

LVQ 신경망을 이용한 간질 파형검출

최혜원, 윤영로, 이성수*

연세대학 보건과학대학 의용전자공학과,

*연세대학 원주의과대학 신경과

The Detection of Interictal Epileptic Waveform Using LVQ Network

H.W.Chi, Y.R.Yoon, S.S.Lee

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

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

ABSTRACT

In this paper, we present the detection algorithm of interictal epileptic waveform using LVQ network and wavelet transform. First wavelet coefficients is used to represent the characteristics of a single channel EEG wave, and make a number of neural network input node smaller. Then, three-layer neural network employing LVQ network is trained and tested using parameters obtained from the first stage. This study showed that preprocessed EEG data can be successfully used to train ANNs to detect epileptogenic discharges with a high success.

서 론

EEG(electroencephalogram)은 뇌파는 대뇌 피질의 전기적 활동을 측정하여 뇌의 기능적 결합을 관찰할 수 있도록 해주는 것으로 뇌의 기능 및 뇌와 관련된 질병을 진단하는데 광범위하게 사용된다. 특히 간질 환자의 발작 유무추정, 발생부위 진단, 치료효과판단 등을 모니터링 하는데 아주 중요한 임상적 방법이다. 간질은 신경세포의 일부가 짧은 시간동안 과도한 전기를 발생시킴으로서 일어나는 신경계의 발작적 증상이다. 이러한 환자의 EEG특성은 배경활동파와는 구별되는 극파(spike), 예파(sharp), 예파와 서파를 동반한 극서파 복합파(sharp and slow complexes)로 대표된다. 장시간의 EEG기록에서 직접 간질파형을 찾는 것은 전문적인 지식이 요구될 뿐만 아니라 시간이 많이 소요되는 단순 반복적 작업이다. 또한 주관적인 판단으로 인해 같은 EEG기록에 대한 다른 의견이 가능하다. 따라서 컴퓨터를 이용한 간질파형의 자동 검출은 객관성을 높이고 정량적인 해석을 위해 필수적이다.

지난 수십년간 간질 활동 파형의 자동 검출은 많은 진전이 있어왔고, 최근에는 인공신경망 및 웨이브렛을 이용하여 EEG극파를 검출하는 많은 연구가 진행되어 왔다. 신경망은 규칙을 완전히 수식화 할 수 없는 인식과 분류작업에 해결책을 제시하고 출력 문턱치값을 조절함으로서 다양한 임상적 요구를 만족시킬 수 있다.

본 논문에서는 웨이브렛으로 전처리하여 간질특징파의 특성을 입력시키며, 동시에 입력노드수를 줄이고,

신경망중 하나인 LVQ를 이용하여 데이터를 학습시킨후 조사하였다.

본 론

1. EEG에서의 극파 및 극서파

EEG극파는 뾰족한 피크와 35-70ms의 지속시간을 갖는 배경파형과 명확히 구분되는 일시적 파형으로 정의하고 있다. 극파는 독립적으로 일어날 수도 있지만 종종 150-300ms동안 지속되는 서파가 동반하여 극파와 서파의 복합파를 형성한다. 그림 1은 EEG의 기본 활동파형과 간질파형의 형태를 보여준다.

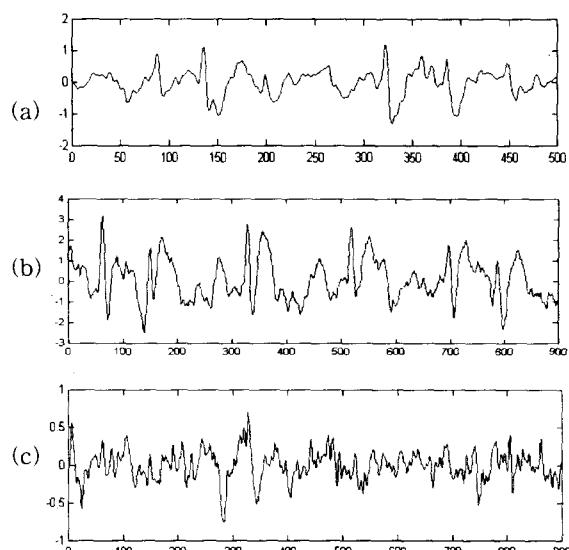


그림 1. EEG 파형

(a) 극파 (b) 극서파 복합파 (c) 배경파형

2. LVQ 네트워크

비지도방식의 경쟁학습을 지도방식으로 수정한 Learing Vector Quantization(LVQ)는 고전적인 Vector Quantization(VQ) 방식을 도입한 알고리즘으로 Kohonen에 의해 제안되었다. VQ는 이전부터 알려진 패턴분류 기법이며 패턴공간을 유한개의 참조벡터(reference vector)로 양자화하는 것이다. LVQ는 이러한 VQ기법을 발전 시킨 것으로서 참조벡터를 뉴런들간의 가중치 벡터에 대응시키고 지도학습을

이용함으로써 적절한 참조 벡터를 구하는 방법이다. 식 1의 학습 규칙에서 보는 바와 같이 입력벡터가 올바르게 분류되었을 때와 그렇지 않은 경우로 나누어 학습을 진행한다.

$$\begin{aligned} w_c(t+1) &= w_c(t) + a(t) \cdot [x(t) - w(t)] \\ &\text{if } x \text{ is classified correctly} \\ w_c(t+1) &= w_c(t) - a(t) \cdot [x(t) - w(t)] \quad (1) \\ &\text{if the classification of } x \text{ is incorrectly} \\ w_c(t+1) &= w_c(t) \quad \text{for } i \neq c \end{aligned}$$

LVQ네트워크의 구조는 2개의 층으로 구성되는데, 첫 번째 층은 경쟁식층이고, 두 번째 층은 선형층이다.

