한양대학교 교내연구비에 의하여 연구되었음.

接受日字: 1997年10月9日, 수정완료일: 1998年1月12日

I. 서 론

EEG(electroencephalogram)는 대뇌 피질의 전기적 활동을 기록한 것으로 뇌의 기능 및 뇌와 관련된 질병을 진단하는데 광범위하게 사용된다. 특히 간질환자의 경우 발작유무 추정, 발생부위 진단, 치료효과 판단 등을 모니터링하는데 아주 중요한 임상적 방법이다^[1]. 간질은 신경세포의 일부가 짧은 시간동안 과도한 전기를 발생시킴으로써 일어나는 신경계의 발작적 증상으로 국부적 또는 전역적으로 발생할 수 있다. 이러한 환자의 EEG 특성은 배경 활동 파형과 구별되는 극파(spike), 예파(sharp) 그리고 예파와 서파를 동반한 복합파(sharp and slow complexes)로 대표된다^[1,2,3]. 장시간의 EEG 기록상에서 직접 눈으로 이러한 간질 파형들을 찾아낸다는 것은 전문적 지식이 요구될 뿐만 아니라 시간이 많이 소요되는 단순 반복적 작업이다. 또한, 해석의 주관적 판단으로 인하여 같은 EEG 기록에 대한 의견 불일치가 가능하다. 따라서 컴퓨터를 이용한 간질파형의 자동검출은 객관성을 높이고 정량적 해석을 위하여 필수적인 것이다^[2,3].

지난 몇십년 동안 간질 활동 파형의 자동 검출은 많은 진전이 있어 왔다. 몇 가지 컴퓨터 알고리듬과 프로그램이 개발되었는데 Gotman이 제안한 모방적 방법(mimetic method)이 주로 사용되었다^[2,3,4]. 이 방법은 극파 검출을 위해 먼저 해석하고자하는 파형을 세그먼트하여 반파(half wave)로 구성한 다음 지속시간(duration), 진폭(amplitude), 기울기(slope), 날카로움(sharpness) 등과 같은 파라메타들을 구하고 각 파라메타는 배경 파형의 파라메타와 비교되었다. 이 방법은 아티팩트/artifact)가 없는 경우 좋은 검출 성능을 나타내었으나 근전도(electromyogram : EMG)나 여러 다른 아티팩트가 섞인 파형에 있어서 성능이 저하되는 단점을 가지고 있었다. 또 다른 접근 방식으로 전문가 시스템을 사용한 인공 지능(artificial intelligence) 접근 방법이 이러한 문제점들을 해결하기 위해 도입되었다^[5,6]. 결과적으로 문제점들에 대해 부분적인 해결책은 되었으나 규칙의 증가와 큰 메모리와 많은 처리능력을 가진 컴퓨터를 필요로 하여 임상에서의 적용에는 장애가 되었다. 최근에는 신경 회로망을 이용하여 EEG 극파을 검출하는 많은 연구가 진행되어왔다^[7,8,9]. 인공 신경망은 규칙을 완전히 수식화 할 수 없는 인식과 분류작업에 해결책을 제시하고

출력 문턱치(threshold)를 조절함으로서 각각의 임상 요구를 만족시킬 수 있었다^[7]. 그러나 다양한 학습 샘플을 필요로 하고 여러 아티팩트의 제거를 위한 문맥적 정보를 위하여 큰 크기의 윈도우를 써운 많은 입력 데이터를 필요로 하여 실제 시스템에서는 비현실적인 단점을 갖고 있었다^[9]. 최근에는 웨이브렛 해석이 EEG에 적용되었고 신경망의 입력노드를 줄이기 위하여 신호의 정보를 감소시키지 않고 검출성능도 떨어뜨리지도 않는 방법으로 도입되었다^[10,11]. 그러나 이 연구는 EEG의 극파검출을 위하여 신경망의 단순한 전처리로서 웨이브렛 변환의 유용성을 검토하는 것에 지나지 않았다^[11]. 그리고 학습된 신경망의 실제적인 임상 데이터에 적용되지 않은 단점을 가지고 있었다.

본 논문에서는 32명의 환자로부터 다양한 학습 샘플을 구하고 이 샘플들은 신경망의 입력 노드를 줄이고 아티팩트 영향을 줄인 효과적 검출을 위해 웨이브렛 변환이 적용된다. 그리고 학습된 신경망의 출력을 이용한 전문가 시스템을 도입한다.

