

뇌 신호원의 시계열 추출 및 인과성 분석에 있어서 ICA 기반 접근법과 MUSIC 기반 접근법의 성능 비교 및 문제점 진단

정영진¹, 김도원¹, 이진영¹, 임창환^{1,2}

¹연세대학교 의공학부, ²연세대학교 의료공학연구원

Comparison of ICA-based and MUSIC-based Approaches Used for the Extraction of Source Time Series and Causality Analysis

Young-Jin Jung¹, Do-Won Kim¹, Jin-Young Lee¹, Chang-Hwan Im^{1,2}

¹Department of Biomedical Engineering, Yonsei University, Wonju, Republic of Korea

²Institute of Medical Engineering, Yonsei University, Wonju, Republic of Korea

(Received June 23, 2008. Accepted August 11, 2008)

Abstract

Recently, causality analysis of source time series extracted from EEG or MEG signals is becoming of great importance in human brain mapping studies and noninvasive diagnosis of various brain diseases. Two approaches have been widely used for the analyses: one is independent component analysis (ICA), and the other is multiple signal classification (MUSIC). To the best of our knowledge, however, any comparison studies to reveal the difference of the two approaches have not been reported. In the present study, we compared the performance of the two different techniques, ICA and MUSIC, especially focusing on how accurately they can estimate and separate various brain electrical signals such as linear, nonlinear, and chaotic signals without a priori knowledge. Results of the realistic simulation studies, adopting directed transfer function (DTF) and Granger causality (GC) as measures of the accurate extraction of source time series, demonstrated that the MUSIC-based approach is more reliable than the ICA-based approach.

Key words : Directed transfer function (DTF), Electroencephalogram (EEG), Forward/Inverse problem, Granger causality (GC), Independent component analysis (ICA), Multiple signal classification (MUSIC), Nonlinear analysis.

1. 서론

최 근, 뇌 연구에 있어서, 뇌 신호원(source)의 시계열(time series) 정보는 간질(epilepsy), 정신분열증(schizophrenia) 등 다양한 뇌 질환의 객관적 진단 및 인지-신경과학(cognitive neuroscience)에서의 뇌 연결성, 인과성 연구 등을 위한 핵심적인 도구로 활용되고 있다[1-10]. 이러한 뇌 신호원의 위치 정보 및 시계열 신호를 추정하기 위한 연구로는 Mosher(1992) 등이 multiple signal classification (MUSIC) 알고리즘 및 주성분분석(principle component analysis, PCA)을 이용하여 신호원을 추정하는 방법을 소개한 이후[11], 최근 Ding(2007) 등이 MUSIC 알고리즘을 개선한 first principle vector (FINE) 알고리즘을 사용하여 간질 환자의 발작 중 EEG 신호를 이용해 간질 발생 신호원을 추정하고

그 신호원 사이의 인과관계를 시계열 분석을 통해 추정한 연구 결과에 이르기까지 다양한 형태로 발전되어 왔다[1-3]. 이와는 다른 접근 방법으로 뇌전도(EEG) 또는 뇌자도(MEG) 신호를 독립요소분석(Independent Component Analysis, ICA)을 사용하여 독립요소들로 분리한 다음 각 독립요소들의 신호원을 추정하고 각 독립요소의 시계열 사이의 연결성 또는 인과성을 분석하는 방법도 널리 연구되어 왔다[4-6,13]. Hesses(2007) 등은 ICA를 통해서 간질 환자의 EEG 신호에서 간질 파형을 분류해 낸 다음, signal subspace correlation에 기초하여 그 신호원을 추정하였다[4]. 또한, Hung(2007) 등은 Creutzfeldt-Jakob 병의 조기 진단을 위해 비슷한 개념의 ICA를 사용하였으며[5], Iriate(2006) 등은 간질 환자의 발작 중 EEG 신호에서 발작을 유발하는 신호원의 위치를 추정하고 그 전과관계를 규명하는데 ICA가 매우 유용한 기술임을 입증하였다[6]. 그 외에도 다양한 적용 분야에서 EEG 신호에 ICA 기술을 접목시킨 연구가 진행 되고 있다[7,10].

Corresponding Author : 임창환
강원도 원주시 흥업면 매지리 234 연세대학교 의공학부
Tel : +82-33-760-2792 / Fax : +82-33-763-1953
E-mail : ich@yonsei.ac.kr

이와 같이 비선형적인 방법인 ICA를 통하여 신호원의 시계열을 추출해 내는 방법은 서로 다른 독립 요소들의 신호를 추출해 내기는 하지만 실제의 신호들 사이의 인과관계를 규명하는데 있어서는 독립 요소들 사이에 의존성(dependency)이 존재하여야 한다는 모순점이 존재한다. 또한 선형적인 방법인 MUSIC을 통해서 신호원을 추정하고 신호원에서의 시계열을 역문제(inverse problem) 해석을 통하여 추출하는 방법은 얼마나 정확한 신호원의 위치를 찾느냐가 문제의 핵심이 되지만, 신호의 위치를 추정하기 위해 사용되는 고유벡터의 직교성 때문에 2차 벡터 이하 성분은 측정된 EEG신호의 특징 벡터성분을 그대로 반영하지 못하는 경우가 발생할 수 있다. 이러한 문제점들은 뇌 신호원을 분석함에 있어서 매우 중요한 문제가 될 수 있음에도 불구하고, 현재까지 이들 기법의 성능에 관련된 체계적인 고찰은 보고된 바 없다. 특히 측정된 EEG 신호의 특성을 고려하여 어떠한 분석 기술을 적용할 것인가를 선택하는 일은 앞서 언급한 뇌 질환 연구 및 인지과학 연구에서 올바른 연구 결과를 도출하는데 큰 영향을 미칠 수 있기 때문에, 이들 분석 기술들 사이의 비교 평가 연구가 필수적이다.