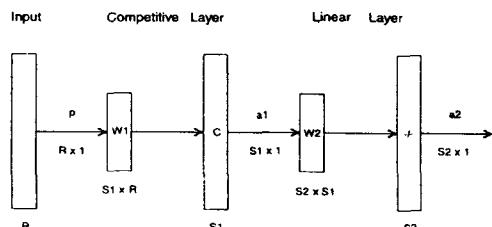


그림 2. LVQ 네트워크 구조

3. 웨이브렛

웨이브렛 변환은 웨이브렛 함수와 스케일 함수를 시변 입력 신호와 곱하여 주파수 영역에서 고주파와 저주파로 주파수 분할을 하게 된다.

$$\begin{aligned} \Psi(n) &= \sum_k h(k) \Phi(2n-k) \\ \Phi(n) &= \sum_k g(k) \Phi(2n-k) \quad (2) \end{aligned}$$

(Ψ : 웨이브렛 함수, Φ : 스케일 함수)

위의 식에서 $h(k)$ 는 웨이브렛 함수의 계수로서 고주파 통과 필터 계수와 같은 역할을 하며 $g(k)$ 는 스케일 함수로써 저주파 통과 필터의 계수로써 작용을 한다. 각 함수들의 계수에 의해서 주파수 분할이 이루어지기 때문에 뇌파 분석에 유용한 모 웨이브렛을 선택하기 위한 모 웨이브렛의 특성이 중요하다.

4. 실험 결과 및 고찰

1) 데이터 수집 및 분류

본 연구에서 이용된 EEG데이터는 원주기독교병원 신경과 뇌파실에서 판독결과 간질로 진단 받은 6명의 환자로부터 선택되었다. 전극은 10-20 전극 배치도에 의해 부착하였고 데이터는 Nihon Kohden EEG 모니터링 시스템의 출력단자에서 National Instrument DAQ board AI-16Ex-50 E Series를 사용하여 12bits 해상도, 300 Hz로 샘플링하여 얻었다. 받아진 16 채널 데이터는 웨이블렛을 통하여 3 레벨 웨이블렛 전개하였다. 측정된 데이터는 두명의 간질 전문 판독사로부터 검토되어 3개의 주요 EEG활동인 간질극파, 간질 극서파 복합파, 비간질성파의 3가지로 분류된다. 각 데이터는 극파를 중심으로 극파의 앞 15 포인트와 뒤 90 포인트로 구성되었다. 이 크기는 350msec에 해당하는 크기로, 간질 특성파의 크기를 담을 수 있는 크기이다.

2) 실험

연속된 데이터가 입력되면 3 레벨 웨이블렛 전개후

신경망의 입력으로 넣는다. LVQ 네트워크를 거쳐서 승리한 뉴런이 현재 데이터의 입력을 상태를 출력한다.

5. 결 과

LVQ네트워크를 사용한 검출법의 유용성을 조사하기 위하여 학습에 사용되지 않은 임의로 추출된 10초간의 데이터로 입력되었다. 대부분의 경우 LVQ네트워크 웨이브렛은 정확하게 분류하였다.

학습에 사용된 데이터는 극파 200개, 극서파 100개의 총 간질 특성파 300개와 근전도 노이즈를 포함하는 간질의 데이터 600개로 구성되었다. 테스트데이터는 407개의 데이터를 포함하는 임의의 데이터를 입력시켰다. 검출성능을 평가하기 위해서 민감도와 선택도를 정의하였다. 민감도와 선택도에 대한 정의는 식 (3) 와 식(4)과 같다.

$$\text{민감도} (\text{Sensitivity}) = \frac{n(\text{ANNOT})}{n(\text{ED})} \times 100 \quad (3)$$

$$\text{선택도} (\text{Selectivity}) = \frac{n(\text{ANNOT} \cap \text{ED})}{n(\text{ANNOT})} \times 100 \quad (4)$$

n: 개수, ED: 간질활동 파형

ANNOT: 찾아낸 간질 파형

표 1

	Trainig data	Test data	Total data
Visual score	300	407	707
LVQ score	268	351	619
Matching	207	272	479

표 2

민감도	87.6%
선택도	77.4%

결 론

본 논문에서는 웨이블렛을 사용하여 다른 잡음과 제거하고 신경망의 입력데이터 수를 줄이며, LVQ 네트워크의 사용으로 학습시간을 줄였다. 앞으로 많은 수의 데이터로 학습된다면 성능이 더욱 향상될 것이다.

참 고 문 헌

1. Carlos E.D'attellis, Susana I., "Detection of epileptic events in Electroencephalograms Using Wavelet Analysis", Annals of Biomedical Eng., vol 25, pp 286-293, 1997
2. Gotman J.and Wang L.Y., "State dependent spike detection:Validation", Electroencephalogr.clin.Neurophysiol., vol. 83, 12, 1992
3. O.Ozdamar and T.Kalayci,"Detection of spikes with artificial neural networks using raw EEG", Comput. and Biomed, vol. 31, 122-142, 1998