웨이브렛은 시간-주파수영역 해석법으로 다변적인 신호의 처리에 효과적이며 본 연구에서는 정상 활동 파형 및 간질 파형으로부터 파라메타의 추출에 이용된다. 그리고 부가 파라메타로서 극파발생시와 극파발생전의 파워비와 변이비가 추가된다. 이것은 일반적으로 극파가 발생했을 때 파워와 진폭이 증가한다는 것에 기초한 것이다^[1,12]. 이렇게 추출된 파라메타는 신경망에 적용되어 학습과 테스트를 하고 기준의 같은 입력 노드의 실제 데이터를 이용한 신경망과 비교되어 그 성능이 우수함을 보인다. 또한, 전처리 신경망을 통하여 얻어진 단채널 검출 결과를 바탕으로 한 전문가 시스템을 실제 간질 환자의 EEG 데이터에 적용하여 유용성을 입증한다. 임상에서의 판독 방법에 기초한 이 전문가 시스템은 주위 인접한 채널의 문맥 정보를 바탕으로 일부 아티팩트를 제거하여 자동검출의 정확도를 높이고 발작이 일어난 부위를 추정하는데 이용된다.

II. EEG에서의 극파

EEG 극파(spike)는 뾰족한 피크(peak)와 20~70ms의 지속시간을 가진 배경파형과 명확히 구분되는 일시적 파형으로 정의하고 있다^[12]. 극파는 독립적으로 일어날수도 있지만 종종 150~300ms 지속되는 서

파(slow wave)가 동반하여 극파와 예파의 복합파(Spike and Slow Wave Complex)를 형성한다. 극파와 복합파는 일반적 EEG 배경 활동으로부터 뚜렷이 구분된다. 또한, 극파는 아티펙트와 혼돈되는 경우가 많아 주위 인접 채널과의 비교 및 판독사의 경험을 토대로한 판독이 필수적이다. 그림 1과 그림 2는 EEG의 4가지 기본 활동 파형과 간질파형의 형태를 보여준다.

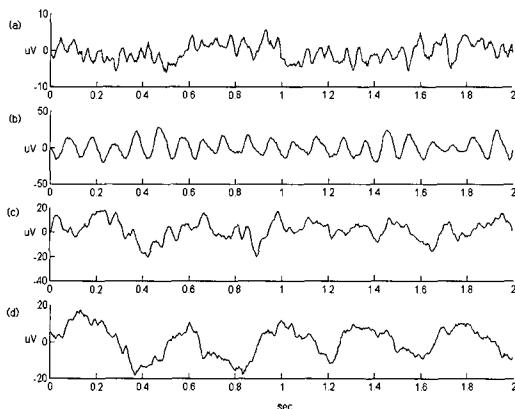


그림 1. EEG의 기본 파형 (a) 베타파 (b) 알파파 (c) 세타파 (d) 델타파

Fig. 1. Basic waveforms of EEG. (a) beta (b) alpha (c) theta (d) delta

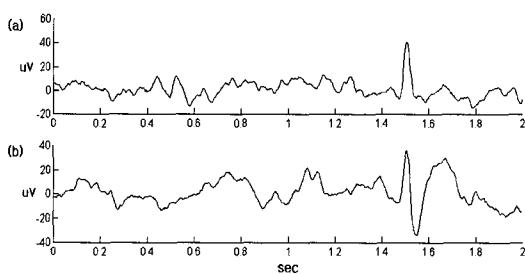


그림 2. 간질 활동 파형 (a) 극파와 복합파 (b) 극파

Fig. 2. Epileptiform activities. (a) spike and wave complexes (b) spike

III. 웨이브렛 변환

웨이브렛 변환(wavelet transform)은 생체신호와 같은 비안정적 신호(nonstationary signal)의 해석에 많이 이용되고 있다^[13,14,15]. 초기의 이산 연속 웨이브렛 변환(discretized continuous wavlet transform:

DCWT)이 컴퓨터를 이용한 연속 웨이브렛 변환(continuous wavelet transform : CWT)의 계산을 가능하게 하였지만, 이것은 단순히 CWT이 샘플링 된 것이고 신호의 복원관점에서 제공되는 임의 정보로 계산 시간을 상당히 증가시켰다. 여기서 충분한 정보 제공, 계산 시간 감소 및 신호의 복원과 실용적 응용에서의 서브밴드코딩을 이용한 다해상도 웨이브렛 변환에 발전하게 되었다^[14,15].

