

독립성분분석에서 Convolution-FFT을 이용한 효율적인 점수함수의 생성 알고리즘

김 웅 명[†] · 이 현 수^{‡‡}

요 약

본 연구에서는 엔트로피를 이용한 독립성분분석(ICA : Independent Component Analysis)에서 점수함수(score function)를 생성하는 알고리즘을 제안한다. 점수함수를 생성하기 위해서 원 신호(original signals)에 대한 확률밀도함수의 추정이 반드시 필요하고 밀도함수가 미분 가능해야 한다. 따라서 원 신호에 따른 적응적인 점수 함수를 유도할 수 있도록 커널 기반의 밀도추정(kernel density estimation)방법을 사용하였으며, 보다 빠른 밀도 추정 계산을 위해서 식의 형태를 컨볼루션(convolution) 변환 한 후, 컨볼루션을 빠르게 계산할 수 있는 FFT(Fast Fourier Transform) 알고리즘을 이용하였다. 제안한 점수함수 생성 방법은 원 신호에 확률밀도분포와 추정된 신호의 확률밀도 분포의 오차를 줄이는 역할을 한다. 실험 결과, 암묵신호분리(blind source separation)문제에서 기존의 Extended Infomax 알고리즘과 Fixed Point ICA 보다 원 신호와 유사한 밀도함수를 추정하였고, 분리된 신호의 신호대잡음비등(SNR)에 있어서 향상된 성능을 얻을 수 있었다.

키워드 : 독립성분분석, 커널밀도추정, 컨볼루션, 퓨리에 변환, 신호분리, 엔트로피

An Algorithm of Score Function Generation using Convolution-FFT in Independent Component Analysis

Woong Myung Kim[†] · Hyon Soo Lee^{‡‡}

ABSTRACT

In this study, we propose this new algorithm that generates score function in ICA(Independent Component Analysis) using entropy theory. To generate score function, estimation of probability density function about original signals are certainly necessary and density function should be differentiated. Therefore, we used kernel density estimation method in order to derive differential equation of score function by original signal. After changing formula to convolution form to increase speed of density estimation, we used FFT algorithm that can calculate convolution faster. Proposed score function generation method reduces the errors, it is density difference of recovered signals and originals signals. In the result of computer simulation, we estimate density function more similar to original signals compared with Extended Infomax and Fixed Point ICA in blind source separation problem and get improved performance at the SNR(Signal to Noise Ratio) between recovered signals and original signal.

Key Words : Independent Component Analysis, Kernel Density Estimation, Convolution, FFT, Source Separation, Entropy

1. 서 론

독립성분분석(Independent Component Analysis : ICA)는 관측된 결과나 확률변수(random variable) 혹은 신호들에 있어서 잠재적으로 감추어진 요소들을 계산하기 위한 통계적인 기법중 하나이다. 즉, 신호의 경우 측정된 데이터에 대한 감추어진 요소들을 독립 성분(independent component)으로 나타낼 수 있다. ICA는 Cocktail party 문제에서 출발하는데, 이 방법은 서로 독립적인 소스 신호들에 대한 혼합된

신호들을 분리하는 암묵신호분리(Blind Source Separation : BSS) 문제에 유용하다[1-3]. ICA는 독립성분을 발견하기 위해, 주로 신호간의 독립성(independence)을 측정하는데 이는 상호정보최소화(mutual information minimization) 혹은 결합 엔트로피 최대화(joint entropy maximization)등의 조건을 이용한다[4, 6, 8, 9, 16, 17]. 그리고 ICA는 주성분 분석(Principal Component Analysis : PCA)과 비교하여 보다 확장된 방법이라고 볼 수 있다[1, 9]. 이와 같은 이유는 PCA가 신호간의 상관 분석을 수행하는 2차적 통계(second-order statistics)방법이고 원 신호(original signals)들 사이에 직교성(orthogonal)을 가져야 신호를 분리할 수 있지만, ICA는 4차적 통계(fourth-order statistics)방법이며, 원 신호들이

[†] 준 회 원: 경희대학교 컴퓨터공학과 박사과정

^{‡‡} 정 회 원: 경희대학교 컴퓨터공학과 교수
논문접수: 2005년 11월 15일, 심사완료: 2006년 2월 4일

직교를 하지 않더라도 신호를 분리할 수 있다[6-8]. 따라서 ICA는 PCA를 이용한 decorrelation 조건 보다 좀 더 강력한 제약사항을 가지게 되고, 고차의 통계적인(highest-order statistics) 특성 분석을 할 수 있다. ICA는 다음과 같은 제약을 가져야 한다[2]. 첫째, 독립요소(Independent Component)는 통계적으로 독립이라고 가정한다. 둘째, 독립요소는 반드시 nongaussian 분포를 가진다. 셋째, 혼합행렬(unknown mixing matrix)은 반드시 정방행렬(square matrix)이다. 이러한 제약 사항은 ICA를 매우 엄격한 조건에서 소스 신호에 대한 추정을 가능하게 한다. 또한 ICA는 매우 다양한 분야에 응용되어 질 수 있는데, 디지털 이미지나 문서 등의 데이터 베이스 분석 혹은 음성, 뇌파분석, EEG 분석 등 매우 다양한 분야에 적용되어질 수 있다[5, 12, 13].

기존의 많은 독립성분분석 알고리즘은 보다 정확한 신호 원을 분리하기 위해서 많은 시도를 해 왔다. 그러나 이와 같은 알고리즘들은 부분적인 최적화로 인해서 원하지 않는 신호들이나 부정확한 신호들로 분리되는 경우가 발생한다. 현재 알려진 ICA 방법 중에서 Fixed-Point 알고리즘은 최적의 신호원을 추출하기 위해서 신호원의 확률밀도함수(Probability Density Function)에 해당하는 비선형 함수를 정의하고 있다[2]. 이는 non-gaussian 성질을 최대화하기 위한 것이다. 이와 같은 비선형 함수는 가정된 신호의 분포에 따라서 틀려지는데 주로 $\tanh(\cdot)$ 혹은 $(\cdot)^3$ 등을 사용한다. Extended Infomax 알고리즘의 경우, 피어슨 혼합 분포 모델(Pearson Mixture Model)을 사용하여 원신호에 대한 확률분포를 계산하여 분리된 신호를 추정하는 학습알고리즘이다[8, 10]. 이 방법은 분포에 대한 단순화를 위하여 4차 모멘텀인 침도(kurtosis)를 사용하였고, 일반적인 가우시안 분포보다 높은 침도를 가지는 super-gaussian 과 낮은 침도를 가지는 sub-gaussian 계열로 나누어 사용하였다. 또한 Cardoso 등에 의해서 제안되어던 JADE 알고리즘은 4차 적률(cumulant)을 이용하여 신호원의 독립성분을 측정하였다[6, 7]. 그리고 Flexible ICA는 4차 모멘트인 침도를 추정해서 적당한 비선형 활성함수를 찾는 방법이다[11]. 이것을 위해서 밀도함수에 감마함수 변환을 이용하여 파라미터를 가진 활성함수를 유도하였다.

