

## 독립성분분석법에 의한 잡음첨가신호의 분석성능비교

# Comparison of Analysis Performance of Additive Noise Signals by Independent Component Analysis

조용현 · 박용수

Yong-Hyun Cho and Yong-Soo Park

대구가톨릭대학교 컴퓨터정보통신공학부

School of Computer and Information Comm. Eng.,

Catholic Univ. of Daegu

### 요 약

본 논문에서는 선형적으로 혼합된 영상신호에 잡음이 첨가된 영상을 대상으로 뉴우턴법과 할선법의 고정점 알고리즘 독립성분분석을 적용하여 분리성능을 비교·검토하였다. 여기서 뉴우턴법의 고정점 알고리즘은 기울기 변화에 따른 속성을 이용하며, 할선법의 고정점 알고리즘은 접선의 변화를 이용하는 속성을 가진다. 실험에 이용된 신호는 2개의 512x512 픽셀 2차원 영상이며, 가우스 분포와 라플라스 분포의 잡음을 각각 이용하였다. 실험 결과, 원 영상을 분리하는 시간에서는 뉴우턴법의 고정점 알고리즘 독립성분분석이 할선법의 고정점 알고리즘 독립성분분석보다 보다 빠르며, 복원성능에서는 할선법의 고정점 알고리즘 독립성분분석이 더욱 우수한 특성이 있음을 알 수 있었다. 한편, 잡음이 많이 첨가될수록 뉴우턴법의 FP-ICA와 할선법의 FP-ICA사이의 추출속도와 분리성능은 더욱 더 큰 차이가 있음도 알 수 있었다.

### Abstract

This paper presents the separation performance of the linearly mixed image signals with additive noises by using an independent component analyses(ICAs) of the fixed-point(FP) algorithm based on Newton and secant method, respectively. The Newton's FP-ICA uses the slope of objective function, and the secant's FP-ICA also uses the tangent line of objective function. The 2 kinds of ICA have been applied to the 2 dimensional 2-image with 512x512 pixels. Then Gaussian noise and Laplacian noise are added to the mixed images, respectively. The experimental results show that the Newton's FP-ICA has better the separation speed than secant FP-ICA and the secant's FP-ICA has also the better separation rate than Newton's FP-ICA. Especially, the Newton and secant method gives relatively larger improvement degree in separation speed and rate as the noise increases.

**Key words** : Independent component analysis, Newton's fixed-point algorithm, Secant's fixed-point algorithm, Gaussian distribution noise, Laplacian distribution noise, Separation performance

## 1. 서 론

통계학, 신호처리, 그리고 신경망 등에서 적당한 변환에 의해 알맞은 데이터의 표현을 찾기 위하여 일반적으로 선형 변환을 이용한다. 최근에 개발된 독립성분분석(independent component analysis : ICA)은 정보 내에 포함된 성분들의 통계적인 의존성을 최소화하는 효과적인 선형변환기법으로 정보통신시스템, 의료신호분석, 독립화자분리시스템, 그리고 경제시계모형 등에 널리 이용되고 있다.

독립성분분석은 데이터의 통계적 성질을 고려한 선형 변환 기법으로 데이터의 분포정보를 이용하는 다차원 방법이다 [1,2].

지금까지 발표된 신경망을 이용한 ICA 방법으로는 엔트

로피를 최소화하는 것에 기초를 둔 고정점(fixed point : FP) 알고리즘, 비선형 PCA에 기초한 recursive least square 알고리즘, 결합엔트로피를 최대화하기 위하여 확률적 기울기를 이용하는 Bell & Sejnowski(BS) 알고리즘, natural gradient 알고리즘 등이 제안되었다[2-4].

최근 cocktail party 문제와 같은 잡음이 존재하는 환경에서 원래의 신호를 분리하기 위한 연구가 활발하게 진행되고 있다[5,6]. 그러나 원 신호에 잡음이 섞인 신호가 관찰될 경우 문제를 해결하려면 비선형변환관계에서 원 신호를 분리해야 하는 문제가 되어 매우 복잡한 알고리즘이 수행되어야 한다 [5]. 본 연구에서는 원 신호에 잡음이 첨가된 것이 아니고, 관찰된 신호에 잡음이 추가되었다고 가정하여 원래의 신호를 분리하는 방법을 제안하였다. 이는 원 신호를 분리할 때 선형변환기법을 이용하는 기존의 알고리즘을 활용하기 위함이다. 이를 위하여 엔트로피 최적화 방법에서 유도된 뉴우턴(Newton)법에 기초한 빠른 학습속도를 갖는 FP 알고리즘과 목적함수의 근의 계산을 간략화 하기 위해 할선법(secant