다해상도 웨이브렛 변환은 각 스케일에서 다른 차단주파수의 필터를 사용하여 신호를 해석한다. 고주파 신호를 해석하기 위하여 고역통과필터를 통과시키고 저주파 신호를 해석하기 위하여 저역통과필터를 통과시킨다. 신호의 정보양의 척도인 신호의 해상도는 필터 연산에 의해 변화되고 스케일은 업 샘플링(upsampling)과 다운 샘플링(downsampling) 연산에 의해 변화된다. 결과적으로, 저역통과필터는 해상도를 반으로 낮추고 스케일을 변화시키지 않는다. 그리고 신호는 반으로 다운샘플링된다. 원래 신호 $x[n]$ 은 먼저 반대역 고역통과필터인 $g[n]$ 과 저역통과 필터인 $h[n]$ 을 통과시킨다. 필터링 후 현재의 신호는 최고주파수가 π 대신에 $\pi/2^0$ 이기 때문에 나이퀴스트 법칙에 의하여 샘플의 반은 제거될 수 있다. 한 레벨의 분해는 식 (1)과 같이 표현될 수 있다.

$$\begin{aligned} y_{high}[k] &= \sum_n x[n] \cdot g[2k-n] \\ y_{low}[k] &= \sum_n x[n] \cdot h[2k-n] \end{aligned} \quad (1)$$

여기서 $y_{high}[k]$ 와 $y_{low}[k]$ 는 필터링후 다운 샘플링의 결과를 나타낸다.

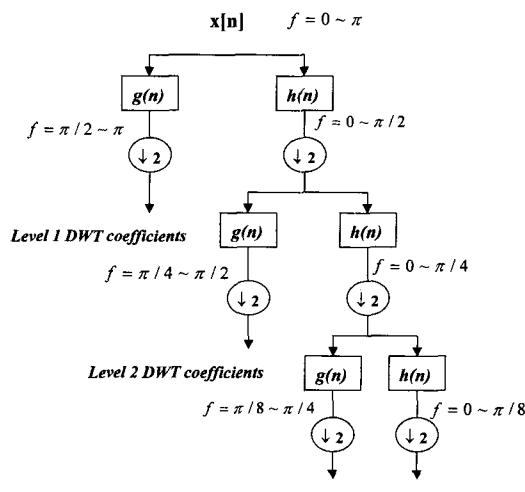


그림 3. 서브밴드 코딩

Fig. 3. Subband coding.

서버밴드 코딩으로 알려진 위의 과정은 계속 전개 시킬 수 있다. 그림 3은 이 과정을 나타낸다. $x[n]$ 은 해석될 신호를 나타내고 $h[n]$ 과 $g[n]$ 은 각각 모 웨이브렛(mother wavelet) 계수로부터의 저역통과 필터와 고역통과필터를 각각 나타낸다. 각 레벨에서 신호의 주파수 대역은 그림에서 f 로서 나타내었다.

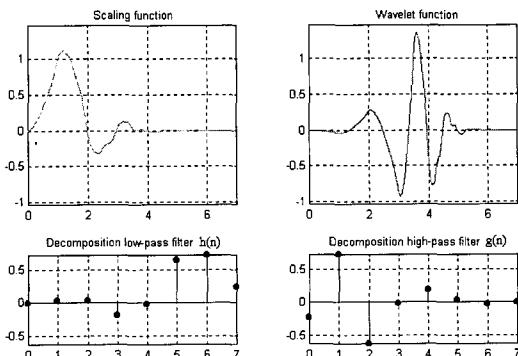


그림 4. Daubechies 8 탭 웨이브렛

Fig. 4. Daubechies 8-tab wavelet.

$h[n]$ 과 $g[n]$ 은 식 (2)과 같은 교체 플립(alternating flip)관계를 만족시켜 QMF(quadrature mirror filter)쌍을 구성하게 된다^[14].

$$g[k] = (-1)^{k+1} h[N-k-1] \quad 1 \leq k \leq N \quad (2)$$

여기서 N 은 모 웨이브렛의 탭(tab) 개수를 나타낸다. 식 (1)과 (2)에서 알 수 있듯이 신호는 각 함수들의 계수에 의하여 주파수 분할이 이루어지기 때문에 해석 신호의 특성을 고려한 모 웨이브렛의 선택이 중요하다. 본 연구에서는 기존의 모 웨이브렛 중에서 시간 영역 및 주파수영역에서의 특성이 우수한 것으로 알려진 다비치(daubechies) 웨이브렛을 적용하였다. 그림 4는 본 연구에서 사용한 다비치 8-탭 웨이브렛 함수를 나타내고 그림 5은 극파를 중앙에 위치시킨 2초간 데이터(512포인터)의 다비치 8-탭을 적용하여 6레벨 웨이브렛 전개를 나타낸 것이다. 그림 5에서와 같이 간질 파형에서 임상적으로 중요한 정보는 웨이브렛 전개시 레벨 2, 3, 4의 웨이브렛 계수 부분에서 가장 뚜렷이 나타남을 볼 수 있다. 이것은 256 샘플링 데이터의 경우 대략 8~32Hz 대역으로 간질 파형의 주 분포구간이 된다. 따라서 간질 활동 파형의 데이터는 이러한 극파를 해석 원도우 상의 중앙에 위치시킨 데이터를 웨이브렛 전개하고 각 레벨마다 중앙으로부

터의 데이터를 선택한다. 이렇게 계수를 선택함으로서 극파발생시의 주위 인접 문맥적 정보를 포함하여 다른 아티펙트성분과 구별한다. 그리고 선택된 데이터 이외에 극파발생시와 극파 발생 이전의 세그먼트와의 파워비와 변이비가 추가되어 신경 회로망에 적용된다.