본 연구에서는 뇌 신호원 시계열 추출을 위한 대표적인 방법인 MUSIC 알고리즘과 ICA 알고리즘을 선형, 비선형, 카오스 시스템에서 생성된 신호원 시계열에 적용하여 신호의 특성에 따른 각각의 분석 방법들의 장단점을 확인하였다. 이와 같이 다양한 시스템에서 생성된 신호를 적용한 이유는, EEG 신호가 선형적인 특성 뿐만 아니라, 비선형적인 특성 및 카오스적 특성도 나타낸다고 잘 알려져 있기 때문이다[17]. 또한 추출된 다양한 특성을 가진 신호원들의 인과성을 관찰하기 위하여 directed transfer function (DTF)과 granger causality (GC) 분석을 적용하여, 실제로 신호원들 사이의 인과관계를 정확히 반영하는지 관찰하였다. 이러한 분석 방법을 적용하기 위해서 montreal neurological institute (MNI)의 표준 뇌 모델을 사용하여 뇌의 임의의 위치에 신호원을 생성한 후 정문제(forward problem) 해석을 통해서 전극(electrode)에서의 가상의 EEG 신호를 생성하였다. 이 때 신호원의 신호는 각각 실제 뇌파 신호의 성격과 유사한 선형, 비선형, 카오스 시스템에서 생성된 신호로 가정하였으며 10 dB의 백색잡음(white noise)을 첨가한 다음 두 방법론을 적용하여 신호원 시계열의 추출 성능과 추출된 여러 신호원 시계열들 사이의 인과성(causality)을 분석하였다. 이상의 분석을 위해서, GUI기반의 MATLAB toolbox를 개발하여 적용하였다.

II. 방법론

A. 컴퓨터 시뮬레이션 방법

정문제 해석을 위해 표준 뇌의 MRI T1 데이터로부터 두피, 두개골 외면, 두개골 내면의 3층으로 구성된 경계요소 데이터를 추출하여 경계요소법(boundary element method, BEM)을 적용하였으며, 신호원을 위치시킬 수 있는 약 10,000개의 노드(grid

point)를 두개골 내면 안쪽으로 고르게 분포시켰다. 두피 표면에 국제적인 10-20 전극 배치법(international 10-20 system)을 가정한 19개의 전극을 배치하였다.

알고리즘들의 검증을 위해, 정문제 해석을 통하여 각 노드에 대한 전극의 민감도를 나타내는 leadfield 행렬을 생성하였다. 이후, 부분공간 노드(subspace grid)상의 임의의 점에 신호원을 위치시키고 선형, 비선형 혹은 카오스 시스템에서 생성된 신호를 입력하여 인위적인 EEG 신호를 생성한 후, 실제 EEG 측정 과정에서 발생하는 잡음을 반영하기 위해서 백색잡음(white noise)을 첨가하여 신호를 생성하였다. 이렇게 생성된 신호에 대해 2가지 방법을 적용하여 신호원 및 신호원의 시계열을 추정하였다. 첫 번째 방법은 주성분 분석을 기반으로 한 MUSIC 알고리즘을 이용하여 신호원의 위치를 추정하고, 그 추정된 위치에서의 시계열을 역문제 해석을 통하여 추출한 후 각각의 신호원들 사이의 인과성을 측정하였다. 두 번째 방법은 측정된 신호에 ICA를 적용하여 신호원의 시계열을 추출한 후 그 독립요소에 해당하는 신호원의 위치를 탐색하고, 그 시계열 사이의 인과성을 측정하였다.

B. Independent Component Analysis (ICA)

ICA는 신호에 대한 사전정보 없이 복잡한 신호로부터 독립성분을 가진 신호원을 찾아내는 대표적인 방법으로서 다음과 같은 식을 이용하여 계산한다[18].

$$X(t, n) = AS(t, n), \tag{1}$$

이 때, $S(t, n)$ 는 독립 신호원의 시계열로서 n 개의 신호원과 t 개의 시간 샘플로 구성된 행렬이며, $X(t, n)$ 는 n 개의 측정 위치에서 측정된 신호의 시계열을 나타낸다. A 는 각각의 독립요소 신호원들을 혼합시키는 n 행과 n 열로 구성된 혼합행렬을 의미하며 원 신호를 분리하기 위한 행렬 W 는 $W = A^{-1}$ 로 정의된다[18]. 본 연구에서는 정보량(entropy)을 측정하기 위해

$$I = \tanh(S')$$

함수를 사용했으며, S' 는 W 에 의해 분리된 신호를 나타낸다 ($S' = WX(t)$). 가중치 갱신을 위해 아래의 식을 이용하였으며 ΔW 가 0에 근접할 때까지 반복적으로 가중치를 갱신하게 된다.

$$\Delta W \propto [W^T]^{-1} - 2IX(n, t)^T$$

C. Multiple Signal Classification (MUSIC)

MUSIC 알고리즘은 입력 공분산 행렬의 고유구조를 이용하여 원 신호원의 위치 및 시계열을 추출할 수 있는 방법이다[11,12]. MUSIC 알고리즘은 분석구간을 설정하여 공간적 자기-상관행렬