접수일자 : 2005년 2월 25일

완료일자 : 2005년 5월 3일

method)<sup>[7]</sup>을 이용한 FP 알고리즘<sup>[8]</sup>을 각각 이용하였다. 512x512 픽셀의 영상신호 2개를 대상으로 임의의 혼합 행렬에 따라 발생하는 혼합신호들을 대상으로 2가지 알고리즘 각각을 실험하였다. 즉 잡음을 첨가한 경우와 그렇지 않는 경우로 나누어 각각의 알고리즘에 적용하였으며, 두 가지 알고리즘 상호간의 분리성능을 비교 검토하였다.

## 2. 신경망 기반 ICA

ICA는 m개의 입력신호  $s$ 가 선형적으로 혼합된 n개의 신호  $x$ 가 알려져 있을 때, 혼합된 신호로부터 역으로 m개의 독립인 입력신호를 찾는 기법이다. 여기서 입력신호들을 혼합하는데 이용된 혼합행렬  $A$ 는 알려져 있지 않으며, 혼합과정에서 잡음  $n$ 이 추가 될 수도 있다. 이때 혼합신호와 입력신호와의 관계는

$$x = As + n = \sum_{i=1}^m s(i)a(i) + n \quad (1)$$

로 표현된다. 여기서 잡음  $n$ 은 보통 입력신호와 구별되지 않기 때문에 생략할 수도 있으며,  $A=[a(1), a(2), \dots, a(m)]$ 으로  $a(i)$ 는 ICA의 basis vector이다. 결국 ICA는 알려진 혼합신호로부터 혼합행렬의 역행렬  $A^{-1}$ 을 찾는 기법이다. 이상의 관계를 요약하면 그림 1과 같다. 그림에서 보면 혼합기(mixer)의 출력신호인 혼합신호는 알 수 있으나 혼합기의 특성인  $A$ 와 입력신호인 원 신호  $s$ 는 알려져 있지 않다. 결과적으로 입력신호와 출력신호가 일치하도록 하는 즉,  $y = Wx = WA s$ 에서  $W=A^{-1}$ 의 관계를 만족토록 하는 것이다.




그림 1. ICA를 위한 구성도

한편, 그림 1로부터 혼합행렬  $A$ 와 역혼합행렬  $W$ 에 대하여 좀 더 상세히 살펴보면 다음 그림 2와 같은 상세도로 나타낼 수 있다. 그림에서  $x = As$ 이고,  $y = Wx$ 이다. 이때 ICA는 출력신호  $y$ 의 각 요소들이 통계적으로 독립성을 유지해야 하며 직교성의 제약조건은 포함하지 않는다. 따라서 ICA는 알려진 혼합신호  $x$ 로부터 출력신호  $y$ 를 찾는 기법으로 궁극적으로는 역혼합행렬  $W$ 을 찾아서 원 신호  $s$ 의 근사값을 알아내는 것이다. 여기서 영평균과 whitening된 혼합신호를 이용하면, 신호의 1차와 2차의 통계성에 따른 상관성이 이미 고려되어 좀 더 효율적인 ICA를 수행할 수 있다.




그림 2. 혼합행렬과 역혼합행렬의 상세도

### 2.1 신호의 영평균과 Whitening

신호의 영평균은 데이터의 1차적 통계성을 고려한 정규화로 학습알고리즘을 간략하게 하는 기법이다.

이는 신호 데이터 벡터  $x$ 에서 평균값  $x^*$ 를 뺀 차를 구함으로써 간단하게 구할 수 있다. 즉, 영평균된 새로운 데이터 벡터  $x$ 는

$$x = x - x^* \quad (2)$$

이다. 한편, 데이터의 2차적 통계성을 고려한 상호간의 의존성을 줄이기 위한 기법으로 whitening이 이용되고 있다. whitening은 데이터 벡터  $x$ 의 공분산행렬이 단위 행렬값  $I$ 를 갖도록 함으로써 구할 수 있다. 즉,  $E\{xx^T\}=I$ 가 되도록 한다. 이렇게 함으로써 whitening된 벡터의 성분들 상호간의 상관성이 줄어들어 강한 독립성분이 된다. 일반적으로 whitening에 PCA<sup>[9]</sup>가 이용되며, 이는 공분산행렬의 고유벡터와 고유치를 추정하는 수치적 기법으로 whitening 행렬  $V$ 는

$$V = D^{(-1/2)}E^T \quad (3)$$

이다. 여기서  $D$ 는 고유값으로 구성되는 대각행렬이며,  $E$ 는 고유벡터로 구성되는 직교행렬이다.