IV. 신경 회로망과 전문가 시스템

1. 역전파 학습 신경망 모델

신경망은 규칙을 완전히 수식화 할 수 없는 인식과 분류작업에 광범위하게 사용되어왔다. 본 논문에서는 일반적인 역전파(back propagation : BP) 학습 신경망을 이용하였다. 이 학습 신경망은 입력과 출력층 사이에 몇 개의 중간층을 가지고 있는 구조를 이루며 입력과 출력 사이의 오차를 최소로 하는 델타 학습법(delta learning)을 통해 각 층 사이의 가중값을 조정해 가는 방식이다.

델타 학습법은 1986년 T. McClelland와 D. Rumelhart가 제안한 학습 방법으로 연속활성화 함수(continuous activation function)만을 사용한다^[16]. 이 학습법은 학습 신호로서 목표치 d 와 실제 출력 y 의 차이뿐만 아니라 활성화 함수의 미분값이 사용되는 점이 특징이다. 따라서, 학습 신호 γ 은 다음과 같이 구할 수 있다.

$$\gamma = (d - y) f'(\text{NET}) \quad (3)$$

k 단계에서의 가중치 변화량 Δw^k 는 식 (4)에 의해,

$$\begin{aligned} \Delta w^k &= \alpha \gamma x \\ &= \alpha(d - y^k) f'(\text{NET}^k)x \\ &= \alpha[(d - f(\text{NET}^k)) f'(\text{NET}^k)x \end{aligned} \quad (4)$$

따라서, $k+1$ 단계의 가중치 w^{k+1} 은 다음과 같다.

$$\begin{aligned} w^{k+1} &= w^k + \Delta w^k \\ &= w^k + \alpha(d - y^k) f'(\text{NET}^k)x \end{aligned} \quad (5)$$

이와 같이 학습이 충분히 끝났을 때, 가중값들은 입력값을 해당하는 출력으로 사상시킬 수 있게 조정된 값을 갖는다. 그림 6은 하나의 은닉층을 가진 BP 신경망 모델의 블록 다이어그램을 나타낸 것이다.

웨이브렛 전처리를 통하여 얻어진 각 스케일에서의

파라메타와 극파발생시와 발생전의 파워비와 변이비로 구성된 파라메타는 간질활동파형의 입력일 경우 출력을 1로하고 정상활동 파형일 경우 출력을 0으로하여 평균자승 에러가 0.05이하가 될 때까지 역전파 알고리듬을 통하여 학습하게된다. 활성함수로는 시그모이드(sigmoid)함수를 사용한다.

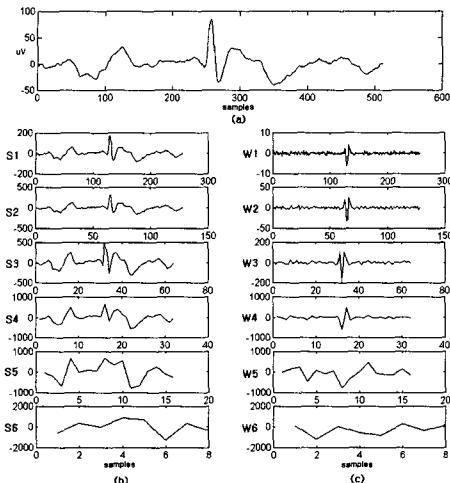


그림 5. 간질파형의 웨이브렛 전개(a) 원 신호 (b) 스케일링 계수 (c) 웨이브렛 계수

Fig. 5. Wavelet representation of epileptiform activities. (a) original signal (b) scaling coefficient (c) wavelet coefficient

2. 전문가 시스템

학습된 신경회로망은 주위 인접한 채널의 문맥정보를 이용하는 임상적 판독 방법에 기초한 전문가 시스템이 적용되어 효율적인 검출을 하게된다. 이 방법은 기준 몽타주(reference montage)의 경우 한쪽 채널에서 극파가 발생하면 영향을 받은 인접한 채널에서도 극파가 발생하고 쌍극 몽타주(bipolar montage)의 경우 극파와 함께 인접한 채널에서 위상 반전이 일어나는 경우 확실한 간질 파형으로 판단하여 발작 부위를 추정하는 규칙에 기초한 것이다^[1,12]. 그림 7은 10-20 전극 배치도(10-20 electrode placement system)를 이용한 기준 몽타주의 F3 채널에서 간질활동 파형이 발생할 경우 인접 채널인 Fp1, F7, C3, Fz의 극파 발생 부위를 나타내고 Time구간에서 신경망의 출력을 이용한 전문가 시스템의 의사코드(pseudo-code)를 작성한 것이다. 이것은 EMG나 단채널의 아티페트를 제거하여 신경망의 오류를 보완하며 정확한 결론을 내리게 된다.

