

# EEG신호의 독립성분 분석과 소스 위치추정

김 응 수<sup>†</sup>

## 요 약

뇌파(Electroencephalogram, EEG)는 뇌에서 막대한 수의 뉴런들의 전위차의 합으로 표현되는 시계열 전위차이다. 규칙적인 시간 간격으로 짚 이를 가진 전극 측정에 의한 EEG로부터 서로 다른 구조를 가진 뇌에서의 뉴런 집단의 동역학을 평가할 수 있다. 최근에는 비선형 동역학 연구를 통해 뇌 기능 연구를 정량적으로 분석할 수 있는 방법이 개발되고 있다. 본 논문은 뇌파 신호를 분석함에 있어서 독립성분분석(Independent Component Analysis, ICA)의 적합성을 고려해 보았고, 15명의 정상인의 발가락 자극에 대한 EEG 신호에 이를 적용하여 독립 소스들을 분리해내었다. 또한 Topological Mapping을 이용하여 각각의 독립 소스들의 기여도를 나타내었다. 이를 통하여 EEG에 독립성분분석을 적용함으로써 뇌 활동의 시간적, 공간적 분석이 가능하고 유용함을 나타내었다.

## Independent Component Analysis of EEG and Source Position Estimation

EungSoo Kim<sup>†</sup>

## ABSTRACT

The EEG is a time series of electrical potentials representing the sum of a very large number of neuronal dendrite potentials in the brain. The collective dynamic behavior of neural mass of different brain structures can be assessed from EEG with depth electrodes measurements at regular time intervals. In recent years, the theory of nonlinear dynamics has developed methods for quantitative analysis of brain function. In this paper, we considered it is reasonable or not for ICA apply to EEG analysis. Then we applied ICA to EEG for big toe movement and separated the independent components for 15 samples. The strength of each independent component can be represented on the topological map. We represented ICA can be applied for time and spatial analysis of EEG.

**키워드 :** 뇌파(EEG), 독립성분(Independent component), 독립성분분석(ICA), 주축성분분석(PCA), 위치추정(position estimation)

## 1. 서 론

독립성분분석은 blind source separation 방법으로 최근 들어 주목받고 있는 알고리즘이다. 혼합된 데이터로부터 통계적으로 독립적인 성분들을 분리해 내는 새로운 기술로서 Bell과 Sejnowski 그리고 Makeig 등에 의해 제안된 방법들이 널리 알려져 있다[1, 2, 5]. 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 [14]이라고도 하는데, 녹음된 결과만을 가지고 두 사람의

목소리를 각각 분리해 내는 것이다. 여기서 녹음된 신호를 각각  $x_1(t)$ ,  $x_2(t)$ 라고 하자. 단,  $x_1$ ,  $x_2$ 는 각각의 크기이며  $t$ 는 시간을 나타낸다. 독립된 두 사람의 음성신호를 각각  $s_1(t)$ ,  $s_2(t)$ 라고 하면, 마이크를 통해 녹음된 신호는 다음과 같은 선형적인 신호의 합으로 나타낼 수 있다.

$$x_1(t) = a_{11} \cdot s_1(t) + a_{12} \cdot s_2(t) \quad (1)$$

$$x_2(t) = a_{21} \cdot s_1(t) + a_{22} \cdot s_2(t)$$

여기서  $a_{11}$ ,  $a_{12}$ ,  $a_{21}$  그리고  $a_{22}$ 는 두 사람이 마이크로부터 떨어져 있는 거리에 비례하는 파라메터 값이다. 만약 우리가 이러한  $a_{ij}$  파라메터 값을 알 수만 있으면 위 식 (1)과 같은 선형방정식은 쉽게 풀 수 있으며 동시에 독립성분을 직접 구할 수 있다. 그러나 이 문제는 그렇게 간단한 문제가 아니다.

2차 상관관계까지 고려하는 주축성분분석(Principal Co-

\* 본 연구는 정보통신부에서 지원하는 대학기초연구지원사업으로 수행되었습니다.

† 종신회원 : 대전대학교 공과대학 컴퓨터정보통신공학부 교수  
논문접수 : 2001년 8월 16일, 심사완료 : 2001년 11월 30일

ponent Analysis, PCA)[13]과 달리 독립성분분석은 신호들간의 고차 상관관계까지를 고려하여 성분들을 분리해내기 때문에 가능한 한 가장 독립적인 소스들로 분리하는 일이 가능하다. 주축성분분석이 신호들간의 관련성(correlation)을 중심으로 이를 최소화하는 방향으로 신호들을 분리(decorrelation)하는 것과는 달리, 독립성분분석은 신호들간의 의존성(dependency)까지 최소가 되도록 분리한다(independency)는 점이 특징이다[2]. 신호들간의 의존성은 고차통계, 정보이론 등과 같은 통계적 방법으로 정의할 수 있으며 혹은 학습 신경회로망에 의해서도 독립성분들을 추정하고 분리할 수 있다.

