

청각 자극에 의해 유발되는 뇌파신호의 분석

*이동한, 김재욱, 이종호
인하대학교 전기공학과

Analysis of EEG Signal Evoked by Auditory Stimulation

*Dong Han Lee, Jae Wook Kim, Chong Ho Lee
*Dept. of Electrical Eng., INHA University

Abstract - 본 논문은 청각 자극이 제시되었을 때 변화되는 뇌파로부터 의미 있는 특징을 찾아내서 정량화 할 수 있는 변수 추출 및 분류 기법을 제시한다. 건강한 피실험자로부터 방향성 있는 청각 자극을 인가했을 때의 뇌파를 검출, 분류하였다. 뇌파의 변수 추출 방법으로는 짧은 시간영역에서의 신호의 갑작스런 변화량도 정량적으로 분석할 수 있는 Mallat's Algorithm을 이용한 웨이블릿 변환(wavelet transform)을 적용하였고, 분류 방법으로는 그 결과로 나온 웨이블릿 계수를 변수로 하여 Neural Network을 학습하여 사용하였다. 향후 피실험자의 훈련을 통해서 청각 자극이 없이 순수한 생각만으로 방향을 검출할 수 있는 뇌파분석기를 만든다면 생각만으로도 물체의 방향을 제어할 수 있을 것이다.

1. 서 론

뇌파(Electroencephalogram, EEG)는 대뇌에서 발 생되는 전위를 대뇌피질(cerebral cortex), 또는 머리표면(intact scalp)에서 기록하는 방법으로서, 인간의 정서 상태를 나타내는 대표적인 신호라 할 수 있다. 이러한 뇌파는 피험자의 상태에 따라서 특정 주파수범위를 갖는 δ 파(4Hz이하), θ 파(4~8Hz), α 파(8~13Hz), β 파(13Hz이상)형을 나타낸다.

이렇게 어떤 정서 상태에 따라 변화되는 뇌파의 패턴을 분류하기 위한 방법으로는 다음과 같은 방법이 있다 (그림 1). 먼저 원 신호로부터 특징 있는 변수를 추출한다. 추출된 변수는 분류 작업을 간편화하기 위해 차원을 줄여야 되며, 그 변수로부터 분류작업을 실행하게 된다.

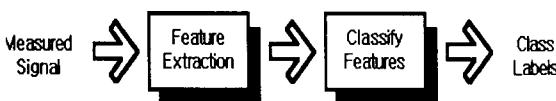


그림1 The classification problem

본 논문에서는 변수 추출방법으로 Time-Frequency 분석의 일종으로서 EEG신호의 변화량을 시간대역과 주파수대역에서 규명하기 모호한 부분의 정보량들을 분석, 정량화 하기에 좋은 웨이블릿 변환을 적용하였고, 분류 작업은 학습을 통해 weight를 변화시켜 분류를 가능케 하는 artificial neural network를 사용하였다.

2. 본 론

2.1 Multiresolution Analysis : the discrete wavelet transform

신호 변환의 주목적은 검출된 신호로부터 적절한 정보를 추출하여 그 신호를 처리, 분석하기 위함이다. 신호

의 주파수 특성을 분석하기 위한 변환으로 여러 가지가 있으나, 가장 대표적인 방법이 푸리에 변환(Fourier Transform)이다. 그러나 신호가 뇌파 신호와 같이 시간에 따라 갑작스럽게 변화하는 nonstationary 데이터의 경우 푸리에 변환은 적합하지가 않다. 웨이블릿 변환은 기저함수를 변이 시키고, 확대, 축소시킴으로써 정보의 손실 없이 신호를 해석할 수 있다. 아래에 웨이블릿의 기본 식을 나타냈다.

$$W(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt \quad (1)$$

다중해상도 웨이블릿 변환은 웨이블릿 함수를 정규직교 기저에서 적용함으로써 주이진 신호의 특성을 분해하여 나타내는 알고리듬이라 할 수 있다. 즉, 나무 구조처럼 높은 해상도의 계수들로부터 낮은 해상도의 계수들을 계산할 수 있으며, 이를 필터 뱅크라고도 부른다. 분해과정은 그림 2에 나타냈으며, 식은 다음과 같다.

$$c_j(n) = \sum_{k=0}^{N-1} h(k-2n) c_{j+1}(k) \quad (2)$$

$$d_j(n) = \sum_{k=0}^{N-1} g(k-2n) c_{j+1}(k) \quad (3)$$

j : Decomposition level
 $h(n)$: Lowpass filter coefficient
 $g(n)$: Highpass filter coefficient

즉, 낮은 해상도의 계수들은 높은 해상도의 계수에 $h(-n)$ 의 lowpass filter와 convolution한 후 1/2로 decimate해서 구한다.

