

웨이브렛과 신경회로망을 이용한 간질 파형 자동 검출

박현석, 박창현*, 이용희, 이두수, 김선일*
한양대학교 전자공학과
*한양대학교 의용생체공학과

AUTOMATIC DETECTION OF EPILEPTIFORM ACTIVITY USING WAVELET AND ARTIFICIAL NEURAL NETWORK

H. S. Park, C. H. Park*, Y. H. Lee, D. S. Lee and S. I. Kim*
Dept. of Electronics & *Dept. of Biomedical Engineering, Hanyang University

ABSTRACT

This paper describes a multichannel epileptic seizure detection algorithm based on wavelet transform(WT), artificial neural network(ANN) and expert system. First, through the WT, a small number of wavelet coefficients is used to represent the single channel epileptic spike. Next, 3-layer feed-forward network employing the error back propagation algorithm is trained and tested using parameters obtained above. Finally, 16 channel expert system which is based on clinical experience is introduced as a artifact rejection and reliable detection.

The suggested algorithm was implemented on personal computer(PC). Two main events i.e., epileptiform and normal activities, were selected from 32 person's EEGs(normal: 20, seizure disorder: 12) in consensus among experts. The result was that WT reduced data input size and ANN detected 97 of the 100 EEGs containing definite spike - sensitivity of 97%. Expert rule system was capable of rejecting a wide variety of artifacts commonly found in EEG recordings. It also reduced false positive detections of ANN.

서 론

뇌파(Electroencephalography : EEG)는 대뇌 피질의 전기적 활동을 기록한 것으로 뇌의 기능 및 뇌와 관련된 질병을 진단하는데 광범위하게 사용된다. 특히 간질환자의 경우 발작유무추정, 발생부위 진단, 치료효과 판단 등을 모니터링하는데 아주 중요한 임상적 방법이다. 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), 첨파(sharp) 그리고 첨파와 서파를 동반한 복합파(sharp and slow complexes)로 대표된다. EEG 기록상에서 직접 눈으로 이러한 간질 파형들을 찾아낸다는 것은 전문적 지식이 요구될 뿐만 아니라 시간이 많이 소요되는 작업이다. 또한 일반적으로 발작은 드물고 예상치 못하기 때문에 24시간 비디오 EEG와 같은 장시간 뇌

파를 모니터링하는 경우 발작 파형의 자동 검출은 필수적이다[1].

지난 몇 십년동안 간질 활동 파형의 자동해석은 많은 진전이 있어 왔다. 몇 가지 컴퓨터 알고리즘과 프로그램이 개발되었는데 Gotman이 제안한 모방적 방법(mimetic method)이 주로 사용되었다[1]. 이 방법은 극파검출을 위해 먼저 해석하고자하는 파형을 구분(segment)하여 반파(half wave)로 구성한 다음 지속 시간, 진폭, 기울기, 날카로움 등과 같은 파라미터들을 구하고 각 파라미터는 배경 파형의 파라미터와 비교되었다. 이 방법은 아티팩트(artifact)가 없는 경우 좋은 검출 성능을 나타내었으나 근전도(Electromyography : EMG)나 여러 다른 아티팩트가 섞인 파형에 있어서 성능이 저하되는 단점을 가지고 있었다. 또 다른 접근방식으로 신경 회로망을 이용하여 EEG 극파를 검출하는 많은 연구가 진행되어왔다[2][3][4]. 인공 신경망은 규칙을 완전히 수식화 할 수 없는 인식과 분류작업에 매력적인 해결책을 제시하고 출력 문턱치(threshold)를 조절함으로써 각각의 임상 요구를 만족시킬 수 있었다. 그러나 다양한 학습 샘플을 필요로 하고 여러 아티팩트의 제거를 위한 문맥적 정보를 위하여 큰 크기의 윈도우를 씌운 많은 입력 데이터를 필요로 하여 실제 시스템에서는 비현실적인 단점을 갖고 있었다.

본 논문에서는 이러한 신경망의 입력 노드를 줄이고 아티팩트 영향을 줄인 효과적 검출을 위해 웨이브렛과 결합된 신경망과 전문가 시스템을 도입한다. 다양한 윈도우 크기와 시간-주파수 필터링 능력으로 잘 알려진 웨이브렛(wavelet)은 데이터를 축소하고 중요 파라미터를 추출하는데 이용된다. 그리고 추출된 파라미터는 신경망에 적용되어 학습과 테스트를 하고 기존의 실제 데이터를 이용한 신경망과 비교된다. 또한 신경망을 통과하여 얻어진 결론을 바탕으로 전문가 시스템을 도입시킨다. 임상에서의 판독 방법에 기초한 이 전문가 시스템은 주위 인접한 채널의 정보를 바탕으로 일부 아티팩트를 제거하여 자동검출의 정확도를 높이고 발작이 일어난 부위를 추정하는데 효과적으로 이용된다.