독립성분분석의 대표적인 응용분야로서 잡음제거 및 분리, 음질개선, 영상 및 화상개선 등과 같은 음성처리분야나 영상처리분야[15]를 꼽을 수 있다. 또한 복잡한 패턴에서 대표적인 특징을 추출하거나 구분이 모호한 성분들을 강조하는 방법 등의 일반적인 패턴인식 등에 응용[16, 17]되기도 하며, 최근에는 통신, 예측분야, 데이터 마이닝을 비롯하여 컴퓨터 단층촬영, EEG, MEG의 분석, Source localization 등과 같은 의학분야[6-9]에도 꼭 넓게 이용되고 있다.

우리는 이 알고리즘을 뇌파에 적용하였다. 뇌파는 뇌 신경세포가 정보를 처리하는 과정에서 발생하는 전기적인 신호를 두피에서 측정한 것이다. 뇌파는 주로 간질 진단 등과 같은 뇌 질환 환자의 진단을 위해 임상에서 주로 사용되었으나[9], 다양한 분석방법이 연구되면서 뇌기능 전반을 이해하기 위한 도구로 꼭 넓게 사용되어지고 있다. 뇌파는 해부학적으로 의미가 있는 영역에 20개의 채널을 통해 측정하므로, 각 채널에서 측정된 신호는 활성화된 부위의 인근 영역에 걸친 신호의 집합체로 볼 수 있다[10-12].

지금까지 뇌파에 대한 연구는 뇌파 자체에 이상이 있는 사람 즉, 뇌 질환을 가진 사람을 대상으로 정상인과의 차이를 구분하는 연구가 대부분으로 주로 선형분석법인 FFT [18]를 이용한 파워스펙트럼을 많이 활용하였으나[11], 뇌파의 비선형성 및 카오스 성질이 알려지면서 상관차원, 리아푸노프 지수(Lyapunov exponent), 상호정보 등 다양한 분석법[9, 10, 12]으로 뇌파의 특징을 밝혀 나가고 있다. 그러나 뇌파의 특성상 측정 시 다양한 artifact가 섞이기 쉬우며, 이것은 선형 및 비선형 분석에 있어서 오차를 증가시키는 원인이 되어왔다. ICA가 이러한 artifact의 제거 및 각 성분들의 발생에 관계된 메커니즘과 해부학적 발생 위치를 추정할 수 있는 도구로 쓰일 수 있음을 나타내고자 한다.

본 논문에서는 뇌 질환자가 아닌 정상 성인을 대상으로 특정한 행위를 시킬 때 발생하는 정상뇌파를 측정한 다음, 이를 독립성분으로 분석하고 각 독립성분들의 발생 부위를 2차원 평면에 나타냄으로써 특정 행위에 수반된 뇌 활동 부위의 관찰 및 다양한 정신상태를 구분하는 지표를 얻는


다. 공간적으로 퍼져 있는 뇌파에 대해 독립성분분석을 적용함으로써 통계적으로 고도로 연관되어 있는 뇌파로부터 각각의 독립적인 소스들을 분리해내었다. 또한 분리된 각 소스들이 해부학적으로 어느 위치에서 기인하는지를 알아보기 위하여 혼합행렬(Mixing matrix)의 열(column)의 요소에 대한 상태적 기여도를 등고선을 이용하여 나타내었다.

## 2. ICA

우선, 평균은 0이며 각각의 성분들은 서로 상호 독립적인  $s(t) = [s_1(t), \dots, s_M(t)]^T$ 를 생각해보자. 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.


$$x(t) = A \cdot s(t) \quad (2)$$

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



(그림 1) 기본 ICA 모델

여기서  $s$ 는 소스(source),  $x$ 는 측정된 데이터(mixture),  $u$ 는 추측한 독립 소스,  $W$ 는 미지의 소스 혼합행렬(mixing matrix),  $y$ 는 blind separation 행렬(unmixing matrix)이다.  $u$ 는 최종 출력이며  $G(u_i) = 1/[1 + \exp(-u_i)]$ 이다[2].




(그림 2) 균일한 분포를 가진 독립성분  $s_1$ 과  $s_2$ 의 결합분포

통계적 측면에서 독립성분분석 모델의 예를 보기 위하여 균일한 분포를 가지는 두 개의 독립성분  $s_1$ 과  $s_2$ 를 생각한다. 단, 이들의 평균은 0이며 분산은 1이 되도록 범위를 정한다. 그러면  $s_1$ 과  $s_2$ 의 결합밀도는 사각형안에서 균일한 분포를 가진다. 이를 (그림 2)에 나타내었다.


이제 이 두 독립성분을 다음의 혼합행렬  $A$ 를 이용하여 관측 데이터  $x_1$ 과  $x_2$ 로 만들어 본 결과를 (그림 3)에 나타내었다. 여기서 랜덤 변수  $x_1$ 과  $x_2$ 는 더 이상 독립적이지 않다.

$$A = \begin{pmatrix} 0.4 & 0.8 \\ 0.9 & 0.7 \end{pmatrix}$$



(그림 3) 관측된 데이터  $x_1$ 과  $x_2$ 의 결합분포

본 논문에서 사용한 독립성분분석 알고리즘은 Bell과 Sejnowski의 정보량 최대화 방법(Infomax)에 기초한다[1]. 이는 'Stochastic gradient learning rule'에 근거하여 비선형 함수를 거친 입력 벡터들의 결합 엔트로피를 최대화시키는 행렬  $W$ 를 찾는 것이다. (그림 1)에서와 같이 측정을 통해



