

# EEG 독립성분과 위치추정

김응수<sup>†</sup>, 이유정<sup>‡</sup>, 조덕연<sup>‡</sup>

대전대학교 컴퓨터정보통신공학부<sup>\*</sup>

선문대학교 대학원<sup>\*\*</sup>

[eskim@dragon.taejon.ac.kr](mailto:eskim@dragon.taejon.ac.kr), [ujung2@yahoo.co.kr](mailto:ujung2@yahoo.co.kr)

## Independent Component of EEG and Source Position Estimation

Eung-Soo Kim<sup>†</sup>, You-Jung Lee<sup>‡</sup>, DukYun Cho<sup>‡</sup>

Div. of Comp.& Comm. Eng., Taejon University<sup>\*</sup>

Graduate School, Sunmoon University<sup>\*\*</sup>

### 요 약

뇌파(Electroencephalogram, EEG)는 뇌의 자발적 전기활동을 두피에서 측정한 것이다. 그 동안 뇌질환과 관련된 임상에서 주로 사용되어져 왔으며, 비선형 동역학 연구를 통해 결정론적인 동역학 신호임이 밝혀짐에 따라 뇌 기능연구 분야에서 그 응용범위가 넓어지고 있다. 우리는 뇌파 신호에 대하여 독립성분분석(Independent Component Analysis, ICA)을 통하여 그 결과를 알아보았다. 즉, 뇌파의 독립성분 분석 적용 타당성을 알아본 다음 이를 적용하여 독립 소스들을 분리해 내었다. 또한 Topological Mapping을 이용하여 각각의 독립 소스들이 뇌의 어느 위치에서 발생하는지도 알아보았다. 이를 통하여 EEG에 독립성분분석을 적용함으로써 뇌 활동의 시간적, 공간적 분석이 가능하고 유용함을 나타내었다.

### 1. 서론

독립성분분석은 blind source separation 방법으로 최근 들어 주목 받고 있는 알고리즘이다. 독립성분분석의 목적은 알 수 없는 선형결합으로 이루어진 신호들의 결과로부터, 원래의 독립 소스들을 구분해 내는 것이다. 예를 들면, 두 사람이 서로 다른 얘기를 하고 있는 방에 두개의 마이크를 이용하여 목소리를 녹음하였다고 하자. 녹음된 결과는 두 사람의 목소리가 섞여서 들릴 것이다. 이를 Cocktail party problem 이라고도 하는데, 녹음된 결과 만을

가지고 두 사람의 목소리를 각각 분리해 내는 것이다. 2차 상관 관계까지 고려하는 주축성분 분석(Principal Component Analysis, PCA)과 달리 독립성분 분석은 고차 상관 관계까지 고려해 성분들을 분리해 내기 때문에 가능한 한 가장 독립적인 소스들로 분리하는 일이 가능하다. 우리는 이 알고리즘을 뇌파에 적용하였다.

뇌파는 뇌 신경세포가 정보를 처리하는 과정에서 발생하는 전기적인 신호를 두피에서 측정한 것이다. 주로 간질진단 등과 같은 뇌 질환의 임상에서 주로 사용되었으나, 다양한 분석방법이 연구되면서

뇌기능 전반을 이해하기 위한 도구로 폭넓게 사용되어지고 있다. 뇌파는 해부학적으로 의미가 있는 영역에 20개의 채널을 통해 측정하므로, 각 채널에서 측정된 신호는 활성화된 부위의 인근영역에 걸친 신호의 집합체로 볼수 있다.

공간적으로 퍼져 있는 뇌파에 대해 독립성분분석을 적용하여 통계적으로 고도로 연관되어 있는 뇌파로부터 독립적인 소스들로 분리해 내었다. 또한 각각 분리된 소스들이 해부학적으로 어느 위치에서 기인하는지도 알아 보았다.

## 2. ICA

우선, 평균은 0이며 각각의 성분들은 서로 상호 독립적인  $s(t) = [s_1(t), \dots, s_M(t)]^T$ 를 생각해 보자. 벡터  $s(t)$ 는 M개의 독립된 스칼라 신호  $s_i(t)$ 로 구성되어 있다.

각 시간  $t$ 에서의 데이터 벡터  $x(t) = [x_1(t), \dots, x_N(t)]^T$ 는 아래와 같다.

$$x(t) = As(t)$$

여기서 A는  $N \times M$  스칼라 행렬이다. 간단히 독립성분분석 기본 모델을 그림으로 나타내면 아래 그림 1과 같다.

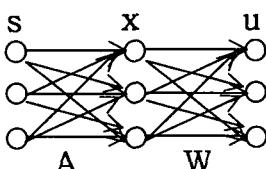


그림 1. 기본 ICA 모델

1

여기서  $s$ 는 소스,  $x$ 는 측정된 데이터,  $u$ 는 추측한 독립 소스,  $A$ 는 미지의 소스 혼합행렬,  $W$ 는 blind separation 행렬이다.

