

첨도를 이용한 군집성을 가진 고정점 알고리즘의 독립성분분석

조 용 현[†] · 김 아 람^{††}

요 약

본 논문에서는 첨도가 추가된 뉴우턴법의 고정점 알고리즘에 의한 독립성분분석을 제안하였다. 여기서 첨도의 추가는 유사한 속성을 가지는 성분의 군집화된 분석순서를 얻기 위함이고, 뉴우턴법의 고정점 알고리즘은 성분의 빠른 분석과 우수한 분석성능을 얻기 위함이다. 제안된 독립성분분석을 500개 샘플을 가지는 6개의 혼합신호와 512×512 픽셀을 가지는 8개의 혼합영상의 분리에 각각 적용하여 실험한 결과, 제안된 기법은 항상 일정한 분석순서를 유지하여 기존의 기법에서 알고리즘의 수행 때마다 랜덤하게 변하는 분석순서의 제약을 해결할 수 있었다. 특히 군집화의 속성을 가진 제안된 독립성분분석은 신호나 영상의 분류나 식별에도 적용할 수 있음을 확인하였다.

Independent Component Analysis of Fixed-Point Algorithm for Clustering Components Using Kurtosis

Yong-Hyun Cho[†] · A-Ram Kim^{††}

ABSTRACT

This paper proposes an independent component analysis(ICA) of the fixed-point(FP) algorithm based on Newton method by adding the kurtosis. The kurtosis is applied for clustering the components, and the FP algorithm of Newton method is applied for improving the analysis speed and performance. The proposed ICA has been applied to the problems for separating the 6-mixed signals of 500 samples and 8-mixed images of 512×512 pixels, respectively. The experimental results show that the proposed ICA has always a fixed analysis sequence. The result can be solved the limit of conventional ICA which has a variable sequence depending on the running of algorithm. Especially, the proposed ICA can be used to classify and identify the signals or the images.

키워드 : 독립성분분석(Independent Component Analysis), 고정점 알고리즘(Fixed-Point Algorithm), 첨도(Kurtosis), 군집화(Clustering), 은닉신호분리(Blind Source Separation)

1. 서 론

독립성분분석(independent component analysis : ICA)은 선형변환 기법 중 가장 널리 이용되는 주요성분분석(principal component analysis : PCA)을 일반화한 것이다. PCA는 공분산을 이용하는 가우스(Gaussian) 분포의 신호에 적절한 2차원 방법으로 데이터의 차원감소에 널리 이용되고 있다[1, 2]. ICA는 비가우스 분포의 신호에도 적용될 수 있는 다차원의 변환으로 생체신호처리, 영상인식 및 음성분석 등 다양한 분야에 적용되고 있다[3-7].

하지만 알려진 수치적 기법을 이용한 ICA에서는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 구한다든지 고차원의 모멘트를 구하는 등 복잡한 계산이 요구된다. 특히 ICA에서 신호모델을 추정하는 것은 혼

합된 출력신호들 사이에 포함된 정보만을 이용하여 혼합행렬을 추정하는 것이며, 이를 위해 출력신호 상호간의 결합 밀도함수를 이용함으로써 계산이 매우 복잡하다. 이러한 복잡한 계산에 따른 많은 비현실적인 계산시간이 요구되는 수치적 기법의 대안으로 간단한 신경망을 이용한 연구가 활발하게 진행되고 있다[4-9].

신경망을 이용한 ICA방법으로는 엔트로피를 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, BS 알고리즘에서 확률적 기울기 대신 자연기울기를 이용한 자연기울기 알고리즘 등이 제안되었다[4-9]. 여기에서 결합엔트로피를 최대화하는 알고리즘은 원 신호를 더 잘 근사하지만 기울기의 변화를 위한 학습율과 같은 파라미터의 설정이 경험적이다. 특히 학습과정에서 학습율의 설정에 따라서는 그 수렴이 느려지

† 정 회 원 : 대구가톨릭대학교 컴퓨터·정보통신공학부 교수
 †† 정 회 원 : 대구가톨릭대학교 대학원 전산통계학과
 논문접수 : 2004년 1월 8일, 심사완료 : 2004년 2월 23일