본 론

간질 파형 자동 검출 알고리즘 구현을 위하여 먼저 채집 분류된 데이터는 극파형태의 신호를 분리하기에 용이한 다해상도(multiresolution)특성을 가진

웨이브렛 변환을 거쳐 필요한 파라미터들을 추출하게 된다.

○ 웨이브렛 변환과 파라미터 추출

웨이브렛 변환은 해석 하고자하는 신호를 모 웨이브렛(mother wavelet)의 스케일 계수(scale coefficient)와 천이 계수(shift coefficient)로 표현하며 다양한 윈도우 크기를 가져 비정상(nonstationary) 신호의 해석에 주로 이용된다.

$$W_f(a, b) = \int_{-\infty}^{\infty} x(t)\psi_{ab}(t)dt \quad (1)$$

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$$

$\psi(t)$: 모 웨이브렛 a : 스케일 계수 b : 천이 계수

식 (1)에서와 같이 원 신호는 스케일 a가 작을 경우 축소된 웨이브렛인 높은 주파수로 표현되고 클 경우 확장된 웨이브렛의 저주파로 표현된다. 이러한 웨이브렛 이론은 여러 수학자들에 의해 dyadic 구조의 필터와 다운 샘플링을 이용한 이산 웨이브렛 변환(discrete wavelet transform)으로 전개되었고 그 이후 많은 연구가 이루어 졌다. 일반적인 이산 웨이브렛변환은 웨이브렛 함수와 스케일 함수를 시변 입력 신호와 곱하여 주파수 영역의 고주파와 저주파로 분할하는 필터 뱅크를 이용하여 구현된다.

$$\phi(n) = \sqrt{2} \sum_{k=0}^N c(k)\phi(2n-k) \quad (2)$$

$$\psi(n) = \sqrt{2} \sum_{k=0}^N d(k)\psi(2n-k) \quad (3)$$

식 (2)와 (3)에서 c(k)와 d(k)는 각각 스케일 함수와 웨이브렛 함수로서 완전 복원(perfect reconstruction) 조건을 만족하는 QMF(Quadrature Mirror Filter) 쌍이다. c(k)는 저역 통과 필터와 같은 역할을 하고, d(k)는 고역 통과 필터와 같은 작용을 한다. 신호는 각 함수들의 계수에 의하여 주파수 분할이 이루어지기 때문에 해석 신호의 특성을 고려한 모 웨이브렛의 선택이 중요하다.

본 연구에서는 여러 기존의 모 웨이브렛들을 테스트하여 간질 파형의 주파수 대역에서 그 특성을 가장 잘 나타내는 다비치(daubechies) 4-탭 웨이브렛을 적용하였다. 그림 1은 극파를 중앙에 위치시킨 2초간 데이터(512포인트)의 6 레벨 웨이브렛 전개를 나타낸 것이다.

그림 1에서와 같이 간질 파형은 웨이브렛 전개시 거의 전 레벨의 웨이브렛 계수에 걸쳐 나타나지만 특히 레벨 3, 4의 웨이브렛 계수 부분에서 가장 뚜렷이 나타남을 볼 수 있다. 이것은 8-32Hz 대역으로 간질 파형의 주 분포구간이다. 간질 활동 파형의 데이터는 이러한 극파를 해석 윈도우상의 중앙에 위치시킨 데이터를 웨이브렛 전개하고 각 레벨마다 파라미터의 수가 조절되어 축소되고 신경회로망에 적용된다.

○ 신경회로망과 전문가 시스템

신경회로망은 여러 가지 패턴 인식과 분류에 있어서 많이 이용된다. 본 논문에서는 극파와 다른 정상





그림 1. 극파의 Daub-4 tab 웨이브렛 전개

활동 파형의 분류를 위하여 일반적으로 잘 알려진 역전파 학습 알고리즘(back propagation learning algorithm)을 이용한 3단 순방향 망(3-layer feedforward network)을 이용한다. 활성화함수(activation function)로는 시그모이드(sigmoid) 함수를 사용하고 간질활동 파형과 정상 활동 파형의 이벤트는 각각 1과 0으로 표현되어 학습 된다. 학습된 신경회로망은 일반적으로 임상적 판독 방법에 기초한 전문가 시스템이 적용되어 효율적인 검출을 하게 된다. 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 일어났을 때 확실한 간질 파형으로 판단하여 발작 부위를 추정하는 규칙에 기초한 것이다. 그림 2은 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 Time 구간에서 신경망의 출력을 이용한 전문가 시스템의 의사코드(pseudo-code)를 작성한 것이다. 이것은 EMG나 단채널의 아티팩트를 제거하여 신경망의 오류를 보완하며 정확한 결론을 내리게 된다.