(그림 4) 추정된 독립성분  $u_1$ 과  $u_2$ 의 결합분포

얻은 입력 신호  $x(t)$ 는 원래의 소스와 미지의 혼합 행렬의 역행렬을 입력신호에 곱해서 얻을 수 있다.  $W$ 를  $A$ 의 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. 즉, 처음에  $W$ 를  $N \times N$  단위행렬로 설정하고 데이터 벡터를 작은 단위로 묶어서 반복적으로 실행함으로써 출력 결합 엔트로피를 최대화시키는 형태로 맞추어 간다.  $W$ 의 계산이 끝나면 이를 이용해 우리가 추측하는 독립소스  $u(t)$ 를 얻을 수 있게 된다. 이러한 방법으로 구해진 독립성분분석 결과를 (그림 4)에 나타내었다.

이 알고리즘의 전체 순서를 정리하면 다음과 같다.

1. 데이터  $x_i(t)$  ( $i=1, \dots, N$ )에 대한 비선형 함수  $G(u_i) = \frac{1}{1 + \exp(-u_i)}$ 를 계산한다.  
이때,  $u_i(t) = Wx(t) = WA_s(t)$ ,  $y_i = G(u_i)$ 이다.
2.  $\Delta W \propto \frac{\partial H(y)}{\partial W} W^T W = \epsilon [I - \phi(u) u^T] W$   
 $\phi(u) = -\frac{\partial p(u)/\partial u}{p(u)} = \left[ -\frac{\partial p(u_1)/\partial u_1}{p(u_1)}, \dots, -\frac{\partial p(u_N)/\partial u_N}{p(u_N)} \right]^T$   
에서 비선형 함수가 시그모이드(sigmoid)함수 이므로 결국,  
 $\phi(u) = 2y_i - 1$ 이 되므로  
 $\Delta W \propto \frac{\partial H(y)}{\partial W} W^T W = \epsilon [I + (1 - 2y_i) u^T] W$ 로서  
 $\Delta W$ 를 계산할 수 있다.  $H(y)$ 는 출력의 결합 엔트로피이며 다음과 같이 정의된다.  $H(y) = \sum p(y) \log 1/p(y)$ , 또한  $\epsilon$ 는 학습율이다.
3.  $W_{\text{update}} = W + \Delta W$
4. 위에서 구한  $W_{\text{update}}$ 를 데이터  $x(t)$ 에 곱하여 추측 소스  $u(t)$ 를 얻을 수 있다.

### 3. EEG 분석을 위한 ICA의 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[14].

- (1) 소스가 독립적일 때
- (2) 각 소스는 가우시안(Gaussian)이 아니며, 정규분포 형태의 소스는 많아야 한 개이다
- (3) 전파 지연 시간(propagation delay)이 무시될 때
- (4) 소스의 확률밀도함수가 logistic sigmoid와 유사할 때
- (5) 독립 소스의 개수가 센서의 수보다 적거나 같을 때

독립이라는 개념을 정의하기 위하여 임의의 랜덤 변수  $s_1$ 과  $s_2$ 를 도입하였을 때, 이들이 상호 독립이라는 것은  $s_1$ 의 값이  $s_2$ 에 어떠한 영향도 미치지 않으며,  $s_2$ 도  $s_1$ 에 영향을 미치지 않는다는 뜻이다. 여기서 독립성은 확률밀도로 정의할 수 있다. 즉,  $s_1$ 과  $s_2$ 의 결합 확률밀도함수(joint probability density function : pdf)[14]를  $p(s_1, s_2)$ 로 기술하고  $s_1$ 의 marginal pdf를  $p_1(s_1)$ 으로 기술하면,  $s_1$ 의 확률밀도함수는  $p_1(s_1) = \int p(s_1, s_2) ds_2$ 로 볼 수 있으며,  $s_2$ 에 대해서도 마찬가지이다. 따라서  $s_1$ 과  $s_2$ 가 독립일 필요충분조건은 결합 확률밀도함수가  $p(s_1, s_2) = p_1(s_1)p_2(s_2)$ 로 기술되어야 하며, 이를 M개의 변수로 확장한 일반식은 다음과 같다.

$$p(s) = \prod_{i=1}^M p_i(s_i) \quad (3)$$

또한 독립성분분석에 있어서 가장 기본적인 제한은 각 독립요소들의 분포가 가우시안이 아니다(nongaussian)라는 점이다. 왜냐하면 가우시안 변수로는 근본적으로 독립성분분석을 하지 못한다. 그 이유는 혼합행렬  $A$ 가 직교하고  $s_i$ 가 가우시안이면, 측정된 데이터  $x_1(t)$ 와  $x_2(t)$ 는 가우시안이며, 상관관계가 없고 단위 편차를 가진다. 이것의 결합밀도는 다음과 같이 주어지며, 완전히 대칭이 되므로 이 자체로는 혼합행렬  $A$ 의 행(row) 방향에 대한 어떠한 정보도 가지고 있지 않으므로 소스들을 분리할 수 없게 된다. 그 예를 식 (4)에 나타내었다.

