

뇌파 분석을 위한 Empirical Mode Decomposition Algorithm

I. 서론

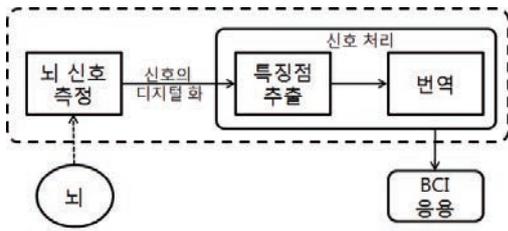
최근 생각에따라 변하는 뇌의 기전을 이용하여 컴퓨터를 컨트롤하고 통신을 하려는 brain-computer interface (BCI) 기술이 대두되고 있다. 특히 뇌의 활동을 측정하는 센서 기술과 신호처리 기술의 발달로 영화에서 보아왔던 텔레파시와 같이 생각만으로 휠체어를 움직이고 컴퓨터에 글자 및 숫자를 입력하는 것들이 조금씩 현실화 되어가고 있다. 이러한 기술들은 특히 척수 및 신경근의 손상으로 인해 사지가 마비된 환자들에게 도움을 주는 재활 목적으로 개발이 되어왔다. 이러한 환자들은 컴퓨터 및 기타 시스템 컨트롤을 위해 눈동자의 움직임이나 호흡의 컨트롤 등을 이용한 재활 장비들을 사용하여왔지만 사지 마비가 매우 심각한 환자들은 이러한 눈동자 및 호흡 컨트롤을 위한 근육 컨트롤 자체가 쉽지 않기 때문에, 특별한 근육의 움직임이 필요 없이 단지 뇌 활동의 변화만을 이용하는 BCI 시스템의 필요성이 더욱 커지고 있다.

뇌의 활동을 비침습적으로 측정하기 위해 다양한 센서 및 진단 장비를 사용하여 왔는데 그중 뇌파 (EEG), 양전자방출단층촬영술 (PET), 기능적 자기공명영상 (fMRI) 등을 예로 들 수 있다. 이들 중 흔히 뇌파라고 불리는 EEG는 작고 가볍게 구현이 가능하여 휴대성이 용이하고 다른 센서에 비해 가격이 저렴하며, 실시간 측정이 가능하여 BCI 시스템 구현에 가장 적합하다고 할 수 있다^[1].

〈그림 1〉은 네 가지 기본 성분으로 이루어진 BCI 시스템의 구조를 나타내고 있다. 먼저 뇌파 신호를 측정하는 뇌 신호 측정 부, 사용자의 지각 및 인지작용 변화에 따라 달라지는 뇌파 신호의 특징을 추출하는 부분, 이러한 특징점을 이용하여 사용자의 지각 및 인지 상태를 판단하는 번역 부분 그리고 BCI 응용 부분으로 나눌 수 있다. 이 중 뇌파 신호를 분석하는 신호처리 부분, 즉 특징점 추출 및 번역 부분이 BCI 시스



박철수
광운대학교 컴퓨터공학과



〈그림 1〉 기본적인 BCI 시스템의 구조

템의 성능을 결정짓는 중요한 역할을 하게 된다. 그런데 현재까지 사용되어지고 있는 신호처리 방법들 중 주파수 성분의 특징점을 추출하기 위해 가장 많이 사용하는 푸리에 분석 방법은 뇌파 신호의 비선형성 (nonlinearity), 비정상성 (nonstationarity) 때문에 지각 및 인지 상태 변화에 따른 뇌파의 주파수 정보를 얻어내는데 문제가 있다^[2]. 푸리에 분석 방법은 선형적인 직교 기저함수 (orthogonal basis function)를 기반으로 하기 때문에 비선형적인 뇌파 신호를 모델링하기 부족하고, 시간에 따라 지속적으로 변하는 뇌파의 주파수 특성 (비정상성)을 효율적으로 모니터링하기에 부족하다. 또한 기존의 신호처리 알고리즘들은 대부분 단 채널 신호를 위한 알고리즘으로 뇌파와 같이 다 채널로 얻어지는 신호의 정보를 모두 함께 고려하여 특징적인 정보를 얻어내지 못한다. 본 글에서는 입력 데이터에 기반하여 기저함수를 만들어 주파수 분석을 하는 empirical mode decomposition (EMD)^[2] 알고리즘을 소개하고 이를 통해 비선형적이고 비정상적인 뇌파 신호로부터 기존의 방법들과 비교하여 더 효율적으로 주파수 성분을 추출해내는 연구에 대해 조사하였다. 더 나아가 다채널 주파수 분석에 맞게 디자인 된 multivariate empirical mode decomposition (MEMD) 알고리즘^[3]에 대해 알아보고 단 채널 알고리즘과 비교하여 향상된 주파수 분석 성능을 확인하였다.

empirical mode decomposition (EMD)은 비선형적이고 비정상적인 뇌파 신호의 분석에 적합한 알고리즘이다.