### 2.2 고정점 알고리즘

고정점 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 그 수렴속도가 적어도 2차 함수정도로 지금까지 알려진 기법 중 가장 빠른 학습속도를 가진다. 이는 신호 내에 포함된 상호정보를 고려한 것으로 그 척도는 독립성의 거리이다. 결국 상호정보를 최소화함으로써 ICA의 해를 구하는 기법이다.

상호정보는 랜덤변수 상호간의 독립성을 이용한 정보이론적 척도로 ICA 변환을 찾기 위한 판별도수단이 될 수 있다. 일반적으로 변수들 상호간의 정보를 표현하는 상호정보는 비가우스성의 척도로 이용되는 negentropy로 정의된다. n개의 랜덤변수 벡터  $y = (y_1, \dots, y_n)^T$ 를 위한 negentropy  $J(y)$ 는

$$J(y) = H(y_{gauss}) - H(y) \quad (4)$$

이다. 여기서  $H(y)$ 는 랜덤변수  $y$ 의 엔트로피(entropy)이며,  $y_{gauss}$ 는 가우스 랜덤벡터이다. 이때 negentropy  $J(y)$ 를 이용한 상호무관(decorrelation)한 n개 랜덤변수  $y_i(i=1, \dots, n)$  사이의 상호정보  $I(y_1, y_2, \dots, y_n)$ 는

$$I(y_1, \dots, y_n) = J(y) - \sum_{i=1}^n J(y_i) \quad (5)$$

로 정의된다. 결국 ICA에서 독립성을 최대화하기 위해 식 (5)로 정의되는 상호정보  $I(y_1, y_2, \dots, y_n)$ 를 최소화하는 것은 negentropy를 최대화하는 것이다. 여기서 negentropy의 최대화는 식 (5)의 우측 2번째 항의 최대화로 가능하다. 이를 위한 근사식으로 최대 엔트로피 원리를 이용한 식은

$$J(y_i) \approx c[E\{G(y_i)\} - E\{G(v)\}]^2 \quad (6)$$

와 같이 정의된다. 여기서  $G$ 와  $c$ 는 각각 비2차(non-quadratic) 함수와 상수이고,  $v$ 는 평균이 0이고 분산이 1인 표준화된 가우스 변수이며, 랜덤변수  $y_i$ 도 평균이 0이고 분산이 1인 변수로 가정한다. negentropy의 근사화를 위한 식 (6)은 ICA 변환을 추정하기 위한 목적함수로 이용될 수 있다. 따라서 ICA에서 독립변수들의 상호간 무관성을 고려한 하나의 독립성분  $y_i = W^T x$ 를 찾기 위한 목적함수  $J_G(W)$ 는 식 (6)에 따라

$$J_G(\mathbf{W}) = [E\{G(\mathbf{W}^T \mathbf{x})\} - E\{G(v)\}]^2 \quad (7)$$

로 표현된다. 이를 전체 n개의 독립성분 모두에 대해서 확장하면

$$\begin{aligned} & \text{maximize } \sum_{i=1}^n J_G(\mathbf{w}_i) \text{ w.r.t. } \mathbf{w}_i, i=1,2,\dots,n \\ & \text{subject to } E\{(\mathbf{w}_k^T \mathbf{x})(\mathbf{w}_j^T \mathbf{x})\} = \delta_{jk} \end{aligned} \quad (8)$$

이 된다. 여기서  $\mathbf{w}_i$ 는 역혼합행렬  $\mathbf{W}$ 의 행벡터 중에 하나이며, ICA 변환은  $\mathbf{s} = \mathbf{W}\mathbf{x}$ 로 얻어진다. 결국 식 (7)이나 (8)로 정의된 ICA를 위한 목적함수를 최대화하기 위한 방법이 요구된다. 이러한 방법으로 가장 간단한 알고리즘은 기울기하강(gradient descent)에 기초를 둔 기법들이나, 이 방법에 기초한 알고리즘들의 제약들을 해결하기 위한 대안으로 FP 알고리즘이 제안되었다<sup>6,7)</sup>.