정보이론을 이용한 ICA에서 점수함수(score function)는 통계적으로 확률분포와 관련이 있다[15-17]. 이러한 ICA 수행과정은 최대우도추정법(maximum likelihood estimation)을 사용하는데, 이는 로그우도값을 최소화하기 위하여 기울기 강하 알고리즘(gradient descent algorithm)을 유도하는 것과 유사하다[2]. 이러한 기법은 가정된 확률분포를 이용한 점수함수를 사용한다는 것이 특징이다. 따라서 ICA를 이용한 신호분리문제에 있어서 원 신호의 대한 확률밀도함수를 발생시켜서 분리 신호들을 정확히 출력할 수 있도록 하는 것이 중요하고, 이를 위해서는 원신호의 밀도함수에 기반한 적당한 점수함수를 생성하는 것이 필요하다. 따라서 본 연구에서는 신호의 밀도함수를 이용하여 소스 신호에 따른 적응적인 점수함수를 유도한다. 이를 위하여 확률밀도추정 방법

중 비 매개변수추정 (nonparametric density estimation) 방법인 커널기반의 추정방법(kernel density estimation)을 사용하였다. 이러한 커널 기반의 추정방식의 사용배경은 미분이 가능하기 때문에 새로운 점수함수의 식을 유도할 수 있다[17]. 그리고 빠른 확률밀도추정을 위해서 점수함수의 식을 컨볼루션(convolution) 형태로 표현하여 처리하였다. FFT(Fast Fourier Transform)의 경우 컨볼루션된 신호를 빠르게 처리할 수 있는 방법이기 때문에[14], 원 신호에 적당한 확률밀도함수를 추정하여 점수함수를 생성할 수 있다. 2장에서는 ICA방법과 로그우도의 목적함수에 대해서 서술하고, 3장에서는 확률밀도함수에 의한 점수함수를 유도하였다. 4장에서는 실제의 음성과 영상에 대한 신호분리 결과를 나타내었다.

2. 최대우도방법에 의한 독립성분분석(Independent Component Analysis)

s 를 $m \times n$ 크기의 통계적인 독립성분(소스)이라고 가정하고, x 는 식 1과 같이 원 신호 s 들에 대한 선형 변환이 된다. 여기서 A 는 혼합행렬(mixing matrix)이라고 가정하고 $m \times m$ 사이즈의 비정칙(nonsingular) 행렬이 된다. 선형적인 혼합 신호들을 만들기 위한 식은 다음과 같이 표현된다.

$$x = As \quad (1)$$

x 는 혼합되어진 신호이며, 다음과 같은 식 2에 의해 신호를 분리하는 모델로 나타낼 수 있다.

$$u = Wx \quad (2)$$

신호를 분리하는 행렬을 W 로 표현하며, 분리행렬 $W = A^{-1}$ 와 같은 조건을 가질 때 분리된 신호 u 를 추정할 수 있다. 여기에서 $f(u)$ 를 u 의 결합 분포(joint density)에 대한 모델이라고 가정하는 경우 각 출력 신호에 대한 주변분포(marginal densities)를 계산하면 아래의 식 3과 같다.

$$f(u) = \prod_{j=1}^m f_j(u^{(j)}) \quad (3)$$

여기에서 $u^{(j)}$ 는 벡터 u 의 j 번째 신호이고 $f_j(u^{(j)})$ 는 신호 u 에 대한 확률밀도함수이다. 측정된 신호 x 에 대한 확률밀도함수는 식 4와 같이 표현 할 수 있다[2-4, 6]. 여기에서 x 에 대한 분포는 W 행렬과 분리 신호 u 의 확률밀도함수의 구성으로 나누어진다.

$$f(x) = |\det W| f(Wx) \quad (4)$$

ICA에서 분리행렬 W 을 최적화 하는 학습 과정이기 때

문제, 다음과 같이 로그우도함수(log-likelihood function)을 사용하면 식 5와 같은 비용함수를 만들 수 있다.

$$\begin{aligned} L(u, W) &= - \sum_{j=1}^m \log f(u_j) \\ &= -n \log |\det W| - \sum_{j=1}^m \sum_{i=1}^n \log f_j(y_i) \end{aligned} \quad (5)$$

일반적으로 식 5는 $W = A^{-1}$ 의 조건을 가질 경우 전역해(global minimum)를 가진다. 또한 natural gradient 방법을 사용한 ICA 학습을 이용하면 전역해에 근사할 수 있다. 이러한 전역해에 근사하기 위해, 위 식을 W 에 대해서 로그우도값을 최대로 하게 되면 식 6와 같이 나타낼 수 있다(최대로그우도값을 구하기 위하여 W 에 대해서 미분을 수행한다).

$$W = W - \eta (E[\varphi(u)u^T] - I)W \quad (6)$$

여기서 η 는 학습상수이며, E 는 기대치이고, 이는 신호에 대한 샘플 평균으로 계산을 한다. I 는 $m \times m$ 크기의 항등행렬을 나타낸다. 일반적으로 식 6에서 사용된 φ 는 비선형 점수함수(nonlinear score function)라고 불리어지고 식 7과 같이 표현된다.

$$\varphi(u) = -[\log f(u)]' = \frac{f'(u)}{f(u)} \quad (7)$$

여기서 $f(u)$ 는 u 에 대한 확률밀도함수이고 $f'(u)$ 는 밀도함수를 u 대해 미분하여 유도된 식이다.

