

신경망과 웨이브렛 변환을 이용한 뇌전도의 간질 극파 검출

최혜원* · 이성수** · 윤영로*

연세대학교 보건과학대학 의용전자공학과, *연세대학교 의공학연구소, **연세대학교 원주의과대학 신경과학교실
(1999년 6월 7일 접수, 1999년 10월 12일 채택)

The Detection of Epileptic Spikes in EEG using Neural Network

H.W. Choi*, S.S. Lee**, Y.R. Yoon*

Dept. of Biomedical Engineering, College of Health Science, Yonsei University

*Research Institute of Medical Instrument, Yonsei University,

**Dept. of Neurology Wonju Medical College, Yonsei University

(Received June 7, 1999. Accepted October 12, 1999)

요약 : 간질은 신경세포의 일부가 짧은 시간동안 과도한 전기를 발생시킴으로서 일어나는 신경계의 발작적 증상으로 배경 활동과와는 구별되는 극파(spike), 예파(sharp), 예파와 서파를 동반한 국서파 복합(sharp and slow complexes)의 뇌파 특징파를 갖는다. 장시간의 뇌파기록에서 시간의 질약과, 정량화를 위해 컴퓨터를 이용한 간질 과정의 자동 검출은 개방성을 높이고 성량적인 해석을 위해 필수적이다. 본 연구에서는 간질 뇌파를 검출하기 위해 웨이브렛 변환과 신경망을 사용하였다. 웨이브렛 변환은 잡음을 제거하고 간질 뇌파의 특징을 강조하며 신경망의 입력노드수를 줄였다. 전문가에 의해서 분류된 간질 특성파와 정상뇌파를 신경망에 입력시켜 최적의 신경망 구조를 선택하였고, 검출 문턱치를 설정하였다. 신경망은 200ms(26개의 데이터포인트) 신호의 웨이브렛 결과와 웨이브렛 변환 후 데이터 상의 최대, 최소 기울기가 입력되어 전체 28개의 입력 노드로 구성하였다. 은닉층은 18노드, 문턱치값은 민감도와 선택도가 일치하는 0.65가 사용되었다. 결과로 임상 환자 데이터에 입력되어 78.54%의 검출률을 보았다.

Abstract : An epilepsy, which has transient epileptiform discharges(EDs) that can be distinguished as a spike and a spike/wave complexes, happens when an ordinary highly complex brain activity is suddenly disrupted. In order to diagnose it, a long term EEG(electroencephalography) monitoring is needed. Epilepsy-monitoring units generate a large amount of normal data, intermixed with relatively rare EDs and seizure. However the long term EEG monitoring to find epileptiform is time consuming. Therefore it is interested in the field of automated computer-based techniques for the recognition of EDs. EEG has many artifacts such as eye movement, EMGs and body movements. Thus, it is difficult to distinguish ED from non-ED. In this paper, we used the wavelet transform to shorten artifacts and strengthen low level signals. Then artificial neural network(ANN) was developed and tested off-line to detect transient EDs. The ANN with variable number of inputs, hidden layer units, and one output unit was used to optimize the detection system. The ANN system was trained and tested with the Back propagation algorithm from a large data set of examples. The effects of different EEG time window and the number of hidden layer neurons were examined by using the optimum detection sensitivity and selectivity. The best ANN configuration occurred with input time window of 200 msec(60 inputs) and added two parameters(maximum slope and minimum slope) and 18 hidden layer neurons. We can get the accuracy of 78.51% from EEG epileptic waveforms using the proposed algorithm.

Key words : Seizure, Wavelet transform, EEG (Electro Encephalography), Neural network

서 론

뇌파(electroencephalogram:EEG)는 대뇌 피질의 미세한 전기

통신자 : 최혜원, (220-710) 강원도 원주시 흥입면 폐지리

연세대학교 보건과학대학 의용전자공학과

Tel. (0371)760-2140 FAX, (0371)763-4050

E-mail : chojhw@unitel.co.kr

직 활동을 측정하여 뇌의 기능적 결함을 관찰할 수 있도록 해주는 것으로 특히 간질 환자의 발작 유부 추정, 발생부위 진단, 치료효과 판단 등을 모니터링하는데 중요한 임상적 방법이나 [1]. 간질은 신경세포의 일부가 짧은 시간동안 과도한 전기를 발생시킴으로서 일어나는 신경계의 발작적 증상으로 EEG특성은 정상 뇌파와는 구별되는 극파(spike), 예파(sharp), 국파와 서파를 동반한 국·서파 복합(sharp and slow complexes)으로 구분된다. 장시간의 EEG기록에서 직진 간질 과형을 찾는 것은

전문적인 지식이 요구 될 뿐만 아니라 시간이 많이 소요되는 단순 반복적 작업이다. 또한 주관적인 판단으로 인해 같은 EEG 기록에 대한 다른 의견이 가능하다. 따라서 컴퓨터를 이용한 간질 파형의 자동 검출은 객관성을 높이고 정량적인 해석을 위해 필수적이다[1].