거나 알고리즘이 수렴되지 않는 경우도 발생된다. 따라서 이런 제약들을 해결하면서도 신경망이 가지는 병렬성, 분산성, 그리고 더 작은 메모리 요구 등의 속성을 가지는 FP 알고리즘이 제안되었다[8,9]. FP 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 뉴우턴(Newton)법[10]에 기초를 두고 있으며, 그 수렴속도는 적어도 2차 함수정도로 지금까지 알려진 기법 중 가장 빠른 분리속도를 가진다. 하지만 이들 ICA에서는 원 신호 사이의 독립성과 비가우성의 조건이 선행되어야 하며, ICA가 적용된 후 출력되는 분석성분의 순서와 부호가 알고리즘의 수행 때마다 달라지는 제약이 있다. 따라서 ICA의 수행과 무관하게 유사한 속성을 가지는 성분들은 항상 일정하게 군집화된 분석순서를 유지하도록 한다면 우수한 고정점 알고리즘의 속성을 더욱 더 잘 살릴 수 있을 것이다.

본 연구에서는 뉴우턴법에 기초한 FP 알고리즘에 침도를 추가한 ICA를 제안한다. 여기서 뉴우턴법의 FP 알고리즘은 빠르고 정확한 성분의 분석을 위함이고, 침도의 추가는 유사한 속성을 가지는 성분의 군집화를 얻기 위함이다. 제안된 기법을 임의로 생성된 500개의 샘플을 가진 6개의 혼합 신호와 512×512 픽셀을 가지는 8개의 혼합영상의 분리를 대상으로 각각 실험하여 타당성을 확인하였으며, 기존 FP 알고리즘의 ICA의 결과들과도 비교·고찰하였다.

2. 고정점 알고리즘에 침도를 추가한 독립성분분석


분석된 성분의 부호와 순서를 고려하지 않는 속성을 가지는 ICA는 은닉신호의 분리(blind source separation : BSS)나 특징추출에 널리 이용되고 있다[3-7]. 여기에서는 BSS를 기준으로 ICA를 소개한다.

ICA는 m개의 입력신호 s로부터 선형적으로 혼합된 n개의 혼합신호 x가 알려져 있을 때, 혼합된 신호로부터 역으로 m개의 독립인 입력신호를 찾는 기법이다. 하지만 입력신호들을 혼합하는데 이용된 혼합행렬 A는 알려져 있지 않으며, 혼합과정에서 잡음 n이 추가 될 수도 있다. 이때 혼합신호와 입력신호와의 관계는

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

로 정의된다. 여기서 n은 보통 입력신호와 구별되지 않기 때문에 생략할 수도 있으며, $\mathbf{A} = [\mathbf{a}(1), \mathbf{a}(2), \dots, \mathbf{a}(m)]$ 으로 a(i)는 ICA의 basis vector이다. 결국 ICA는 알려진 혼합신호로부터 혼합행렬의 역행렬 $\mathbf{A}^{-1} (= \mathbf{W})$ 을 찾는 기법이다. 이때 혼합행렬 A와 역혼합행렬 W의 관계를 상세히 살펴보면 (그림 1)과 같은 구성도로 나타낼 수 있다. 여기서 ICA는 후단의 점선부분으로 $\mathbf{x} = \mathbf{A}\mathbf{s}$ 이고, $\mathbf{y} = \mathbf{W}\mathbf{x}$ 이다. 따라서 ICA는 알려진 혼합신호 x로부터 출력신호 y를 찾는 기법으로 궁극적으로는 역혼합행렬 W을 찾아서 원 신호 s의

근사값을 알아내는 것이다.