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(-\frac{x_1^2 + x_2^2}{2}\right) \quad (4)$$


뇌파의 경우, 확률적으로 독립적인 뇌 활동에 따라 전기적 포텐셜이 순간적으로 신경 세포에 전달되어 발생하는 신호이므로 첫 번째와 두 번째 그리고 세 번째 조건을 만족한다. 또한 신경 세포의 기본 단위인 뉴런의 확률밀도함수가 logistic sigmoid라는 것은 여러 연구를 통해 알려져 있으므로[10-12] 뇌파 역시 시그모이드 함수의 형태임을 짐작할 수 있다. 마지막으로 각 채널에 기록된 뇌파에 기여한 독립적인 소스의 적절한 수를 알지 못하므로 정확한 센서의 수를 알 수 없어 네 번째 조건은 정확히 확인할 수 없다. 그러나 독립성분분석의 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 compumedics video-EEG monitoring 37 channel,

model E를 사용하여 국제 전극배치법 10-20system[19]을 기본으로 하여 20개 채널(Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, A1, A2, Fz, Cz)의 전극을 두피에 붙인 후 각 전극의 뇌파신호와 심전도, 안전도를 기록하였다. 연구대상자는 소리와 전파의 방해를 받지 않도록 차단된 방에서 뇌파 검사를 시행했고 편안히 침대에 눕게 한 후 입을 가볍게 다물고 몸을 이완시켜 근육에 의한 artifact를 줄이고 먼저 눈을 감게 한 후 가능한 한 눈동자를 움직이지 말도록 하였다. 정신상태에 대해서는 지정된 상태를 실시하기 직전에 지시하였으며 대상자가 상태를 완전히 이해한 후부터 기록을 시작하였다. 연구대상자는 대뇌질환을 가지지 않은 정상 성인 15명을 대상으로 하였으며, 편안히 누운 상태에서 눈을 감고 양 엄지발가락을 동시에 움직이게 하는 동작을 시행하게 한 다음 그 상태에서 1분간 뇌파를 측정하였다. 뇌파검사는 표본추출 주파수(sampling frequency) 256Hz로 하였고 민감도(sensitivity)는 7uV/mm, 고주파 여과(hight frequency filter) 70Hz, 저주파 여과(low frequency filter) 1Hz로 설정하였다[3]. 측정된 뇌파파형 중 임의의 한 사람의 뇌파를 (그림 6)에 나타내었다.



(그림 6) 20채널의 Raw EEG 데이터


### 4.2 ICA 분석

(그림 6)에서 보여진 바와 같이 측정된 뇌파를 독립성분분석을 통하여 아래 (그림 7)과 같이 20개의 독립신호로 분리하였다. 이 신호들이 (그림 1)의  $u(t)$  즉, 독립적인 추측소스의 결과이다. 독립성분신호  $u(t)$ 는 다음의 과정을 거쳐 출력된 신호를 의미한다.

$$y(t) = G(u(t)) = \int_{-\infty}^u P(u) du, \quad \frac{dy}{du} = P(u) \quad (5)$$

원래의 뇌파신호는 두피에서 측정되기 전까지 알 수 없

는 요인들, 예를 들면 다양한 artifact의 혼입 및 전기적 잡음, 외부교란 등과 함께, (그림 7)에서 보여진 것과 같은 독립성분들이 선형적으로 결합되어 만들어진 신호임을 알 수 있다.



(그림 7) 20채널의 ICA 데이터

(그림 7)에 나타난 각 성분들의 특징은 소스 혼합행렬(mixing matrix)  $A$ 의 열(column)의 요소와 관련되어 있다. 예를 들어 첫 번째 독립성분의 신호파형은 소스 혼합행렬  $A$ 의 첫 번째 열인  $A_{11}, A_{21}, \dots, A_{20,1}$ 의 항과 밀접한 관계를 가지고 있다. 마찬가지로 두 번째 독립신호는  $A$ 의 두 번째 열인  $A_{12}, A_{22}, \dots, A_{20,2}$ 의 항과 밀접한 관계를 가지고 있음을 알 수 있다. 이는 측정된 데이터(mixture)  $x$ 가 혼합행렬  $A$ 의 행(row)과 관련이 있는 것, 다시 말해, 첫 번째 측정 데이터(mixture)의 경우,  $x_1 = A_{11} \cdot s_1 + A_{12} \cdot s_2 + \dots + A_{1,20} \cdot s_{20}$ 인 것과 비교하여 대단히 중요한 점을 상기시키고 있다. 즉, 측정된 데이터는 혼합행렬의 행의 각 항과 각 독립소스의 곱을 선형적으로 합함으로써 구해진 값임을 확인할 수 있다. 그러나 ICA에 의해 구해진 임의의 하나의 독립성분은 혼합행렬, 엄밀히 말하면  $A = W^T$ 의 각 열의 항과 밀접한 관계를 가지고 있음을 알 수 있다.

정리하면 (그림 6)에서 보여진 측정된 데이터는 혼합행렬  $A$ 의 행(row)의 요소와 관련이 있으며, (그림 7)에서 보여진 독립신호들은  $A$ 의 열(column)의 요소와 직접적인 관련이 있다. 따라서 측정된 신호로부터 혼합행렬  $A$ 의 성질을 정확히 분석함으로써 독립성분 신호들의 각 특징을 이해할 수 있다. 또한 이러한 혼합행렬의 성질을 이용하여 즉, 혼합행렬  $A$ 의 열(column)의 요소 값을 이용하여 뇌파 측정 위치에서 각 요소들의 강도를 표시함으로써 독립성분이 뇌의 어느 부위에서 상대적으로 강한 영향을 받고 있는지를 확인할 수 있다.