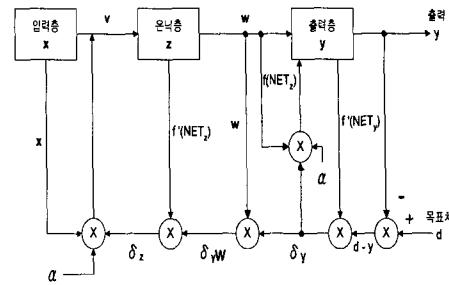
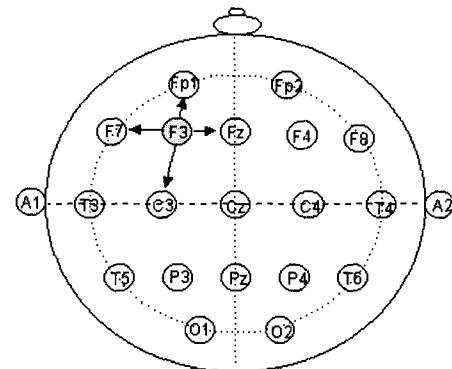


그림 6. BP 알고리즘의 블록 다이어그램
Fig. 6. Block diagram of BP algorithm.



ANNOT = Neural Output Threshold;

/* Expert System */

```
// This is a expert rule for F3 location at Time
IF((Time.F3 > ANNOT) AND (Time.Fp1 > ANNOT)) OR
((Time.F3 > ANNOT) AND (Time.F7 > ANNOT)) OR
((Time.F3 > ANNOT) AND (Time.C3 > ANNOT)) OR
((Time.F3 > ANNOT) AND (Time.Fz > ANNOT)))
THEN "F3 IS A DEFINITE SPIKE"
```

ELSE IF

"F3 IS A ILL-DEFINED SPIKE"

그림 7. 기준 몽타주에 의한 전문가 시스템

Fig. 7. Expert system of reference montage.

V. 실험 결과 및 고찰

1. 데이터 채집 및 분류

본 연구에서 이용된 EEG 데이터는 대학 병원 신경과 뇌파실에서 14세 이상 그룹으로부터 판독결과 간질로 진단 받은 12명의 환자와 진단결과 정상으로 나타난 20명의 환자로부터 선택하였다. 전극은 10-20 전극배치도에 의해 부착하고 16채널의 쌍극 몽타주와 기준 몽타주를 이용하였다. 데이터는 Nihon Kohden EEG 모니터링 시스템의 앰프 출력단자에 16채널 테

이터 캡처 보드인 DT2821(Data Translation Inc.)을 장착한 개인용 컴퓨터를 연결하여 12bits/sample 해상도로 256Hz 샘플링하여 얻었다. 16채널 EEG 앤프는 1~70Hz 대역 통과(band pass) 필터와 60Hz 노치(notch) 필터, 민감도(sensitivity) $7\mu V/mm$ 로 설정하였다. 측정된 데이터는 두 명의 EEG 판독사로부터 검토되어 2개의 주요 EEG 활동으로 분류되었다. 하나는 간질활동 파형(극파, 예파, 복합파)이고 또 하나는 다른 정상활동 파형이다. 간질활동 파형의 경우 그림 8과 같이 극파를 2초(512 포인터)의 후반부 해석 윈도 우상의 중앙에 위치시켜 377개 파일을 만들고 정상활동 파형의 경우 임의의 점을 중앙에 위치시킨 512 샘플의 900개의 파일을 만들었다. 극파 발생시의 1초 데이터와 비교한 두 개의 파라메타를 이끌어 내는데 이용된다. 그림 9는 분류된 파형의 일부를 보여준다.

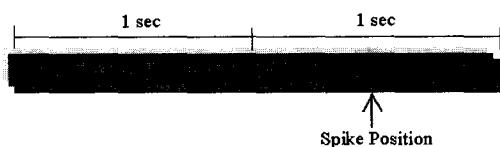


그림 8. EEG의 간질 활동 파형 채집

Fig. 8. Collection of epileptiform activities in the EEG.