(그림 1) 혼합행렬과 역혼합행렬의 상세 설명도

일반적으로 ICA의 계산을 간략화하기 위하여 영평균과 whitening의 전처리 과정을 이용한다[3, 4]. 신호의 영평균은 신호벡터 x에서 평균값 \mathbf{x}^* 를 뺀 $\mathbf{x} = \mathbf{x} - \mathbf{x}^*$ 로 구할 수 있다. 또한 whitening은 신호 x의 공분산행렬 $E(\mathbf{x}\mathbf{x}^T)$ 을 단위행렬 I가 되도록 함으로써 구할 수 있다. 이를 위해 PCA가 널리 이용되며, PCA에 의한 whitening 행렬 $\mathbf{V} = \mathbf{D}^{(-1/2)}\mathbf{E}^T$ 이다. 여기서 D는 고유값으로 구성되는 대각행렬이며, E는 고유벡터로 구성되는 직교행렬이다.

FP 알고리즘의 ICA는 엔트로피 최적화로부터 유도된 기법으로 지금까지 알려진 기법 중 가장 빠른 학습속도를 가진다[5, 8]. 신호벡터 x가 whitening되어 있다고 가정할 때, 뉴우턴법의 FP 알고리즘에 의한 근사화된 반복기법의 역혼합행렬 W 경신식은

$$\begin{aligned} \mathbf{W}^+ &= \mathbf{W} - [E\{\mathbf{x}\mathbf{g}(\mathbf{W}^T\mathbf{x})\} - \beta\mathbf{W}] / [E\{g'(\mathbf{W}^T\mathbf{x})\} - \beta] \\ \mathbf{W} &= \mathbf{W}^+ / \|\mathbf{W}^+\| \end{aligned} \quad (2)$$

와 같다. 여기서 $\beta = E\{\mathbf{W}^T\mathbf{x}\mathbf{g}(\mathbf{W}^T\mathbf{x})\}$ 이다. 또한 식 (2)의 위식 양쪽에 $\beta - E\{g'(\mathbf{W}^T\mathbf{x})\}$ 를 곱해 구해지는 더욱 간단한 FP 알고리즘은

$$\begin{aligned} \mathbf{W}^+ &= E\{\mathbf{x}\mathbf{g}(\mathbf{W}^T\mathbf{x})\} - E\{g'(\mathbf{W}^T\mathbf{x})\}\mathbf{W} \\ \mathbf{W} &= \mathbf{W}^+ / \|\mathbf{W}^+\| \end{aligned} \quad (3)$$

과 같다. 여기서 g(·)는 비선형 함수로 (·)³과 tanh(·) 함수가 일반적으로 이용된다[4, 8]. 그러나 고정점 알고리즘의 ICA에서도 성분을 분석할 때 부호와 순서를 고려하지 않는 제약은 여전히 가지고 있다.

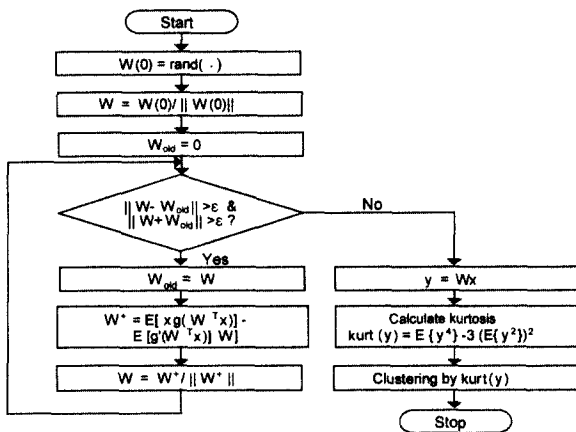
한편 침도는 비가우성의 고전적 척도로 널리 이용되고 있다[5-7]. 이는 4차 cumulant로 다음의 식 (4)와 같이 계산된다.

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2 \quad (4)$$

여기서 y는 랜덤변수이며, 대부분 비가우스 랜덤변수의 침도는 영이 아닌 양이나 음의 값을 가진다. 만약 랜덤변수들의 침도가 음의 값을 가지면 subgaussian이고, 양의 값을 가지면 supergaussian이다. subgaussian 분포의 랜덤변수는 침에하지 않고 일정한 확률밀도 함수를 가지며, super-