뇌파신호는 뇌의 상태나 기능, 위치에 따라 다양하게 나타난다. 이러한 신호는 뇌의 전기적 현상이 일어나는 부분에 대하여 시공간적 상태의 차이를 반영하는 것으로 치매, 간질의 진단이나 대사성 질환의 대뇌 평가상태와 같은 임상에의 응용을 비롯하여 인지나 감성 상태의 변화 등을 통한 인지기능의 연구나 뇌 연구 등에 널리 이용되고 있다. 전통적인 뇌파 검사의 시각적 해석에서는 주로 알파파(alpha wave)와 베타파(beta wave)가 변하는 형태에 따라 뇌의 상태를 파악하는데 관심을 가져왔다. 일반적으로 의식적 행동을 줄임에 따라 뇌파 중 알파파가 양쪽 대뇌반구에서 감소하며 의식적 노력을 할수록 베타파가 증가한다[20, 21]. 또한 최근의 한 연구는 움직임을 시각적으로 받아들이는 뇌의 활동부위를 확인하기 위해 움직이는 물체를 관측하는 동안 측정된 뇌파를 정량적으로 분석하였다. 결과는 움직임을 시각적으로 받아들이는 부위는 감각운동피질(sensorimotor cortex)이 담당한다는 것을 확인할 수 있었다[22].

그러나 뇌기능의 미세한 상태변화에 관여하는 유사부동(quasi stationary)상태를 구성하는 뇌의 전기적 변화를 차트기록에 의한 시각적 해석이나 시간 및 주파수 분석 등과 같은 일반적인 분석방법으로 확인하기는 어렵다. 왜냐하면 뇌는 다발적 공간영역의 작용을 통합하며, 자극에 대한 적절한 반응을 만들어 내기 위해서 여러 피질부위에 퍼져있는 신경세포의 활동력을 통합하기 때문이다. 특히 본 연구에서 관심을 가진 양 엄지발가락 움직임과 관련된 뇌파의 해부학적 측면에서의 발생 부위는 Central vertex 중 Cz을 중심으로 한 영역이며, 표피에서 6~10cm 정도의 깊은 곳에서 발생하는 정보인 만큼 두피측정 뇌파로는 그 움직임에 대한 영향을 뇌 부위별로 평가하기란 사실상 불가능하다[23, 24].

안정상태, 계산상태, 움직임을 인식하는 상태에 대한 뇌부위별 분석에 있어서는 수학적 계산을 할 때 전두엽이 활성화되고, 움직임에 대한 반응은 후두엽이 활성화된다. 정상 성인에 있어서 그림을 보는 시각적 자극보다 소리에 의한 청각자극에 우리 뇌는 좀 더 복잡한 전기적 활동이 필요할 것이라 추측할 수 있고, 신체 일부의 움직임일지라도 상대적으로 세밀한 움직임인 양 엄지발가락만을 동시에 움직일 때가 어려움 없이 쉽게 시행할 수 있는 양 검지손가락을 움직일 때보다 많은 전기적 활동이 필요할 것이라 추측할 수 있다.

그러나 차트기록, FFT와 같은 선형분석 혹은 상관차원 등과 같은 비선형 분석법으로는 뇌의 깊은 곳에서 발생되는 이러한 신호의 발생 부위 및 그 기여도를 확인하기 어렵다.

여기서는 양 엄지발가락을 동시에 움직이는 특정 행위에 의한 뇌파를 20채널로서 측정하고 이를 독립성분으로 분리

한 다음 각 성분들의 발생 부위를 추정 계산된 소스 혼합 행렬을 이용하여 2차원 평면상에 나타냄으로써 특정 행위에 수반된 뇌 활동 부위를 관찰하였다. 한 독립성분의 투영은 그 성분에 의해 발생된 전위의 변화양상을 나타내므로 Topological map에서의 활성정도가 큰 지점이 그 독립성분의 소스라고 간주될 수 있다.

각 성분별 뇌파의 활성 영역을 나타낸 (그림 8)은 앞의 (그림 6), (그림 7)의 raw EEG와 ICA EEG에서 보여진 것처럼 한 사람의 측정된 데이터에 대한 결과이다. 전반적인 활성 부위는 전두엽, 두정엽 및 후두엽에서 주로 강한 기여도가 발생함을 확인할 수 있다. 특히 (그림 8)에서 보여진 것처럼 채널 18번은 Cz 영역을 중심으로 강한 기여도를 나타내고 있으며, 이는 양 엄지발가락 움직임과 관련된 뇌 활성부위의 영향을 독립성분분석을 통하여 확인할 수 있음을 잘 나타내고 있다. 따라서 측정된 뇌파를 이용하여 그 활성 부위를 추정함으로써 인간의 의식적 행위에 대한 뇌 활성 부위를 시각적으로 확인할 수 있음을 알 수 있다. 또한 채널 3번과 채널 5번을 통하여 Cz를 중심으로 광범위한 영역에 걸쳐 엄지발가락 움직임에 대한 활성부위가 나타남을 확인할 수 있다. 그밖에 Fp1 영역에서 눈동자 움직임으로 추정되는 artifact가 발생된 것을 확인할 수 있으며, 뇌파에 기록된 파형만으로 artifact의 여부를 판정하기 어려울 때, 이렇게 발생시킨 map을 통하여 그 발생 부위를 확인함으로써 정확한 진단 및 해석이 가능함을 알 수 있다.


