

실시간 뇌파 특성 분석을 위한 저잡음 스펙트럼 추정 알고리즘

Low Noise Time-Frequency Analysis Algorithm for Real-Time Spectral Estimation

김연수*, 박범수*, 김성은*[★]

Yeon-Su Kim*, Beom-Su Park*, Seong-Eun Kim*[★]

Abstract

We present a time-frequency analysis algorithm based on the multitaper method and the state-space frameworks. In general, time-frequency representations have a trade-off between the time duration and the spectral bandwidth by the uncertainty principle. To optimize the trade-off problems, the short-time Fourier transform and wavelet based algorithms have been developed. Alternatively, the authors proposed the state-space frameworks based on the multitaper method in the previous work. In this paper, we develop a real-time algorithm to estimate variances and spectrum using the state-space framework. We test our algorithm in spectral analysis of simulated data.

요약

본 연구에서는 multitaper 기반의 스펙트럼 추정기법과 상태-공간 모델링 기반의 변수 추정 기법을 통합한 시간-주파수 분석 알고리즘을 제안한다. 일반적으로 시간-주파수 분석에는 불확실성 원리에 의해 시간 해상도와 주파수 해상도 사이에 트레이드오프 문제가 발생한다. 트레이드오프 문제를 최적화하기 위해서 short-time Fourier transform(STFT)와 wavelet 기반의 알고리즘들이 제안되었다. 본 논문의 저자는 다른 대안으로 상태-공간 프레임워크를 기반으로 한 새로운 multitaper 스펙트럼 추정 방법을 제안하였다. 그러나 기존의 방법은 스펙트럼이 시간에 따라 변하지 않는 경우에 잘 동작하지만, dynamic하게 변할 경우 제대로 추정하지 못하는 문제점이 있다. 그래서 본 논문에서는 상태-공간 모델에 사용되는 상태 노이즈와 관찰 노이즈를 주기적으로 업데이트 하는 방법을 제안하고자 한다. 우리는 제안 알고리즘을 시뮬레이션 데이터를 사용하여 테스트 하였고, 시간에 따라 변하는 스펙트럼에 대해서도 잘 동작하는 것을 확인하였다.

Key words : Bayesian parameter estimation, EEG, Kalman filter, multitaper, spectrum estimation

* Dept. of Electronics and Control Engineering, Hanbat National University

★ Corresponding author

E-mail : sekim@hanbat.ac.kr, Tel : +82-42-821-1131

※ Acknowledgment

※ This paper was supported by newly appointed professor research fund of Hanbat National University in 2017.

Manuscript received Aug. 23, 2019; revised Sep. 16, 2019; accepted Sep. 23, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

스펙트럼 분석은 시계열(time series) 데이터로부터 의미 있는 정보를 추출하기 위한 매우 중요한 기술이다. 특히 뇌파(electroencephalogram, EEG)는 비침습적으로 획득할 수 있는 뇌신호로서, 뇌의 발달과 기능에 대한 중요한 정보를 제공하기 때문에 뇌과학 및 뇌공학 분야에서 활발하게 연구에 이용되고 있다[1]. 뇌파는 최근에는 마취분야에서 뇌파를 통해 마취제에 의한 뇌의 상태 변화를 분석하는 연구가 활발하게 진행되었고, 무의식-각성을 구분하

는 중요한 표식을 뇌파로부터 발견하는 성과를 거두었다[2]. 뇌파 분석에는 다양한 기법이 활용되지만, 뇌의 기능적 동작과 뇌파의 주파수 특성이 매우 밀접한 상관관계를 가지는 것이 밝혀지고 있어서, 뇌파의 주파수 특성인 스펙트럼 분석이 주로 사용되고 있다.