데이터 벡터  $\mathbf{x}$ 의 상관행렬  $E\{\mathbf{x}\mathbf{x}^T\}=\mathbf{I}$ 로 whitening되어 있다고 가정할 때, 하나의 독립성분을 위한 식 (7)에서 FP 알고리즘을 유도하면 다음과 같다. 식 (7)에서  $J_G(\mathbf{W})$ 의 최대화는 반드시  $E\{G(\mathbf{W}^T \mathbf{x})\}$ 의 최적에서 얻어진다. 즉, Kuhn-Tucker 조건으로부터,  $E\{(\mathbf{W}^T \mathbf{x})^2\} = \|\mathbf{W}\|^2 = 1$  조건 하에서  $E\{G(\mathbf{W}^T \mathbf{x})\}$ 의 최적은 다음의 값

$$E\{\mathbf{x}g(\mathbf{W}^T \mathbf{x})\} - \beta \mathbf{W} = 0 \quad (9)$$

으로 얻어진다. 여기서  $g(\cdot)$ 는 비2차 함수  $G$ 의 미분이고,  $\beta = E\{\mathbf{W}_0^T \mathbf{x}g(\mathbf{W}_0^T \mathbf{x})\}$ 인 상수이며  $\mathbf{W}_0$ 는  $\mathbf{W}$ 의 최적값이다. 따라서 방정식 (9)의 근을 구하기 위해 빠른 수렴속도를 가지는 뉴우턴법<sup>8)</sup>을 이용한다. 뉴우턴법은 적당한 초기값이 설정되었을 때 항상 근에 수렴하는 속성이 있다. 이를 위해 식의 좌변 항을  $F(\mathbf{W})$ 로 나타내고, 그것의 Jacobian matrix  $JF(\mathbf{W})$ 를 구하면 다음과 같다. 즉,

$$JF(\mathbf{W}) = E\{\mathbf{x}\mathbf{x}^T g'(\mathbf{W}^T \mathbf{x})\} - \beta \mathbf{I} \quad (10)$$

이다. 한편 데이터 벡터  $\mathbf{x}$ 가 이미 whitening되어 있어 뉴우턴법에 의해 해를 구하는데 이용되는  $JF(\mathbf{W})$ 의 역행렬 계산을 간단하게 하기 위해 식 (10)의 우변 첫째 항을

$$\begin{aligned} E\{\mathbf{x}\mathbf{x}^T g'(\mathbf{W}^T \mathbf{x})\} &= E\{\mathbf{x}\mathbf{x}^T\}E\{g'(\mathbf{W}^T \mathbf{x})\} \\ &= E\{g'(\mathbf{W}^T \mathbf{x})\}\mathbf{I} \end{aligned} \quad (11)$$

로 근사화할 수 있다. 식 (11)을 식 (10)에 대입하면 Jacobian matrix는 대각선 행렬이 되어 쉽게 역행렬이 계산된다. 따라서  $\beta$ 를  $\mathbf{W}_0$  대신에  $\mathbf{W}$ 의 현재 값으로 나타내어 근사화된 반복기법으로 근인 역혼합행렬  $\mathbf{W}$ 를 구하는 뉴우턴법은

$$\begin{aligned} \mathbf{W}_* &= \mathbf{W} - [E\{\mathbf{x}g(\mathbf{W}^T \mathbf{x})\} - \beta \mathbf{W}] / [E\{g'(\mathbf{W}^T \mathbf{x})\} - \beta], \\ \mathbf{W}^* &= \mathbf{W}_* / \|\mathbf{W}_*\| \end{aligned} \quad (12)$$

와 같다. 여기서  $\mathbf{W}^*$ 는  $\mathbf{W}$ 의 새롭게 경신된 값이고,  $\beta = E\{\mathbf{W}^T \mathbf{x}g(\mathbf{W}^T \mathbf{x})\}$ 이다. 결국 식 (12)는 뉴우턴법에 기초를 둔 ICA를 위한 FP 알고리즘이다. 또한 식 (12)의 뒷식 양쪽에  $\beta - E\{g'(\mathbf{W}^T \mathbf{x})\}$ 를 곱해 구해지는 더욱 간단한 뉴우턴법의 FP 알고리즘은

$$\mathbf{W}^* = E\{\mathbf{x}g(\mathbf{W}^T \mathbf{x})\} - E\{g'(\mathbf{W}^T \mathbf{x})\}\mathbf{W}, \quad \mathbf{W}^* = \mathbf{W}^* / \|\mathbf{W}^*\| \quad (13)$$

으로 표현될 수 있다. 따라서 뉴우턴법의 고정점 알고리즘에 의한 역혼합행렬  $\mathbf{W}$ 의 경신과정을 요약하면 다음과 같다.