II. Empirical Mode Decomposition

Empirical mode decomposition은 입력 데이터를 기반으로 특징 성분을 추출하는 방법으로 신호가 지니

고 있는 고유의 정보를 amplitude modulation (AM)/ frequency modulation (FM) 성분으로 분리해 낸다^[2]. 특히 알고리즘은 신호의 선형성 또는 정상성에 대한 어떠한 가정에 기반하고 있지 않기 때문에 더욱 정확한 신호의 특징점을 찾아낼 수 있다.

1. Background

자연과학이나 공학에서 일반적으로 다루어지는 많은 데이터들을 분석할 때 겪는 가장 큰 어려움들은 다음과 같다^[4].

- 짧은 길이의 데이터
- 데이터의 비정상성
- 데이터의 비선형성

일반적으로 신호 분석에서 가장 많이 쓰이는 방법 중 하나인 주파수 스펙트럼 분석은 주로 데이터의 주파수 성분을 추출 및 조사하는 방법으로 대개 푸리에 분석 방법을 이용하여 이루어지고있다. 그러나 푸리에 분석 방법의 기본 가정은 분석하려는 데이터의 길이가 충분히 길어야 하지만 우리가 다루는 데이터들은 종종 이를 만족하기 어려울때가 많고, 짧은 길이 데이터의 시작과 끝에서 발생하는 에러 또한 무시할 수 없다.

또한 신호의 주파수 성분은 시간에 따라 지속적으로 변하는 비정상성을 지니고 있는데, 충분한 길이의 데이터가 필요한 푸리에 분석은 빠르게 변하는 주파수 성분을 정확히 모니터링하기 쉽지 않다. 이를 극복하기 위하여 short-time Fourier transform (STFT) 라는 방법을 이용하는데, 이는 입력 데이터를 짧은 길이의 데이터로 나누고 푸리에 분석을 나누어진 각 데이터에 적용하여 시간에 따라 변하는 주파수 성분을 지속적으로 모니터링 한다. 그러나 이 방법 또한 가장 낮은 주파수 성분을 얻기 위해서는 특정 길이의 데이터가 필요하며 이는 고주파 성분에서의 주파수 변화를 놓칠 수 있다. 또한 여전히 정현파 기반의 기저함수를 사용하여 신호를 모델링하지만 실



제 뇌파 신호는 정현파 신호와 같이 정형화된 패턴을 갖고 있지 않아 분석 오차를 가질 수밖에 없다. 푸리에 분석 이외에 또 다른 주파수 분석 방법으로는 wavelet 분석 방법이 있는데 이는 STFT와 다르게 주파수 영역 별로 입력 데이터의 길이를 조정하여 짧은 길이의 데이터로 분해하고 이를 wavelet 모함수를 이용하여 모델링한다. 따라서 STFT보다는 조금 더 정확한 time-frequency 분석이 가능하다. 그러나 이 분석 방법 역시 wavelet 모함수를 기저함수로 이용하여 입력 데이터와 패턴이 일치할 수 없는 함수로 모델링을 함으로 나타나는 오차를 피할 수는 없다.

2. Intrinsic Mode Function 을 이용한 순시 주파수 예측

순시 주파수 (instantaneous frequency)는 비정상성 뇌파 데이터의 주파수 정보를 보다 현실적이고 정확히 제공해 줄 수 있는 주파수 분석 방법이다. 순시 주파수는 아래 식에서 정의된 Hilbert 변환을 이용하여 구해진다.

$$Y(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{X(t')}{t-t'} dt' \quad (1)$$

$X(t)$ 는 입력 데이터이고, P 는 Cauchy principal value 를 나타낸다. 이렇게 구해진 $Y(t)$ 를 이용하여 입력 신호 $X(t)$ 의 해석 신호 (analytic signal)를 아래와 같이 나타낼 수 있다.