신호의 스펙트럼을 추정하는 기법은 매우 고전적인 수학의 한 연구 분야이고, 기본적으로 신호가 정상(stationary) 상태라는 가정을 사용하고 있다. 일반적으로는 Fourier 기법을 기반으로 한 multitaper (MT) 스펙트럼 추정 기법이 간단하면서도 잡음이 적기 때문에 스펙트럼 분석에 가장 많이 활용되고 있다[3], [4]. 그러나 우리가 사용하는 대다수의 신호는 비정상(non-stationary) 신호이기 때문에, 스펙트럼이 시간에 따라 매우 천천히 변한다고 가정하고 sliding window 기법을 사용하여 스펙트럼 추정을 하고 있다. 즉, 신호를 짧은 길이를 갖는 여러 개의 신호로 중첩되게 나누고, 각 짧은 신호는 정상상태라고 가정한 후 Fourier 및 Wavelet 기법을 사용하여 스펙트럼을 추정하고 있고, MT 기법을 적용하여 스펙트럼을 추정하는 것이 잡음 최소화에 최적화 된 것으로 보고되었다[4]. 이런 방법으로 시간에 따른 스펙트럼 변화를 분석할 수 있게 되는 것이다.

하지만, 슬라이딩 윈도우(sliding window)를 적용하여 스펙트럼을 추정하게 되면 각 구간(window) 안에 있는 데이터들 간의 상호연관성을 무시하고 구간 내에 있는 데이터만을 사용한 독립적인 추정 결과가 도출되는 문제가 있다[5]. 이러한 문제를 해결하기 위해 각 구간에서 추정되는 값이 서로 연관성을 갖도록 상태-공간(state-space) 모델을 개발하여 이를 기반으로 추정하는 기법이 제안되었다[5].

본 논문에서는 상태-공간 모델을 기반으로 스펙트럼을 추정하는 알고리즘의 전개과정을 상세하게 소개하고, 기존 방법의 문제점을 제기하고, 성능을 개선하기 위한 새로운 방법을 제안하고자 한다. 기존의 상태-공간 모델 기반의 알고리즘들은 칼만 필터에서의 분산 변수를 이미 알고 있다고 가정하거나 알고리즘을 시작하기 전에 5분 정도의 데이터를 사용하여 기댓값 최대화 알고리즘(EM : expectation-maximization)을 구동하여 미리 분산변수를 추정하여 사용하도록 되어 있다[5]. 하지만 이렇게 되면 신호의 스펙트럼이 시간에 따라 변하는 경우 처음

에 추정된 분산 값이 더 이상 의미가 없어지게 된다. 그래서 본 논문에서는 뇌의 상태에 따라 스펙트럼의 특성이 크게 변하는 뇌파 신호에도 사용할 있도록 하기 위해 분산 변수를 주기적으로 업데이트 하는 알고리즘을 개발하였다. 매 1분마다 지난 1분 동안의 데이터를 사용하여 분산을 계산하여 업데이트 되도록 하여, 실시간으로 스펙트럼을 추정한 결과 값을 화면에 보여주는 의료기기 시스템에서도 사용할 수 있도록 하였다. 본론에서는 기존의 상태-공간 모델 기반의 알고리즘을 소개하고, 새롭게 개발된 분산 추정 및 업데이트 기법을 제안한다. 그리고 마취상태에서 획득된 뇌파 스펙트럼을 자기회귀(autoressive, AR) 신호로 모델링하여 발생시킨 시계열 신호에 제안된 알고리즘을 적용하였다. 실험결과를 통해 개발된 알고리즘이 시간에 따라 변화하고 있는 뇌파의 변화를 잘 추정하는 것을 확인할 수 있었다.