(spatial autocorrelation matrix)의 공간적 특징 벡터들을 고유값 분해를 통하여 추출한 후 부분공간 상관도(subspace correlation, 이후 SC)를 측정하여 신호원의 위치 및 시계열을 추정한다[12]. 이 때 공간의 상관행렬 R_F 는 다음과 같이 정의된다.

$$R_F = (1/p)FF^T, \quad (2)$$

$$R_F = \Phi\Lambda\Phi^T, \quad (3)$$

이 때, F 는 전극에서 측정된 신호로, 측정된 시간 샘플에 해당하는 t 행과 전극의 수를 나타내는 n 열로 구성된 행렬이다. Φ 는 고유벡터(eigenvector)를 의미하며, Λ 는 고유치(eigenvalue)를 나타낸다. 고유치가 매우 작다는 것은 그에 해당하는 고유벡터가 잡음에 가까움을 의미한다. 따라서 구해진 고유치 중에서 큰 고유치에 해당하는 고유벡터를 신호벡터(signal vector), Φ_s , 라 하며, 작은 고유치에 해당하는 고유벡터를 잡음벡터(noise vector), Φ_n , 라고 한다. 현재 널리 사용되는 MUSIC에서는 식(4)에서와 같이 잡음벡터를 이용한 SC를 사용한다.

$$SC\{G\} = \lambda_{\min}\{U_G^T\Phi_n\Phi_n^TU_G\} \quad (4)$$

이 때, G 는 부분공간의 leadfield 행렬을 의미하며, U_G 는 특정 노드의 leadfield 행렬을 특이치 분해(singular value decomposition)하여 계산한 고유벡터 전체를 나타낸다. 이 결과 $U_G^T\Phi_n\Phi_n^TU_G$ 는 x, y, z 축에 대한 상관계수를 나타내는 3행 3열 행렬로 구성된다. 이를 다시 고유치 분해를 통해서 가장 작은 고유치를 찾아 최종적으로 $SC\{G\}$ 를 계산한다. 측정된 신호의 특징을 나타내는 잡음벡터와 각각의 노드에 대한 leadfield 행렬의 고유벡터와의 상관도를 계산하여, 그 상관도가 가장 낮은 곳이 신호의 특징을 가장 많이 가진 곳으로 간주되어 신호원의 발생지점이라고 추정하게 되며 이 위치에서의 시계열을 선형 역산 과정을 통해 추정할 수 있다[11].

D. Directed Transfer Function (DTF)

Directed transfer function (DTF)은 식(6)과 같이 multivariate autoregressive (MVAR)에 기초하여 시계열 사이의 인과성을 측정하기 위한 선형 분석 방법이다[15].

$$\sum_{i=0}^P A(i)X(t-i) = E(t), \quad \text{단, } A(0) = I \quad (6)$$

이 때, $X(t)$ 는 측정된 신호를 나타내며 $E(t)$ 는 백색잡음(white noise)을 의미한다. $A(i)$ 는 신호의 계수를 의미한다. 이를 이용하여 전달함수(transfer function) $H(f)$ 를 다음과 같이 구할 수 있다.

$$H(f) = \left(\sum_{i=0}^P A(i)e^{-i2\pi\Delta t}\right)^{-1} \quad (7)$$

에서 f 는 주파수 이고 Δt 는 샘플링 구간을 나타내며, 이 전달함수를 정규화(normalize) 시킨 γ_{ij}^2 는 다음과 같이 정의된다.

$$\gamma_{ij}^2 = \frac{|H_{ij}(f)|^2}{\sum_{m=1}^k |H_{im}(f)|^2} \quad (8)$$

이 값은 시계열 i 에서 시계열 j 로의 인과성을 나타내며, 또한 정규화된 γ_{ij}^2 값은 0과 1사이의 값을 가지게 된다. 본 연구에서는 인과성의 존재 여부를 결정짓는 문턱치 값을 surrogate 검사를 통하여 결정하였다[19]. 추정된 신호원의 시계열 신호를 이용하여 surrogate 데이터 집합을 만든 후 각각의 집합에 대해 DTF 값을 획득하였다. 이 분포는 정규 분포를 이루게 되는데, 여기서 통계적으로 유의미한 수준인 0.01%에 해당하는 값을 문턱치 값으로 설정하였다.

E. Granger causality (GC)

Granger causality (GC)는 시계열 상에서 두 신호 간의 인과성을 측정하는 다른 방법으로 측정된 두 신호원을 각각 한 개의 신호원과 두 개의 신호원으로 모델링할 때 발생하는 각각의 잔차(residual)의 분산 값을 이용하여 인과관계를 추정한다[16]. 우선, 두 측정된 신호 $x(n)$ 과 $y(n)$ 을 식(9)와 같이 각각 하나의 신호원으로 모델링하여 그 오차인 u_1 과 v_1 를 구한다.

$$\begin{aligned} x(n) &= \sum_{k=1}^p a_{1k}x(n-k) + u_1(n), \\ y(n) &= \sum_{k=1}^p b_{1k}y(n-k) + v_1(n). \end{aligned} \quad (9)$$

또한 식(10)을 이용하여 두 개의 신호원으로 MVAR 모델링하여 그 오차인 u_2 와 v_2 를 구한다.

$$\begin{aligned} x(n) &= \sum_{k=1}^p a_{1k}x(n-k) + \sum_{k=1}^p c_{2k}y(n-k) + u_2(n), \\ y(n) &= \sum_{k=1}^p b_{1k}x(n-k) + \sum_{k=1}^p d_{2k}x(n-k) + v_2(n). \end{aligned} \quad (10)$$