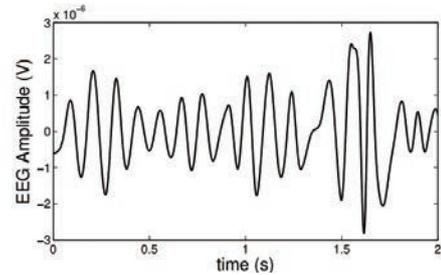
$$Z(t) = X(t) + jY(t) = a(t)e^{j\theta(t)} \quad (2)$$

$$\begin{aligned} a(t) &= [X^2(t) + Y^2(t)]^{1/2}, \\ \theta(t) &= \arctan\left(\frac{Y(t)}{X(t)}\right) \end{aligned} \quad (3)$$

Hilbert 변환을 이용하여 구한 $Z(t)$ 는 순시 진폭 (instantaneous amplitude), $a(t)$, 와 순시 위상 (instantaneous phase), $\theta(t)$, 로 나타낼 수 있고 $\theta(t)$ 를 미분하면 우리가 원하는 순시 주파수 (instantaneous frequency)를 얻을 수 있다.^[5]

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (4)$$

이러한 순시 주파수가 보다 정확한 주파수 정보를 갖기



〈그림 2〉 전형적인 intrinsic mode function 의 예^[4]

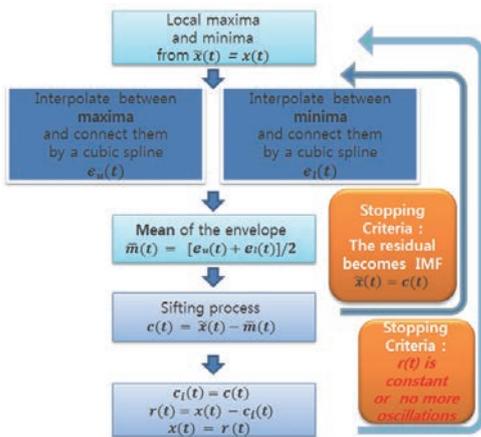
위해서는 $X(t)$ 가 monocomponent 신호이어야 한다는 전제조건이 있다^[6]. 신호가 매 순간마다 하나의 주파수 성분만을 가질 때 우리는 그 신호를 monocomponent 신호라고 정의한다. monocomponent는 또한 narrowband 로 정의할 수 있는데 이는 한 신호의 극점의 개수가 영을 지나는 횟수와 같을 때 narrowband 신호라고 정의를 내린다^[7]. 더 나아가 Norden Huang은 정확한 순시 주파수를 얻기 위한 조건을 하나 더 제시하였는데, 이는 신호가 영을 중심으로 위 아래가 서로 대칭이 되어야 한다는 것이다^[2]. Norden Huang은 (1) 극점과 영을 지나는 횟수가 같고 (2) 영을 중심으로 한 신호의 대칭성 조건이 만족하는 신호를 intrinsic mode function (IMF) 이라고 정의를 내리고 이를 통해 구해진 주파수 정보가 더욱 실제 값에 가까운 결과라고 말하고 있다. 〈그림 2〉는 이러한 조건을 만족하는 전형적인 IMF 신호의 예를 보여주고 있다.

3. Empirical Mode Decomposition

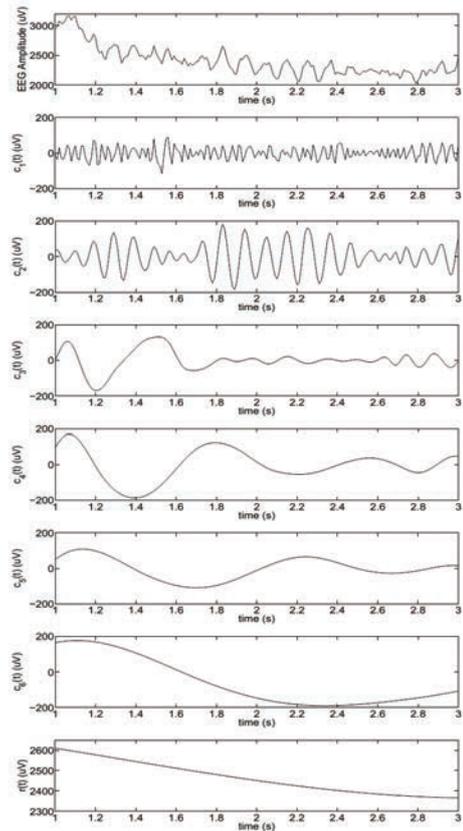
앞서 설명한 monocomponent/narrowband 신호는 하나의 주파수 성분 또는 mode가 매 시간 마다 존재해야 한다고 하였는데 실제 우리가 다루는 신호는 두 개 이상의 성분이 존재할 수 있다. 따라서 이러한 여러 개의 성분을 분해하기 위하여 Norden Huang은 empirical mode decomposition 알고리즘을 제안하였다. 서론에서 언급하였듯 EMD 알고리즘은 어떠한 기저함수에 의존하지 않고 데이터 자체에서 고유의 진동 또는 주파수 성분을 찾아내는 방법이며, 기존의 주파수 분석 방법보다 더 정확한 순시 주파수 정보를 얻어내 비정상성 및 비선형성을 갖는 뇌파 신호 분석에 매우 용이하다. 구체적인 알고리즘의 방법은 〈표 1〉에 기술되어 있으며 〈그림 3〉에 도식