II. 본론

1. 상태-공간 모델 기반 스펙트럼 추정

먼저 연속 실수 신호를 F_s (Hz)로 샘플링 하여 관찰 이산 신호 y_t 를 생성하였다. 그리고 이 신호는 다음과 같이 원래 신호 z_t 에 가우시안 노이즈 ϵ_t 가 첨가되어 생성되었다고 가정하자.

$$y_t = z_t + \epsilon_t \quad (1)$$

여기서 z_t 가 원래신호이고 지역적으로 정상신호 특성을 갖는다고 가정한다. 즉, 신호의 스펙트럼이 매우 느리게 변화하는 신호이다. ϵ_t 는 평균이 0이고 분산 σ_ϵ^2 을 갖는 가우시안 노이즈이다. $t = 1, 2, \dots, T$ 로 정의한다. 신호에 길이가 J 인 window를 중첩 없이 적용하여 길이가 J 이고 k 번째 관측 벡터 Y_k 를 다음과 같이 표현할 수 있다.

$$Y_k = Z_k + \epsilon_k = W_k X_k + \epsilon_k \quad (2)$$

여기서 W_k 는 $J \times J$ 행렬이고, (l, j) 번째 성분을 $(W)_{l,j} = J^{-1/2} \exp(i2\pi(l-1)(j-1)/J)$ 로 정의한다. 이때, $k=1, 2, \dots, K$ 이고, $T=KJ$ 이다. ϵ_k 는 $J \times 1$ 가우시안 노이즈 벡터이고, $J \times J$ 공분산 행렬은 σ_ϵ^2 을 가지는 대각 행렬 $I(\sigma_\epsilon^2)$ 이다. 그리고 $X_k = (X_k(w_1), \dots, X_k(w_J))'$

는 w_j 주파수에서의 주파수 성분 값을 의미하고 성분 값은 복소수이다. 또한, $w_j = 2\pi(j-1)/J$ 로 정의한다. 여기서 $j=1,2,\dots,J$ 이고 $l=1,2,\dots,J$ 이다.

식 (2)로 주어진 신호의 벡터 모델에 MT 기법을 적용하기 위해서 우리는 m 번째 Slepian 테이퍼 (taper) 함수를 S^m 로 정의한다. 총 M 개의 테이퍼를 사용한다고 가정하자. 식 (2)의 좌변에 테이퍼를 곱하고 이산 푸리에 함수 (F_k)를 적용하면, 다음의 성질을 만족하게 된다.

$$F_k S^m Y_k = F_k Y_k^m \quad (3)$$

Y_k^m 은 Y 의 신호에 m 번째 테이퍼를 적용한 함수이고 여기서 $F_k W_k = I$ 이 만족된다. 식 (3)을 식 (2)에 적용하기 위해, 이산 푸리에 변환을 식 (2) 양변에 적용하면, 다음의 식을 얻을 수 있다.

$$F_k Y_k^m = X_k^m + F_k \varepsilon_k^m \quad (4)$$

X_k^m 는 원래 신호에 m 번째 테이퍼를 적용한 신호의 주파수 성분을 의미한다. 이산 푸리에 변환을 적용한 주파수 성분에 위 첨자로 F 를 표시하여 식 (4)를 다음과 같이 표현한다.

$$Y_k^{m,F} = X_k^m + \varepsilon_k^{m,F} \quad (5)$$

식(5)가 상태-공간 모델의 관찰 (observation) 모델이 된다. 여기서 $\varepsilon_k^{m,F}$ 는 복소수 가우시안 랜덤 벡터이고, 공분산 행렬은 $I(\sigma_\varepsilon^{2,m})$ 이고, $\sigma_\varepsilon^2 = \sum_{m=1}^M \sigma_\varepsilon^{2,m}/M$ 의 관계가 성립한다. MT 방법의 스펙트럼은 다음과 같이 주어진다.

$$f_k^{MT}(w_j) = M^{-1} \sum_{m=1}^M \|Y_k^{m,F}(w_j)\|^2 \quad (6)$$

그리고 현재 주파수 성분은 이전 구간에서의 주파수 성분과 무작위 보행(random walk) 관계를 가진다고 가정하고 다음과 같이 정의한다.

$$X_k^m = X_{k-1}^m + v_k^m \quad (7)$$

여기서 $m = 1, \dots, M$ 이고, v_k^m 는 평균이 0인 가우시안 벡터이고 $J \times J$ 공분산 행렬이 $I(\sigma_{v,j}^{2,m})$ 을 갖는다고 가정한다. 이때, $j = 1, \dots, J$ 이다. 식 (7)이 상태-

공간 모델의 state 모델이 된다.