15인을 대상으로 실험하였으며 case 2에서 case 15까지의 분석 및 평가에 대한 결과중 지면이 허락하는 범위 내에서 몇 케이스를 부록에 나타내었다. 우선 case 2의 경우를 살펴보면 채널 11에서 양 엄지발가락 움직임과 관련된 map기여도를 확인할 수 있으며, case 3의 경우는 채널 8, case 4의 경우는 채널 19, case 5의 경우 채널 6번에서 각각 기여도를 확인할 수 있다. 양 엄지발가락 움직임과 관련된 활성부위는 그밖에도 일부 관찰할 수 있으나 case 1과 같이 대부분 활성 영역이 광범위하게 걸쳐있는 특징을 나타낸다.

그러나 이렇게 케이스마다 엄지발가락 움직임의 기여도 평가에서 각 채널이 일정하지 않고 불규칙하게 나타나는 것은 독립성분분석법이 가지고 있는 특성에 기인하므로 이를 이용하여 데이터를 해석하고자 할 때는 특히 이 점에 주의하여야 한다. 즉, raw EEG의 경우에는 Fp1부터 Cz까지 일정한 순서로 뇌파가 측정 기록되어 있지만, 일단 독립성분분석을 행하면 모든 데이터의 순서가 완전히 바뀌게 된다. 따라서 ICA EEG에서 표시한 바와 같이 독립성분들에 있어서는 채널별 표시가 아니라 단순히 순서만을 기입한 것을 확인할 수 있다. 부록에 나타낸 ICA EEG 및 Topological map의 결과도 랜덤하게 뒤섞인 성분들을 나타내고 있으므로 Cz를 중심으로 한 map기여도의 채널별 표

시가 일정하지 않은 것이다.

이와 같은 방법으로 독립성분과 Topological map을 대응 시켜 가면서 각 성분들의 뇌 활성 부위를 선택적으로 확인할 수 있으며, 정상인의 다양한 행동 양식에 따른 다양한 뇌파를 측정하고 비교 분석함으로써 행동에 따른 뇌 전위 발생 부위 및 기여도 등을 확인할 수 있다.

Topological map에서 검은 점들은 20개의 뇌파 채널을 의미하며, 혼합행렬에서의 각 성분들의 기여도를 등고선 형태와 색깔을 가진 명암으로 나타내었다. 등고선의 간격이 조밀하고 색깔이 짙을수록 기여도가 크며 색깔이 옅을수록 기여도가 낮다.



(그림 8) Topological Map

그밖에 여기서는 분석 데이터의 확률밀도에 관한 변수들을 도입하여 각 채널에서의 평균값, 표준편차, Kurtosis 등에 관한 분석 결과를 다음의 <표 1>에 나타내었다. 여기서 평균은 일반적으로 first moment와 관련 있는 양으로서  $\bar{x} = 1/N \sum_{j=1}^N x_j$ 로 정의되며, 표준편차는 second moment와 관련 있는 변수이다. Kurtosis는 fourth moment와 관련 있는 양으로서 확률분포의 뾰족성 정도를 나타내며  $kurtosis = 1/N \sum_{j=1}^N \left[ \frac{x_j - \bar{x}}{\sigma} \right]^4 - 3$ 로 정의된다. Kurtosis는 양의 값이나 음의 값을 가질 수 있으며, 양의 값일 때 supergaussian 음의 값일 때 subgaussian이라고 한다.

또한 측정된 데이터와 독립성분분석을 통하여 재구성된 데이터와는 어떠한 차이가 있는가를 알아보기 위하여 각각의 데이터에 대하여 상관차원 값의 평균값( $N = 15$ )을 계산한 결과치를 <표 2>에 나타내었다. 여기에서도 나타나듯이 상관차원의 값이 커짐을 확인할 수 있는데, 이는 위상공간의 궤적이 더 복잡하게 표현되며 시계열을 발생시킨 시스템의 구조가 더 복잡하다는 증거를 제시하며 독립성분분석을 통하여 데이터의 비선형 및 카오스성을 향상시킨 결과로 볼 수 있으며 이 방법의 유효성을 잘 나타내고 있다고 볼 수 있다.

