

할선법의 고정점 알고리즘과 첨도에 의한 군집성의 독립성분분석

Independent Component Analysis for Clustering Components by Using Fixed-Point Algorithm of Secant Method and Kurtosis

조용현
Yong-Hyun Cho

대구가톨릭대학교 공과대학 컴퓨터정보통신공학부
School of Computer and Information Comm. Eng., Catholic Univ. of Daegu

요 약

본 논문에서는 할선법의 고정점 알고리즘과 첨도를 조합한 독립성분분석을 제안하였다. 여기서 할선법의 고정점 알고리즘은 기존 뉴우턴법의 고정점 알고리즘에서 요구되는 복잡한 도함수의 계산과정을 간략화 함으로써 성분의 빠른 분석과 좀더 우수한 분석성능을 얻기 위함이고, 첨도는 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 기존 할선법의 고정점 알고리즘에서 수행 때마다 랜덤하게 변하는 분석순서의 제약을 해결할 수 있었다. 특히 군집화의 속성을 가진 제안된 독립성분분석은 신호나 영상의 분류나 식별에도 적용할 수 있음을 확인하였다.

Abstract

This paper proposes an independent component analysis(ICA) of the fixed-point (FP) algorithm based on secant method and the kurtosis. The FP algorithm based on secant method is applied to improve the analysis speed and performance by simplifying the calculation process of the complex derivative in Newton method, the kurtosis is applied to cluster the components. 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 based on secant method which has a variable sequence depending on the running of algorithm. Especially, the proposed ICA can be used for classifying and identifying the signals or the images.

Key Words : 할선법(Secant Method), 고정점 알고리즘(Fixed-Point Algorithm), 독립성분분석(Independent Component Analysis), 첨도(Kurtosis), 군집화(Clustering)

1. 서 론

통계학이나 신호처리 등에서 선형변환은 적절한 데이터의 표현을 위해 일반적으로 이용된다. 선형변환의 이용은 문제를 계산적으로나 개념적으로 좀 더 간단하게 만들 수 있기 때문이며, 그 중에서도 공분산을 이용하는 2차원 방법의 주요성분분석(principal component analysis : PCA)이 가장 널리 이용되고 있다[1,2]. 이는 가우스(Gaussian) 변수의 모든 정보는 공분산행렬 내에 포함되기 때문에 가우스 분포의 데이터에 대해서는 적당한 것이다. 하지만 통신이나 신호 및 영상 처리 등에서의 데이터에는 비가우스 분포도 있으며, 이러한 경우에도 효과적으로 적용될 수 있는 선형변환 기법의

연구가 요구된다.

이러한 PCA의 제약을 해결하기 위한 대안으로 독립성분분석(independent component analysis : ICA)이 제안되었으며, 이는 데이터의 통계적 성질을 고려한 선형변환 기법으로 데이터의 분포정보를 이용하는 다차원 방법이다[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 혼합된 출력신호들 사이에 포함된 정보만을 이용하여 혼합행렬을 추정하는 것이며, 이를 위해 출력신호 상호간의 결합밀도함수를 이용함으로써 계산이 매우 복잡하다. 이러한 복잡한 계산에 따른 많은 비현실적인 계산시간이 요구되는 수치적 기법의 대안으로 간단한 신경망을 이용한 연구가 활발하게 진행되고 있다 [8-10].

신경망을 이용한 ICA방법으로는 엔트로피를 최소화하는 것에 기초를 둔 고정점(fixed point : FP) 알고리즘, 비선형

접수일자 : 2004년 1월 7일
완료일자 : 2004년 5월 20일

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[3-9]. 여기에서 결합엔트로피를 최대화하는 알고리즘은 원 신호를 더 잘 근사화하지만 기울기의 변화를 위한 학습율과 같은 파라미터의 설정이 경험적이다. 특히 학습과정에서 학습율의 설정에 따라서는 그 수렴이 느려지거나 알고리즘이 수렴되지 않는 경우도 발생된다. 따라서 이런 제약들을 해결하면서도 신경망이 가지는 병렬성, 분산성, 그리고 더 작은 메모리 요구 등의 속성을 가지는 FP 알고리즘이 제안되었다[5-8].