식 (5)와 식 (7)을 상태-공간 모델로 두고 베이저안 추정 기법을 사용하면 다음과 같은 칼만 필터 알고리즘을 유도할 수 있다[5]. 주어진 구간 k 에서의 식은 다음과 같다.

$$X_{k|k-1}^m(w_j) = X_{k-1|k-1}^m(w_j) \quad (8a)$$

$$\sigma_{k|k-1,j}^{2,m} = \sigma_{k-1|k-1,j}^{2,m} + \sigma_{v,j}^{2,m} \quad (8b)$$

$$X_{k|k}^m(w_j) = X_{k|k-1}^m(w_j) + C_{k,j}^m (Y_{k,j}^{F,m} - X_{k|k-1}^m(w_j)) \quad (8c)$$

$$\sigma_{k|k,j}^{2,m} = (1 - C_{k,j}^m) \sigma_{k|k-1,j}^{2,m} \quad (8d)$$

$m = 1, \dots, M$, $k = 1, \dots, K$ 및 $j = 1, \dots, J$ 로 주어지고, Kalman gain은 다음과 같다.

$$C_{k,j}^{2,m} = (\sigma_\varepsilon^{2,m} + \sigma_{k|k-1,j}^{2,m})^{-1} \sigma_{k|k-1,j}^{2,m} \quad (9)$$

표기법 $k|s$ 는 s 번째 window까지 관측된 이전의 모든 데이터로 k 번째 window의 값을 추정된 것을 나타낸다. k 번째 칼만 필터 추정 값이 주어지면 k 에서의 주파수 w_j 에서의 스펙트럼 추정치는 다음과 같다.

$$f_{k|k}^{SS-MT}(w_j) = M^{-1} \sum_{m=1}^M \|X_{k|k}^m(w_j)\|^2 \quad (10)$$

여기서 SS-MT는 state-space multitaper를 의미한다. 기존의 MT 방법에서는 식(6)과 같이 현재의 관찰 값만 사용하는 반면에, SS-MT 기법은 기존의 MT 기법과 달리 이전의 데이터와의 상관관계를 고려하여 데이터의 변화 양상을 잘 반영하게 되고, 추가적인 추정 노이즈를 획기적으로 제거하는 장점을 가진다.

이러한 차이는 Kalman gain에 의해서 발생하게 되는데, Kalman gain은 추정시스템이 현재 관찰 값과 추정 값 중에 어떤 값에 더 큰 가중치를 둘 것인지를 결정하게 된다[5]. Kalman gain이 1에 가까워지면, 현재 관찰 값을 더 신뢰하는 것을 의미하게 되어 관찰 값에 더 큰 가중치를 두게 된다. 반면에, Kalman gain이 0에 가까워지면, 추정 값을 더 신뢰하고 더 큰 가중치를 두게 된다. 따라서, MT 방법은 SS-MT 기법에서 항상 Kalman gain이 1인 경우와 같은 결과가 된다.