〈표 1〉 EMD 알고리즘^[4]

- The standard EMD algorithm
1. Let $\tilde{x}(t) = x(t)$ ($x(t)$ is an input signal)
 2. Find all local maxima and minima of $\tilde{x}(t)$
 3. Identify an upper and lower envelope, $e_u(t)$ and $e_l(t)$, interpolating all local maxima and minima
 4. Estimate the local mean, $\bar{m} = (e_l(t) + e_u(t))/2$
 5. Subtract $\bar{m}(t)$ from $\tilde{x}(t)$, $c_i(t) = \tilde{x}(t) - \bar{m}(t)$ (i is an order of IMF)
 6. Let $\tilde{x}(t) = c_i(t)$ and go to step 2) and repeat the same process until $c_i(t)$ becomes an IMF



〈그림 3〉 EMD 알고리즘의 순서도



〈그림 4〉 EMD를 이용하여 하나의 뇌파신호를 여러 주파수 성분인 IMF 들로 분해한 결과^[4]

화하였다. 반복적으로 지역 평균 (local mean) 값을 입력 데이터에서 빼주고 그 나머지가 앞서 언급한 IMF의 두 가지 조건을 만족한다면 첫 번째 IMF로 선정을 한다. 이후 초기 입력 데이터에 첫 번째 IMF를 뺀 나머지 값을 이용하여 다시 같은 방법으로 나머지 IMF를 구하게 된다. 최종적으로 입력 $x(t)$ 는 IMF, $c_i(t)$ 들로 아래와 같이 표현이 된다.

$$x(t) = \sum_{i=1}^M c_i(t) + r(t) \quad (5)$$

〈그림 4〉는 하나의 뇌파 신호를 EMD를 이용하여 각 주파수 성분인 IMF로 분해한 예를 보여준다. 이렇게 구한 IMF들은 앞서 말한 monocomponent/narrowband 신호의 조건을 만족하여 Hilbert 변환을 통해 정확한 순시 주파수를 만들어 내게 된다.

III. Multivariate Extensions of Empirical Mode Decomposition

EMD 알고리즘은 정형화된 기저함수에 의존하지 않고 입력 신호를 바탕으로 고유의 주파수 성분을 추출해낸다.

2차원 또는 다차원으로 확장된 EMD 알고리즘을 이용하여 다채널 데이터의 공통 주파수 성분을 효율적으로 추출해 낼 수 있다. 이와 같은 성질은 특히 대부분 다채널로 측

정이 되는 뇌파 신호의 효율적이고 정확한 분석에 큰 도움을 준다.

1. Background

앞서 설명한 EMD 알고리즘은 주파수 성분을 특정 기저함수에 근거하지 않고 실험적으로 입력 데이터 자체만을 갖고 추출하는데, 이는 멀티채널 데이터 분석에 있어서 몇 가지 문제점을 지니고 있다. 그중 첫 번째는, 각



채널 데이터마다 IMF 개수가 다르고 서로 다른 채널에서 같은 순서로 추출된 IMF들이 같은 주파수 성분을 갖고 있다고 보장할 수 없다는 것이다. 두 번째는 모드 변환(mode-mixing) 문제로 간혹 지역 평균값을 구하는 과정에 있어 오차가 발생하여 특정 시 구간에서 잘못된 모드가 나타날 수 있다는 것이다. 이러한 경우 다채널 데이터 분석에 있어서 채널 간 주파수 비교 분석에 오류를 야기할 수밖에 없게 된다. 다채널 데이터의 EMD 분석에 있어 발생하는 이러한 문제를 해결하기 위하여 복소수 또는 multivariate EMD 알고리즘이 개발되었다.