gaussian 분포의 랜덤변수는 넓고 첨예한 확률밀도함수를 가진다[7]. 균일 분포함수의 랜덤변수는 양의 첨도, 라플라스 분포함수의 랜덤변수는 음의 첨도, 그리고 가우스 분포함수의 랜덤변수는 영의 첨도값을 가진다. 일반적으로 첨도는 계산적으로나 이론적으로 간단하기 때문에 ICA에서 비가우시성의 척도로 널리 이용된다. 본 연구에서는 기존 ICA에서 성분의 분석순서를 고려하지 않는 제약을 해결하기 위해 FP 알고리즘에 계산이 간단한 점도를 추가한 ICA를 제안한다. 이는 유사한 속성을 가지는 랜덤변수는 유사한 첨도값을 가지는 특성을 이용한 것이다. 이렇게 하면 뉴턴법의 FP 알고리즘이 가지는 빠른 수렴속성을 그대로 살리면서도 유사한 속성을 가지는 성분끼리 군집화하여 좀 더 효율적으로 독립성분을 분석할 수 있다. 또한 점도를 이용하면 크기는 subgaussian과 supergaussian 및 가우스 분포 신호들의 군집화가 가능하고, 각 군집내에서의 순서화도 가능하다.

이상의 FP 알고리즘에 점도가 추가된 제안된 ICA에 의한 역혼합행렬 W 의 경신과정을 도시하면 다음의 (그림 2)와 같다. (그림 2)에서 점도의 계산은 고정점 알고리즘의 ICA에 의해 분석된 성분을 대상으로 이루어지며, 계산된 값을 내림차순이나 올림차순으로 순서화하여 분석성분을 정렬한다. 또한 여기에서 벡터 x 는 whitening 된 신호벡터이며, ϵ 은 고정점 알고리즘의 종료를 위한 조건으로 1보다 작은 임의의 값이다.



(그림 2) FP 알고리즘에 점도가 추가된 제안된 ICA


3. 실험 및 결과분석

제안된 군집속성을 가지는 ICA의 타당성과 성능을 평가하기 위하여 1차원 혼합신호와 2차원 혼합영상을 각각 분리하는 문제에 적용하였다. 학습의 종료조건 $\epsilon = 0.0001$ 로 하였다. 신호의 분리성능을 평가하기 위해 원 신호 s_i 와 분리된 신호 y_i 사이의 평균절대오차 MAE(mean absolute error) $= \frac{1}{N^2} \sum_{i=1}^N |s_i - y_i|$ 를 정의하여 비교하였으며, N^2 은 전체 픽셀


수이다. 실험은 펜티엄 IV-2.2G 컴퓨터상에서 Matlab 5.1[11]로 실행하였고, $(\cdot)^3$ 의 비선형 함수를 이용하였다.

3.1 1차원 신호

500개의 샘플을 가지는 1차원 배열의 6개 신호로부터 6×6 임의의 혼합행렬에 따라 생성된 6개의 혼합신호를 대상으로 실험하였다. (그림 3)은 실험에 이용된 6개의 원 신호와 생성된 6개의 혼합신호를 각각 나타낸 것이다. 특히 (그림 3)(b)의 혼합신호 각각에서는 원 신호들의 정보를 발견할 수 없으며, 실제에서 혼합신호들은 알려져 있으나 원 신호들은 미지의 신호들이다. 또한 실험에서는 영평균과 whitening의 전처리된 혼합신호들을 이용하였다.



(a) 원 신호




(b) 혼합신호


(그림 3) 500개 샘플의 6개 신호

(그림 4)는 (그림 3)(b)의 혼합신호를 대상으로 FP 알고리즘과 FP 알고리즘에 점도가 추가된 제안된 ICA 의해 각각 분리된 신호들을 나타낸 것이다. (그림 4)에서 보면, 원 신호와 분리된 신호들 사이의 분리순서는 서로 일치하지 않으며, sin(2)의 경우 부호도 반대임을 알 수 있다. 이는 독립성분을 분석할 때 부호나 순서를 고려하지 않는 ICA의 고유한 속성이 반영되었기 때문이다. 한편 (그림 4)(a)에서 기존 FP 알고리즘의 ICA에 의해 분리된 신호들은 유사한 성분끼리 서로 군집화가 이루어지지 않음을 알 수 있다. 하지만 (그림 4)(b)의 제안된 ICA에서는 점도에 따라 유사한 속성을 가지는 신호가 서로 군집화 되었음을 알 수 있다.