실험 및 결과

○ 데이터 채집 및 분류

본 연구에서 이용된 EEG 데이터는 한양대학병원 신경과 뇌파실에서 판독결과 간질로 진단 받은 12명의 환자(남자: 6 여자: 6)와 진단 결과 정상으로 나타난 20명의 환자(남자: 13, 여자: 7)로부터 채집하였다. 간질환자의 평균 연령은 15.5세, 정상인의 평균 연령은 38.2세이다. 전극은 10-20 전극배치도에 의해 부착하고 16채널의 쌍극 몽타주와 기준 몽타주를 이용하였다. 데이터는 Nihon Kohden EEG 모니터링 시스템의 앰프 출력단자에 16채널 데이터 캡처 보드인 DT2821(Data Translation)을 장착한 개인용 컴퓨터를 연결하여 12bits/sample 해상도로 256Hz 샘플링하여 얻었다. 16채널 EEG는 0.1-70Hz 대역 통과(band pass) 필터와 60Hz 대역 저지(band stop) 필터를 거쳐 민감도(sensitivity) 7 μ V/mm로 증폭되어 디지털화된 데이터이다. 이 데이터는 두명의 EEG 판



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 2. 기준 몽타주에 의한 Rule Base 시스템

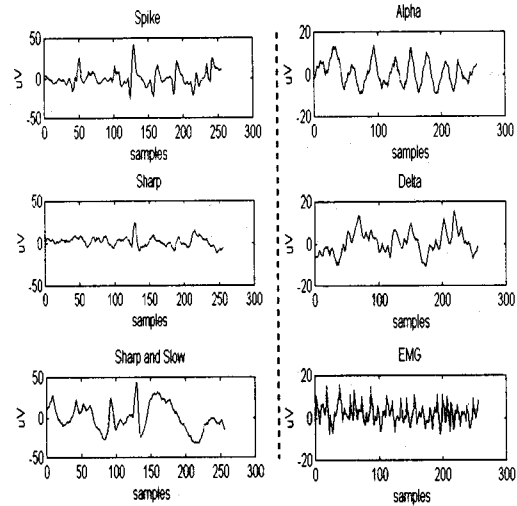
독사로부터 검토되어 2개의 주요 EEG 활동으로 분류되었다. 하나는 간질활동파형(극파, 첨파, 복합파)이고 또 하나는 다른 정상활동 파형이다. 간질활동파형의 경우 극파를 해석 윈도우상의 중앙에 위치시킨 1초간 데이터인 256샘플의 300개 파일을 만들고 정상활동 파형의 경우 임의의 점을 중앙에 위치시킨 256 샘플의 720개의 파일을 만들었다. 그림 3은 분류된 파형의 일부를 보여준다.

○ 구현 및 결과

분류된 파형들은 웨이브렛 변환을 거쳐 레벨 2, 3, 4, 5에서 각각 중앙을 기준으로 8, 16, 8, 8개의 웨이브렛 계수를 추출하였다. 이렇게 추출된 43개 이외의 부가적 파라미터로 원래 신호 256포인트의 평균 파워(average power)와 간질 파형의 주 분포 주파수 대역인 레벨 3에서 웨이브렛 계수의 평균 파워가 계산되었다. 이렇게 구해진 45개의 파라미터는 0과 1사이로 스케일링(scaling)되어 신경회로망의 학습과 테스트에 이용되었다.

신경회로망의 입력 층(input layer) 개수는 45개, 은닉층(hidden layer) 개수는 7개, 출력 층 개수는 1로 하여 전체 학습데이터의 평균 자승 오차(mean square error)가 0.01이하가 될 때까지 학습하였다. 성능 비교를 위하여 실제 데이터가 0과 1사이의 값으로 스케일링 한후 입력으로 취하는 신경 회로망도 전개 시켰다. 비교 신경회로망은 입력 층 개수 256, 은닉층 개수 15, 출력층 개수 1이고 학습 한계치는 동일하게 주었다. 전체 분류된 720개의 파일 중 620개(간질활동파형: 200개, 정상파형: 420개)의 데이터가 학습데이터로서 임의로 선택되고 나머지는 테스트 데이터(간질활동파형: 100, 정상파형: 300)로 이용되었다.