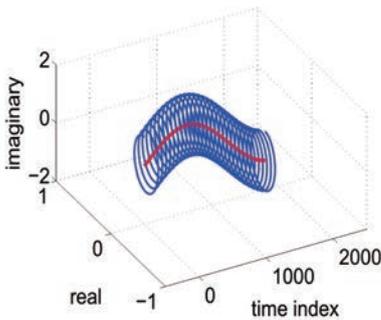
Multivariate EMD 알고리즘은 다채널 데이터의 시-주파수 분석에 매우 효과적이다.

2. 복소수 EMD

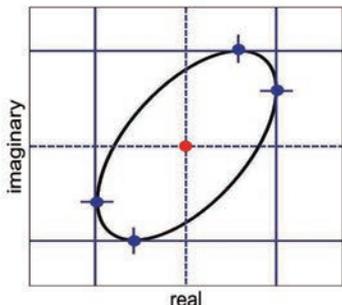
두 채널 데이터를 EMD 알고리즘을 이용하여 동시에 처리하기 위하여 각 데이터를 실수부와 허수부에 놓고 복소수 화 하여 EMD 알고리즘을 이 복소수 데이터에 바로

적용하여 복소수 형태의 IMF를 얻을 수 있도록 하였다^[8]. <그림 5 (a)>는 복소수로 표현된 두 채널 데이터를 실수부, 허수부 그리고 시간 축 위에 3차원 튜브 형태로 도식화 한 것이다. 이러한 3차원 튜브 신호를 기본적인 EMD 알고리즘과 같이 복소수 값의 지역 평균값을 반복적으로 빼주어 복소수 형태의 IMF를 구하게 된다. 그림에서 튜브 내에 표현된 붉은 색 선이 복소수의 지역 평균값을 나타내는데 이 값은 <그림 5 (b)>와 같이 3차원 튜브의 네 방향 포락선을 찾아 이들의 평균값으로 구하게 된다. 지역 평균값이 빼어진 나머지 값의 실수부 그리고 허수부 신호가 IMF 성립조건 두 가지를 만족시키는지를 확인하여 일반 EMD와 같은 방식으로 복소수 형태의 IMF를 얻어낼 수 있다. 이와 같이 두 채널의 IMF를 복소수 형태로 동시에 얻기 때문에 두 채널간의 IMF 개수는 항상 일치하게 되고, 모드 변환 문제가 발생한다 하더라도 두 채널 데이터 모두 동시에 발생하기 때문에 주파수의 비교 분석에 있어서는 크게 문제되지 않는다.

일반 EMD와 복소수 EMD 알고리즘의 성능을 비교하기 위하여 두 개 주파수의 정현파 신호를 이용하여 아래 식 (6), (7)과 같은 신호를 임의로 만들고 EMD와 복소수 EMD를 이용하여 IMF로 분해해 보았다.

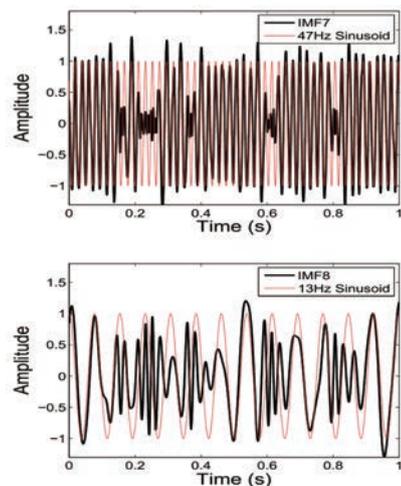


(a) 3차원 평면에서의 복소수 데이터

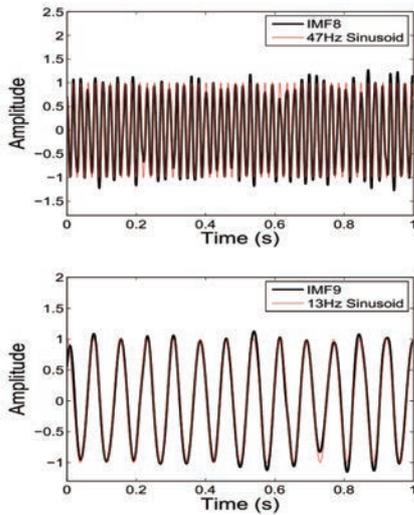


(b) 복소수 데이터의 절단면

<그림 5> 복소수 신호를 3차원 공간에 표현 (a). 붉은색 선은 지역 평균값을 의미. 3차원 공간에 표현된 튜브형태 신호의 특정 시간 절단면 (b)^[4]. 붉은색 점이 한 순간의 지역 평균값이 되며 이는 튜브의 포락선들(파랑색 점들)의 평균으로 구해짐