이 때, 신호를 1개로 가정하였을 때의 모델링 오차와 신호를 2개로 가정하였을 때 모델링 오차가 동일하다면 Y 는 X 의 영향을 받지 않았다고 볼 수 있지만 그 반대의 경우 Y 는 X 의 영향을 받

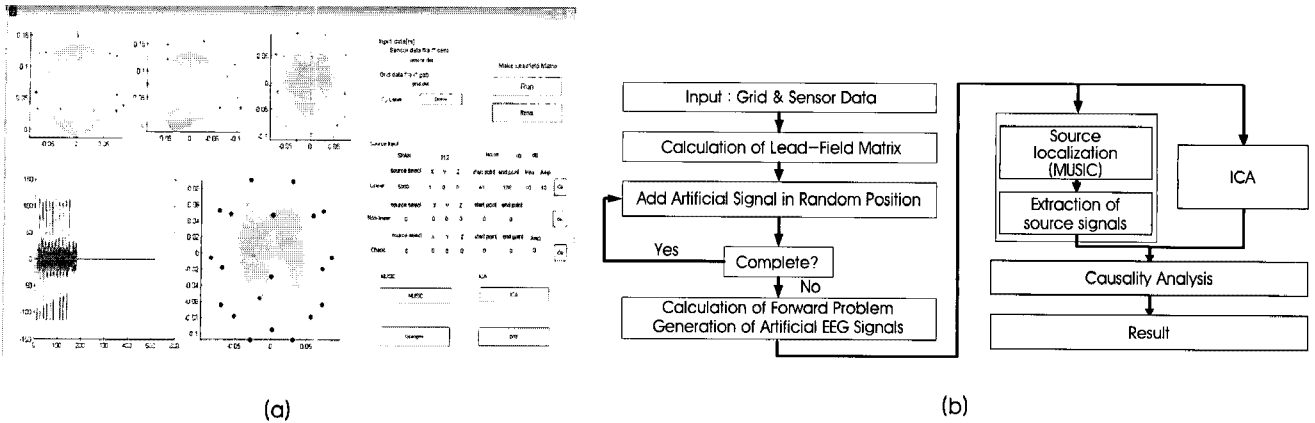


그림 1. 신호들 간의 causality 측정을 위한 MATLAB GUI toolbox: (a) 프로그램 실행 장면; (b) GUI toolbox 실행 순서도.
 Fig. 1. The developed MATLAB GUI toolbox to analyze the causality among extracted source time series: (a) A screenshot of the GUI toolbox; (b) The flowchart of the developed GUI toolbox.

왔다고 볼 수 있다. 따라서 X가 Y에 영향을 주는 정도를 나타내는 $F_{X \rightarrow Y}$ 를 다음과 같이 정의한다.

$$F_{X \rightarrow Y} = \ln \frac{\text{var}(v_1)}{\text{var}(v_2)}. \quad (11)$$

만약 $F_{X \rightarrow Y}$ 가 $F_{Y \rightarrow X}$ 보다 충분히 크다면 신호 X는 신호 Y에 더 큰 영향을 주었다고 볼 수 있다.

F. Matlab GUI toolbox

앞서 언급한 이론들을 이용하여 신호를 분석하기 위해서 Matlab v7.4 (R-2007a)를 이용하여 GUI toolbox를 제작하였다. (그림 1)의 (a)는 실제 제작된 GUI toolbox를 적용하여 분석하는

사례를 나타내며 (b)는 제작된 GUI toolbox의 실행 과정을 나타내는 순서도이다.

III. 결과

(그림 2)의 선형, 비선형, 카오스 시스템에서 생성된 다양한 시계열을 각각 임의로 선정된 4개의 신호원 위치에 부여하여 정문제 해석을 통해 가상의 측정된 신호를 생성한 다음, 이 가상의 EEG 데이터에 ICA와 MUSIC을 적용하여 각각의 시계열 신호원을 분리하였다. 이어서 각 방법에서 얻어진 시계열에 GC와 DTF를 적용하여 신호원들 사이의 인과관계를 확인 하였다. (그림 2)의 (a)-(c) 신호 생성을 위해서 식(12)를 사용하였다.




그림 2. 시뮬레이션에 사용한 신호원 시계열: (a) 선형 시스템에서 생성된 신호, (b) 비선형 시스템에서 생성된 신호, (c) 카오스 시스템에서 생성된 신호.
 Fig. 2. The source time series used for the present simulations: (a) signals generated from a linear system; (b) signals generated from a nonlinear system; (c) signals generated from a chaotic system.

$$\begin{aligned}
 (a) &= P_L \cdot \sin(2\pi \cdot F/ss) \\
 (b) &= P_N \cdot e^{0.02x} \cos(0.8\pi x) \\
 (c) &= cx(1-x)
 \end{aligned}
 \tag{12}$$

(a)의 경우 $P_L=13$ 인 \sin 주기 함수를 사용하였으며, 이 때 F 는 주기함수의 주파수를 나타내며, ss 는 주기함수가 발생하는 구간의 길이를 의미한다. (b)의 경우 $P_N=10$ 인 비선형 주기 함수를 사용하였다. 또한 (c)는 $c = 3.8$ 이고, 초기 값이 0.7인 logistic 카오스 함수를 적용하여 신호를 생성하였다.

샘플링율은 256 Hz이며 신호원 2는 신호원 1의 시계열 신호에 대해 8 샘플만큼 지연된 신호를 부여하였고 신호원 4는 신호원 1의 시계열 신호에 대해 12 샘플만큼 지연된 신호를 부여하였다. 따라서 causality 분석 결과는 신호원 1에서 신호원 2로, 신호원 3에

서 신호원 4로 인과성이 보여 져야 된다. 정문제 해석으로 계산된 가상의 측정 신호에 10 dB의 백색잡음을 첨가한 다음 위의 3가지 신호 각각에 대해 MUSIC과 ICA를 적용한 결과의 사례들을 (그림 3)~(그림 5)에 나타내었다.