3. 커널기반의 확률밀도 추정에 의한 점수함수의 생성

3.1 SFG(Score Function Generation) 알고리즘

통계학적으로 확률밀도를 추정하는 방법은 매개변수방식과 비매개변수방식으로 나누어진다. 매개변수 방식은 베이시안(Bayesian) 추정 등이 사용되고, 이것은 확률밀도함수를 특정한 함수의 형식으로 가정하여 요구되는 변수의 값을 추정하는 방식이다. 반면 비매개변수 방식은 히스토그램이나 커널을 이용하여 추정하는(Kernel Density Estimate : KDE) 방법이 사용된다. 그 중 커널을 이용한 추정방법은 미분이 가능하므로, 본 연구에서는 커널을 이용한 확률밀도 추정방법을 사용한다. 커널기반의 추정은 아래와 같이 정의되어진다. 식 8과 9는 확률밀도추정을 위한 근사식이다.

$$\hat{f}(u) \approx f(c) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{c-u_i}{h}\right) \quad (8)$$

$$K(z) = \frac{1}{\sqrt{2\pi}} \exp^{-z^2/2} \quad (9)$$

식 8와 식9를 이용하여 c 에 대해서 미분을 하게 되면 식 7과 같은 형태로 나타나게 된다. 여기에서 c 는 가우시안 커널들의 중심점이고 일차원 벡터로 표현된다. l 을 커널의 개수라고 할 때, $c = [c_1, c_2, \dots, c_l]$ 로 되어진다. 여기에서 u 대신에 c 로 미분을 하는 이유는 KDE 출력결과가 c 의 차원과 동일하기 때문이다. 또한 식 9에서 n 과 π 부분은 상수이기 때문에 생략할 수 있다. 따라서 미분을 하여 유도된 식은 아래와 같다.

$$\hat{\varphi}(u) \approx \varphi(c) = \frac{\frac{1}{h^2} \sum_{i=1}^n (c-u_i) \exp\left(-\frac{(c-u_i)^2}{2h^2}\right)}{\sum_{i=1}^n \left(-\frac{(c-u_i)^2}{2h^2}\right)} \quad (10)$$

윗 식에서 n 은 독립성분분석에서 신호 샘플의 수이다. 즉 u 는 ICA 신호 출력으로부터 측정된 값이다. h 는 일반적으로 양수이고, 각 커널의 넓이에 해당되는 부분이다. 일반적으로 bandwidth 혹은 smoothing parameter라고 한다[14]. 커널을 이용한 확률추정 방법은 시간이 많이 소요되기 때문에, 위의 식 10을 컨볼류션 형태로 바꾼다. 커널 샘플에서 측정되어진 값들은 각 영역에서 커널의 출력과 관련이 있기 때문에 컨볼류션이 가능하다. 즉 컨볼류션 형태는 주파수 도메인에서 곱의 형태로 나타나기 때문에 우리는 커널추정방법을 이용한 확률밀도함수를 주파수 도메인으로 변경하기 위해서 FFT(Fast Fourier Transform)을 사용하도록 한다.

식 10을 FFT 식을 이용한 형태로 나타내면 식 11과 12로 나타난다. 여기서 g 를 가우시안 커널이라고 정의하고, g' 은 g 를 미분한 값이다. h 는 측정되어진 히스토그램이라고 한다. F 는 $f(u)$ 이고, H 는 $f'(u)$ 이다.

$$F \equiv \text{ifft}(fft(h) * fft(g)) \quad (11)$$

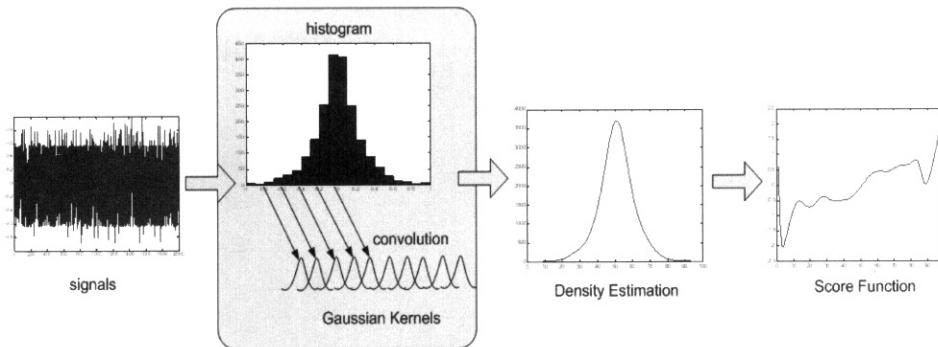
$$H \equiv \text{ifft}(fft(h) * fft(g')) \quad (12)$$

FFT-convolution 기법을 사용한 점수함수는 계산 복잡도가 $O(n^2)$ 에서 $O(n \log n)$ 으로 줄어들게 된다. 따라서 ICA에서 점수함수를 빠른 시간내에 생성하여 계산할 수 있다. 여기에서 커널의 수, l 은 1024개로 고정하여 사용하였다. 또한 점수함수 생성 후에 c 와 u 에 대한 차원의 차이를 없애기 위해서 선형 보간 기법(linear interpolation)을 사용하였다.

(그림 1)은 SFG 알고리즘에 대한 전체 흐름도 및 개념을 나타낸다. 신호의 입력이 들어오면 일단 히스토그램을 계산한 후, 각 구간의 가우시안 커널을 이용하여 컨볼류션을 하게 되고 밀도함수에 대한 추정을 할 수 있다. 따라서 ICA에서 원 신호에 근사한 점수함수를 매번 생성하게 된다.