FP 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 뉴턴(Newton)법에 기초를 두고 있으며, 그 수렴속도는 적어도 2차 함수정도로 지금까지 알려진 기법 중 가장 빠른 분리속도를 가진다. 그러나 뉴턴법에 기초한 고정점 알고리즘은 역혼합행렬의 경신을 위하여 비선형 방정식의 해를 구할 때 함수의 성질에 따라 그 수렴시간이 증가하거나 근에 수렴하지 못하고 발산하는 경우가 있으며, 특히 역혼합행렬의 초기값 설정에 분석성능이 매우 의존한다. 또한 도함수 값이 0에 수렴할 경우 알고리즘의 비현실적인 수렴현상도 일어날 수 있다. 따라서 초기값의 설정 등과 같은 뉴턴법에 기초한 FP 알고리즘이 가지는 제약을 해결할 수 있다면 좀 더 효과적인 성분분석이 가능할 것이다. 한편 FP 알고리즘이나 기울기 알고리즘을 각각 이용하는 기존의 ICA에서는 분석성분의 순서가 알고리즘의 수행 때마다 달라지는 제약이 있다. 따라서 ICA의 수행과 무관하게 유사한 속성을 가지는 성분들이 항상 일정하게 군집화된 분석순서를 유지하도록 한다면, 기존의 고정점 알고리즘보다 우수한 속성을 가진 ICA가 될 것이다.

본 연구에서는 할선법에 기초한 FP 알고리즘[10]과 침도(kurtosis)[11]를 조합한 ICA를 제안한다. 여기서 할선법의 FP 알고리즘은 뉴턴법의 FP 알고리즘에서 발생하는 계산의 복잡성을 줄이고 수렴제약을 해결하여 좀 더 빠르고 정확한 성분의 분석을 위함이고, 침도의 추가는 유사한 속성을 가지는 성분의 군집화를 얻기 위함이다. 제안된 ICA를 500개의 샘플을 가진 6개의 혼합신호와 512×512 픽셀을 가지는 8개의 혼합영상의 분리를 대상으로 각각 실험하여 타당성을 확인하였으며, 침도가 추가되지 않은 단순한 할선법에 기초한 FP 알고리즘의 ICA 결과들과도 성능을 비교·고찰하였다.

2. 할선법의 고정점 알고리즘과 침도를 조합한 독립성분분석

PCA가 가우스 분포를 가지는 신호들의 2차원 선형변환 기법이라면, ICA는 비가우스 분포인 군집성이나 독립성을 가지는 변수의 고차통계에 기초한 다차원 변환기법으로 PCA를 확장시킨 것이다. 따라서 ICA는 PCA보다 분포 데이터의 속성을 더욱 더 잘 나타내며, 은닉신호의 분리(blind source separation : BSS)나 특징추출에 널리 이용되고 있다[3,4]. 여기에서는 BSS를 기준으로 ICA를 소개한다.

ICA는 m 개의 입력신호 \mathbf{s} 로부터 선형적으로 혼합된 n 개의 혼합신호 \mathbf{x} 가 알려져 있을 때, 혼합된 신호로부터 역으로 m 개의 독립인 입력신호를 찾는 기법이다. 하지만 입력신호들을 혼합하는데 이용된 혼합행렬 \mathbf{A} 는 알려져 있지 않으며,

혼합과정에서 잡음 $\tilde{\mathbf{N}}$ 이 추가 될 수도 있다. 이때 혼합신호와 입력신호와의 관계는

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

로 정의된다. 여기서 $\tilde{\mathbf{N}}$ 은 보통 입력신호와 구별되지 않기 때문에 생략할 수도 있으며, $\mathbf{A}=[\mathbf{a}(1), \mathbf{a}(2), \dots, \mathbf{a}(m)]$ 으로 $\mathbf{a}(i)$ 는 ICA의 기저벡터이다. 결국 ICA는 알려진 혼합신호로부터 혼합행렬의 역행렬 $\mathbf{A}^{-1}(=\mathbf{W})$ 을 찾는 기법이다. 이때 혼합행렬 \mathbf{A} 와 역혼합행렬 \mathbf{W} 의 관계를 보면 그림 1과 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 \mathbf{x} 로부터 출력신호 \mathbf{y} 를 찾는 것이며, 궁극적으로는 역혼합행렬 \mathbf{W} 을 찾아서 원 신호 \mathbf{s} 의 근사값을 알아내는 것이다.




그림 1. ICA의 구성도

일반적으로 신호의 통계성에 따른 상관성을 고려하여 좀 더 효율적인 ICA를 수행하기 위하여 영평균(zero-mean)과 whitening의 전처리 과정을 이용한다[5-7]. 신호의 영평균은 데이터의 1차적 통계성을 고려한 정규화로 학습알고리즘을 간략하게 하는 기법이며, 신호벡터 \mathbf{x} 에서 그 평균값 \bar{x} 를 뺀 $\mathbf{x} = \mathbf{x} - \bar{x}$ 로 구할 수 있다. 또한 whitening은 데이터의 2차적 통계성을 고려하여 상호간의 의존성을 줄이기 위한 기법이며, 신호 \mathbf{x} 의 공분산행렬 $E\{\mathbf{x}\mathbf{x}^T\}$ 을 단위행렬 \mathbf{I} 가 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 \mathbf{D} 는 고유값으로 구성되는 대각행렬이며, \mathbf{E} 는 고유벡터로 구성되는 직교행렬이다.