지난 수십 년간 간질 활동 파형의 자동 검출은 많은 진전이 있어왔다. 기존의 검출 방법으로는, 모방적 방법(mimetic algorithm)[2][3], 전문가 시스템[4], 뇌파의 천이(transient) 파라메터를 이용하는 법[5]-[10]등이 사용되어져 왔다. 하지만 이 방법들은 뇌파 전문가들이 동의하는 특정 데이터의 집합을 정의 하여야만 하는 단점을 갖는다. 이 단점을 해결하기 위해 원 신호를 신경망의 입력으로서 사용하는 방법이 사용되었다[11][12]. 이 방법은 각각 전문가들에 따라 다른 파라메터에 의존하지 않고 검출된 파형에만 의존하는 검출 방법이다. 인공 신경망은 규칙을 완전히 수식화 할 수 없는 인식과 분류 작업에 해결책을 제시하는 방법으로 출현 문턱치(threshold)를 조절함으로서 각각의 임상 요구를 만족시킬 수 있었다. 그러나 다양핚 학습 셈플을 필요로 하고, 여러 아티팩트의 제거를 위한 문맥적 정보를 위하여 큰 크기의 원도우를 써운 많은 입력 데이터를 필요

로 하여, 실제 시스템에서는 비현실적인 단점을 갖고 있다. 웨이브렛을 이용한 방법은 간질 극파의 발생시 신호의 전력비가 커진다는 사실에 기인하여 양적적인 웨이브렛을 이용하여 신호의 전력비를 구하고 일정한 문턱치 이상의 파형을 간질 특징파로 검출하는 방법이다[11][13]-[15]. 이 방법은 아티팩트가 없는 경우 좋은 검출 능력을 나타내었으나 균전도나 여러 다른 아티팩트가 섞인 파형에 있어서 성능이 저하되는 단점을 가지고 있다.

본 연구에서는 신경망을 이용하여 검출하였다. 신경망은 간단한 뉴런을 상호 연결한 시스템으로 학습과정은 기대되는 결과의 한가지 예반을 요구하고, 규칙을 정할 필요가 없다. 시스템은 학습 과정 동안 뉴런들 사이의 무게 값을 변형시킴으로서 자신의 규칙을 발견시키는 방법이다. 그러므로 신경망의 수행은 시스템에 대해 선택된 학습 방법과 테스트 방법의 선택에 따라 달라진다. 신경망을 실제 입장에 적용시키기 위해서는 신경망 자체의 구조를 최소화 시키는 것이 중요하다. 기존의 방법은 2-하강 표본화(downsampling)를 하지만 신호의 손실을 가시게 되므로 본 연구에서는 웨이브렛을 사용하여 신경망의 입력 노드 수를 줄이며 동시에 신호 자체의 손실을 줄였다.