(그림 3)의 (a)는 선형 시스템에서 생성된 신호에 MUSIC을 적용하여 시계열을 추출한 결과로서 MUSIC을 통해서 4개의 신호원들이 비교적 잘 분리됨을 확인할 수 있다. (c)는 (a)에 나타낸 신호원들의 인과성을 DTF를 이용하여 평가한 결과이다. 총 12개의 세부 그림으로 이루어져있으며, 각각의 세부 그림의 x 축 방향은 0~50Hz의 주파수를 나타내며, y 축은 각각의 주파수에 대한 인과성 정도를 나타낸다. 예를 들어 i 행 j 열의 세부 그림에서 대부분의 주파수에 대해 인과성이 높게 나타났다면 i 번째 시계열 신호가 j 번째 시계열 신호에 영향을 주었다고 판단하게 된다. (c)에 나타낸 결과에서 1행 2열의 세부그림과 3행 4열의 세부그림에서 인과성

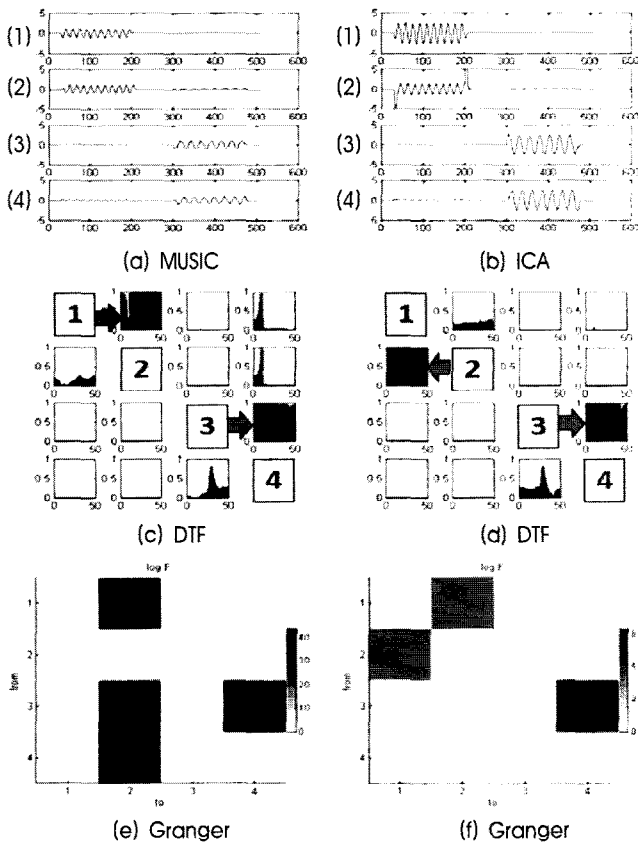


그림 3. 10dB 잡음이 첨가된 선형 시스템에서 생성된 신호의 시뮬레이션 결과 사례: (a) MUSIC에 의해 추정된 신호, (b) ICA에 의해 추정된 신호, (c) (a)-신호의 DTF 결과, (d) (b)-신호의 DTF 결과, (e) (a)-신호의 GC 결과, (f) (b)-신호의 GC 결과.

Fig. 3. An example of simulation results for the signals generated from a linear system: (a) Time series extracted using MUSIC; (b) Time series extracted using ICA; (c) Results of DTF applied to the results of MUSIC; (d) Results of DTF applied to the results of ICA; (e) Results of GC applied to the results of MUSIC; (f) Results of GC applied to the results of ICA.

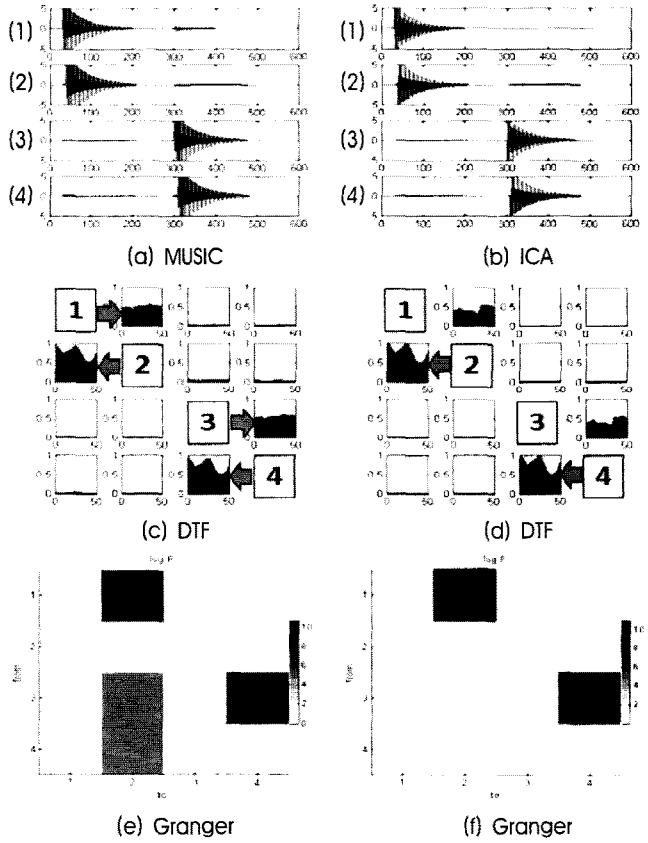


그림 4. 10 dB 잡음이 첨가된 비선형 시스템에서 생성된 신호의 시뮬레이션 결과 사례: (a) MUSIC에 의해 추정된 신호, (b) ICA에 의해 추정된 신호, (c) (a)-신호의 DTF 결과, (d) (b)-신호의 DTF 결과, (e) (a)-신호의 GC 결과, (f) (b)-신호의 GC 결과.