한편 수치해석에서 할선법은 현재의 함수 값과 바로 이전의 함수 값을 이용하여 방정식의 근을 구하는 방법으로 기존의 뉴턴법에서 별도의 1차 미분인 도함수 값의 계산을 요구하지 않는다[10,11]. 따라서 기존 뉴턴법에 기초한 FP 알고리즘에서 목적함수의 근을 구하기 위해 1차 미분인 도함수의 값을 계산하는 제약을 해결하기 위하여 할선법에 기초한 FP 알고리즘이 이용될 수 있다[10]. 이때 신호벡터 \mathbf{x} 가 whitening되어 있다고 가정할 때, 할선법의 FP 알고리즘에 의한 근사화된 반복기법의 역혼합행렬 \mathbf{W} 의 경신식은

$$\begin{aligned} f(\mathbf{W}_{old}) &= [E\{\mathbf{x}\mathbf{g}(\mathbf{W}_{old}^T\mathbf{x})\} - \beta\mathbf{W}_{old}] \\ f(\mathbf{W}) &= [E\{\mathbf{x}\mathbf{g}(\mathbf{W}^T\mathbf{x})\} - \beta\mathbf{W}] \\ \mathbf{W}^* &= \mathbf{W} - f(\mathbf{W})\{[\mathbf{W} - \mathbf{W}_{old}]/\{f(\mathbf{W}) - f(\mathbf{W}_{old})\}\} \\ \mathbf{W} &= \mathbf{W}^*/\|\mathbf{W}^*\| \end{aligned} \quad (2)$$

와 같다. 여기서 \mathbf{W}_{old} 는 바로 전에 계산된 \mathbf{W} 의 값이고, $\beta = E\{\mathbf{W}^T\mathbf{x}\mathbf{g}(\mathbf{W}^T\mathbf{x})\}$ 이다. 또한 $\mathbf{g}(\cdot)$ 는 비선형 함수로 (\cdot) 과 $\tanh(\cdot)$ 함수가 일반적으로 이용된다[4-7]. 그러나 할선법에 기초한 FP 알고리즘의 ICA에서도 성분을 분석할 때 순서를 고려하지 않는 제약은 여전히 남아있다.

한편 침도는 비가우스성의 고전적 척도로 널리 이용되고

있다[5-7]. 이는 4차 cumulant로 다음의 식 (3)과 같이 계산된다.

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

여기서 y 는 랜덤변수이며, 대부분 비가우스 랜덤변수의 첨도는 영이 아닌 양이나 음의 값을 가진다. 만약 랜덤변수들의 첨도가 음의 값을 가지면 subgaussian이고, 양의 값을 가지면 supergaussian이다. subgaussian 분포의 랜덤변수는 첨예하지 않고 일정한 확률밀도함수를 가지며, supergaussian 분포의 랜덤변수는 넓고 첨예한 확률밀도함수를 가진다. 균일 분포함수의 랜덤변수는 양의 첨도, 라플라스 분포함수의 랜덤변수는 음의 첨도, 그리고 가우스 분포함수의 랜덤변수는 영의 첨도 값을 가진다. 일반적으로 첨도는 계산적으로나 이론적으로 간단하기 때문에 ICA에서 비가우스성의 척도로 널리 이용된다. 본 연구에서는 기존 ICA에서 성분의 분석 순서를 고려하지 않는 제약을 해결하기 위해 FP 알고리즘에 계산이 간단한 첨도를 추가한 ICA를 제안한다. 이는 유사한 속성을 가지는 랜덤변수는 유사한 첨도값을 가지는 특성을 이용한 것이다. 이렇게 하면 FP 알고리즘이 가지는 빠른 수렴속성을 그대로 살리면서도 유사한 속성을 가지는 성분끼리 군집화하여 좀 더 효율적으로 독립성분을 분석할 수 있다. 또한 첨도를 이용하면 크게는 subgaussian과 supergaussian 및 가우스 분포 신호들의 군집화가 가능하고, 각 군집내에서의 순서화도 가능하다. 결국 좀 더 빠르면서도 정확하게 성분을 분석하기 위하여 뉴턴법 대신 할선법의 FP 알고리즘을 이용하고, 랜덤한 분석순서를 가지는 ICA 고유의 제약을 해결하기 위하여 첨도를 이용하면 매우 효과적인 ICA가 이루어 질 수 있다.