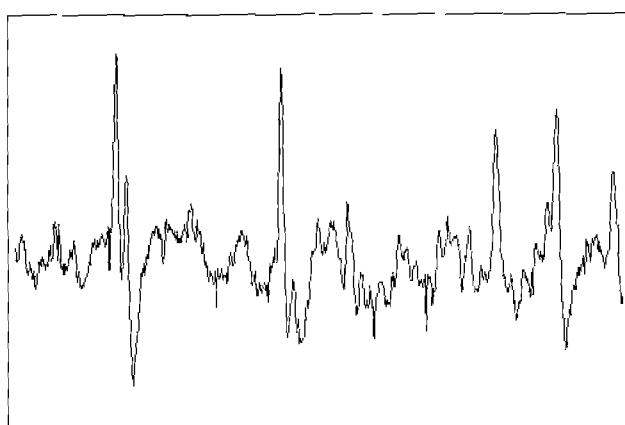


그림 1. 간질 특징파를 지닌 뇌파

Fig.1. EEG wave in epilepsy

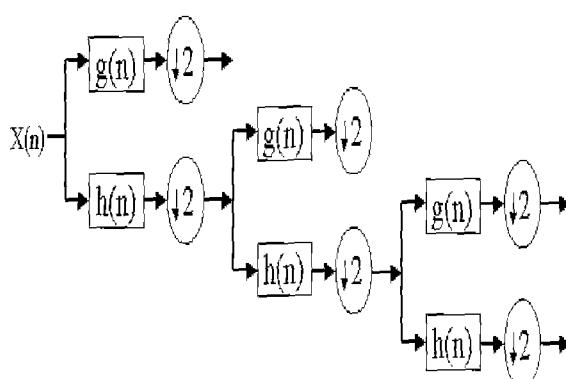


그림 2. 웨이브렛 변환의 반복필터뱅크

Fig. 2. Repetitive filter bank of wavelet transform

간질의 특징파

간질 질환의 특징파에는 극파, 극·서파 복합파가 있다. 극파는 끝이 뾰족하고 날카로우며 지속시간이 30-80ms인 음성극파(negative spike)이다. 극파는 뇌의 표면에 광범위하게 나타나거나 국부적으로 나타난다. 이때 국부적으로 나타난 초점부 위는 발작의 원인인 것이 많다[1]. 극·서파 복합파는 극파 이후 서파가 출현하여 질화한 형태로 지속 시간은 150-300msec으로서 파형이나 출현 빈도 주파수도 여러 가지이다. 신경 결핍 발작형 간질(소발작, petit mal)에서는 3Hz의 극·서파 복합이 규칙적이며 정확하게 양측 동기성으로 넓게 분포되어 나타난다. 그림 1은 간질 특징파를 가지고 있는 뇌파의 예이다.

웨이브렛

웨이브렛 이론은 다양한 신호처리 응용 분야의 많은 기법을 통합한 이론으로서 최근에는 비정상적 신호(nonstationary) 인생체 신호처리 분야에서 널리 응용되고 있다.

이산 웨이브렛 변환은 연속 웨이브렛 변환의 스케일링 요소와 천이 요소를 이산화하고 써 얻을 수 있다[16]. 이때, 웨이브렛 함수 $\phi(\cdot)$ 와 스케일링 함수 $\psi(\cdot)$ 는 식(1), 식(2)로 표현될 수 있다.

$$\phi(n) = \sum_k g(n)\phi(2n-k) \quad (1)$$

$$\psi(n) = \sum_k h(n)\psi(2n-k) \quad (2)$$

이산 웨이브렛 변환의 분석 알고리즘에서 웨이브렛 필터 계수 $h(n)$ 은 고역동파 필터 계수를 의미하고 스케일링 필터

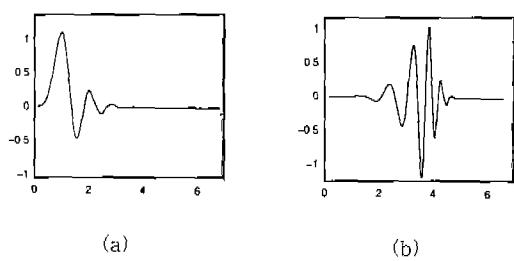


그림 3. 다비치8 웨이브렛
Fig. 3. Daubechies 8 Wavelet

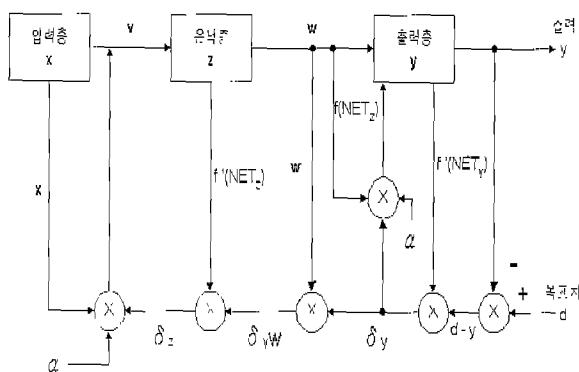


그림 4. 오류 역전파 알고리즘 블록도
Fig. 4. Block-diagram of back-propagation algorithm

계수 $g(n)$ 은 저역 통과 필터 계수를 의미한다[16].