먼저 saw-tooth 함수 2개가 군집화 되었고, 다음으로는 cos 함수, 2개의 sin 함수, 그리고 다른 함수와 유사성이 거의 없는 impulse noise 순으로 분리됨을 알 수 있다. 이는 유사성이 있는 신호끼리의 군집화로 saw-tooth 함수는 saw-tooth 함수끼리 sin 함수는 sin 함수끼리 군집화 되었으며, sin 함수의 경우 saw-tooth 함수가 아닌 cos 함수와 한 무리로 군집화됨을 알 수 있다. 이는 제안된 ICA가 신호나 영상의 분류나 식별에도 이용될 수 있음을 보여주는 것이다. 한편 기존의 ICA와 제안된 ICA를 각각 20회 실행하였을 때, 기존의 ICA에서는 알고리즘의 수행 때마다 신호의 분석순서가 변하나 제안된 ICA에서는 항상 일정한 분석순서가 유지됨을 확인하였다.



(a) 고정점 알고리즘



(b) 제안된 알고리즘

(그림 4) 6개의 분리된 신호

<표 1>은 혼합신호를 대상으로 기존의 고정점 알고리즘과 제안된 알고리즘의 ICA 각각을 20회 반복 시행한 후, 학습반복수 itr, CPU시간으로 정의된 분리시간 t, 그리고 평균절대오차 MAE의 평균을 각각 나타낸 것이다. 표에서 보면, 6개의 신호를 분리하는데 기존의 ICA나 제안된 ICA 모두 소요된 학습반복수는 총 41회로 1개의 신호를 추출하는데 평균 약 6.8회 정도 수행되었다. 이는 제안된 알고리즘의 ICA도 기존 ICA의 고정점 알고리즘을 그대로 이용하기 때문이다. 그러나 분리시간에서 기존 ICA는 총 1.16초로 평균 약 0.19초가 소요된 반면, 제안된 ICA에서는 총 1.19초로 평균 약 0.2초 정도가 소요되었다. 이는 제안된 ICA에서는 기존 ICA의 후처리 과정으로 첨도를 계산하고 그에 따라 신호를 정렬하는데 총 약 0.03초 정도 더 소요되었기 때문이다. 하지만 원 신호와 분리된 신호의 평균절대오차에서는 기존의 ICA와 제안된 ICA 둘 다 동일한 정확성을 가지며, 총 1.51로 1개의 신호에 대해서는 평균 약 0.25 정도임을 알 수 있다. 한편 혼합된 영상으로부터 sin(1)을 분리하는데 가장 오랜 시간이 소요되었으며, 정합도에서는 saw-tooth(2)가 가장 낮음을 알 수 있다. 이는 sin(1)과 saw-tooth(2) 신호가 다른 신호들에 비해 신호들 사이에서 종속성이 많기 때문으로 추측할 수 있다.

3.2 2차원 영상

512×512의 픽셀을 가지는 8개의 원 영상으로부터 8×8의 임의의 혼합행렬에 의해 생성된 8개의 혼합영상들을 대상으로 실험하였다. (그림 5)는 8개의 원 영상과 생성된 8개의 혼합영상을 나타낸 것이다. 여기에서도 혼합영상 각각에서 원 영상들의 정보들을 발견할 수 없으며, 혼합영상들은 알려져 있으나 원 영상들은 미지의 영상들이고, 전처리된 혼합영상들을 ICA에 이용하였다.