<그림 6> EMD를 이용하여 식 (6)과 (7) 신호로부터 47 Hz와 13 Hz 성분 추출^[4]



〈그림 7〉 복소수 EMD를 이용하여 식 (6)과 (7) 신호로부터 47 Hz와 13 Hz 성분 추출^[4]

$$f_1 = 13 \text{ Hz} \quad \text{and} \quad f_2 = 47 \text{ Hz}$$

$$t = 1/f_s, \dots, 2s \quad \text{and} \quad f_s = 10 \text{ kHz}$$

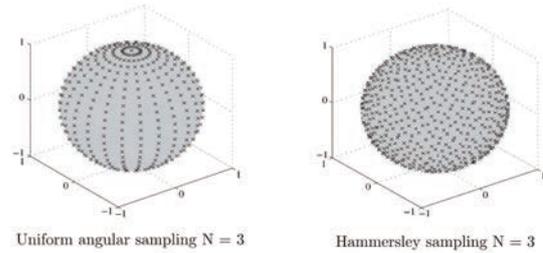
$$x_1(t) = \cos(2\pi f_1 t) + \cos(2\pi f_2 t + \frac{\pi}{6}) + v_1(t) \quad (6)$$

$$x_2(t) = 1.7 \cos(2\pi f_1 t + \frac{\pi}{4}) + 1.3 \cos(2\pi f_2 t + \frac{2\pi}{3}) + v_2(t) \quad (7)$$

$v_1(t)$ 와 $v_2(t)$ 는 0 dB 의 서로 다른 백색 가우시안 노이즈다. 이 신호를 일반 EMD와 복소수 EMD를 이용하여 13 Hz의 주파수 성분과 47 Hz 의 주파수 성분을 추출해 내고자 한다. 〈그림 6〉과 〈그림 7〉은 위 두 신호를 일반 EMD와 복소수 EMD를 이용하여 주파수 성분으로 분해하여 13 Hz와 47 Hz 성분을 포함하는 IMF들로 나타낸 결과이다. 두 그림에서 보는 것과 같이 복소수 EMD를 이용하여 두 채널 신호를 동시에 분석할 때 더욱 정확한 정현파 신호를 얻어 내는 것을 확인할 수 있다.

3. Multivariate Empirical Mode Decomposition

앞서 설명한 복소수 EMD 알고리즘은 두 채널 데이터만 처리할 수 있는 한계가 있다. 이를 극복하고 다채널 데이터에 EMD 알고리즘을 적용하기 위해 multivariate EMD 알고리즘이 개발되었다^[3]. MEMD 알고리즘 또한 전반적인 알고리즘 구현은 일반 EMD 알고리즘과 같고



〈그림 8〉 MEMD의 지역 평균값을 구하기 위한 3차원 평면 방향 벡터^[3]

복소수 EMD와 마찬가지로 지역 평균값을 구하는 방법에서만 차이를 갖는다. n 차원 신호의 지역 평균값을 구하는 방법은 n 개의 채널에서 얻어지는 n 차원의 데이터를 여러 방향으로 투영하여 n 차원의 포락선 신호를 얻어 이들의 평균으로 지역 평균값을 얻어내게 된다. 〈그림 8〉에서 세 채널 데이터로 구성된 3차원 데이터의 포락선 값을 구하는 예를 보여주고 있다. 3차원 데이터이기 때문에 입체 구를 이용하여 이에 투영되는 점들로 표현할 수 있는데, uniform angular sampling과 Hammersley sampling을 이용하여 3차원 공간으로 데이터를 투영할 수 있다. 그림에서 보는 것과 같이 Hammersley sampling 투영 방법이 보다 골고루 투영 점들을 선택하여 좀 더 정확한 지역 평균값을 예측하게 된다. 이렇게 구한 3차원 (n 채널 데이터의 경우 n 차원) 지역 평균값을 반복적으로 입력 신호에서 빼주어 n 차원 IMF를 만들어 주고 이를 복원하여 각 채널의 IMF를 구하게 된다. 이 방법 또한 n 채널 데이터를 동시에 이용하여 IMF 성분들을 구하게 되어 동시에 추출된 IMF들 간 주파수 성분은 거의 동일한 정보를 갖으며 IMF의 개수 또한 채널 간 항상 동일하다.