이산 신호 $x(n)$ 에 대한 $j=J$ 단계까지의 이산 웨이브렛 변환은 식(3)으로 정의된다.

$$x(n) = \sum_{j=1}^J \sum_{k \in Z} g_j(k) \psi_{j,k}(n-2^j k) + \sum_{k \in Z} h_j(k) \phi(n-2^j k) \quad (3)$$

신호의 각 함수들의 계수에 의하여 주파수 분할이 이루어 지기 때문에 해석 신호의 특성을 고려한 모 웨이브렛의 선택이 중요하다. 본 연구에서는 기존의 모 웨이브렛 중에서 시간 영역 및 주파수 영역에서의 특성이 우수한 것으로 알려진 다비치 웨이브렛을 사용하여 구현하였다. 이 웨이브렛은 완전 재구성 특성을 만족하는 유한 차수의 필터이다[17]. 반복 필터 링크를 사용하여 간질 특성파가 분포하는 주파수 대역까지 웨이브렛 변환을 적용하여 고주파 잡음은 제거하고 간질의 특성파는 강조한다.

그림 3은 본 연구에서 사용된 다비치 8 웨이브렛이다.

본 연구에서는 신호를 간질 뇌파의 특성영역인 0-35 Hz를 위한 웨이브렛 레벨 3을 사용한다. 3레벨의 웨이브렛을 사용하였을 경우 데이터 수는 줄어든다. 표 1은 각 원도우의 데이터 노드수에 대하여 3 레벨 웨이브렛을 전개한 결과이다.

웨이브렛 과정을 거친 데이터는 신경망 입력으로 들어갈 시 뇌파의 특징을 유지하면서, 데이터 수는 줄어든 입력이 된다.

표 1. 웨이브렛 전개된 후 입력 노드수
Table 1. The number of input node after wavelet transform

| 원도우 크기 | 데이터 수 | 3레벨 웨이브렛 전개 | 무가 파라메터 포함 |
|---------|-------|-------------|------------|
| 350msec | 105 | 37 | 39 |
| 250msec | 75 | 30 | 32 |
| 200msec | 60 | 26 | 28 |
| 150msec | 45 | 22 | 24 |
| 120msec | 36 | 20 | 22 |
| 100msec | 30 | 18 | 20 |

신경망의 입력 노드수를 줄이는 것은 신경망의 구조를 줄임으로서 학습 시간 및 실행 시간을 줄이는데 필수적이다. 또한 간질 극파는 정상 뇌파와는 구분되는 큰 기울기와 작은 기울기를 구성한다. 따라서 부가 파라메터로서, 필터 처리된 데이터의 최대 기울기와 최소 기울기의 두 값을 포함하여 신경망으로 입력된다.

신경망

신경망은 전문가로부터 제공된 예로 학습하는 시스템을 개발하는 데로서 간단한 뉴런을 상호 연결함으로써 학습 할 수 있는 시스템이다. 본 연구에서는 가장 일반적인 신경망인 오류 역전파 알고리즘(Back propagation algorithm)을 사용하여 간질의 극파를 감출하였다. 오류 역전파 알고리즘은 순방향 다중 신경망의 학습에 효과적으로 적용할 수 있어서 다양한 분야에 보편적으로 활용되는 매우 중요한 학습 알고리즘으로[18] 입력 x 에 대한 출력 y 와 목표치 d 사이의 차를 오류라 하며 이를 오류를 최소화하기 위하여 신경 단위들간의 연결강도 v 를 조정하는 최적화 과정이다. 본 연구에서 활성화 함수 $f(\cdot)$ 로는 양극성 시그모이드함수를 사용하였다. 따라서 가중치의 합 NET은 식(4)로 계산되고, 학습신호 δ , 는 식(5)로 결정되고, 이때 가중치 변화량은 식(6)으로 결정된다.

$$NET = xv^T \quad (4)$$

$$\delta_x = (d - y)f'(NET) = -\frac{1}{2}(d - y)(1 - y) \quad (5)$$

$$\Delta v^k = \alpha \delta_x x \quad (\alpha : \text{학습률}) \quad (6)$$

따라서 $k+1$ 단계에서의 가중치는 다음과 같다.

$$v^{k+1} = v^k + \Delta v^k = v^k + \alpha \delta_x x^k \quad (7)$$

그림 4는 BP 학습 알고리즘의 블록나이어그램이다.