Fig. 4. An example of simulation results for the signals generated from a nonlinear system: (a) Time series extracted using MUSIC; (b) Time series extracted using ICA; (c) Results of DTF applied to the results of MUSIC; (d) Results of DTF applied to the results of ICA; (e) Results of GC applied to the results of MUSIC; (f) Results of GC applied to the results of ICA.

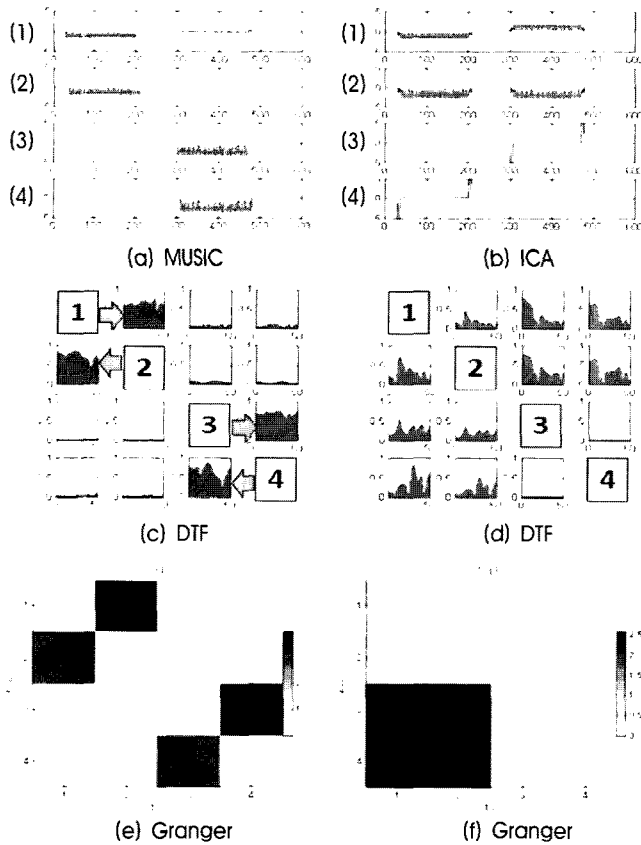


그림 5. 10dB 잡음이 첨가된 카오스 시스템에서 생성된 신호의 시뮬레이션 결과 사례: (a) MUSIC에 의해 추정된 신호, (b) ICA에 의해 추정된 신호, (c) (a)-신호의 DTF 결과, (d) (b)-신호의 DTF 결과(인과성 나타나지 않음), (e) (a)-신호의 GC 결과, (f) (b)-신호의 GC 결과.

Fig. 5. An example of simulation results for the signals generated from a chaotic system: (a) Time series extracted using MUSIC; (b) Time series extracted using ICA; (c) Results of DTF applied to the results of MUSIC; (d) Results of DTF applied to the results of ICA; (e) Results of GC applied to the results of MUSIC; (f) Results of GC applied to the results of ICA.

수치가 높게 나타났다. 이 결과는 1번째 시계열 신호가 2번째 시계열 신호에 영향을 주었으며 또한 3번째 시계열 신호가 4번째 시계열 신호에 영향을 주었다는 것을 의미한다. (e)의 경우 (a)에 나타난 신호원들의 인과성을 GC를 이용하여 평가한 결과이다. GC의 결과는 DTF의 결과와는 달리 하나의 실수 값으로 이루어져 있기 때문에 그 인과성이 수치가 높은 곳에는 진한 색으로, 그 인과성 수치가 낮은 곳에는 연한 색으로 나타내었다. 인과성 방향을 나타내는 방법은 DTF에서 보여준 방법과 동일하다. (e)의 결과에서 1행 2열과 3행 4열에서 높은 인과성 수치를 나타낸 것은 가장한 조건과 일치하지만, 3행 2열, 4행 2열에서와 같이 실제와 다르게 인과성 수치가 높게 발생하기도 하였다. (b)는 ICA를 이용한 신호 분리 결과로서 첫번째 시계열 신호와 두번째 시계열 신호를 잘 분리하지 못하는 것을 확인할 수 있다. 이는 ICA분석이 각 신호원들 사이의 의존성이 존재할 경우 이를 잘 분리하지 못하는 특징을 반영한 것이라 할 수 있다. 그러나 시계열 신호에서 인과성을 계산하기 위해서는 의존성이 반드시 존재하여야 하므로 이 결과는 인과성을 찾아내기 위해 ICA를 사용하는 방법의 한계를 나타낸다고 할 수 있다. (f)에 나타난 GC를 이용한 인과성 추정 결과는 시계열 추출이 정확하지 못한 경우에도 가정하였던 인과성을 비교적 잘 표현할 수도 있음을 보여주고 있는데 하나의 사례를 통해 이를 일반화할 수는 없으므로 이후에 다양한 조건 하에서 시뮬레이션을 수행하였다.

비선형 시스템에서 생성된 신호의 분석 결과인 (그림 4)를 확인하면 ICA와 MUSIC의 두 방법의 결과 모두 신호원의 시계열을 잘 분리한 결과를 확인할 수 있다. GC 결과는 DTF의 결과에 비해 보다 정확한 인과성 결과를 나타내 주고 있지만 여전히 잘못된 인과성 추정 결과도 관찰되어진다.