3.2 L(W) 비용함수를 이용한 점수함수의 최적화

KDE를 사용하면 샘플 값에 대한 분포의 추정을 보다 명



(그림 1) SFG 알고리즘의 전체 흐름도

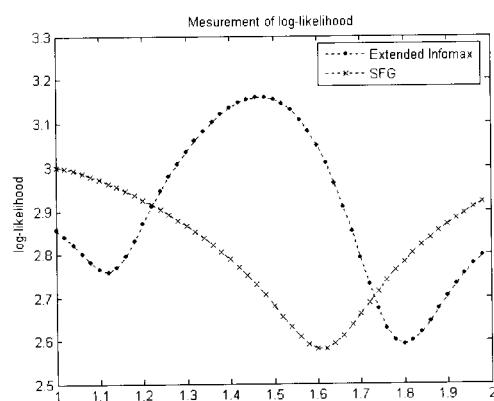
확히 할 수는 있지만 ICA의 전역해를 찾기가 힘들어 진다. 왜냐하면 ICA 학습식은 대부분의 경우 확률밀도분포를 가정하고 만들어진 최대우도추정법을 사용하기 때문이다. 식 6은 고정된 점수함수를 이용한 방식이기 때문에, 학습 시작부터 SFG 알고리즘을 사용하게 되면 해에 수렴하지 못하는 경우가 발생한다. 다음의 예는 임의의 신호 2개를 아래와 같이 혼합행렬 A를 사용하여 신호를 혼합하였다.

$$A = \begin{bmatrix} 0.9 & 0.1 \\ -0.1 & 0.9 \end{bmatrix} \quad (13)$$

신호분리를 위해서 Extended Infomax 알고리즘을 이용하여 $L(W)$ 값을 측정하였고, 분리행렬 W 는 아래와 같다.

$$W = \begin{bmatrix} \sin(\theta) & \cos(\theta) \\ -\cos(\theta) & \sin(\theta) \end{bmatrix} \quad (14)$$

아래의 (그림 2)는 행렬 W 를 이용하여 θ 값을 변경하여 우도를 측정한 결과이다. Extended Infomax 알고리즘의 경우, θ 값이 1.8 정도가 PI(Performance Index)가 제일 작게 나타났다. 이는 W 행렬에 대해서 올바른 범위임을 알 수 있다. 그리고 비용함수에 대한 로그우도 값은 SFG 알고리즘의 경우 1.6정도가 올바른 범위임을 알 수 있다. 따라서 Extended Infomax 알고리즘으로 알맞은 범위에 θ 를 위치시킴으로써, 로그우도 값을 최소화 시키는 것이 효과적이다.



(그림 2) 신호2개를 이용한 우도값의 측정

ICA에서 W 는 학습 반복이 일어남에 따라서 일정한 값을 유지하는 특성을 가진다. 따라서 다음과 같은 식을 유도할 수 있는 데, 여기에서 $L(W)^{(t)}$ 는 현재 단계에서 측정된 $L(W)$ 값을 나타내고 $L(W)^{(t-1)}$ 는 이전에 측정된 $L(W)$ 값을 나타낸다고 가정한다. 여기에서 ϵ 은 1이하의 작은 상수 값이다.

$$\|L(W)^{(t)} - L(W)^{(t-1)}\| \leq \epsilon \quad (15)$$

즉, 측정된 값의 범위가 매우 작으면 학습이 안정화되었다고 판단을 하기 때문에 SFG 방법을 사용하게 된다. <표 1>은 SFG 알고리즘에 대한 전체적인 과정을 나타내고 있다.

<표 1> SFG 알고리즘 학습 과정

- ```

단계1. W행렬 초기화
단계2. Extended Infomax 알고리즘으로 ICA학습
단계3. 식 15를 이용하여 모니터링A
 If \|L(W)^{(t)} - L(W)^{(t-1)}\| \leq \epsilon 이면 단계 4 수행
 else 단계2 수행
단계4. 식 6과 식 10을 이용한 SFG 알고리즘 수행

```

#### 4. 시뮬레이션 및 고찰

제안된 SFG 방법에 대한 성능을 평가하기 위해서, 임의의 분포를 가진 랜덤신호 3개와 음성8개를 신호를 각각 혼합하여 실험하였으며, TIF 정지영상 4개를 혼합하여 실험하였다. 전체 알고리즘은 Matlab 7.0 언어에서 구현되었다. 본 연구에서는 신호에 대한 확률밀도분포의 정확성을 평가하기 위해서 원 신호의 첨도(kurtosis) 및 웨도(skewness) 그리고 복원된 신호의 첨도 및 웨도에 대해서 비교하였다. 그리고 알고리즘 성능에 따른 SNR(Signal-to-Noise Ratio)값과 PI(Performance Index)값을 비교하였다. 식 16과 17은 각각에 SNR과 PI를 정의한 식이다.

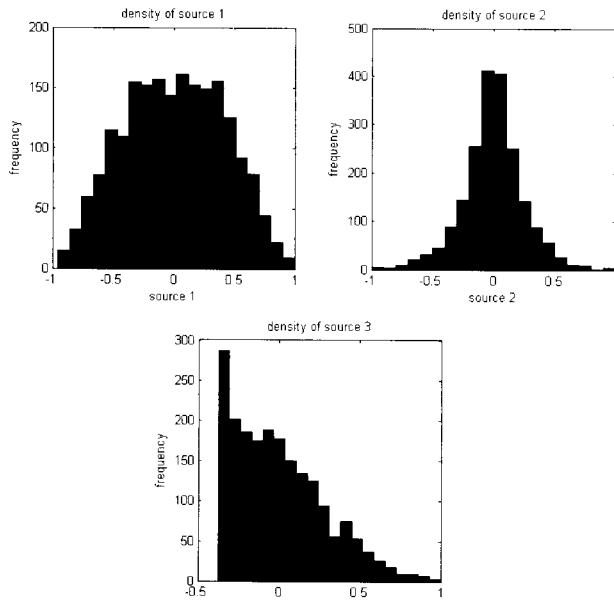
$$SNR(dB) = 10 \log_{10} \left( \frac{\sum_{j=1}^m s_j^2}{\sum_{j=1}^m (\hat{s}_j - s_j)^2} \right) \quad (16)$$

$$E = \sum_{i=1}^m \left( \sum_{j=1}^m \frac{|P_{ij}|}{\max|P_{ik}|} - 1 \right) + \sum_{i=1}^m \left( \sum_{j=1}^m \frac{|P_{ij}|}{\max|P_{ik}|} - 1 \right) \quad (17)$$

식 16에서  $s$ 는 원 신호이고  $\hat{s}$  추정된 신호이고,  $m$ 은 신호원의 개수이다. 식 17은 Amari의 애러 조건이고 여기서  $P = WA$ 이다.