MEMD 알고리즘의 성능을 평가하기 위하여 세 개의 주파수를 이용하여 세 채널의 정현파 신호를 아래와 같이 구현하여 MEMD를 이용한 IMF들을 구해보았다.

$$f_s = 2048, f_1 = 5/f_s, f_2 = 11/f_s, f_3 = 23/f_s$$

$$a(t) = \begin{cases} \sin(2\pi f_1 t) + v_1(t), & t = 1, \dots, 2048 \\ \sin(2\pi f_2 t) + v_2(t), & t = 2049, \dots, 4096 \end{cases} \quad (8)$$

$$b(t) = \sin(2\pi f_1 t) + \sin(2\pi f_2 t) + v_3(t), t = 1, \dots, 4096 \quad (9)$$

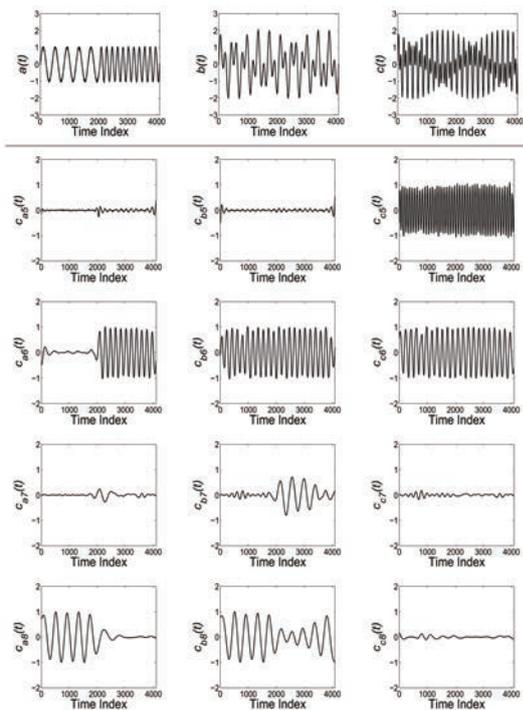


$$c(t) = \sin(2\pi f_2 t) + \sin(2\pi f_3 t) + v_4(t), t = 1, \dots, 4096 \quad (10)$$

$v_1(t)$ 와 $v_2(t)$, $v_3(t)$, $v_4(t)$ 는 서로 다른 30 dB 백색 가우시안 노이즈이다. <그림 9>는 MEMD를 이용하여 이 세 채널 데이터를 동시에 분석하여 얻은 IMF들을 보여주고 있다. 첫 번째부터 네 번째 IMF들은 노이즈에 해당하는 IMF들이기 때문에 나타내지 않았고 중요한 세 개의 주파수 성분들이 잘 나타나는 IMF들만 그렸다. 같은 단계의 IMF들끼리는 서로 거의 같은 주파수 성분을 갖는 것을 확인할 수 있었고, 일곱 번째와 여덟 번째 IMF들 ($c_{a7}(t)$, $c_{b7}(t)$, $c_{c7}(t)$, $c_{a8}(t)$, $c_{b8}(t)$, $c_{c8}(t)$)은 모드 변환 현상을 보이는데 세 채널 모두 동시에 나타나기 때문에 채널 간 주파수 성분 비교 분석에는 문제가 되지 않는다.

IV. MEMD를 이용한 뇌파 분석

우리가 팔을 움직이려는 상상을 할 때 움직임을 관장하

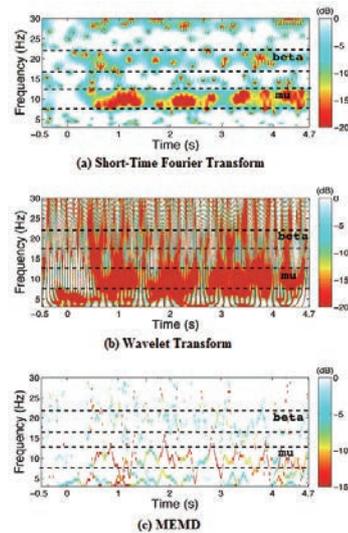


<그림 9> MEMD를 이용하여 식 (8), (9), (10)의 3채널 신호를 동시에 분석하여 얻은 IMF. 같은 단계의 IMF들은 항상 같은 주파수 성분을 가짐^[4]