카오스 시스템에서 생성된 신호의 분석 결과인 (그림 5)를 확인해보면, MUSIC을 적용 하였을 때에는 신호원을 비교적 잘 추출하는 결과를 (a)로부터 확인할 수 있으나 (c)에 제시된 DTF의 결과는 비선형 시스템에서 발생한 신호를 분석할 때와 유사하게 방

표 1. 모의실험의 종합 결과

Table 1. Summary of simulation results

Signal types	MUSIC			ICA		
	CC	Correct Estimation DTF (%)	Correct Estimation GC (%)	CC	Correct Estimation DTF (%)	Correct Estimation GC (%)
Linear (10dB~70dB)	0.65	40	65	0.55	40	46
Nonlinear (10dB~70dB)	0.76	49	76	0.64	44	44
Chaos (10dB~70dB)	0.75	54	75	0.41	36	34
Linear (70dB)	0.95	77	95	0.72	49	66
Nonlinear (70dB)	1.0	64	100	0.80	48	56
Chaos (70dB)	1.0	83	100	0.51	44	26

향성에서 다소 잘못된 결과를 나타냄을 확인할 수 있다. 반면에 ICA를 이용한 분석의 경우 (b)의 결과에서 보듯이 신호원 시계열을 전혀 분리하지 못하였으며, 그로 인하여 (d), (f)의 결과처럼 실제와 전혀 다른 인과성 추정 결과를 보여주고 있다.

이상의 사례들을 보다 일반화시키기 위하여 다양한 조건 하에서 반복적인 시뮬레이션을 수행하였다. (표 1)에서 지연시간과 신호원의 위치, 신호원의 길이 및 잡음의 비율을 변화시킨 다음 약 2000번의 시뮬레이션을 통해 얻어진 결과를 정리하였다. 표에서 CC는 가정한 원 신호원 시계열과 추출된 신호원 시계열 사이의 상관관계수 (Correlation Coefficient)를 의미하는 것으로 완벽한 추정이 이루어졌을 때 1의 값을 가지게 된다. DTF 및 GC에 해당하는 값들은 가정한 연결성을 정확히 추정해 내는 비율(%)을 의미하는 것으로서 100%는 연결성을 모두 올바르게 추정하였음을 의미한다. 시뮬레이션에서 잡음은 10dB, 30dB, 50dB, 70dB의 4가지로 생성하였으며 잡음 정도에 따른 영향을 살펴보기 위하여 전체의 평균 (10dB ~ 70dB)과 잡음이 거의 없는 경우인 70dB의 결과로 나누어서 정리하였다.

MUSIC과 ICA를 통하여 추출된 신호를 비교하여 보면 MUSIC이 ICA에 비해 모든 경우에 대해 향상된 신호원 시계열 추출 성능을 보임을 확인할 수 있다. 특히 잡음이 적은 경우(70dB)에 그 차이가 더욱 분명히 드러나며 신호원의 시계열 추출 성능이 높아짐에 따라 인과성을 올바르게 추정하는 성공률도 함께 높아짐을 확인할 수 있다. 인과성을 측정하는 방법에 있어서는 GC가 DTF에 비해 우수한 성능을 보여주고 있다. 특히 잡음이 적은 경우 MUSIC을 기반으로 GC를 이용하여 그 인과성을 측정하였을 경우에 상당히 높은 성공률을 보였으나 ICA를 기반으로 추출한 시계열에 DTF나 GC를 적용한 경우에는 두 방법 모두 상대적으로 저조한 성공률을 나타내었다.

IV. 결론

앞선 결과들을 바탕으로 볼 때 신호원들 사이의 인과관계를 규명하는데 있어서 신호원 시계열의 정확한 추출이 인과성 분석 결과에 큰 영향을 미침을 다시 한 번 확인할 수 있었다. ICA의 경우 신호원 시계열 추출에 실패할 경우 완전히 왜곡된 신호를 나타내게 되지만, MUSIC을 기초로 하여 신호원을 추출할 경우에는 일부 오차가 발생하더라도 원래의 신호와 상당히 유사한 신호를 얻을 수 있음을 확인하였다. 또한 ICA의 경우 비선형 시스템에서 생성된 신호는 어느 정도 신호원을 분리해 내는 결과를 보였으나, 선형 및 카오스 시스템에서 생성된 신호는 잘 분리해내지 못하는 결과를 관찰할 수 있었다. 결론적으로 ICA를 이용하는 방법은 뇌 모델의 정문제/역문제 해석을 거치지 않고 각 신호들 사이의 독립성분을 분석함으로써 간편하게 뇌 내부의 신호원을 분리해 낼 수 있지만 실제 뇌 특정 위치에서 발생한 신호가 뇌의 다른 위치로 전파된 경우에 대해서는 정확한 신호원 분석이 어려움을 알 수 있다. 종합적으로 볼 때, 뇌 신호원의 시계열 신호를 추출할 때, MUSIC을

이용하는 방법이 더 높은 성능을 보임을 시뮬레이션을 통해 일관되게 확인할 수 있었다. 또한 인과성을 추정함에 있어서는 특히 잡음이 적은 경우에 GC의 성능이 DTF보다 우수함을 확인할 수 있었다. 하지만 신호원이 왜곡되어 추출될 경우에는 두 방법 모두 인과성 추정 성능이 급격히 하락하는 것을 확인할 수 있었다. 따라서, 뇌 신호원의 시계열 추출 성능을 향상시키기 위한 새로운 방법론의 개발이 필요하며 추출된 시계열에 왜곡이 존재할 경우에도 인과성 분석의 정확도를 향상시킬 수 있는 새로운 인과성 측정 지표의 도입이 필요할 것으로 여겨진다. 본 비교 연구의 결과는 뇌 신호원의 추출 및 인과성 분석 연구를 수행하기 위한 적합한 방법을 선택하는 데 있어서 중요한 참고 자료로 활용될 수 있을 것으로 기대된다.