#### 4.1 임의의 램덤 분포에 대한 신호 분리 실험

첫번째 실험은 첨도와 웨도가 틀린 3개의 신호에 대해서 실험을 하였으며, 원 신호에 대한 밀도 분포는 그림 3과 같다. 첫번째 신호는 가우시안 분포와 비슷하게 신호를 생성하였으며, 두번째 신호는 첨도가 높은 형태 슈퍼가우시안 형태로 생성하였다. 그리고 세번째 신호는 웨도가 기울어진 형태의 분포를 생성하였는데, 웨도의 경우 왼쪽으로 기울어질 경우 0보다 큰 수치를 가진다.



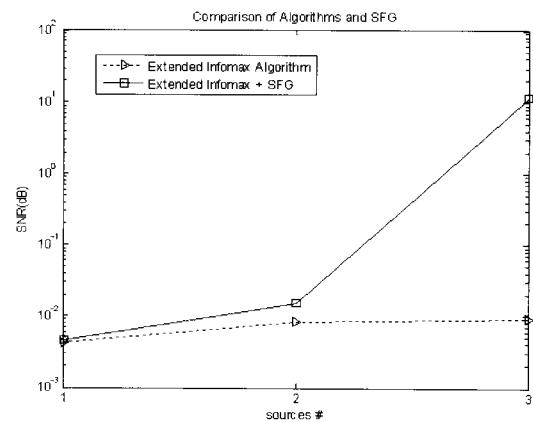
(그림 3) 임의의 신호 3개에 대한 밀도분포

이와 같은 분포를 사용하여 아래와 같은 혼합행렬  $A$ 를 사용하여 신호를 혼합하였다.

$$A = \begin{bmatrix} -1.5937 & -0.39989 & 0.71191 \\ -1.441 & 0.6900 & 1.2902 \\ 0.57115 & 0.81562 & 0.6686 \end{bmatrix} \quad (18)$$

위의 (그림 3)과 약 2000개의 샘플수를 가진 신호를 이용하여 SFG 방법으로 점수함수를 생성하여 ICA 알고리즘에 적용시켜 보았다. 우선 Extended Infomax 알고리즘을 이용하여 로그우도 값을 안정시키었는데 학습 모니터링에 의해서 기존의 슈퍼 가우시안(super-Gaussian)과 서브 가우시안(sub-Gaussian) 계열의 점수함수에서 새로 생성된 점수함수로 학습을 변화하여 시작하였다. 또한 우도값의 안정화를 위하여 최대 100회를 수행하였으며 로그 우도 값의 변화가

0.0001 이하가 되면 학습이 종료되어 SFG 학습을 수행하게 된다. 그리고 SFG 학습도 최대 100회를 수행하였다. 사용된 학습률은 Extended Infomax에서는 0.005이고 SFG 알고리즘 사용시 학습률은 0.02이다. 그럼 4에서 나타난 SNR값은 최대 학습회수 200회를 수행한 결과이다. SFG 알고리즘은 확률분포를 재계산하여 점수함수를 생성하는 방법으로써, 고정된 점수함수로 학습하는 Extended Infomax 알고리즘과 비교하여 보다 원 신호에 근사한 분포를 추정하였음을 알 수 있다.



(그림 4) Extended Infomax 알고리즘과 SFG방법의 SNR비교

<표 2>과 <표 3>는 원 신호에 대한 첨도(kurtosis)와 웨도(skewness)를 비교한 부분이다. 첨도의 경우 원 신호 분포에 대한 뾰족한 정도를 나타내는 수치인데, SNR이 높게 나타나는 신호가 원 신호에 대한 첨도의 수치와 비슷하게 나타남을 알 수 있다. 웨도의 경우 빈번하게 음수와 양수가 바뀜을 알 수 있다. 이러한 이유는 ICA 방법이 주로 첨도나 분포를 미리 가정하여 점수함수를 사용하는 학습 방법이기 때문에 웨도의 수치영역이 바뀔 수 있다는 것이다. 특히 점수함수를 이용한 방법의 경우 엔트로피에 기반한 방법이기 때문에 웨도의 반전현상이 나타났을 경우에, 엔트로피 값의 차가 없다는 특징을 가진다.

<표 2> 추정된 신호와 원 신호들에 대한 첨도의 비교

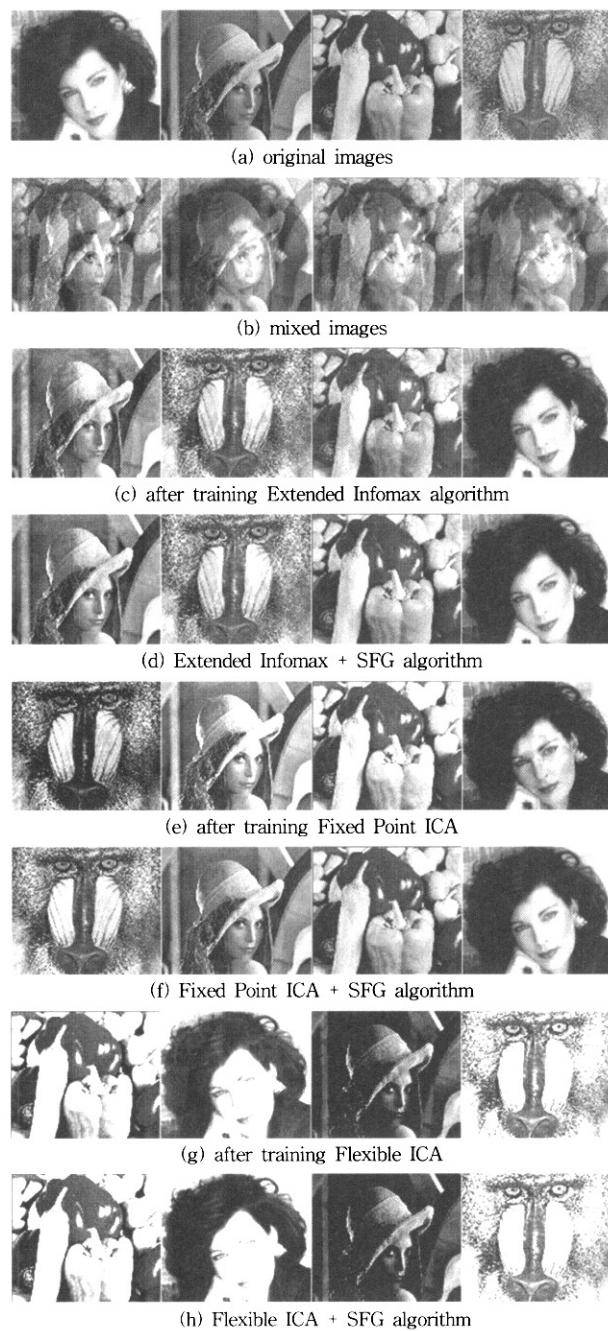
|                                              | source1 | source2 | source3 |
|----------------------------------------------|---------|---------|---------|
| Original Kurtosis                            | 2.2055  | 4.4583  | 3.0209  |
| Recovered Kurtosis<br>(Extended Infomax)     | 2.3467  | 4.1919  | 2.9501  |
| Recovered Kurtosis<br>(Extended Infomax+SFG) | 2.3360  | 4.2916  | 3.0203  |