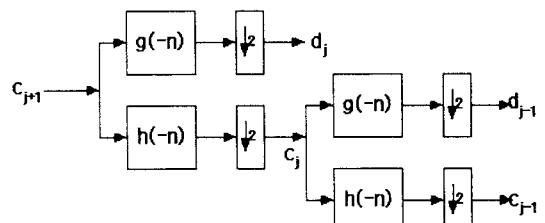


그림2 Two-band analysis bank

이와 같이 웨이블릿 필터에 의해 분할된 고주파 신호 성분과 저주파 신호 성분들은 웨이블릿 필터를 반복적으로 사용함에 따라 더욱 정밀한 필터 뱅크로 구성된다.

만일 원 신호가 128Hz로 sampling되었다면, Nyquist rule에 의한다면 원 신호의 최대주파수는 64Hz가 된다. 이 신호를 웨이블릿 필터 뱅크로 5 level로 분해해 나간다면 그림 3과 같은 모습으로 된다. 즉, 뇌파에서는 32~64Hz, α 파와 β 파, θ 파, δ 파로 분해된다.

주파수 해상도면에서는 Detail level 5에서 가장 높으며, 시간 해상도면에서는 level이 높아질수록 1/2로 downampling되기 때문에 Detail level 1에서 가장 높다.

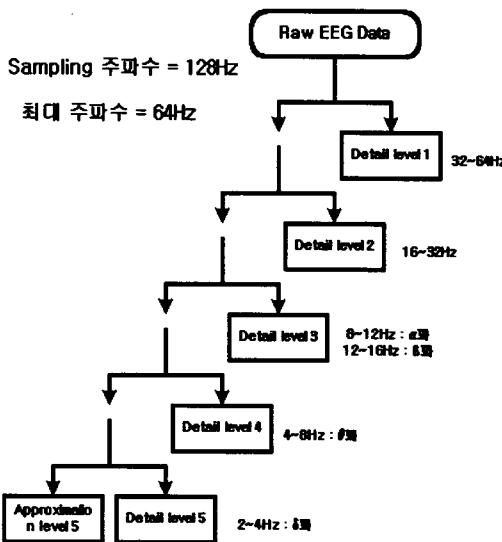


그림3 EEG 신호의 분할 과정

2.2 Artificial Neural Network

인간의 두뇌 구조를 모방한 신경망이 한동안의 침체기를 벗어나 그 중흥기를 맞이하는데 큰 기여를 한 것들을 들자면 역전파 학습 알고리즘을 빼놓을 수 없다. 역전파 학습은 감독 학습 알고리즘이라서 주어진 입력 값에 대한 목표 값이 필요하다. 이 알고리즘의 기본적인 개념은 주어진 목표 값과 입력 값 사이의 오차를 최대한 줄이는 것이다. 여기서의 오차는 다음과 같이 나타난다.

$$E = \sum_{j=0}^N (t_j - O_j)^2 \quad (4)$$

t_j : 신경망의 총 N개의 출력뉴런 중 j번째 목표 값
 O_j : 출력뉴런 중 j번째의 실제 출력 값

위에서 보듯이 역전파 알고리즘은 주어진 입력에 대해 신경망을 통과한 출력이 최대한 목표 값과 가까운 값을 가지기 위해 E값을 점차적으로 줄여나가는 Gradient descent 알고리즘을 이용한 것이다. 역전파 알고리즘의 신경망 내부의 뉴런간의 weight들은 다음의 식에 따라 오차를 줄이는 방향으로 갱신된다.

$$\Delta W_{ij} \propto -\frac{\partial E}{\partial W_{ij}} \quad (5)$$

그리고 그 식은 다음과 같이 변할 수 있다.

$$\Delta W_{ij}(n) = \alpha W_{ij}(n-1) + \eta \delta_i(n) O_j(n) \quad (6)$$

η : 학습율, α : 관성율

위 식에서 보듯이 역전파 알고리즘은 입력 값과 목표 값이 적절한 대응을 이루어져야지만 올바른 결과를 얻어낼 수 있다. 이러한 적절한 쌍을 이를 신경망을 가지고 학습을 한다면 학습에 사용되지 않은 임의의 데이터에

대해서도 믿을만한 출력 값을 나타내주므로 EEG의 웨이블릿 계수도 내재시킬 수 있다는 것이다.

2.3 EEG신호의 변수 추출과 분류

EEG 신호의 분류 방법은 다음과 같은 단계를 가진다.