표 1과 표 2는 웨이브렛 전처리를 거친 신경망과 실제 데이터를 이용한 신경망의 학습 데이터와 테스트 데이터에 대한 분류 정확도를 각각 나타낸 것이다. 문턱치(threshold)는 Webber가 제안한 0.65를 이



(a) 간질활동파형 (b) 정상활동파형
그림 3. 분류된 데이터의 예

용한 경우를 나타내고 임상의의 스타일에 따라 출력의 문턱치의 값을 조정할 수 있었다[3]. 정확도의 비교는 감도(sensitivity)와 선택도(selectivity)로서 비교하였다. 감도와 선택도의 정의는 다음과 같다.

$$\text{감도 (Sensitivity)} = \frac{n(\text{ANNOT})}{n(\text{ED})} \times 100$$

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

n : 개수

ED : 간질 활동 파형

ANNOT : 신경망이 찾아낸 간질파형

문턱치 = 0.65	학습된 데이터	테스터 데이터
감도(Sensitivity)	100%	97%
선택도(Selectivity)	100%	89.5%

표 1. 웨이브렛 전처리를 거친 신경망

문턱치 = 0.65	학습된 데이터	테스터 데이터
감도(Sensitivity)	100%	95%
선택도(Selectivity)	100%	91.3%

표 2. 실제 데이터를 이용한 신경망

신경회로망에 웨이브렛 전처리 이용함으로써 실제 데이터가 입력으로 사용된 신경망에 비하여 입력노드의 개수를 5.7배 감소시켰고 실제 데이터의 신경망보다 높은 감도를 얻을 수 있었다.

마지막으로 학습된 신경망을 이용하여 실제 16채널 데이터에 대한 전문가 시스템을 적용하였다. 전체 화일에 대해 5초간 16채널 디스플레이 화면상의 기준 몽타주의 EEG를 대상으로 하였으며 각 채널 처음 256포인트(1초간 데이터)부터 시작하여 2 포인트 옮겨가며 마지막 256포인트까지 신경회로망을 통과하고 16채널 전문가 시스템을 적용시켰다. 그림 4는 개발된 프로그램으로 간질환자로 판명된 12세 남자 데이터에 대하여 검출을 수행한 결과의 일부를 나타낸다. 그림은 1.75초에서 오른쪽 반구(hemisphere)의

C4-P4에서 극파가 검출되고 3.6초에서는 F4, F8로 확장되어 검출된 결과를 보여준다. 이러한 전문가 시스템을 적용시킴으로써 전처리를 거친 신경망의 민감한 검출 결과에 대한 잘못된 검출을 보정할 수 있었다. 그리고 실제 데이터가 입력 파라미터로 주어진 신경망의 경우 학습이 잘 이루어지지 않은 간질 파형 검출의 정확도가 떨어졌지만 전처리를 통한 신경망은 전문가 시스템으로 향상된 검출이 가능하였다.

결론

웨이브렛과 신경회로망, 전문가 시스템을 이용하여 16 채널 간질파형 자동 검출을 수행하였다. 웨이브렛 전처리 과정을 거침으로써 실제 데이터를 이용할 때 보다 입력노드를 줄일 수 있었고 보다 향상된 감도를 얻을 수 있었다. 그리고 인접 채널의 연관성을 바탕으로 한 전문가 시스템을 이용함으로써 더욱 신뢰성있는 검출성능으로 구현할 수 있었다. 임상치의 판독방법에 기초한 이 방법은 근전도, 전극 등으로 인한 아티팩트를 영향을 제거하여 단 채널에서의 오류를 수정·보완할 수 있었다. 이러한 실제 파형의 특성을 고려한 전처리와 신경회로망, 그리고 임상치의 경험을 바탕으로 한 이 알고리즘은 실제로 디지털 신호처리 프로세서를 이용하여 효율적으로 이용될 수 있을 것이다.

참고 문헌

- [1] J. Gotman, "Automatic recognition of epileptic seizures in the EEG", *Electroenceph. and clinical Neurophysiology*, 54, pp. 530-540, 1982
- [2] 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 clinical Neurophysiology*, 91, pp. 194-204, 1994
- [3] W. R. S. Webber, Ronald P. Lesser, Russel T. Richardson, Kerry Wilson, "An approach to seizure detection using an artificial neural network", *Electroenceph. and clinical Neurophysiology*, 98, pp. 250-272, 1996
- [4] Tulga Kalayci and Ozcan Ozdamar, "Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes", *IEEE Eng. in Med. and Biology*, March/April, pp. 160-166, 1995



그림 4. 웨이브렛 전처리 신경망과 전문가 시스템을 적용한 간질파형 검출