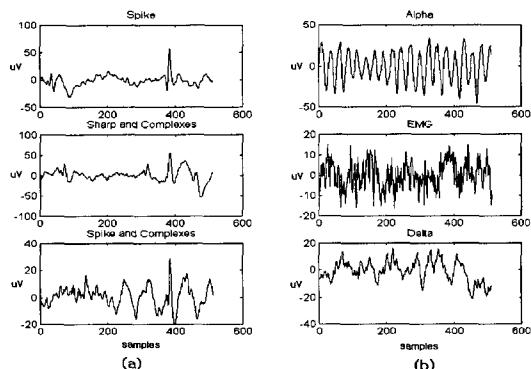


그림 9. 분류된 데이터의 예

(a) 간질활동 파형 (b) 정상활동 파형

Fig. 9. Examples of classified EEG event.
(a) epileptiform activities (b) normal activities

2. 추출 파라메타를 이용한 신경망과 원래 데이터를 이용한 신경망과의 비교

다음으로 선택된 34개의 파라메타를 이용하여 역전

파 학습 신경회로망에 적용시켰다. 비교를 위하여 극파를 중앙에 위치시킨 후 좌우 대칭으로 원래 데이터의 총 34개의 포인터를 선택하여 신경회로망에 적용시켰다. 따라서 입력층의 개수는 34, 은닉층의 개수는 8개, 출력층은 1로하여 학습 평균자승에러가 0.05이하가 될 때까지 학습시켰다. 전체 분류된 1277개의 파일 중 870개(간질활동파형: 270개, 정상파형: 600개)의 데이터가 학습 데이터로서 임의로 선택되고 나머지는 테스트 데이터(간질활동파형: 107, 정상파형: 300)로 이용되었다. 그럼 10은 웨이브렛 전처리를 이용한 신경망의 문턱치에 따른 민감도와 선택도 그리고 민감도와 선택도의 평균인 정확도의 그래프를 나타낸다. 그리고 그림 11은 원래 데이터를 이용했을 때 신경망 출력의 문턱치에 따른 결과를 나타낸다. 민감도와 선택도의 정의는 식 (6)와 식 (7) 같다.

$$\text{민감도} (\text{Sensitivity}) = \frac{n(\text{ANNOT})}{n(\text{ED})} \times 100 \quad (6)$$

$$\text{선택도} (\text{Selectivity}) = \frac{n(\text{ANNOT} \cap \text{ED})}{n(\text{ANNOT})} \times 100 \quad (7)$$

n : 개수, ED : 간질 활동 파형,
ANNOT : 신경망이 찾아낸 간질파형

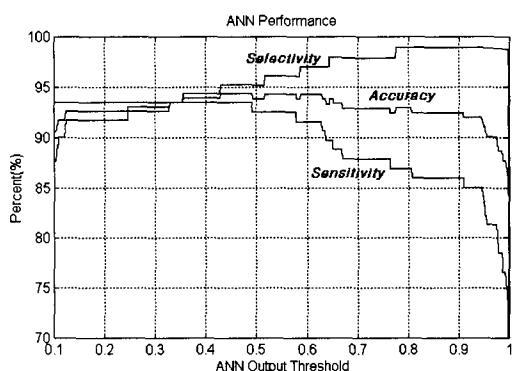


그림 10. 신경망의 민감도와 선택도 그래프

Fig. 10. A graph of the sensitivity and selectivity of the preprocessed neural network.

검출 성능은 민감도와 선택도 곡선의 교차점에 의하여 평가하였다. 표 1은 두 신경망의 비교를 나타낸다. 결과적으로 전처리된 신경망은 93.5%로서 원래 데이터를 이용한 신경망의 90.2%보다 높은 정확도를 얻을 수 있었다. 또한, 일반적으로 선택도는 오검출

(false positive)을 줄이는 인자로 간질 진단을 위한 장시간 EEG 모니터링에서 중요한 파라메타인데 그림 10과 그림 11에서 전처리 신경망이 선택도가 우수함을 알수있다.

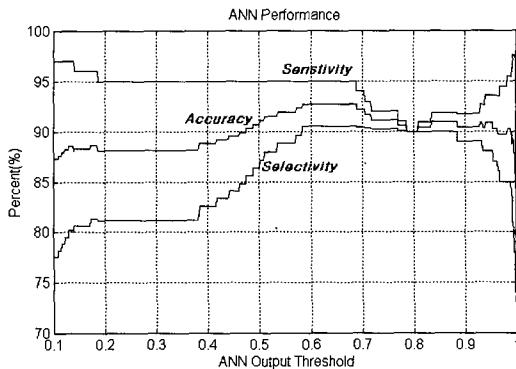


그림 11. 원래 EEG 데이터 신경망의 민감도와 선택도

Fig. 11. A graph of the sensitivity and selectivity of the neural network with raw EEG.