본 논문에서 사용한 독립성분분석 알고리즘은 Bell 과 Sejnowski의 정보량 최대화 방법(Infomax)에 기초한다. 이는 'Stochastic gradient learning

rule'에 근거하여 비선형 함수를 거친 입력 벡터들의 결합 엔트로피를 최대화 시키는 행렬  $W$ 를 찾는 것이다. 그럼에서와 같이 측정을 통해 얻은 입력 신호  $x(t)$ 는 원래의 소스와 미지의 혼합 행렬의 역행렬을 입력신호에 곱해서 얻을 수 있다.  $W$ 를 A의 역행렬에 가장 근사한 형태로 구해 원래의 소스  $s(t)$ 를 추측하는 것이다. 따라서 측정된 뇌파 데이터의 결합 엔트로피를 최대화 시키는  $W$ 를 구할 수 있다.  $W$ 는 처음에  $N \times N$  단위행렬로 설정하고 데이터 벡터를 작은 단위로 뭉어서 반복적으로 실행함으로써 출력 결합 엔트로피를 최대화 시키는 형태로 맞추어간다.  $W$ 의 계산이 끝나면 이를 이용해 우리가 추측하는 독립소스  $u(t)$ 를 얻을 수 있게 된다. 이 알고리즘의 전체 순서를 정리하면,

1. 데이터  $x_i(t)$  ( $i = 1, \dots, N$ )에 대한 비선형 함수

$$g(u_i) = \frac{1}{1 + \exp(-u_i)}$$

를 계산한다.

이 때,  $u(t) = Wx(t) = WAs(t)$ ,  $y_i = g(u_i)$ 이다.

$$2. \Delta W = \varepsilon \frac{\partial H(y)}{\partial W} W^T W = \varepsilon [I - \phi(u)u^T]W$$

$$\phi(u) = -\frac{\partial p(u)}{\partial u} = \left[ -\frac{\partial p(u_1)}{\partial u_1}, \dots, -\frac{\partial p(u_N)}{\partial u_N} \right]^T$$

에서 비선형 함수가 'sigmoid' 함수 이므로 결국,  $\phi(u) = 2y_i - 1$ 가 되므로

$$\Delta W = \frac{\partial H(y)}{\partial W} W^T W = \varepsilon [I + (1 - 2y_i)u^T]W$$

$\Delta W$ 를 계산 할 수 있다.  $H(y)$ 는 출력의 결합 엔트로피이고,  $\varepsilon$ 는 학습율이다.

$$3. W_{update} = W + \Delta W$$

4. 위에서 구한  $W$ 를 데이터  $x(t)$ 에 곱하여 추측 소스  $u(t)$ 를 얻을 수 있다.

### 3. ICA의 EEG 적용

뇌파는 20개의 채널을 통해 각 채널 부위의 활성화된 신호를 측정하게 된다. 우리는 이러한 신호를 만들어 내는 독립적인 원래의 소스와 뇌 영역이 무엇인지 의문을 가지게 된다. 이러한 의문을 풀기 위해서 독립성분분석 기법을 사용하였다.

독립성분분석은 다음과 같은 소스 분포들에 대하여 적용된다.

- (1) 소스가 독립적일 때
- (2) 전파 지연 시간(propagation delay)이 무시될 때
- (3) 소스의 확률밀도함수가 logistic sigmoid와 유사할 때
- (4) 독립 소스의 개수가 센서의 수보다 적거나 같을 때

뇌파의 경우, 확률적으로 독립적인 뇌 활동에 따라 순간적으로 신경 세포에 전달되어 발생하는 신호이므로 첫번째와 두번째 조건을 만족한다. 또한 신경 세포의 기본 단위인 뉴런의 확률밀도함수가 logistic sigmoid라는 것은 여러 연구를 통해 알려져 있으므로 뇌파 역시 sigmoid함수의 형태임을 짐작할 수 있다. 마지막으로 각 채널에 기록된 뇌파에 기여한 독립적인 소스의 적절한 수를 알지 못하므로 정확한 센서의 수를 알 수 없어 네번째 조건은 정확히 확인 할 수 없다. 그러나 독립성분 분석의 결과는 생리학 또는 정신생리학적인 중요성을 결정하는데 사용되어지므로 마지막 조건을 엄격하게 만족하지 않는다 하여도 그 결과는 뇌 기능을 이해하는데 훌륭하게 적용할 수 있다.