단계 1 : 초기 역혼합행렬  $\mathbf{W}(0)$ 를 임의의 값  $\text{rand}(\cdot)$ 로 설정한다.

단계 2 :  $\mathbf{W} = \mathbf{W}(0) / \|\mathbf{W}(0)\|$ 의 값을 계산한다.

단계 3 :  $\mathbf{W}_{\text{old}} = \mathbf{0}$ 로 설정한다.

단계 4 :  $\|\mathbf{W} - \mathbf{W}_{\text{old}}\| > \epsilon$ 이고  $\|\mathbf{W} + \mathbf{W}_{\text{old}}\| > \epsilon$ 이면 다음의 식에 따라  $\mathbf{W}$ 를 계산하고, 그렇지 않으면 과정을 종료한다.

(1)  $\mathbf{W}_{\text{old}} = \mathbf{W}$ 를 계산한다.

(2)  $\mathbf{W}^* = E\{\mathbf{x}g(\mathbf{W}^T \mathbf{x})\} - E\{g'(\mathbf{W}^T \mathbf{x})\}\mathbf{W}$ 를 계산한다.

(3)  $\mathbf{W}^* = \mathbf{W}^* / \|\mathbf{W}^*\|$ 를 계산한다.

### 2.3 할선법을 이용한 FP-ICA

할선법은 현재의 함수 값과 바로 이전의 함수 값만을 이용하여 해를 구함으로써 기존의 뉴우턴법을 이용할 때처럼 별도의 1차 미분 계산이 요구되지 않는다. 이는 뉴우턴법에 비해 할선법이 반복에 소요되는 시간이 적게 걸리는 근거이다. 따라서  $\beta$ 를  $\mathbf{W}_0$  대신에  $\mathbf{W}$ 의 현재값으로 나타낸 근사화된 반복기법으로 역혼합행렬  $\mathbf{W}$ 를 구하는 할선법은

$$\begin{aligned} f(\mathbf{W}^\#) &= [E\{\mathbf{x}g(\mathbf{W}^\# \mathbf{x})\} - \beta \mathbf{W}^\#] \\ f(\mathbf{W}) &= [E\{\mathbf{x}g(\mathbf{W}^T \mathbf{x})\} - \beta \mathbf{W}] \\ \mathbf{W}^* &= \mathbf{W} - f(\mathbf{W}) / \{f(\mathbf{W}) - f(\mathbf{W}^\#)\} \\ \mathbf{W} &= \mathbf{W}^* / \|\mathbf{W}^*\| \end{aligned} \quad (14)$$

와 같다. 여기서  $\mathbf{W}^\#$ 은 바로 전에 계산된  $\mathbf{W}$ 의 값이고,  $\beta = E\{\mathbf{W}^T \mathbf{x}g(\mathbf{W}^T \mathbf{x})\}$ 이다. 결국 식 (14)는 할선법을 이용한 ICA를 위한 FP 알고리즘이다. 여기서는 역혼합행렬  $\mathbf{W}$ 를 구하는데 별도의 1차 미분인 Jacobian matrix의 계산이 요구되지 않아 보다 빠른 계산이 가능하다.

따라서 제안된 할선법의 FP 알고리즘에 의한 역혼합행렬  $\mathbf{W}$ 의 경신과정을 요약하면 다음과 같다.

단계 1 :  $\mathbf{W}(0) = \text{rand}(\cdot)$ 로 설정한다.

단계 2 :  $\mathbf{W} = \mathbf{W}(0) / \|\mathbf{W}(0)\|$ 의 값을 계산한다.

단계 3 :  $\mathbf{W}^\# = \mathbf{0}$ 로 설정한다.

단계 4 :  $\|\mathbf{W} - \mathbf{W}^\#\| > \epsilon$ 이고  $\|\mathbf{W} + \mathbf{W}^\#\| > \epsilon$ 이면 다음의 식에 따라  $\mathbf{W}$ 를 계산하고, 그렇지 않으면 과정을 종료한다.

(1)  $\beta$ ,  $f(\mathbf{W}^\#)$ , 그리고  $f(\mathbf{W})$ 를 계산한다.