따라서 할선법에 기초한 FP 알고리즘에 첨도가 추가된 제안된 ICA에 의한 역혼합행렬 W 의 경신과정을 도시하면 다음과 같다. 여기서 벡터 x 는 whitening된 신호이며, ϵ 은 1보다 작은 임의의 값이다.

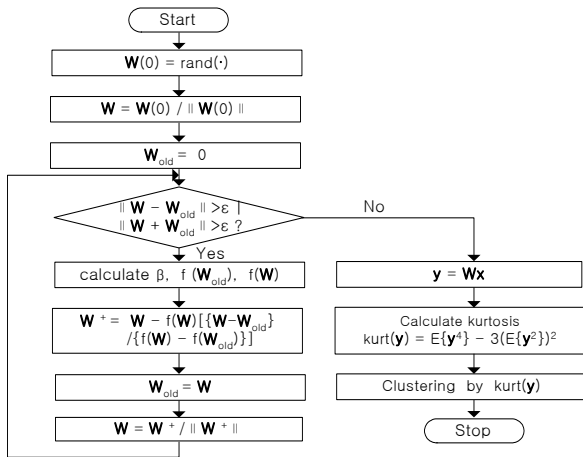


그림 2. 할선법의 FP 알고리즘에 첨도가 추가된 제안된 ICA


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) = $\frac{1}{N^2} \sum_{i=1}^{N^2} |s_i - y_i|$ 를 정의하여 비교하였으며, 여기서 N^2 은 전체 픽셀수이다. 실험은 펜티엄 IV-2.2G 컴퓨터상에서 Matlab 5.1[11]로 실행하였고, 이때 $(\cdot)^3$ 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 3은 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. 500개의 샘플을 가진 6개 신호

그림 4는 그림 3(b)의 혼합신호를 대상으로 할선법에 기초한 FP 알고리즘의 ICA와 첨도가 추가된 제안된 ICA 각각에 의해 분리된 신호들을 나타낸 것이다. 그림 4에서 보면, 두가지 알고리즘 모두에서 원 신호와 분리된 신호들 사이의 분리 순서는 서로 일치하지 않으며, sin(2)의 경우는 부호도 반대임을 알 수 있다. 이는 독립성분을 분석할 때 부호나 순서를 고려하지 않는 ICA의 고유한 속성이 그대로 반영되었기 때문이다. 한편 그림 4(a)의 할선법에 기초한 FP 알고리즘의 ICA에 의해 분리된 신호들은 유사한 성분끼리 서로 군집화가 이루어지지 않음을 알 수 있다. 하지만 그림 4(b)의 제안된 ICA에서는 첨도에 따라 유사한 속성을 가지는 신호가 서로 군집화 되었음을 알 수 있다. 여기서는 먼저 saw-tooth 함수 (2)와 (1) 2개가 군집화 되었고, 다음으로는 유사한 속성을 가지는 삼각함수인 cos 함수와 sin 함수 (1)과 (2) 2개, 그리고 다른 함수와 유사성이 거의 없는 impulse-noise순

로 군집화되어 분리됨을 알 수 있다. 결국 유사성이 있는 신호끼리의 군집화로 saw-tooth 함수는 saw-tooth 함수끼리 sin 함수와 cos 함수의 경우 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) 활선법의 고정점 알고리즘