〈표 1〉 각 채널별 평균, 표준편차, Kurtosis의 평균값 (N=15)

채널	평균	표준편차	Kurtosis
Fp1	5.23	0.16	-0.04
Fp2	5.29	0.25	-0.27
F3	4.70	0.40	0.03
F4	4.67	0.27	0.23
C3	4.64	0.38	-0.37
C4	4.59	0.35	-0.14
P3	4.52	0.41	-0.33
P4	4.57	0.37	0.61
O1	4.45	0.38	-0.46
O2	4.47	0.30	-0.47
F7	4.47	0.47	0.79
F8	4.48	0.48	0.03
T3	4.53	0.43	0.25
T4	4.66	0.44	-0.15
T5	4.49	0.30	-0.49
T6	4.41	0.31	-0.47
A1	4.36	0.39	-0.33
A2	4.52	0.37	-0.12
Fz	4.69	1.02	-0.05
Cz	4.56	0.34	-0.27

〈표 2〉 상관차원 값의 비교 (N=15)

채널	측정데이터	ICA 데이터
Fp1	0.82775	2.29678
Fp2	1.1944	2.81293
F3	1.44060	3.00426
F4	2.32982	2.76285
C3	2.19552	5.51820
C4	2.42631	3.30567
P3	1.72797	3.06035
P4	1.82896	2.88032
O1	1.85855	2.00109
O2	1.64320	2.11271
F7	2.10355	2.27614
F8	2.69766	3.82073
T3	3.74462	2.10520
T4	2.12512	2.31177
T5	2.79677	3.29421
T6	2.38085	2.88343
A1	2.29351	3.34678
A2	2.43991	3.08496
Fz	2.22855	3.09129
Cz	1.78232	2.88769

## 5. 결 과

뇌파는 많은 수의 신경 세포들의 전기신호의 합이다. 따라서 그 크기는 신경세포의 활성정도를 나타내는 좋은 예이

다. 이러한 특성들과 용이한 측정방법 때문에 뇌를 연구하는 데 가장 효과적인 수단으로 쓰이고 있다. 그러나 뇌파는 측정된 특정 부위에서의 뉴런들의 활성 정도에 따른 영향만을 나타내는 신호가 아니며, 뇌의 다양한 부위에서 복잡하게 영향을 받아 나타난 신호이므로 그 특징을 이해하는데 어려움이 많으며, 고도의 훈련을 받은 전문가가 아니고서는 뇌파의 특징과 뇌 활동의 의미를 이해하기 어렵다. 또한 뇌기능의 미세한 상태변화에 관여하는 유사부동 상태를 구성하는 뇌의 전기적 변화를 차트기록에 의한 시각적 해석이나 선형분석 등과 같은 일반적인 분석방법으로 확인하기는 어렵다. 본 연구에서 관심을 가진 양 염지발가락 움직임과 관련된 뇌파의 해부학적 측면에서의 발생 부위는 뇌의 한 중간인 Cz을 중심으로 한 영역이며 표피에서 6~10cm 정도의 깊은 곳에서 발생하는 정보인 만큼 두피 측정 뇌파로는 그 움직임에 대한 영향을 뇌 부위별로 평가하기가 쉽지 않다.


따라서 이러한 뇌파를 독립성분분석을 통하여 각각의 독립성분으로 분석하고, 이러한 성분들이 뇌의 각 영역에서 어떠한 강도로 영향을 받고 있는지를 Topological map을 통하여 나타냄으로써 각각의 독립 성분들의 전체 뇌 영역에 대한 활성 영역 및 기여도를 한 눈에 볼 수 있도록 하였다. 즉, 독립 성분들이 주로 뇌의 어느 부위에서 발생되는지를 시각적으로 나타냄으로써 뇌의 활성 정도를 부위별로, 성분별로 확인할 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 나타내었으며, 다양한 artifact의 제거, 3차원 Source localization을 위한 연구 등에도 폭넓게 활용될 수 있을 것으로 본다. 또한 정상 성인에 있어서 그림을 보는 시각적 자극보다 소리에 의한 청각자극에 우리뇌는 좀 더 복잡한 전기적 활동이 필요할 것이라 추측할 수 있고, 신체 일부의 움직임일지라도 상대적으로 세밀한 움직임인 양 염지발가락만을 동시에 움직일 때가 어려움 없이 쉽게 시행할 수 있는 양 검지손가락을 움직일 때보다 많은 전기적 활동이 필요할 것이라 추측할 수 있다.


그밖에 앞에서 언급하였듯이 독립성분분석을 통하여 시계열을 발생시키는 시스템의 구조가 더 복잡해지며 계의 비선형성을 향상시키는 결과를 확인할 수 있으며, 이는 뇌파 신호의 비선형성, 카오스성에 따른 분석결과의 신빙성에도 큰 영향을 준다. 본 연구는 뇌파 신호가 결정론적 비선형 다이나믹스를 나타내는 카오스 신호임을 전제로 행하여졌으며, 양 염지발가락을 동시에 움직이게 하는 것처럼 섬세한 운동을 의식적으로 시행토록 할 때 우리 뇌의 전기적 활동력이 증가한다는 것을 알 수 있었다. 이것으로 다양한 정신상태에 따라 다른 값을 가지는 뇌파의 ICA 분석은 여러 가지 신경생리학적 변화 설명에 이용될 수 있고 질병의 진단에도 이용될 수 있을 것으로 기대된다.

부록. Raw EEG 데이터에 대한 케이스별 분석 결과 (case2~5)


Case 2.



(그림 a1) Raw EEG 데이터(LSK09)




(그림 b1) ICA EEG 데이터




(그림 c1) Topological map (LSK09)


Case 3.



(그림 a2) Raw EEG 데이터(KJY09)




(그림 b2) ICA EEG 데이터




(그림 c2) Topological map (KJY09)


Case 4.



(그림 a3) RAW EEG 데이터(SEK09)




(그림 b3) ICA EEG 데이터




(그림 c3) Topological map(SEK09)


Case 5.