다중 신경망의 학습은 단층 신경망의 경우와는 달리 긴 학습 시간이 요구되며 어떤 경우에는 학습이 이루어지지 않을 수 있다. 따라서 다중 신경망을 빠르고 올바르게 학습 시키기 위해서는 초기 연결강도, 학습률, 은닉층의 뉴런수 등 여러 요인을 고려하여야 한다[19]. 본 연구에서는 3층의 신경망을 구성하였고, 입력층과 은닉층의 뉴런수를 최적화 시키기 위해서 노

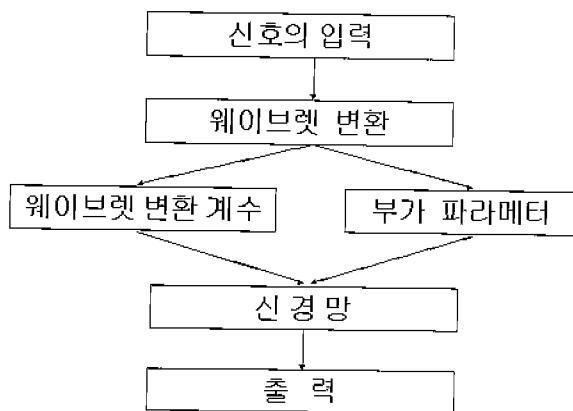


그림 5. 제안된 알고리즘의 흐름도
Fig. 5. Flowchart of suggested algorithm

표 2. 학습 및 테스트 위해 사용된 데이터 수

Table 2. The number of data for training and testing

| | 학습 | 테스트 |
|--------|------|------|
| 간질 특징파 | 300 | 407 |
| 간질 외파 | 1200 | 2493 |

노드수를 조절하여 최대의 검출률을 보이는 값으로 결정하였다. 또한 출력층의 노드수는 간질 파형일 때 1, 간질 외 파형일 때 -1이다. 신경망의 학습률은 0.01로 고정하였다.

실험 및 결과

1. 데이터 수집

뇌파 데이터는 원주 기독병원 신경외과에서 간질 환자로 진단된 환자 8명으로부터 측정되어, Nihon Kothen 4400 모니터링 시스템의 아날로그 출력 단자로부터 입력 받았으며 National Instrument DAQ board AI-16Ex 50 E Series를 이용하여 300Hz로 샘플링 하였고, 12 bits/sample을 하였다. 받아들여진 데이터를 간질 극파, 극·서파 복합, 간질파 외파로 뇌파 전문가의 동의를 얻어서 분류되었다. 분류된 데이터는 1-70Hz의 대역 통과 필터 치러된 후 60Hz 협대역 제거 필터를 사용해 선원 잡음을 제거하고, 그림 5와 같은 알고리즘의 입력으로 들어간다.

간질 특징파(극파, 극·서파 복합)와 간질 외파의 두 분류가 사용되었고, 간질 특징파는 피크가 15번째에 위치하고, 왼쪽으로 15개, 오른쪽으로 90개의 데이터 값을 갖는 창을 구성하였다. 간질 외파의 경우는 임의의 점을 위치시킨 파일을 구성하였다. 그림 6은 신경망의 입력으로 사용되는 데이터의 수와 원도우 크기를 타나낸다.

위의 과정을 사용하여 1200개의 간질 특징파 파일을 만들었으며, 간질 외파를 테스트하기 위해 2493개의 정상뇌파 및 잡음파 파일을 구성하였다. 표 2는 학습 및 테스트를 위해 사용된 데이터의 수이고 그림 7은 학습과 테스트에 사용된 데이터의 예이다.

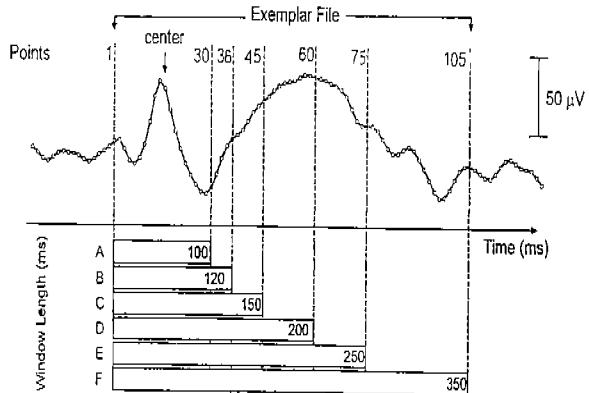


그림 6. 신경망의 입력 창
Fig. 6. Input window of neural network

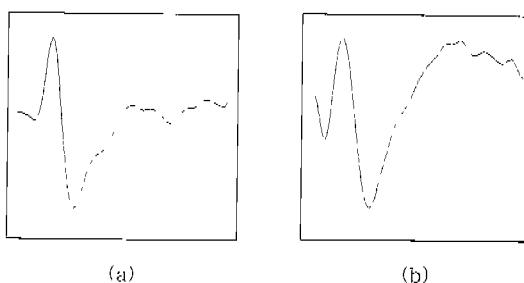


그림 7. 간질파 예
(a)극파 (b)극·서파 복합
Fig. 7. Example of epileptic wave
(a) spike wave (b) spike and slow complex