- 신호의 전처리 - EEG 신호를 다중해상도 웨이블릿으로 분할한 다음 나온 계수들을 변수로서 사용한다.
- 전처리 과정에서 나온 변수들은 artificial neural network의 입력이 되며, 학습에 의해 뇌파의 상태를 분류하게 된다.

EEG 신호의 데이터 수집은 128Hz로 sampling했으며, 전극은 primary auditory cortex부위인 T3, T4, T5, T6에서 뇌파 신호를 추출하였다. 청각 자극 방법은 그림4에서와 같이 10초간의 휴식기를 거쳐 5초 동안 무작위의 원쪽 청각자극 또는 오른쪽 청각 자극을 제시한다. 청각자극으로는 22kHz로 샘플링된 5초 동안의 stereo wav파일로서 청동소리가 사용되었다. 또한 시각에 대한 영향을 비교해 보기 위해 눈을 떴을 때와 감았을 때의 청각 자극에 대한 상태도 비교해 보았다.



그림4 청각 자극 방법

수집된 데이터는 그림3과 같은 다중해상도 웨이블릿 변환을 통해 5 단계로 분할되어지며, 그 중에서 의미 있는 Detail level 3, 4, 5의 데이터만 변수로서 쓰이게 된다. Detail level 3, 4, 5의 데이터는 그림3에서와 같이 α 파와 β 파, θ 파, δ 파를 나타낸다. 각 level에서의 데이터들은 1초 길이로 segment를 만든다. 각 segment들은 Neural Network의 입력으로 쓰이며, 전파 정류된 Detail신호 성분의 에너지를 절대값의 평균(Mean Absolute Value)으로 나타낸 것이다. 즉, Detail level 5 데이터의 경우, segment값은 1초에 $128/2^5$ 의 데이터 개수가 나오고, $128/2^5$ 개의 데이터를 합한 후 $128/2^5$ 로 나눈 값이 된다.

각 전극마다 3개의 변수(detail level 3, 4, 5)가 나오게 되고, 실험에 쓰이는 전극은 4개이므로 총 12개의 변수가 나오게된다. 이 12개의 변수는 신경회로망의 입력으로 쓰이게 된다.

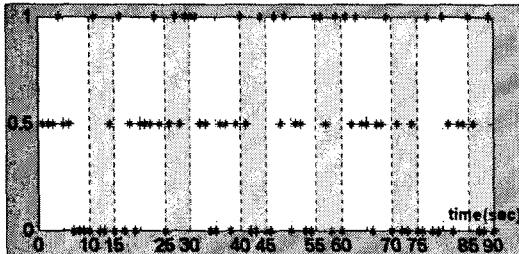
신경회로망은 일반적인 역전파 학습 알고리즘을 사용하였으며, 12개의 input neuron과 1개의 output neuron, 3 layer를 사용하였다. 학습율과 관성을 변화시켜 가면서 최소의 에러가 나오도록 학습을 시킨다. 원쪽 청각 자극에 대한 목표 값은 '0'으로 학습시키고, 오른쪽 청각 자극에 대한 목표 값으로는 '1'로 나타내게 하여 학습을 시키게 된다. test용 data로 학습이 끝난 network를 simulation을 하게 되면 오른쪽도 원쪽도 아닌 값들도 있기 때문에 '0.95' 미만의 값과 '0.05' 초과의 값들은 중립상태인 '0.5'의 값으로 지정을 해 주도록 threshold를 만든다.

3. 실험 결과 및 결론

다중해상도 웨이블릿 변환은 daubechies 6 웨이블릿을 사용하였고, Network 학습은 test data로 2000 iteration 학습시켰으며, MSE(Mean Square Error)

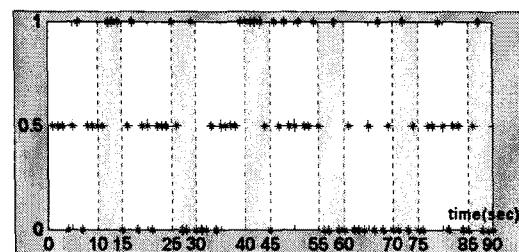
는 눈을 떴을 때 0.000143, 눈을 감았을 때 0.000132가 나왔다. 청각자극 순서와 그에 대한 실험 결과 그래프는 그림5에 표시하였다.