2. 상태 노이즈 분산 추정

기존의 SS-MT 기법에서는 식 (8b)와 식 (9)에서 사용된 상태노이즈 분산 $\sigma_{v,j}^{2,m}$ 과 관찰노이즈 분산 $\sigma_{\epsilon}^{2,m}$ 을 알고 있다고 가정하고 있거나, 알고리즘을 시작하기 전에 미리 구해놓게 된다. 기존의 논문에서는 처음 5분의 데이터를 기반으로 EM 알고리즘을 구동하여 다음과 같이 분산 변수를 미리 계산하였다[5].

$$\sigma_{v,j}^2 = \frac{1}{2K} \sum_{k=1}^K (W_{k-1|K,j} - R(W_{k,k-1|K,j} + W_{k|K,j})) \quad (11)$$

$$\sigma_{\epsilon}^2 = \frac{1}{JK} \sum_{j,k=1}^K (\|Y_{k,j}^F\|^2 - 2R(Y_{k,j}^{F*} X_{k|K}(\omega_j)) + W_{k|K,j}) \quad (12)$$

이때, $R(\cdot)$ 은 실수를 취하는 함수이고, 각 변수는 다음과 같이 정의된다.

$$\begin{aligned} X_{k|K,j}(\omega_j) &= E[X_k(\omega_j) | Y_{1:K,j}^F] \\ W_{k|K,j} &= E[\|X_k(\omega_j)\|^2 | Y_{1:K,j}^F], \\ W_{k,k-1|K,j} &= E[X_k(\omega_j) X_{k-1}^*(\omega_j) | Y_{1:K,j}^F] \end{aligned}$$

데이터 시작 부분의 데이터를 사용하여 EM 기법으로 계산된 식 (11)과 식 (12)가 수렴할 때까지 반복하여 최종 분산 변수를 추정하게 된다. 이렇게 추정된 분산 값을 사용하여 SS-MT 기법을 적용하고 스펙트럼을 계산하게 된다. 하지만 이렇게 하면, 분산 변수가 초기에 추정된 상태로 고정되기 때문에, 뇌의 상태에 따라 다변하는 뇌파 스펙트럼을 실시간으로 추정할 수 없는 문제가 발생한다. 이러한 문제를 개선하기 위해서, 기존의 논문에서는 뇌파에서 변화가 발생하는 구간을 미리 설정하고 그 구간에 대해서 따로 EM 알고리즘을 적용하여 분산 변수를 각 구간별로 계산하는 과정을 추가하였다[5]. 그러나 이런 방식은 이미 어떤 시점에 뇌파 데이터에 변화가 발생하는지 알고 있어야 하기 때문에, 실시간으로 입력되는 데이터를 지연 없이 처리하여 결과를 모니터링 하는 시스템에는 적용할 수 없는 단점이 있다.

따라서, 본 논문에서는 실시간 데이터 처리를 위해 분산을 현재까지 입력되고 있는 데이터만을 이용하여 추정하고 그 변수를 사용하여 실시간으로 SS-MT 알고리즘을 구동하는 방안을 제안하고자

한다. 일반적으로 뇌파의 변화 특성을 알 수 없기 때문에 매 주기 p 분마다 EM 알고리즘을 사용하여 뇌파의 분산 변수를 주기적으로 추정한 후, 이를 사용하여 SS-MT 기반 스펙트럼을 계산하는 것이 기본 아이디어이다. 그러나 한 주기 동안 입력된 데이터만으로 분산 변수를 추정하게 되면 그 이전 데이터들과의 관련성을 무시하게 되어 잡음의 유무에 따라 추정된 값이 크게 변동하는 문제가 발생하게 된다. 이러한 문제를 해결하기 위해서 현재의 분산 변수와 이전의 분산 변수들과의 상관관계를 만들어 주기 위해 지수이동평균(exponential moving average)을 취하여 다음과 같이 시간에 따른 평활(smoothing) 기법을 구현하였다.

$$\hat{\sigma}_{v,j}^{2,m}(n) = \alpha \hat{\sigma}_{v,j}^{2,m}(n-1) + (1-\alpha) \sigma_{v,j}^{2,m}(n) \quad (13)$$

$$\hat{\sigma}_{\epsilon}^{2,m}(n) = \alpha \hat{\sigma}_{\epsilon}^{2,m}(n-1) + (1-\alpha) \sigma_{\epsilon}^{2,m}(n) \quad (14)$$