참고문헌

- [1] L. Ding and B. He, "Spatio-temporal EEG source localization using a three-dimensional subspace FINE approach in a realistic geometry inhomogeneous head model," *IEEE Trans. Biomed. Eng.*, vol.53, no.9, pp.1732-1739, 2006.
- [2] L. Ding, C. Wilke, B. Xu, X. Xu, W. van Dronghen, M. Kohrman and B. He, "EEG source imaging: correlating source locations and extents with electrocorticography and surgical resections in epilepsy patients," *J. Clin. Neurophysiol.*, vol.24, no.2, pp.130-136, 2007.
- [3] L. Ding, G. A. Worrell, T. D. Lagerlund and B. He, "Ictal source analysis: localization and imaging of causal interactions in humans," *Neuroimage*, vol.34, no.2, pp.575-586, 2007.
- [4] C. W. Hesse and C. J. James, "Tracking and detection of epileptiform activity in multichannel ictal EEG using signal subspace correlation of seizure source scalp topographies," *Med. Biol. Eng. Comput.*, vol.45, no.10, pp.909-916, 2007.
- [5] C. I. Hung, P. S. Wang, B. W. Soong, S. Teng, J. C. Hsieh and Y. T. Wu, "Blind source separation of concurrent disease-related patterns from EEG in Creutzfeldt-Jakob disease for assisting early diagnosis," *Ann. Biomed. Eng.*, vol.35, no.12, pp.2168-2179, 2007.
- [6] J. Iriarte, E. Urrestarazu, J. Artieda, M. Valencia, P. Levan, C. Viteri and M. Alegre, "Independent component analysis in the study of focal seizures," *J. Clin. Neurophysiol.*, vol.23, no.6, pp.551-558, 2006.
- [7] Jausovec, N. and K. Jausovec. "Spatiotemporal brain activity related to intelligence: a low resolution brain electromagnetic tomography study." *Brain. Res. Cogn. Brain Res.*, vol.16 no.2 pp.267-72, 2003.
- [8] K. Kobayashi, T. Akiyama, T. Nakahori, H. Yoshinaga and J. Gotman, "Systematic source estimation of spikes by a combination of independent component analysis and RAP-MUSIC. I: Principles and simulation study," *Clin. Neurophysiol.*, vol.113, no.5, pp.713-724, 2002.
- [9] K. Kobayashi, T. Akiyama, T. Nakahori, H. Yoshinaga and J. Gotman, "Systematic source estimation of spikes by a combination of independent component analysis and RAP-MUSIC. II:

- Preliminary clinical application," *Clin. Neuro-physiol.*, vol.113, no.5, pp.725-734, 2002.
- [10] T. B. Liu, L. M. Tang and M. Wu, "[Study on an epilepsy EEG processing system based on independent component analysis (ICA)]," *Zhongguo Yi Liao Qi Xie Za Zhi*, vol.31, no.1, pp.26-29, 2007.
- [11] C. M. Michel, M. M. Murray, G. Lantz, S. Gonzalez, L. Spinelli and R. Grave de Peralta, "EEG source imaging," *Clin. Neurophysiol.*, vol.115, no.10, pp.2195-2222, 2004.
- [12] J. C. Mosher, P. S. Lewis and R. M. Leahy, "Multiple dipole modeling and localization from spatio-temporal MEG data," *IEEE Trans. Biomed. Eng.*, vol.39, no.6, pp.541-557, 1992.
- [13] X. Wang, J. Meng and T. Qiu, "Research on chaotic behavior of epilepsy electroencephalogram of children based on independent component analysis algorithm," *Sheng Wu Yi Xue Gong Cheng Xue Za Zhi*, vol.24, no.4, pp.835-841, 2007.
- [14] A. K. Liu, J. W. Belliveau and A. M. Dale, "Spatiotemporal imaging of human brain activity using functional MRI constrained magnetoencephalography data: Monte Carlo simulations," *Proc. Natl. Acad. Sci. USA*, vol.95, no.15, pp.8945-8950, 1998.
- [15] M. J. Kaminski and K. J. Blinowska, "A new method of the description of the information flow in the brain structures," *Biol. Cybern.*, vol.65, no.3, pp.203-210, 1991.
- [16] Granger, C. W. J., "Investigating causal relations by econometric models and cross-spectral methods." *Econometrica* vol.37, pp.424-438 1969.
- [17] Y. J. Lee, Y. S. Zhu, Y. H. Xu, M. F. Shen, H. X. Zhang and N. V. Thakor, "Detection of non-linearity in the EEG of schizophrenic patients," *Clin. Neurophysiol.*, vol.112, no.7, pp.1288-1294, 2001.
- [18] A. J. Bell and T. J. Sejnowski, "An information-maximization approach to blind separation and blind deconvolution," *Neural Comput.*, vol.7, no.6, pp.1129-1159, 1995.
- [19] T. Schreiber and A. Schmitz, "Surrogate time series," *Physica D-Nonlin. Phenom.*, vol.142, no.3-4, pp.346-382, 2000.