청각 자극 초	10~ 15	25~ 30	40~ 45	55~ 60	70~ 75	85~ 90	100~ 105	115~ 120	130~ 135	145~ 150
눈을 떴을 때	왼쪽	오른 쪽	왼쪽	오른 쪽	왼쪽	왼쪽	오른쪽	왼쪽	오른쪽	왼쪽



a. 눈을 떴을 경우

청각 자극 초	10~ 15	25~ 30	40~ 45	55~ 60	70~ 75	85~ 90	100~ 105	115~ 120	130~ 135	145~ 150
눈을 감았을 때	오른 쪽	왼쪽	오른 쪽	왼쪽	왼쪽	왼쪽	오른쪽	왼쪽	왼쪽	왼쪽



b. 눈을 감았을 경우

그림5 Test data로 simulation해본 결과

그림5를 보면 처음 10초간은 휴식기의 상태로서 '0.5'의 값을 나타내며, 다음 5초간은 방향성 있는 청각자극의 상태로 '0'(왼쪽) 또는 '1'(오른쪽)의 값을 나타내는 성향을 보인다. 위 그래프를 표1에 나타냈다.

눈을 감았을 때 왼쪽은 71.4%, 오른쪽은 66.67%를 제대로 분류하였고, 눈을 떴을 때의 경우 왼쪽은 63.3%, 오른쪽은 50%를 제대로 분류하였다. Primary Auditory cortex 부위의 전극만을 검출했다 하더라도 시각에 대한 외부 자극이 청각에도 약간은 작용을 하였기 때문에 감았을 때의 분류가 훨씬 잘 되었다. 그림5에서 청각 자극이 끝난 뒤의 휴식기 경우에도 자극의 잔상이 남기 때문에 휴식기에도 전 청각 자극의 영향을 받아 휴식기에 해당하는 '0.5'의 값만 나오지 않고 이전의 청각 자극 값들이 간간이 나오게 됨을 알 수 있다.

본 논문에서는 웨이블릿 변환을 이용해서 non-stationary한 EEG 신호를 전처리 과정으로 실행하였고, 이 방법으로의 변수 추출로 EEG 신호의 분류를 가능케 하였다. 기존의 웨이블릿 함수 알고리즘은

가까운 기저 웨이블릿 함수를 디자인하여 사용한다면 좀 더 신호를 잘 표현할 수 있을 것이고, 또한 실시간으로 데이터 처리가 가능한 웨이블릿 알고리즘을 개발한다면 상태 분류를 끈바로 확인할 수 있는 실시간 분류가 가능할 것이다. 더 나아가 외부의 자극이 없이 순수한 생 각 자체만으로 방향 분류를 가능케 한다면 물체를 생각으로 제어가 가능할 것이다.

표1 EEG 데이터의 분류 결과 표

EEG Class		휴식기	왼쪽	오른쪽
휴식 기	눈을 떴을 때	44/100	31/100	25/100
	눈을 감았을 때	50/100	30/100	20/100
왼쪽	눈을 떴을 때	6/30	19/30	5/30
	눈을 감았을 때	5/35	25/35	4/35
오른 쪽	눈을 떴을 때	5/20	5/20	10/20
	눈을 감았을 때	3/15	2/15	10/15

위의 숫자는 총 150개의 데이터 중에 100개의 휴식기 데이터를 나타낸다. 눈을 감았을 경우 왼쪽 자극은 35개, 오른쪽 자극은 15개를 나타내고, 눈을 떴을 경우 왼쪽 자극은 30개, 오른쪽 자극은 20개를 나타낸다.
(1초에 1개의 데이터가 나온다)

(참 고 문 헌)

- [1] Neep Hazarika, Jean Zhu Chen, Ah Chung Tsoi, Alex Sergejew, "Classification of EEG Signal Using the Wavelet Transform", 1998
- [2] C. Sidney Burrus, Ramesh A. Gopinath, Haitao Guo, "Introduction to Wavelets and Wavelet Transforms", Prentice-Hall, 1998
- [3] 김정환, "웨이브렛 변환을 이용한 청각자극에 의해 유발되는 뇌파의 분석에 관한 연구", 1996
- [4] Chin-Hsing Chen, Jiann-Der Lee, Ming-Chi Lin, "Classification of Underwater Signals Using Wavelet Transforms and Neural Networks", 1997
- [5] Rodrigo Quiroga, "Quantitative analysis of EEG signals: Time-frequency methods and Chaos theory", 1998
- [6] J. Zhu, N. Hazarika, A.C. Tsoi, and A.A. Sergejew, "Classification of EEG Signals Using Wavelet Coefficients and an ANN", Brain Topography, Vol. 7, No 99, 1994
- [7] Robi Polikar, "The wavelet Tutorial", <http://www.public.iastate.edu/~rpolikar/wavelets>