표 1. 신경망의 학습비교

Table 1. Comparison of neural network.

	추출 파라메타를 이용한 신경망	원래 데이터를 이용한 신경망
정확도(%)	93.5	90.2

3. 전문가 시스템과 임상실험

전처리 신경망 모듈을 이용하여 실제 간질환자의 16채널 데이터에 적용시켰다. 16채널 데이터에 같은 신경망을 이용하고 각각의 인식된 극파들은 앞에서 언급한 인접채널의 정보를 이용하는 전문가 시스템을 적용시켰다. 표 2는 전처리 신경망을 이용한 시스템과 전처리 신경망과 전문가 시스템을 병행한 시스템의 검출 성능을 비교한 표이다. 이 임상 테스트의 결과로 전문가 시스템은 전처리 신경망만을 사용했을 때보다 오검출율을 줄일 수 있었고 신뢰성 있는 검출을 할 수 있었다. 그림 12는 실제로 프로그램으로 구현한 결과를 나타낸다. 그림에서 극파는 화살표로서 표시하였으며 극파 발생시의 영역을 음영으로 표시하여 눈으로 쉽게 확인할 수 있게 하였다. 이 환자는 2년 동안 간질 증상을 가진 13살의 여자아이로 수면 중에 오른쪽 반구에 극파를 가진 서파가 나타남을 볼 수 있다. 이 그림은 본 논문의 제안한 웨이브렛 전처리를 이용한

신경망과 전문가 시스템이 성공적으로 극파를 검출할 수 있다는 것을 보여준다.

표 2. 시스템 검출 성능 비교

Table 2. Comparison of the system detections.

시스템	판독사 등의 동의	시스템 검출	동시 검출	(동시검출) ÷ (시스템 검출) (%)
전처리 신경망	78	102	75	73.5
전처리 신경망과 전문가 시스템	78	91	73	80.2

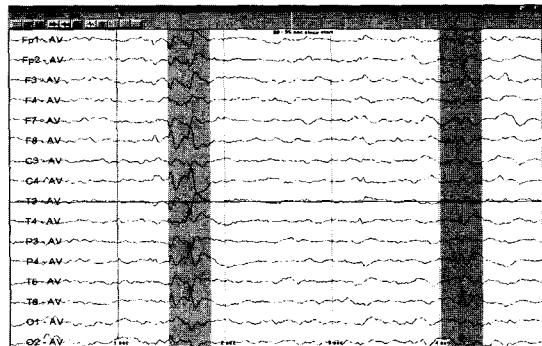


그림 12. 웨이브렛 전처리 신경망에 기반한 인접채널 시스템의 예

Fig. 12. A sample output of adjacent channel system based on wavelet preprocessed ANN output.

실퍼본 바와 같이, 웨이브렛 전처리 테스트 결과는 만족스러웠으며 실제 EEG 데이터를 이용한 임상적용에서 전문가 시스템은 단채널 아티팩트를 줄일 수 있었다. 그러나, 일부 오검출은 기계적 또는 환자의 움직임으로 인하여 발생하였다. 또한, 다양한 극파와 환자의 데이터가 학습 데이터에 적용됨으로써 일부 오검출이 발생하였다. 이러한 오검출은 EEG 기록자와 판독사의 경험으로 버려질 수 있다. 연구에서는 개인용 컴퓨터 기반에서 Visual C++를 이용하여 시스템을 구현하였으며 기존의 단순 처리 방법과 비교하여 계산량이 많아 속도는 늦어지는 단점은 가지고 있었다. 일단 다채널 DSP 프로세서가 이용된다면 빠르고 실용적인 실시간 시스템이 구현될 수 있을 것이다. 그리고, 앞으로 실제 극파를 특성을 고려한 모 웨이브렛의 설계와 기존의 모 웨이브렛과의 정량적 분석은 앞으로의 연구방향으로 제시된다.

VI. 결 론

다양한 EEG 데이터를 기본으로 웨이브렛 전처리와 신경회로망 그리고 전문가 시스템을 이용하여 16 채널 간질 파형 자동 검출을 수행하였다. 웨이브렛 전처리 과정을 거친으로써 실제 데이터를 이용할 때보다 입력 노드를 줄일 수 있었고 향상된 정확도를 얻을 수 있었다. 그리고 인접 채널의 연관성을 바탕으로한 전문가 시스템을 이용함으로써 더욱 신뢰성 있는 검출성능으로 구현할 수 있었다. 임상의의 판독방법에 기초한 이 방법은 근전도, 전극 등으로 인한 아티펙트를 영향을 제거하여 단채널에서의 오류를 수정·보완할 수 있었다. 이러한 실제 파형의 특성을 고려한 전처리와 신경 회로망, 그리고 임상의의 경험을 바탕으로 한 이 알고리듬은 실제로 디지털 신호처리 프로세서를 이용하여 효율적으로 이용될 수 있을 것이다.