(2)  $\mathbf{W}^* = \mathbf{W} - f(\mathbf{W}) / \{f(\mathbf{W}) - f(\mathbf{W}^\#)\}$  계산한다.

(3)  $\mathbf{W}^\# = \mathbf{W}$ 로 둔다.

(4)  $\mathbf{W} = \mathbf{W}^* / \|\mathbf{W}^*\|$ 를 계산한다.

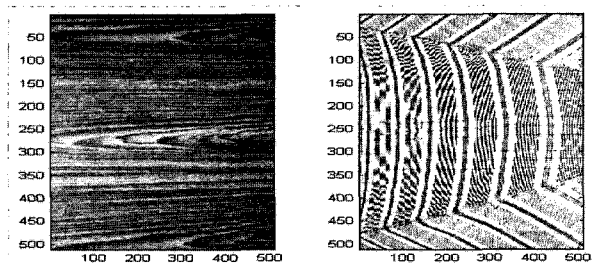
위의 과정에서 벡터  $\mathbf{x}$ 는 whitening된 신호벡터이며,  $\epsilon$ 은 1보다 작은 임의의 값이다. 여기서  $g(\cdot)$ 는 비선형함수이며 일반적으로  $(\cdot)^3$ 과  $\tanh(\cdot)$ 의 함수가 이용된다.  $(\cdot)^3$ 함수는  $\tanh(\cdot)$ 함수보다 좀 더 안정적인 수렴특성을 갖는다. 본 연구에서는  $\epsilon=0.0001$ 과  $(\cdot)^3$ 함수를 적용한 결과들을 나타낸다.

### 3. 시뮬레이션 결과 분석


제안된 학습알고리즘의 신경망 기반 ICA의 타당성과 성능을 평가하기 위해서 영상신호를 대상으로 실험하였다. 원영상은 각각 512x512 픽셀의 독립된 2차원 신호이며, 이들을 임의의 랜덤행렬값으로 혼합한 혼합영상을 대상으로 가우스(Gaussian) 및 라플라스(Laplacian) 잡음을 첨가한 후 전자

리하여 뉴우턴법과 할선법의 FP-ICA를 각각 수행하였다. 영상의 분리성능을 평가하기 위해 각 영상의 절대합평균오차 (absolute sum mean error : asme)를 정의하여 원 신호와 복원된 신호의 정합성을 각각 비교하였다. 이때  $asme = \frac{1}{(512)^2} \sum_{i=1}^512 \sum_{j=1}^512 |x_i - y_j|$  이며, 여기서  $x_i$ 와  $y_j$ 는 각각 원 신호와 복원된 영상의  $i$ 번째 픽셀값이다. 실험은 팬티엄IV-1.5G 컴퓨터 상에서 Matlab 5.1로 실행하였다.

그림 3은 2개의 원 영상과 임의의 혼합행렬에 의해 생성된 혼합영상에 가우스 잡음이 첨가된 영상 각각을 나타낸 것이다. 특히 그림 3(b)의 혼합영상에는 평균이 0이고 분산이 0.001인 가우스 잡음이 첨가된 영상들이며, 여기서는 원 영상과 잡음이 겹쳐 나타남을 알 수 있다. ICA를 이용한 실험은 혼합영상들로부터 미지의 원 영상들을 역으로 추출하는 것이다. 실험에서는 혼합영상들을 영평균과 whitening의 전처리 후 이를 대상으로 ICA를 수행하였다.



(a) 원 영상




(b) 가우스 잡음이 첨가된 혼합영상

그림 3. 512x512 픽셀의 영상


그림 4는 그림 3(b)의 잡음이 첨가된 혼합영상들을 대상으로 뉴우턴법 FP-ICA와 할선법 FP-ICA를 각각 수행한 후 복원된 영상들이다. 그림 4(a)와 (b)에서는 원 영상과 복원된 영상들 사이의 순서가 일치되지 않음을 알 수 있다. 이는 분석과정에서 입력의 순차를 고려하지 않는 ICA의 속성이 반영되었기 때문이다. 여기서 복원영상과 원 영상을 순서에 맞추어 서로 육안으로 비교하면 상당히 유사함을 알 수 있다. 결국 복원영상은 임의행렬을 이용하여 생성한 혼합영상의 독립성분이다.