여기서 $\sigma_{v,j}^{2,m}$ 과 $\sigma_{\epsilon}^{2,m}$ 는 매 주기마다 EM에 의해 추정된 값을 의미하고, n 은 p 분씩 n 번째 주기를 의미하고, α 는 0과 1 사이 실수로 이전 추정 값에 가중치를 얼마나 줄 것인지를 결정하게 된다. α 가 1에 가까울수록 이전 값에 큰 가중치를 주게 되고, 0에 가까울수록 현재 추정 값에 더 큰 가중치를 주

Input:

EEG data sampled at f_s : $y_t, t = 1, 2, \dots, T$
 Applying non-overlapping window: w (sec)
 Vector form: $Y_k, J \times 1, J = wf_s, k = 1, 2, \dots, K$

Initial parameter estimation:

For p -min data ($1 \leq k \leq 60p/w$),
 Do EM algorithm (Eqs. (11) & (12))

(Repeatedly perform EM algorithm every p minutes)

For $k = \frac{60p}{w} : K$

If $kw \bmod 60p \neq 0$
 Do SS-MT algorithm (Eqs. (8) & (9))

Else
 Do EM algorithm (Eqs. (11) & (12))
 Smoothing parameters (Eqs. (13) & (14))
 Do SS-MT algorithm (Eqs. (8) & (9))

End

End

Fig 1. Pseudocode of the proposed algorithm.

그림 1. 제안 알고리즘 의사코드(pseudocode)




Fig. 2. Spectrogram comparisons of the proposed algorithm and original multitaper method:

(A) Original multitaper method (B) Adaptive state-space multitaper method

그림 2. 제안 알고리즘 성능 테스트 (AR 신호 사용)

(A) 기존의 multitaper로 추정된 spectrogram (B) 제안된 방법으로 추정된 spectrogram

게 된다. 신호가 정상(stationary) 상태이면 분산의 시간 변화량은 크지 않을 것이기 때문에 일정한 값이 작은 변동 폭을 가지고 유지될 것이다. 이런 경우 α 는 1에 가까운 값으로 설정하는 것이 좋다. 반면에, 입력 신호가 시간에 따른 변화가 큰 경우에는 현재 추정 값이 더 중요해지기 때문에 α 를 감소시킬 필요가 있다. 이를 통해 분산을 매 입력이 들어올 때마다 추정할 수 있고, 분산에 큰 변화가 발생할 때 마다 새로 추정된 값으로 업데이트를 하여 SS-MT 알고리즘이 스펙트럼이 시간에 따라 변하는 경우에도 잘 동작할 수 있도록 해주게 된다.

제안 알고리즘을 이해하기 쉽게 설명하기 위해 그림 1과 같이 의사코드로 표현하였다.

3. 실험 결과

제안된 알고리즘의 성능 검증을 위해 마취 환자로부터 측정된 EEG 데이터의 스펙트럼을 추정하는 실험을 수행하였다. 기존 논문[6]에서 사용한 마취상태에서 획득된 뇌파 스펙트럼을 자기회귀(autoregressive, AR) 신호로 모델링하여 발생시킨 시계열 신호를 입력 신호로 사용하였다. 사람에게 측정된 신호를 사용할 경우 윤리적 문제가 있어서 AR 기법으로 모델링한 시뮬레이션 신호를 사용하여 실험을 수행하였다. 원래 신호는 propofol을 사용하여 전신마취를 유지하는 동안 250 Hz에서 기록된 30분의