참 고 문 헌

- [1] 韓善浩, Saito Shoji, "臨床脳波", 一潮閣, 1987
- [2] J. Gotman, "Automatic recognition of epileptic seizures in the EEG", *Electroenceph and clin Neuroph*, vol. 54, pp. 530-540, 1982.
- [3] D. J. Koffler, J. Gotman, "Automatic detection of spike-and-wave bursts in ambulatory EEG recordings", *Electroenceph and clin Neuroph*, vol. 61, pp. 165-180, 1985.
- [4] J. Gotman, "Automatic seizure detection: improvements and evaluation", *Electroenceph and clin Neuroph*, vol. 76, pp. 317-324, 1990.
- [5] John R. Glover, Periklis Y. Ktonas, Narasimhan Raghavan, Jose M. Urunuela, Syama S. Velamuri, and Edward L. Reilly, "A multichannel Signal Processor for the Detection of Epileptogenic Sharp Transients in the EEG", *IEEE Trans Biomed Eng*, BME-33(12), pp. 1121-1128, 1986.
- [6] John R. Glover, Narasimhan Raghavan, Periklis Y. Ktonas, James D. Frost, "Context-based automated detection of epileptogenic sharp transients in the EEG: Elimination of false positives", *IEEE Trans Biomed Eng*, BME-36(5), pp. 519-527, 1989.
- [7] Andrew J. Gabor, Masud Seyal, "Automated interictal spike detection using artificial neural networks", *Electroenceph and clin Neuroph*, vol. 83, pp. 271-280, 1992.
- [8] W. R. S. Webber, Brian Litt, K. Wilson and R. P. Lesser, "Practical detection of epileptiform discharges(EDs) in the EEG using an artificial neural network: a comparison of raw and parameterized EEG data", *Electroenceph and clin Neuroph*, vol. 91, pp. 194-204, 1994.
- [9] N. Pradhan, P. K. Sadasivan, G. R. Arunodaya, "Detection of seizure activity in EEG by and artificial neural network: A preliminary study", *Computers and Biomedical Research* 29, pp. 303-313, 1996.
- [10] S. J. Schiff, A. Aldroubi, M. Unser, S. Sato, "Fast wavelet transformation of EEG", *Electroenceph and clin Neuroph*, vol. 91, pp. 442-455, 1994.
- [11] Tulga Kalayci and Ozcan Ozdamar, "Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes", *IEEE Eng Med Biology*, March/April, pp. 160-166, 1995.
- [12] 安昌一, 小兒脳波學, 新光出版社, 1994, pp. 24-30.
- [13] Gilbert Strang and Truong Nguyen, *Wavelets and Filter Banks*, Wellesley-Cambridge Press, pp. 108-259, 1996.
- [14] Martin Vetterli, "Wavelets and Filter Banks: Theory and design", *IEEE Trans on Sig Pro*, Vol. 40, No. 9, pp. 2207-2232, 1992.
- [15] Martin Vetterli, Jelena Kovacevic, "Wavelets and subband coding", Prentice Hall, pp. 92-194 1995.
- [16] Jacek M. Zurada, *Introduction to Artificial Neural Systems*, PWS Publishing Company, pp. 165-248, 1992.

저자소개



朴鉉錫(正會員)

1973년 5월 19일생. 1996년 2월 한양대학교 공과대학 전자공학과(학사). 1998년 2월 한양대학교 일반대학원 전자공학과(석사). 1998년 1월 - 현재 (주)현대전자. 주관심분야 : 생체신호처리, DSP 응용

李斗秀(正會員)

1946년 7월 3일생. 1968년 2월 전북대학교 공과대학 전자공학과(학사). 1970년 2월 전북대학교 공과대학 전자공학과(석사). 1973년 2월 - 1979년 3월 전북대학교 전자공학과 조교수. 1979년 3월 - 현재 한양대학교 전자공학과 교수. 주관심분야 : 디지털 신호처리, 의공학, 시스템 해석



金先一(正會員)

1952년 12월 2일생. 1976년 2월 서울대 공학사. 1978년 2월 서울대 공학석사. 1987년 2월 미국 Drexel대 의공학 박사. 1988년 5월 - 현재 한양대학교 의과대학 교수. 주 관심 분야 : 3차원 의학 영상, 의료정보, 생체신호처리