2 실험

신경망의 성능은 전처리과정, 신경망 학습과정에서의 오차 허용 범위, 입력 및 유통층에서의 노드수 등의 파라미터에 의해 영향을 받게 된다. 최적의 신경망을 구성하기 위해서는 객관적인 성능평가 및 비교가 필요하다. 본 연구에서는 민감도와 선택도를 사용하였다. $n(ED)$ 는 간질활동 파형갯수이고, $n(ANNOT)$ 는 검출해낸 간질 파형의 개수이다.

$$\text{민감도} (\text{Sensitivity}) = \frac{n(ANNOT \cap ED)}{n(ED)} \times 100 \quad (8)$$

$$\text{선택도} (\text{Selectivity}) = \frac{n(ANNOT \cap ED)}{n(ANNOT)} \times 100 \quad (9)$$

n: 갯수, ED: 간질활동 파형
ANNOT: 찾아낸 간질 파형

1) 웨이브렛 변환에 의한 추출파라미터를 이용한 신경망과 전처리 과정 없이 데이터를 이용한 신경망과의 비교

전처리 하였을 때의 검출 성능을 비교하기 위해서 민감도와 선택도 측면의 교차점에 의하여 평가하였다. 평가를 위해 사용된 파라미터에서 입력 창의 노드기는 200msec이다. 웨이브렛 전

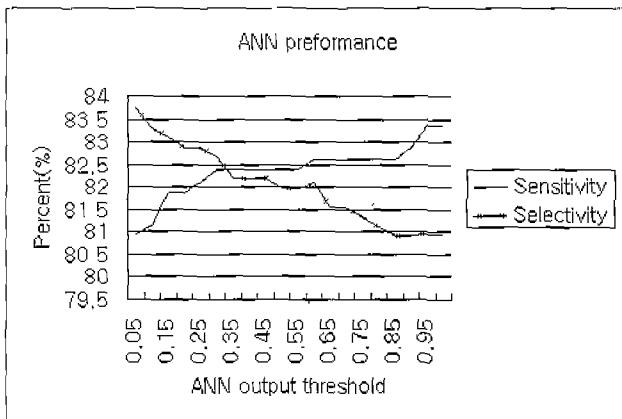


그림 8. 전처리 없는 EEG 데이터의 신경망 민감도와 선택도 그래프

Fig. 8. The sensitivity and the selectivity graph of Neural network for raw EEG data

표 3. 웨이브렛 전처리 신경망과 전처리 없는 데이터를 이용한 신경망과의 학습 비교

Table 3. Comparison of accuracy between wavelet preprocessed data and raw data

| | 전처리 없는 상태 신경망 | 전처리 상태 후 신경망 |
|--------|------------------|-----------------|
| 정확도(%) | 82.12 | 85.7 |

표 4. 은뇌층의 노드수에대한 검출률

Table 4. The change of detection rate depending on the number of node in hidden layer

| 은뇌층 노드수 | 검출률(%) | 은뇌층 노드수 | 검출률(%) |
|------------|--------|---------|--------|
| 10 | 84.03 | 20 | 82.92 |
| 11 | 83.05 | 21 | 81.45 |
| 12 | 83.3 | 22 | 80.59 |
| 13 | 83.3 | 23 | 85.01 |
| 14 | 86.47 | 24 | 84.77 |
| 15 | 76.56 | 25 | 79.11 |
| 16 | 75.55 | 26 | 82.06 |
| 17 | 81.6 | 27 | 78.87 |
| 18 | 88.2 | 28 | 84.75 |
| 19 | 83.29 | 29 | 81.57 |

처리한 경우 2개의 노드가 파라미터를 포함하여 28개의 입력 노드수를 갖고 전처리 없는 그대로의 신호를 이용하는 신경망의 경우 60개의 입력 노드수를 갖는다. 은뇌층의 노드수는 20으로 고정하였고, 출력 노드수는 1로 하였다. 그림 8과 그림 9는 웨이브렛으로 전처리하였을 때와 신경망으로의 전처리하였을 때의 민감도, 선택도 곡선이다. 표3은 추출 파라미터와 원 데이터를 이용했을 때의 신경망 성능 비교이다.

결과로, 전처리된 신경망은 85.7%로서 전처리과정이 없는 데이터를 이용한 경우보다 82.12% 보다 높은 정확도를 얻을 수 있었다.