뇌파로 구성된다. 우리는 테이퍼(taper)의 값인 M 을 5로 선택했는데 이것은 MT 방법에 대한 2 Hz의 스펙트럼 분해능에 해당한다. window 크기인 w 는 4초이고 $J=1,000$ 이 된다. α 는 0.4를 사용하였고, 주기 p 는 1분으로 하였다. 매 1분마다 EM 알고리즘을 통해 노이즈 변수가 추정되었고, 지수이동 평균에 의해 smoothing 되었다. 그림 2에서 제안한 SS-MT spectrogram과 기존의 MT spectrogram을 비교하였다. 그림 2의 (A)는 기존의 multitaper 방법으로 추정된 spectrogram이고, (B)는 제안 방법을 사용하여 추정한 결과를 나타낸다. 마취제 투여에 따라 변화하는 뇌파의 스펙트럼을 제안된 기법으로 잘 추정하고 있고, 잡음도 획기적으로 감소시켰음을 확인할 수 있다. 이는 상태-공간 모델 기반의 추정 기법의 장점인 잡음 제거 성능도 그대로 유지되고 있음을 알 수 있다.

III. 결론

제안된 방법을 사용하면 잡음이 제거된 깨끗한 스펙트럼을 데이터 입력 시마다 실시간으로 보여 줄 수 있다. 기존의 기법은 모델 변수를 초기에 고정하여 데이터의 모델 특성이 변해도 이를 반영할 수 없는 문제점이 있지만, 제안 기법은 매 주기마다 모델 변수를 추정하고 이를 이전의 변수들과 연

관성을 갖도록 smoothing하여 시간에 따른 변화를 잘 추정할 수 있도록 하였다. 제안된 기법을 활용하면 마취뿐만 아니라 손쉽게 수면 상태의 변화에 따른 스펙트럼 변화도 관찰할 수 있을 것으로 기대가 되고, 잡음이 제거된 고해상도 스펙트럼 데이터를 기계학습 알고리즘에 사용하여 학습에 활용하면 스펙트럼 분석을 통하여 자동으로 수면의 상태를 판별할 수 있는 알고리즘을 개발할 수 있을 것이다.

References

- [1] F. L. da Silva, "EEG and MEG: Relevance to neuroscience," *Neuron*, vol.80, no.5, pp.1112-1128, 2013. DOI: 10.1016/j.neuron.2013.10.017
- [2] P. L. Purdon et al., "The ageing brain: Age-dependent changes in the electroencephalogram during propofol and sevoflurane general anaesthesia," *Brit. J. Anaesthesia*, vol.115, pp.i46-i57, 2015. DOI: 10.1093/bja/aev213.
- [3] D. B. Percival and A. T. Walden, *Spectral Analysis for Physical Applications*, Cambridge, UK: Cambridge Univ. Press., 1993.
- [4] B. Babadi and E. N. Brown, "A review of multitaper spectral analysis," *IEEE Trans. Biomed. Eng.*, vol.61, no.5, pp.1555-1564, 2014. DOI: 10.1109/TBME.2014.2311996
- [5] S. Kim, M. K. Bher, D. Ba, and E. N. Brown, "State-space multitaper time-frequency analysis," *Proc. Nat. Acad. Sci. USA*, vol.115, no.1, pp.E5-E14, 2018. DOI: 10.1073/pnas.1702877115
- [6] D. Ba, B. Babadi, P. L. Purdon, E. N. Brown, "Robust spectrotemporal decomposition by iteratively reweighted least squares," *Proc Natl Acad Sci USA*, vol.111, no.50, pp.E5336-E5345, 2014. DOI: 10.1073/pnas.1320637111

BIOGRAPHY

Seong-Eun Kim (Member)



2004 : BS degree in Electronics and Electrical Engineering, POSTECH.
2010 : PhD degree in Electronics and Electrical Engineering, POSTECH.
2011~2014 : Research Staff Member, Samsung Electronics.
2014~2017 : Postdoctoral Associate, MIT.

2017~current: Assistant Professor, Hanbat National University.

Yeon-Su Kim (Member)



2019 : BS degree in Electronics and Control Engineering, Hanbat University.
2019~current: MS candidate in Electronics Engineering, Hanbat National University.

Beom-Su Park (Member)



2021 : expected BS in Electronics and Control Engineering, Hanbat National University.