<표 3> 추정된 신호와 원 신호들에 대한 웨도의 비교

|                                              | source1 | source2 | source3 |
|----------------------------------------------|---------|---------|---------|
| Original Skewness                            | -0.0283 | -0.0839 | 0.7444  |
| Recovered Skewness<br>(Extended Infomax)     | 0.0931  | -0.0106 | 0.6690  |
| Recovered Skewness<br>(Extended Infomax+SFG) | 0.0912  | -0.0256 | 0.7440  |

#### 4.2 영상 분리에 대한 시뮬레이션

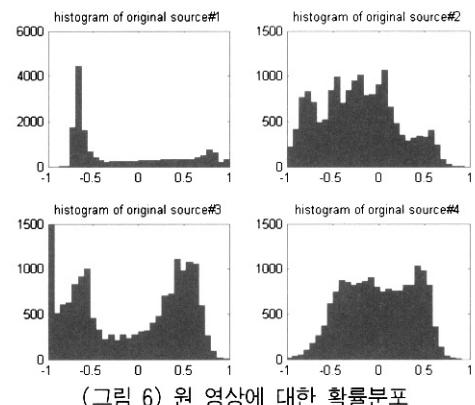
영상 실험을 위해서 TIF 파일 규격인 128\*128 사이즈의 흑백영상을 사용하였으며, 4\*4 행렬을 이용하여 혼합하였다. 원 영상 및 혼합된 이미지는 그림 5와 같다. ICA의 입력을 위해서 흑백 영상을 0과 1사이의 범위로 정규화 한 후, -1과 +1의 범위를 가지도록 변환하였다. 사용된 혼합행렬 A는 아래와 같다. 혼합행렬에서 음수를 사용하지 않은 이유는 나중에 역변환의 문제로 인해서 사용을 하지 못하여 양수의 범위를 가진 혼합행렬을 발생시키었다. 혼합된 영상은 그림 5의 (b)와 같다.



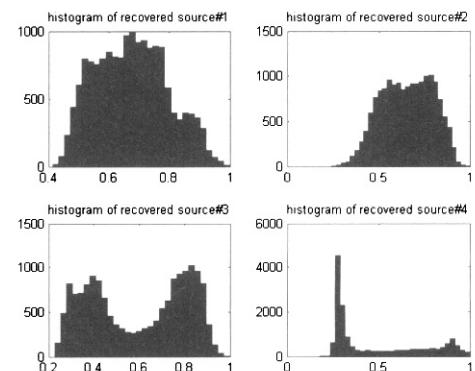
(그림 5) 혼합된 영상에 대한 SFG 알고리즘의 분리수행

#### 4.2.1 Extended Infomax 알고리즘과 SFG를 사용한 경우

이 실험에서는 Extended Infomax 알고리즘의 학습을 최대 100번으로 제한하여 수행하였으며 로그우도값을 측정하여 약 80회에서 학습이 종료되었다. 블록의 크기는 200으로 하였고 학습상수  $\eta$ 는 0.007로 초기화하여 수행을 하였다. 분리행렬 W는 모두 동일하게 항등행렬로 초기화 하였다. Extended Infomax ICA의 수행결과 PI는 약 3.9에서 학습이 더 이상 진행되지 못하였다. 이러한 이유는 이 알고리즘이 점수함수를 단순히 슈퍼가우시안과 서브가우시안의 두개로 나누어서 학습을 하기 때문이다. 따라서 SNR 값을 높일 수 있는 SFG 알고리즘을 사용하여, 분리된 결과는 기존의 Extended Infomax 알고리즘과 비교하여 PI(Performance Index)와 SIR 값 성능 모두가 높게 나타났다. 여기서 사용된 학습상수  $\eta$ 는 0.2로 최대학습회수 100회를 수행하였을 경우 PI의 값은 0.097로 나타났다. (그림 10)은 신호에 따른 SNR값을 비교 평가한 것이다.



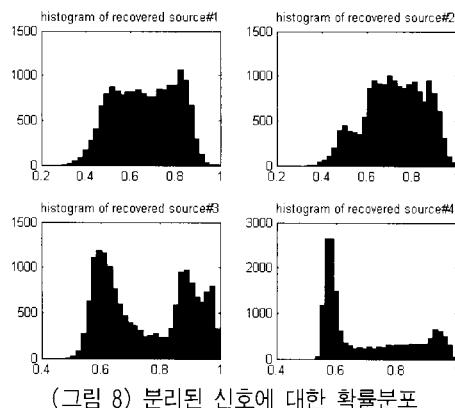
(그림 6) 원 영상에 대한 확률분포



(그림 7) 분리된 신호에 대한 확률분포

#### 4.2.2 Fixed Point ICA와 SFG를 사용한 경우

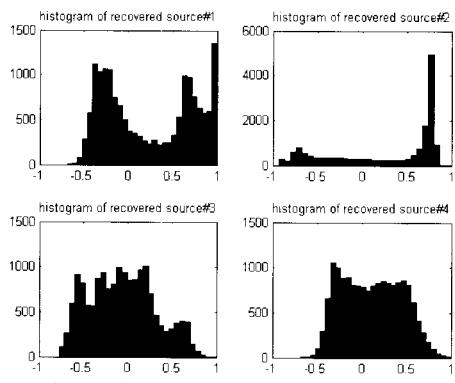
FPICA에서는 학습률을 0.0001로 낮게 하여 학습을 시켰으며, 학습된 결과는 그림 5의 (e)와 같다. 그림 5의 (e)에서의 영상은 기존의 있었던 영상과 혼합된 부분을 발견할 수 있는데 SFG 학습 후 결과의 영상은 이러한 겹쳐진 부분이 많이 없어졌음을 알 수 있다. 그림 8은 학습이 끝난 후 추정된 확률분포를 나타낸 것이다.