(그림 6) 역시 (그림 5)(b)의 혼합영상을 대상으로 기존의 FP 알고리즘과 제안된 알고리즘의 ICA를 각각 적용하여 분리된 8개의 영상들을 나타낸 것이다. 여기에서도 원 영상과 분리된 영상들 사이의 순서는 서로 일치하지 않으며, 지문(3)의 경우는 부호도 반대임을 알 수 있다. 이 역시 부호나 순서를 고려하지 않는 ICA 고유의 속성이 반영되었기

<표1> 6개의 혼합신호 분리에 따른 결과

원 신호	기 존 ICA			제 안 된 ICA		
	학습반복수, n	분리시간, t	평균절대오차, MAE	학습반복수, n	분리시간, t	평균절대오차, MAE
sin(1)	11	0.30	0.29	11	0.32	0.29
saw-tooth(1)	8	0.23	0.14	8	0.23	0.14
cos	8	0.23	0.29	8	0.24	0.29
impulse-noise	8	0.23	0.2	8	0.23	0.2
saw-tooth(2)	5	0.14	0.33	5	0.14	0.33
sin(2)	1	0.028	0.26	1	0.03	0.26
계	41	1.16	1.51	41	1.19	1.51
평 균	6.8	0.19	0.25	6.8	0.20	0.25

때마다 분석순서가 달라지나 제안된 ICA에서는 항상 일정한 분석순서가 유지되었다.

때문이다. 신호에서처럼 (그림 6(a)의 기존 FP 알고리즘의 ICA 경우 분리된 영상들에서 지문, 얼굴, 레나, 그리고 벽지 영상이 섞여서 서로 군집화가 되지 않음을 알 수 있다. 하지만 (그림 6(b)의 점도를 이용한 제안된 ICA에서 유사한 속성을 가지는 영상들은 서로 군집화 되었음을 알 수 있다. 즉 벽지, 레나, 2개의 얼굴, 그리고 4개의 지문으로 군집화 되었다. 특히 다른 영상들과 유사성이 거의 없는 벽지를 비롯하여 얼굴은 얼굴끼리 지문은 지문끼리의 군집화가 이루어져, 이는 제안된 ICA가 신호나 영상의 분류나 식별에도 이용될 수 있음을 다시 한 번 보여 주는 것이다. 여기에서도 신호에서처럼 기존의 ICA와 제안된 ICA를 각각 20회 실행하였을 때, 기존의 ICA에서는 알고리즘의 수행

<표 2>도 혼합영상을 대상으로 제안된 알고리즘의 ICA를 20회 각각 반복 시행한 후, 학습반복수 itr, CPU시간으로 정의된 분리시간 t, 그리고 평균절대오차 MAE의 평균을 각각 나타낸 것이다. 표에서도 8개의 영상을 분리하는데 기존의 ICA나 제안된 ICA 모두의 수행 학습반복수는 총 77.5회로 1개의 영상을 분리하는데 평균 약 9.7회 정도이다. 이 또한 제안된 알고리즘의 ICA에서는 기존 ICA의 고정점 알고리즘을 그대로 이용하기 때문이다. 하지만 분리시간에서 기존 ICA는 총 96.89초로 평균 약 12.11초 소요된 반면,

제안된 ICA에서는 총 100.75초로 평균 약 12.59초 정도가 소요되었다. 이 또한 제안된 ICA에서는 기존 ICA의 후처리 과정으로 첨도를 계산하고 그에 따라 신호를 정렬하는데 총 약 3.86초 정도 더 소요되었음을 알 수 있다. 그러나 원 영상과 분리된 영상의 평균절대오차에서 두 알고리즘의 ICA는 각각 총 10.16으로 1개 영상에 대해서는 평균 약 1.27 정도의 동일한 정확성을 나타냄을 알 수 있다. 여기에서도 지문(3) 영상의 분리시간이 가장 오래 걸리며, 정확도에서는 레나가 가장 낮음을 알 수 있다. 이는 지문(3)과 레나 영상이 다른 영상들과 유사성이 많기 때문으로 추측된다.

따라서 혼합신호와 혼합영상의 분리실험을 통하여, 제안된 ICA는 첨도가 가지는 계산의 용이성을 살리면서도 성분의 분석순서를 고려치 않는 기존 ICA의 제약을 효과적으로 해결할 수 있다. 또한 제안된 ICA는 유사한 첨도값을 가지는 성분끼리의 군집화가 가능하여 여러 가지 신호나 영상을 식별하거나 분류하는데 효과적인 수단으로 적용될 수 있다.