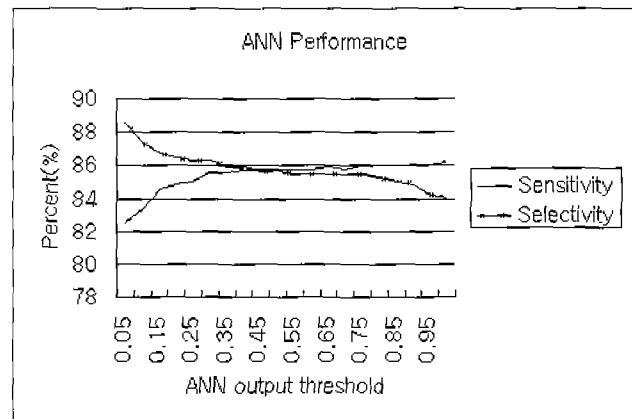


그림 9. 웨이브렛 전처리한 EEG 데이터의 신경망 민감도와 선택도 그래프

Fig. 9. The sensitivity and the selectivity graph for wavelet preprocessed data

표 5. 윈도우의 크기에 따른 검출률

Table 5. The change of detection depending on the window size

| 윈도우 크기 | 검출률(%) | 윈도우 크기 | 검출률(%) |
|--------|--------|--------|--------|
| 30 | 79.2 | 60 | 83.01 |
| 36 | 82.38 | 75 | 82.54 |
| 45 | 81.77 | 105 | 81.29 |

표 6. 민감도와 선택도에 따른 비교

Table 6. The sensitivities and the selectivities for various methods

| 방법 | 민감도 | 선택도 |
|----------|--------|--------|
| 제안된 방법 | 78.54% | 81.06% |
| 파틴 인식법 | 72.2% | 53.9% |
| 웨이브렛 이용법 | 90.7% | 41.19% |

2) 은뇌층의 크기에 대한 신경망의 검출 비교

은뇌층의 노드수를 결정하기 위하여 입력창의 크기는 350ms 105개의 점이 웨이브렛 변환되어, 입력 노드수는 37개로 하였고, 출력 노드 수는 1, 출력 문턱치 값은 0.9로 설정하였다. 표 4는 검출률에 대한 백분율(%) 값이다. 은뇌층의 노드수를 18개로 하였을 때 가장 좋은 결과를 얻음을 알 수 있다.

3) 입력 원도우의 크기에 따른 효과

입력 창의 크기를 결정하기 위해서 은뇌층의 노드수는 18개, 출력노드는 1, 문턱치 값은 0.65로 하였다. 입력층의 크기는 표 5와 같이 가변하여 실험하였다.

결과적으로 입력창의 크기를 60개의 200msec로 한 경우 가장 좋은 검출률을 보였다

4) 임상실험

구성된 신경망을 가지고 원주 기독병원 신경외과에서 간질

로 판단되어 24시간 모니터링 시스템으로 측정된 8명의 환자의 뇌파 연속 데이터를 제안된 신경망의 입력으로 넣어 간질 특성 파의 검출률을 검사하였다.

사용된 신경망은 위의 실험 결과로 제시된 60노드의 입력창 크기와 18개의 은닉층을 갖도록 구성하였고, 출력 문법치 값은 0.65로 설정하였다. 표 6은 같은 환자 데이터에 대해서 본 연구에서 제안된 알고리즘과 웨이브렛, 패턴 인식방법을 이용하여 검출한 민감도와 선택도의 비교치이다. 웨이브렛을 이용한 경우 민감도가 90.7%로서 좋은 결과를 나타냈지만 간질 특징파를 정확히 검출해 내는 척도인 선택도의 경우, 41.19% 낮아 정확도가 떨어짐을 알 수 있다. 본 연구에서 제안된 알고리즘의 경우 민감도는 78.54%, 선택도는 81.06%를 나타내어 잘못된 파를 검출할 확률이 기존의 방법보다 낮음을 알 수 있다. 이것으로 제안된 알고리즘이 장시간의 모니터링동안 움직임 등의 짧음이 섞일 경우에도 좋은 결과를 보여줄을 알 수 있다.

결 론

본 연구에서는 실제 환자의 다양한 뇌파데이터를 기본으로 웨이브렛 전처리와 신경 회로망을 이용하여 간질 과정 자동 검출을 수행하였다. 웨이브렛 전처리 과정을 거친으로써 실제 데이터를 이용할 때보다 입력 노드 수를 줄이면서도 항상된 정확도를 얻을 수 있었다. 또한 신경망을 사용하여, 최적의 결과를 보이는 구조를 선택하였다. 이것은 환자의 운동으로 인한 근전도 노이즈등의 짧음이 큰 영향을 끼치는 뇌파 모니터링의 경우 중요한 의미를 갖는 선택도를 향상시킬 수 있었다. 이러한 실제 과정의 특성을 고려한 전처리와 신경 회로망을 바탕으로 한 이 알고리즘은 실제로 디지털 신호처리 프로세서를 이용하여 효율적으로 이용될 수 있을 것이다.