(그림 a4) Raw EEG 데이터(KMA09)



(그림 b4) ICA EEG 데이터



(그림 c4) Topological map (KMA09)

## 참 고 문 헌

- [1] A. J. Bell and T. J. Sejnowski, "An Information-maximization approach to blind separation and blind deconvolution," *Neural Computation*, Vol.7, pp.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, No.2, pp. 409-433, 1999.
- [3] S. H. Chae, et al, "Nonlinear analysis of EEG in various mental states of normal person," *Journal of Korean Neurological Association*, Vol.18, No.5, pp.581-588, 2000.
- [4] K. Kobayashi, I. Merlet and J. Gotman, "Separation of spike from background by independent component analysis with dipole modeling and comparison to intracranial recording," *Clinical Neurophysiology*, Vol.112, pp.405-413, 2001.
- [5] S. Makeig, et al, "Independent Component Analysis of Electroencephalographic Data," "Advances in Neural Information Processing Systems," Vol.8, 1996.
- [6] L. Zhukov and D. Weinstein, "Independent Component Analysis for EEG Source Localization," *IEEE Engineering in Medicine and Biology*, pp.87-96, May/June, 2000.
- [7] G. Wubbeler, et al, "Independent Component Analysis of Noninvasively Recorded Cortical Magnetic DC-Fields in Humans," *IEEE Trans. on Biomedical Eng.*, Vol.47, No.5, pp.594-599, 2000.
- [8] R. Vigario, et al, "Independent Component Analysis to the Analysis of EEG and MEG Recordings," *IEEE Trans. on Biomedical Eng.*, Vol.47, No.5, pp.589-593, 2000.
- [9] J. Jeong, J. Gore and B. Peterson, "Mutual information analysis of the EEG in patients with Alzheimer's disease," *Clinical Neurophysiology*, Vol.112, pp.827-835, 2001.
- [10] S. Blanco, et al, "Using nonlinear dynamic metric tools for characterizing brain structures," *IEEE Engineering in Medicine and Biology*, pp.83-92, July/August, 1997.
- [11] J. C. Sigl and N. G. Chamoun, "An Introduction to bispectral analysis for the electroencephalogram," *Journal of Clinical Monitoring*, Vol.10, No.6, pp.392-404, 1994.
- [12] W. Lutzenberger, et al, "Fractal dimension of electroencephalographic time series and underlying brain processes," *Biological Cybernetics*, Vol.73, pp.477-482, 1995.
- [13] I. T. Jolliffe, "Principal Component Analysis," Springer-Verlag, 1986.
- [14] Te-Won Lee, "Independent Component Analysis, Theory and Applications," Kluwer Academic Publishers, 2001.
- [15] J. H. van Hateren and A. van der Schaaf, "Independent component filters of natural images compared with simple cells in primary visual cortex," *Proc. Royal Society ser., B.* 265, pp.359-366, 1998.
- [16] A. Hyvärinen, E. Oja, et al, "Image feature extraction by sparse coding and independent component analysis," *Proc. Int. Conf. On Pattern Recognition*, pp.1268-1273, 1998.
- [17] M. Lewicki and B. Olshausen, "Inferring sparse, overcomplete images codes using an efficient coding framework," *Advances in Neural Information Processing*, pp.815-821, MIT Press, 1998.
- [18] B. L. Jackson, "Signals, System and Transforms," Addison Wesley, 1991.
- [19] Saito Shoji, "Clinical electroencephalography," Ilchokak, 1987.
- [20] A. C. Papanicolaou and D. W. Loring, "Task-related EEG asymmetries : a comparison of alpha blocking and beta enhancement," *Int. J. Neuroscience*, pp.81-85, 1998.
- [21] H. Petsche, S. Kaplan, AV Stein, O. Filz, "The possible meaning of the upper and lower alpha frequency ranges for cognitive and creative tasks," *Int. J. Psychophysiology*, 26, pp.77-97, 1997.
- [22] S. Cochin, C. Barthelemy, et al, "Perception of motion and qEEG activity in human adults," *Electroencephal. Clin. Neurophysiol.*, pp.287-295, 1998.
- [23] E. Niedermeyer, F. Silva, "Electroencephalography Basic Principles," Clinical Applications, and Related Fields, Fourth Edition, Lippincott Williams & Wilkins, 1999.
- [24] Private communication with K. G. Choi M. D who is a faculty member of the Department of Neurology at Ewha Womans University Medical School.



### 김 응 수

e-mail : eskim@dju.ac.kr

1977년 부산대학교 공과대학 전자공학과

졸업

1979년 부산대학교 대학원 전자공학과

졸업(석사)

1993년 日本 東北大學校 公學研究과 전자

공학과 졸업(박사)

1986년~1987년 日本 Waseda University 객원연구원

1984년~1994년 한국전자통신연구원 책임연구원

1994년~2000년 선문대학교 전자정보통신공학부 교수

2000년~현재 대전대학교 공과대학 컴퓨터정보통신공학부 교수

관심분야 : Neural network and Brain computing, Statistical physics of neural net, Chaos and Fractal theory on neural network, Bioinformatics, and mainly engaged in research on signal processing of the biomedical signals, EEG, ECG, fMRI.