표 1은 혼합영상, 가우스 잡음(평균=0, 분산=0.001)이 첨가된 혼합영상, 그리고 라프라스 잡음(평균=0, 분산=0.01)이 첨가된 혼합영상 각각을 대상으로 10번씩 실험을 수행한 후의 복원영상에 대한 분석성능을 나타낸 것이다. 여기서 성능 척도로는 원 영상과 복원영상의 픽셀단위 절대합평균오차 asme와 분리를 위한 학습반복수 k 및 CPU 시간 t의 평균을 각각 나타낸 것이다. 우선 잡음이 첨가되지 않은 혼합영상을 대상으로 뉴우턴법과 할선법 FP-ICA 경우, 2개 영상에 대해 평균적으로 절대합평균오차는 약 0.0069로 두 방법은 동일한 추출성능이 있음을 알 수 있다. 하지만 뉴우턴법과 할선

법의 FP-ICA 각각에서 학습반복수는 약 3.59와 약 2.6으로 할선법이 다소 적으나, 분리하는 소요된 시간에서는 각각 약 3.93과 약 4.61로 뉴우턴법이 할선법보다 다소 빠름을 알 수 있다. 한편 가우스 잡음이 첨가된 혼합영상에서는 절대합평균오차에서 각각 약 0.2387과 약 0.226으로 할선법이 뉴우턴법의 FP-ICA보다 약 1.1배 정도 우수하며, 학습반복수와 소요시간에서는 각각 약 1.93과 약 2.37 및 약 4.72와 약 5.41로 뉴우턴법의 FP-ICA가 할선법의 FP-ICA보다 다소 빠르게 원 영상을 추출함을 알 수 있다. 또한 라프라스 잡음이 첨가된 혼합영상에서 절대합평균오차에서 뉴우턴법과 할선법은 각각 약 0.1006과 약 0.0932로 할선법의 FP-ICA가 약간 우수한 추출성능이 있음을 알 수 있다. 학습반복수 및 소요시간에서 각각 뉴우턴법과 할선법은 약 3.68과 약 2.23 및 약 4.35와 약 4.82로 학습반복수에서는 할선법이 소요시간에서는 뉴우턴법이 다소 우수한 성능이 있음을 확인할 수 있다. 전체적으로 보면, 절대합평균오차로 나타나는 추출성능에서는 할선법의 FP-ICA가 추출에 소요되는 시간에서는 뉴우턴법의 FP-ICA가 우수한 성능이 있음을 알 수 있다.



(a) 뉴우턴법



(b) 할선법

그림 4. FP-ICA에 의해 복원영상

표 1. 잡음의 첨가 유무에 따른 실험결과

잡음		뉴우턴법 FP-ICA			할선법 FP-ICA		
		절대합 평균오차, asme	학습 반복수, k	소요 시간, t	절대합 평균오차, asme	학습 반복수, k	소요 시간, t
비 첨가	1	0.0025	2.73	3.02	0.0025	2.60	4.58
	2	0.0112	4.45	4.83	0.0112	2.60	4.64
	평균	0.0069	3.59	3.93	0.0069	2.60	4.61
가우스잡음	1	0.2370	1.30	2.51	0.2350	2.20	4.67
	2	0.2403	3.60	6.94	0.2171	2.90	6.16
	평균	0.2387	1.93	4.72	0.2260	2.37	5.41
라프라스 잡음	1	0.1015	4.36	5.16	0.0941	2.00	4.33
	2	0.0997	3.00	3.54	0.0922	2.45	5.31
	평균	0.1006	3.68	4.35	0.0932	2.23	4.82

한편 그림 6은 가우스 잡음이 첨가되지 않은 혼합영상과 평균값을 0으로 고정하고 분산값을 각각 0.001, 0.005, 및 0.01로 변경시킨 가우스 잡음이 첨가된 혼합영상에 뉴우턴법과 할선법의 FP-ICA를 각각 수행한 결과이다. 여기서 절대합평균오차 asme와 분리에 소요되는 소요시간 t 각각을 10 번의 시행에 따른 평균값을 나타낸 것이다. 그림에서 보면, 잡음 량을 조정하는 분산  $\sigma$  값에 따른 두 가지 알고리즘의 절대합평균오차 asme는 거의 유사한 값을 가지나 할선법의 FP-ICA가 전체적으로 뉴우턴 FP-ICA보다 추출성능에서는 다소 우수한 특성이 있음을 알 수 있다. 또한 원 영상을 분리하는데 소요시간 t에서는 할선법의 FP-ICA가 뉴우턴법의 FP-ICA 보다 빠른 추출시간이 있음을 알 수 있다. 특히 분산  $\sigma$  값이 커짐에 따라서 할선법의 FP-ICA와 뉴우턴법의 FP-ICA사이의 추출속도와 분리성능은 더욱 더 큰 차이가 있음을 알 수 있다. 결국 혼합영상에 첨가되는 잡음의 량이 많아질수록 뉴우턴법의 FP-ICA가 속도에서는 더욱 빠른 분리성능을 가지며, 할선법의 FP-ICA는 상대적으로 더욱 더 정확하게 분리할 수 있음을 알 수 있다.