참 고 문 헌

1. 최규식, “임상 생리학”, 대학서림, pp. 343-435, 1999
2. D.S.L.Lloyd, C.D.Binnie, and B.G.Batchelor, “Pattern recognition in EEG”, *Adv. Behav. Biol.* Vol. 5, pp. 153-159, 1972
3. F.H.Lopes Da Silva, A.Dijk and H.Smits, “Detection of nonstationarities in EEGs using the Autoregressive model. An application to EEGs of Epileptics”, *Circ. Computerized EEG analysis*, pp. 180-199, 1975.
4. B.I.K.Davey, W.R.Fright, G.J.Carroll, and R.D.Jones, “Expert system approach to detection of epileptiform activity in the EEG”, *Medical and Biological Engineering and Computing*, pp. 365-370, July, 1989
5. Patrik Wahlberg and Goran Salomonsson, “Feature extraction and Clustering of EEG epileptic Spikes”, *Computers and Biomedical Research*, Vol. 29, pp. 382-294, 1996
6. Feucht M, Hoffmann K, Steinberger K, Witte H, Benninger F, Arnold M, Doering A., “Simultaneous spike detection and topographic classification in pediatric surface EEGs”, *Neuroreport*, No. 8, pp. 2193-2197, July, 1997
7. J.D.Jr.Frost, “Automatic recognition and characterization of epileptiform discharges in the human EEG”, *J. Clin. Neurophysiol.*, No. 2, pp. 231-49, July, 1985
8. Principe J.C., Smith J.R., “Automatic recognition of spike and wave bursts”, *Electroencephalogr Clin Neurophysiol Suppl*, No. 37, pp. 115-32, 1985
9. Guedes de Oliveira P., Quiciroz C., Lopes da Silva F., “Spike detection based on a pattern recognition approach using a microcomputer”, *Electroencephalogr. Clin. Neurophysiol.*, No. 56, pp. 97-103, July, 1983
10. P.Pola, O.Romagnoli, “Automatic analysis of interictal epileptic activity related to its morphological aspects”, *Electroencephalogr. Clin. Neurophysiol.*, No. 46, pp. 227-31, February, 1979
11. T.Kalayci, O.Ozdamar, “Wavelet Preprocessing for Automated Neural network Detection of Spikes”, *IEEE Engineering in Medicine and Biology*, Vol. 14 No. 2, pp. 160-166, March/April, 1995
12. A.J.Gobor, and M.Seyal, “Automated interictal spike detection using artificial neural networks”, *Electroenceph. Clin. Neurophysiol.* Vol. 83, pp. 271-280, 1992
13. S.J.Schiff, A.Aldroubi, M.Unser and S.Sato, “Fast Wavelet Transform of EEG”, *Electroenceph. Clinical. Neurophysiology*. Vol. 91, No. 6, pp. 442-455, 1994
14. W.R.S.Webber, B.Litt, K.Wilson and R.P.Losser, “Practical detection of epileptiform discharges(EDs) in the EEG using an artificial neural network: A comparison of raw and parameterized EEG data”, *Electroencephalogr. Clin. Neurophysiol.* Vol. 91, pp. 194-204, 1994
15. D.ClarenOcon, M.Renaudin, P.Gourmelon, A.Kerckhovec, R.Caterini, E.Boivin, P.Ellis, B.Hille, M.FaiTHome, “Real-time spike detection in EEG signals using the wavelet transform and a dedicated digital signal processor card”, *J. Neurosci Methods*, No. 70, pp. 5-14, December, 1996
16. Metin Akay, “Wavelets in Biomedical Engineering”, *Annals of Biomedical Engineering*, Vol. 23, pp. 531-542, 1995
17. Mattin Vetterli, Jelena Kovacevic, “Wavelet and Subband Coding”, pp. 231-245, 1993
18. 오창석, “뉴로 컴퓨터”, *지성출판사*, pp. 173-225, 1998
19. Fausett D., “Strictly Local Backpropagation”, *IEEE Int. Joint Conf. on Neural Networks*, Vol. 3, pp. 125-130, 1990