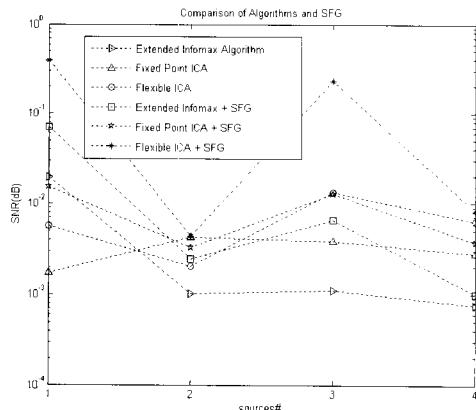
(그림 8) 분리된 신호에 대한 확률분포

#### 4.2.3 Flexible ICA와 SFG를 사용한 경우

Flexible ICA의 경우 학습 상수는 0.005로 하여 독립성분 분석 학습을 수행하였다. 영상에 대해서 Flexible ICA가 가장 좋은 학습 성능을 보였으며, 그림 5에서 보여지듯 SNR 값이 높게 나타났다. 확률밀도 분포를 살펴보면, Flexible ICA와 SFG를 학습 후 영상 1, 2, 4 분포에 대한 반전현상이 나타난 것을 알 수 있다. 이와 같은 결과는 독립성분 분석에서 분포가 반전될 경우 엔트로피가 원래의 엔트로피와 같다는 문제점에서 출발된다. 이러한 경우는 엔트로피와 첨도를 이용하는 모든 알고리즘에서 문제점으로 나타난다.



(그림 9) 분리된 신호에 대한 확률분포

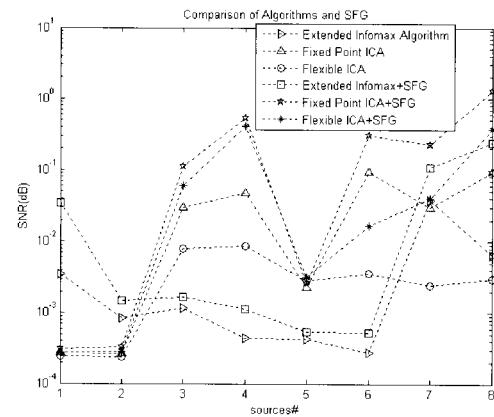


(그림 10) 영상분리에 대한 각 알고리즘의 SNR비교

#### 4.3 음성신호 8개에 대한 분리 실험

본 실험은 8개의 음성신호에 대해서 나타난 결과이다. 원 신호는 8000개 샘플 크기를 가졌고, 혼합행렬 A는 -1과 +1 사이의 값으로 초기화를 하였다. 분리행렬 W는 항등행렬로 초기화하여 학습을 시작하였다. Extended Infomax에서 사용된 학습율은  $\eta = 0.007$ 이다. 최대 학습회수는 200번으로 고정하였다. 약 175번에서 촉 15에 만족하여 extended Infomax에서 8개의 신호에 대해서, Flexible ICA는 98회의 학습에서 로그우도값을 만족하였다. 200회 학습 수행 후 SFG 학습 회수는 100회로 고정하였다. 독립성분분석 방법의 특성상 분리행렬 W에 permutation 행렬이 포함되기 때문에 분리된 신호의 순서가 원 신호의 순서와 다르게 발생된다. (그림 11)은 원 신호를 기준으로 하여 각각의 SNR을 나타낸 결과이다.

신호 1과 2에서 Extended Infomax 알고리즘이 가장 높게 나타남을 알 수 있는데, 이와 같은 이유는 음성신호의 경우 슈퍼가우시안 분포와 유사한 신호가 들어있음을 나타낸다. 그러나 신호 3번째와 8번째의 분포는 Flexible ICA와 Fixed Point ICA 알고리즘이 좀 더 좋은 성능을 나타냄을 알 수 있었다. 음성신호도 SFG를 이용한 경우, 전체적으로 보다 좋은 SNR 값을 가지는 것을 알 수 있었고, SFG 알고리즘의 성능이 기존의 알고리즘 보다 우수한 결과를 가짐을 알 수 있었다. 그러나 SFG 알고리즘의 경우, 기존의 알고리즘의 SNR이 나쁘게 나타날 경우 역시 낮은 SNR값을 가짐을 알 수 있다.



(그림 11) 음성신호에 대한 각 알고리즘과 SFG 방법의 SNR 비교

## 5. 결 론

독립성분 분석에서 최대우도 추정방법에 의한 가정된 확률분포를 이용한 점수함수는 독립성분분석 방법에서 일정량의 에러를 항상 포함하게 된다. 따라서 이러한 양을 줄일 수 있는 방법이 필요로 하게 된다. 특히 EEG 신호 분석, 음성인식 등에서 오차의 범위를 줄이는 것이 중요하다. 본 연구에서 이러한 문제점을 해결하기 위해, 확률밀도추정 방법에 의해서 점수함수를 생성하여 원 신호의 확률밀도와 추정된 신호의 확률밀도 사이의 차를 줄일 수 있는 방법을 제안하였다. 일반적으로 확률 밀도 추정을 위한 계산 시간은 매

우 많은 시간이 소요된다. 본 연구에서 계산을 줄이기 위해서 convolution-FFT 방법을 사용하였고 또한 로그우도값을 이용하여 분리행렬  $W$ 에 대해서 안정화를 판단하는 방법을 제안하였다. 이러한 이유는 SFG 알고리즘만을 사용한 경우보다 분리 수렴성이 높아진다는 장점이 있다. SFG 알고리즘은 기준의 방법을 우선 학습한 후 확률분포의 추정오차를 줄이는 방법이다. 이러한 추정오차를 줄이는 방법은 점수함수를 생성하여 원 신호의 확률분포와 근사하게 학습을 수행하는 방법이다. 실험 결과에서 알 수 있듯이, SFG 알고리즘은 기준의 알고리즘 보다 SNR 및 PI 값 모두에서 성능 향상을 이루었고, 음성 및 영상의 대부분의 신호에서 기준의 알고리즘보다 좀 더 원 신호를 근사한 신호가 출력됨을 알 수 있었다.