### 4. 방법 및 시뮬레이션

#### 4.1 EEG측정

뇌파는 국제 전극배치법 10-20system에 따라 20개의 채널을 이용하여 측정하였다. 피험자는 대뇌질환을 가지지 않은 정상 성인 10명을 대상으로 하였으며, 편안히 누운 상태에서 시작하여 양 엄지 발가

락을 동시에 움직이게 한 후 1분간 뇌파를 측정하였다. 이와 같이 측정된 뇌파는 아래 그림 2(A)와 같다. Fp1 ~ Cz 까지 총 20개의 채널에 대해 측정되었으며 샘플링 주파수는 256KHz로 측정되었다.

#### 4.2 ICA 분석

측정된 뇌파를 독립성분분석을 통하여 아래 그림 2(B)와 같이 20개의 독립 신호로 분리하였다. 이 신호들이 그림 1의  $u(t)$  즉, 독립적인 추축 소스의 결과이다. 다시 말해, 원래의 뇌파신호는 두뇌에서 측정되기 전까지 알 수 없는 요인들과 그림 2(B)와 같은 독립 성분들이 선형적으로 결합되어 만들어진 신호임을 알 수 있다. 또한 그림 2(C)는 일부 독립 성분들을 2차원으로 매핑하여 나타낸 것이다. 이 Topological Map에서 검은 점들은 20개의 뇌파 채널을 의미하며, 각 성분들의 기여도를 등고선 형태로 나타내었다.

### 5. 결과

뇌파는 많은 수의 신경 세포들의 전기신호의 합이다. 따라서 그 크기는 신경세포의 활성정도를 나타내는 좋은 예이다. 이러한 특성들과 용이한 측정 방법 때문에 뇌를 연구하는데 가장 효과적인 수단으로 쓰이고 있다. 이러한 뇌파를 독립성분분석을 통하여 각각의 독립성분으로 분석하였을 뿐 아니라 Topological Map을 기록하였다. 특히 Topological Map을 통해 각각의 독립 성분들의 전체 뇌 영역에 대한 기여도를 한 눈에 볼 수 있다. 한 독립성분의 투영은 그 성분에 의해 발생된 전위의 변화양상을 나타낸다. 따라서, Topological Map에서의 활성정도가 큰 지점이 그 독립성분의 소스라고 간주될 수 있다. 본 논문에서는 독립성분분석을 뇌파에 적용하여 뇌 활동의 시간적, 공간적 분석이 가능함을 나타내었다.

## 6. 참고문헌

- [1] A.J. Bell and T.J. Sejnowski, "An Information-maximization approach to blind separation and blind deconvolution", *Neural Computation*, 7:1129-1159, 1995
- [2] Te-Won Lee, Mark Girolami and Terrence J. Sejnowski, "Independent Component Analysis using an Extended Infomax Algorithm for Mixed Sub-Gaussian and Super-Gaussian Sources", *Neural Computation*, Vol:11(2), 409-433, 1999

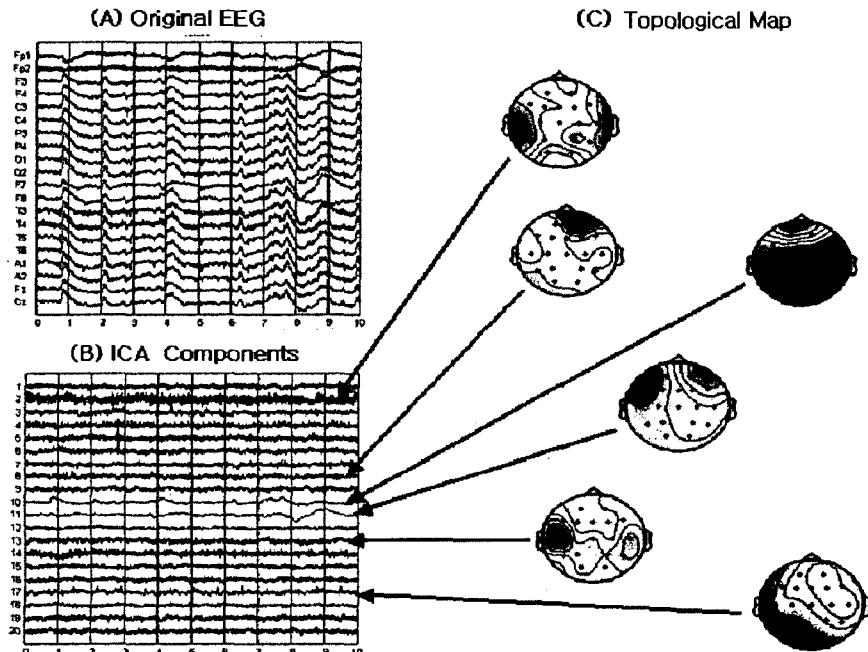


그림 2. (A) 20채널의 EEG Raw 데이터  
(B) EEG 독립성분분석 결과 (C) Topological Map