4. 결 론

본 논문에서는 뉴우턴법의 고정점 알고리즘에 첨도를 추가하여 군집성을 고려한 독립성분분석을 제안하였다. 여기에서 뉴우턴법의 고정점 알고리즘은 성분의 빠른 분석속도와 우수한 분석성능을 얻기 위함이고, 첨도의 추가는 유사한 속성을 가지는 성분의 군집화된 분석순서를 얻기 위함이다.

제안된 독립성분분석을 500개 샘플을 가지는 6개의 혼합신호와 512×512 픽셀을 가지는 8개의 혼합영상의 분리에 각각 적용하여 실험한 결과, 제안된 기법은 항상 일정한 분석순서를 유지하여 기존의 기법에서 알고리즘의 수행 때마다 랜덤하게 변하는 분석순서의 제약을 해결할 수 있었다. 특히 군집화의 속성을 가진 제안된 독립성분분석은 신호나 영상의 분류나 식별에도 적용할 수 있음을 확인하였다.

향후 제안된 ICA를 좀 더 다양한 큰 규모의 문제와 분류나 식별을 위한 문제에 적용하는 연구가 지속적으로 이루어져야 할 것이다.

참 고 문 헌

[1] 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.
 [2] S. Haykin, 'Neural Networks : A Comprehensive Foundation,' Prentice-Hall, 2ed, London, 1999.
 [3] P. Comon, "Independent Component Analysis - A New Concept?," *Signal Processing*, Vol.36, No.3, pp.287-314, Apr., 1994.
 [4] A. Hyvarinen, "Survey on Independent Component Anal-

ysis," *Neural Computing Surveys*, Vol.2, pp.94-128, Apr., 1999.

[5] A. Hyvarinen, J. Karhunen, and E. Oja, 'Independent Component Analysis,' John Wiley & Sons, Inc., New York, May, 2001.
 [6] T. W. Lee, 'Independent Component Analysis : Theory and Applications,' Kluwer Academic Pub., Boston, Dec., 1998.
 [7] S. Roberts and R. Everson, 'Independent Component Analysis : Principles and Practice,' Cambridge Univ. 2001.
 [8] A. Hyvarinen and E. Oja, "A Fast Fixed Point Algorithms for Independent Component Analysis," *Neural Computation*, 9(7), pp.1483-1492, Oct., 1997.
 [9] J. Karhunen, "Neural Approaches to Independent Component Analysis and Source Separation," '4th European Symp., Artificial Neural Network, ESANN96, Burges, Belgium, pp.249-266, Apr., 1996.
 [10] Y. H. Cho and Y. S. Park, "Independent Component Analysis of Fixed Point Algorithm Based on Secant Method," *Proc. of the International Conference on MLMTA'03*, Las Vegas, U.S.A., pp.302-306, June, 2003.
 [11] K. Atkinson, 'Elementary Numerical Analysis,' John Wiley & Sons, Inc., New York, 1993.
 [12] J. Wesley Hines, 'MATLAB Supplement to Fuzzy and Neural Approaches in Engineering,' John Wiley & Sons, Inc., June, 1997.

조 용 현

e-mail : yhcho@cu.ac.kr
 1979년 경북대학교 공과대학 전자공학과 (공학사)
 1981년 경북대학교 대학원 전자공학과 (공학석사)
 1993년 경북대학교 대학원 전자공학과 (공학박사)

1983년~1984년 삼성전자(주) 사원
 1984년~1987년 한국전자통신연구소 연구원
 1987년~1997년 영남이공대학 전자과 부교수
 1997년~현재 대구가톨릭대학교 컴퓨터정보통신공학부 부교수
 관심분야 : 신경망, 병렬분산처리, 신호처리, 영상인식, 교환기 등

김 아 람

e-mail : jasmine6653@hotmail.com
 2002년 대구가톨릭대학교 컴퓨터정보통신공학과(공학사)
 2004년 대구가톨릭대학교 대학원 전산통계학과(공학석사)
 2004년~현재 3BSYSTEM INC. 연구팀 근무

관심분야 : 신경망 이론, 신호 및 영상처리