그리고 ICA에서 일반적으로 원 신호의 수가 많아지게 되면 해당되는 학습의 곡선이 복잡해지기 때문에, 우도값이 안정화가 되지 않는 경우가 발생한다. 이러한 부분은 독립성분분석의 학습 문제라고 생각된다. SFG 학습 알고리즘의 경우  $W$  행렬이 안정화되어야만 하는 문제점을 가지고 있는데, 이러한 부분은 결합엔트로피를 최대화하는 제약조건을 이용하면 해결할 수 있다. 즉 새로운 밀도 추정자(estimator)를 구성해야만 한다는 것이다. 이러한 사항은 추후 연구를 통해 해결해야 하는 문제점이다.

## 참 고 문 헌

- [1] P. Comon, "Independent Component Analysis, A New Concept?", *Signal Processing*, Vol.36, No.3, pp.287-314, 1994.
- [2] A. Hyvärinen, J. Karhunen, Erkki Oja, "Independent Component Analysis", Wiley interscience, 2001.
- [3] S.-i. Amari, A. Cichocki, and H. H. Yang, "A New Learning Algorithm for Blind Source Separation," *Advances in Neural Information Processing Systems*. Cambridge, MA: MIT Press, Vol.8, pp.757-763, 1996.
- [4] A. J. Bell and T. Sejnowski, "An Information-Maximization Approach to Blind Separation and Blind Deconvolution," *Neural Computation*, Vol.7, No.6, pp.1129-1159, 1995.
- [5] A. J. Bell and T. J. Sejnowski, "The 'Independent Components' of Natural Scenes are Edge Filters," *Vision Research*, Vol.37, pp.3327-3338, 1997.
- [6] J.-F. Cardoso, "Blind Signal Separation: Statistical Principles," *Proc. IEEE. Special Issue on Blind Identification and Estimation*, Vol.9, pp.2009-2025, Oct. 1998.
- [7] J.-F. Cardoso, "Higher-Order Contrasts for Independent Component Analysis," *Neural Computation*, Vol.11, No.1, pp.157-192, Jan., 1999.
- [8] M. Girolami and C. Fyfe, "An Extended Exploratory Projection Pursuit Network with Linear and Nonlinear anti-Hebbian Lateral Connections Applied to the Cocktail Party Problem," *Neural Networks*, Vol.10, No.9, pp.1607-1618, 1997.
- [9] D. Obradovic and G. Deco, "Information Maximization and Independent Component Analysis: Is There a Difference?", *Neural Computation*, Vol.10, pp.2085-2101, 1998.
- [10] T.-W. Lee, M. Girolami, and T. 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.417-441, 1999.
- [11] S. Choi, A. Cichocki, and S. Amari, "Flexible Independent Component Analysis", *Journal of VLSI Signal Processing*, Vol.26, No.2, pp.25-38, August, 2000.
- [12] S. Makeig, T.-P. Jung, A. J. Bell, D. Ghahremani, and T. J. Sejnowski, "Blind Separation of Event-related Brain Responses into Independent Components," in *Proc. National Academic Sciences USA*, Vol.94, pp.979-984, 1997.
- [13] T.-P. Jung, C. Humphries, T.-W. Lee, M. J. McKeown, V. Iragui, S. Makeig, and T. J. Sejnowski, "Removing electroencephalographic artifacts by blind source separation", *Psychophysiology*, Vol.37, pp.163-178, 2000.
- [14] B. W. Silverman, 'Density Estimation for Statistics and Data Analysis' New York: Chapman and Hall, 1985.
- [15] N. Vlassis and Y. Motomura, "Efficient source adaptivity in independent component analysis," *IEEE Trans. Neural Networks*, Vol.12, pp.559-566, May.2001.
- [16] S. Fiori and P. Bucciarelli, "Probability Density Estimation Using Adaptive Activation Function Neurons", *Neural Processing Letters*, Vol.13, No.1, pp.31-42, Feb., 2001
- [17] Woong Myung Kim and Hyon Soo Lee, "An Efficient Score Function Generation Algorithm with Information Maximization", *Advances in Natural Computation. Lecture Note on Computer Science*, Vol.3610, pp.760-768, 2005.



김 용 명

e-mail : wmkim@khu.ac.kr

1996년 상지대학교 전자계산학과(이학사)

1999년 경희대학교 컴퓨터공학과(공학석사)

2001년 경희대학교 컴퓨터공학과 박사수료

1999년 3월~현재 경희대학교 컴퓨터공학과  
박사과정

2002년 3월~현재 오산대학 컴퓨터정보과 겸임교수

관심분야: 패턴인식 및 신경망, 음성 및 영상처리, 멀티미디어  
신호처리



이 현 수

e-mail : leehs@khu.ac.kr

1979년 경희대학교 전자공학과(학사)

1982년 4월 일본 게이오대학원 전기공학과  
(공학석사)

1985년 4월 일본 게이오대학원 계산기공학과  
(공학박사)

1999년 9월~2000년 8월 미국 오레곤 주립대학교 전기 및 컴퓨터  
공학과 방문연구원, 미국 캘리포니아대학교(U.C.I) 전기  
및 컴퓨터공학과 방문연구원

1985년~현재 경희대학교 컴퓨터공학과 교수

2005년~현재 경희대학교 전자정보대학 학장 및 정보통신대학원  
원장

관심분야: 컴퓨터구조 및 VLSI, 병렬처리, 패턴인식, 신경망,  
음성처리