그림 6. 잡음량에 따른 분리성능

#### 4. 결 론

본 논문에서는 원 영상신호가 선형적으로 혼합된 영상신호들에 잡음을 첨가하고, 이들로부터 원 영상신호를 추출하기 위해 뉴우턴법의 FP-ICA와 할선법의 FP-ICA를 각각 적용하여 분리성능을 비교 검토하였다.

첨가되는 잡음은 가우스와 라플라스 잡음이며, 이들의 발생을 위해 평균값은 고정하고 분산 값을 변화시켰다. 발생된 잡음을 각각 512x512 픽셀의 2개의 혼합영상에 첨가하여 실험하였다. 실험의 결과, 할선법의 FP-ICA이 뉴우턴법의 FP-ICA보다 분리성능에서는 더욱 우수한 특성이 있음을 확인하였다. 또한 분리하는데 소요되는 시간에서는 뉴우턴법의 FP-ICA가 할선법의 FP-ICA보다 빠른 특성이 있음을 확인하였다.

향후 다양한 잡음환경에서 원 영상신호의 분리에 대한 연구가 뒤따라야 할 것이며, 다른 신경망을 이용한 방법들과의 비교연구도 병행되어야 할 것이다.

#### 참 고 문 헌

- [1] P. Comon, "Independent Component Analysis -A New Concept?", *Signal Processing*, vol.36, No.3, pp. 287-314, Apr. 1994
- [2] T.W. Lee, *Independent Component Analysis : Theory and Applications*, Kluwer Academic Pub., Boston, 1998
- [3] J. Karhunen, E. Oja, L. Wang, R. Vigarío, and J. Joutsensalo, "A Class of Neural Networks for Independent Component Analysis", *IEEE Trans. on Neural Networks*, Vol. 8, No. 3, pp.486-504, May 1997
- [4] A. Hyvarinen, "Fast and Robust Fixed-Point Algorithms for Independent Component Analysis", *IEEE Trans. on Neural Networks*, Vol. 10, No. 3, pp.626-634, May 1999
- [5] A. Hyvarinen, "Gaussian moments for Noisy independent component analysis", *IEEE Signal Processing Letters*. Vol. 6, No. 6, pp.145-147, June 1999
- [6] Hyung-Min Park, *Adaptive Filtering Methods or Acoustic Noise Reduction and Noisy speech Recognition*, Ph.D. thesis, KAIST, Daejeon, 2003
- [7] K. Atkinson, *Elementary Numerical Analysis*, John Wiley & Sons, Inc., New York, 1993
- [8] 조용현, 박용수, "신경망 기반 독립성분분석을 이용한 효율적인 복합영상분리", *한국 퍼지 및 지능시스템 학회*, Vol. 12, No. 3, pp. 210-218, June 2002
- [9] K. I. Diamantaras and S. Y. Kung, *Principal Component Neural Networks : Theory and Applications, Adaptive and learning Systems for Signal Processing, Communications, and Control*, John Wiley & Sons, Inc., 1996

#### 저 자 소 개

조용현(Yong-Hyun Cho)

2004년 6월 퍼지 및 지능시스템학회 논문지 제 14권, 제 3호. pp.336-341 참조

e-mail : yhcho@cu.ac.kr



박용수(Yong-Soo Park)

1979년 경북대 전자공학과 졸업.

1981년 동 대학원 졸업(석사)

1999~2002 대구가톨릭대 대학원 졸업 (박사)

1985년~1992년 LG반도체(주) 근무

1993년~1994년 반도체 엔지니어링(주) 근무

1995년~1998년 포항1대학 및 선린대학 강의

1999년~2000년 포항직업전문학교 교사  
2002년8월~2004년2월 대구가톨릭대학 시간강사  
2004년3월~현재 대구가톨릭대학 강의 전담교수

관심분야 : 신경회로망, 퍼지 이론, 이미지 프로세싱

Phone : 053)850-2747

Fax : 053)850-2740

E-mail : timpark@chollian.net