는 뇌의 중앙 부분에서 강한 뇌파변화가 나타난다. 이러한 뇌 기전은 BCI 시스템을 구현할 때 빈번히 사용되는 패러다임이다. 특히 이러한 뇌파변화는 특정 주파수 영역 (mu 리듬: 8~12 Hz, beta 리듬: 18~23 Hz)에서 눈에 띄게 나타나는데 이러한 주파수 성분을 MEMD를 이용하여 기존의 푸리에 분석이나 wavelet 분석보다 더 효과적으로 추출해내려는 연구가 있었다^[1]. <그림 10>은 동작 상상을 하는 동안 뇌의 중앙 부분에서 발생하는 뇌파를 푸리에 분석 (STFT), wavelet 그리고 MEMD를 이용하여 시 주파수 성분을 분석한 결과이다. 그림에서 보는 것과 같이 0 초에서부터 동작 상상이 시작되면 mu 리듬과 beta 리듬이 활성화되는 것을 확인할 수 있다. 특히 세 가지 주파수 분석 방법 중 MEMD 방법이 mu 리듬과 beta 리듬을 매우 정확히 추출해 내는 것을 확인할 수 있다.

V. 향후 연구 및 결론

지금까지 empirical mode decomposition에 대해 알아보았고 다채널 분석에서 EMD 알고리즘이 어떻게 확장되고 분석이 되는지 확인하였다. 기저함수를 사용하지 않는 EMD 알고리즘의 특징 때문에 기존 주파수 분석



<그림 10> 동작 상상 동안 나타나는 뇌파의 시 주파수 성분 변화. 0 초에서부터 동작 상상이 시작되면 mu 리듬, beta 리듬이 활성화되는 것을 확인할 수 있음^[1]



알고리즘보다 좀 더 정답에 가까운 결과를 만들어준다. EMD 알고리즘은 입력 데이터 자체만을 기반으로 분석하고, 다채널 데이터 정보를 효율적으로 활용하여 실제 값에 보다 가까운 주파수 성분을 추출하여 향후 BCI 시스템 성능 향상에 크게 기여할 것으로 기대된다.

참고 문헌

[1] C. Park, D. Looney, N. Rehman, A. Ahrabian, and D. P. Mandic, "Classification of motor imagery BCI using multivariate empirical mode decomposition," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 21, no. 1, pp. 10–22, 2013.

[2] N. E. Huang, Z. Shen, S. R. Long, M. L. Wu, H. H. Shih, Z. Quanan, N. C. Yen, C. C. Tung, and H. H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," in *Proceedings of the Royal Society A*, vol. 454, pp. 903–995, 1998.[52] L. Cohen, *Time-frequency analysis*. Prentice Hall signal processing series, Prentice Hall PTR, 1995.

[3] N. Rehman and D. P. Mandic, "Multivariate empirical mode decomposition," *Proceedings of the Royal Society A*, vol. 466, no. 2117, pp. 1291–1302, 2010.

[4] C. Park, "Data-Driven Multivariate and Multiscale Methods for Brain Computer Interface," Ph. D. thesis, Department of Electrical & Electronic Engineering at Imperial College London, 2012.

[5] L. Cohen, "Instantaneous anything," in *Proc. IEEE Int. Conf. Acoust., Speech Signal Process.*, 1993, vol. 5, pp. 105–108.

[6] L. Cohen, *Time-frequency analysis*. Prentice Hall signal processing series, Prentice Hall PTR, 1995.

[7] M. Schwartz, W. R. Bennett, and S. Stein, *Communication systems and techniques*. John Wiley and Sons, 1995.

[8] G. Rilling, P. Flandrin, P. Gongalves, and J. M. Lilly, "Bivariate empirical mode decomposition.," *IEEE Signal Processing Letters*, vol. 14, no. 12, pp. 936–939, 2007.



박철수

- 1997년 서강대학교 전자공학과
- 2004년 서울대학교 협동과정 의용생체공학과 (석사)
- 2007년 영국 임페리얼 칼리지 런던 (박사)
- 2014년~현재 Assisntant Professor, Kwangwoon University
- 2012년~2013년 Postdoctoral Researcher, University of California, San Diego
- 2008년~2011년 Research Assistant, Imperial College London
- 2007년~2007년 Researcher, LS Cable

〈관심분야〉

Biomedical Signal Processing, Computational Neuroscience, Machine Learning