(b) 제안된 고정점 알고리즘

그림 4. ICA에 의해 분리된 6개 신호

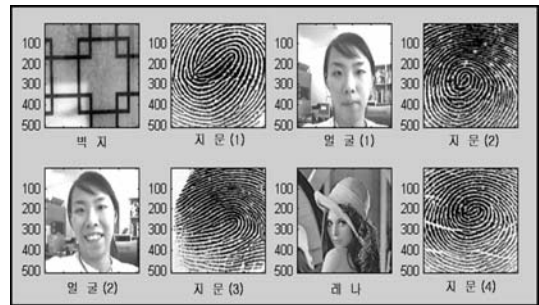
표 1은 혼합신호를 대상으로 기존 활선법의 FP 알고리즘 ICA와 제안된 알고리즘의 ICA를 각각 20회 반복 시행한 후, 학습반복수 itr, CPU시간으로 정의된 분리시간 t, 그리고 평균절대오차 MAE의 평균을 나타낸 것이다. 표에서 6개의 신호를 분리하는데 소요된 학습반복수는 총 38.1회로 1개의 신호를 추출하는데 평균 약 6.3회 정도로 기존의 ICA나 제안된 ICA 모두 동일하게 수행되었다. 이는 제안된 알고리즘의 ICA도 기존 ICA의 활선법에 기초한 고정점 알고리즘을 그대로 이용하기 때문이다. 그러나 분리시간에서 기존 ICA는 총 0.92초로 평균 약 0.15초가 소요된 반면, 제안된 ICA에서는 총 1.02초로 평균 약 0.17초 정도가 소요되었다. 이는 제안된 ICA에서는 기존 ICA의 후처리 과정으로 침도를 계산하고 그에 따라 신호를 정렬하는데 총 약 0.1초 정도 더 소요되었기 때문이다. 하지만 원 신호와 분리된 신호의 평균절대오차에서는 기존의 ICA와 제안된 ICA 둘 다 동일한 정확성을 가지며, 총 1.39로 1개의 신호에 대해서는 평균 약 0.23 정도임을 알 수 있다. 한편 혼합된 영상으로부터 cos를 분리하는데 가장 오랜 시간이 소요되었으며, 정확도에서는 saw-tooth(2)가 가장 낮음을 알 수 있다. 이는 cos과 saw-tooth(2) 신호가 다른 신호들에 비해 신호들 상호간의 종속성이 많기 때문으로 추출될 수 있다.

표 1. 6개의 혼합신호 분리에 따른 결과

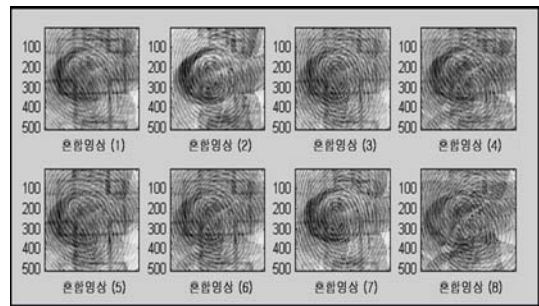
원 신호	활선법의 고정점 알고리즘 ICA			제안된 고정점 알고리즘 ICA		
	학습 반복수, n	분리 시간, t	평균절대오차, MAE	학습 반복수, n	분리 시간, t	평균절대오차, MAE
sin(1)	8.2	0.20	0.26	8.2	0.22	0.26
saw-tooth(1)	7.4	0.18	0.12	7.4	0.20	0.12
cos	8.6	0.21	0.26	8.6	0.23	0.26
impulse-noise	8.0	0.19	0.15	8.0	0.22	0.15
saw-tooth(2)	4.9	0.12	0.31	4.9	0.13	0.31
sin(2)	1.0	0.024	0.29	1.0	0.027	0.29
계	38.1	0.92	1.39	38.1	1.02	1.39
평균	6.3	0.15	0.23	6.3	0.17	0.23

3.2 2차원 영상

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



(a) 원 영상

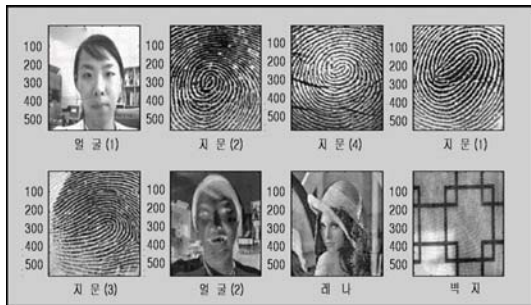


(b) 혼합영상

그림 5. 512×512 픽셀의 8개 영상

그림 6 역시 그림 5(b)의 혼합영상을 대상으로 활선법의 FP 알고리즘과 제안된 FP 알고리즘의 ICA를 각각 적용하여 분리한 8개의 영상들을 나타낸 것이다. 여기에서도 원 영상과 분리된 영상들 사이의 순서는 서로 일치하지 않으며, 얼굴(2)와 지문(4)의 경우는 부호도 반대임을 알 수 있다. 이 역시 부호나 순서를 고려하지 않는 ICA 고유의 특성 때문이

다. 1차원 신호에서처럼 그림 6(a) 할선법의 FP 알고리즘 ICA 경우, 분리된 영상들에서 지문, 얼굴, 레나, 그리고 벽지 영상이 섞여서 서로 군집화가 되지 않음을 알 수 있다. 하지만 그림 6(b)의 침도를 이용한 제안된 ICA에서는 유사한 속성을 가지는 영상들이 서로 군집화 되었음을 알 수 있다. 즉 벽지, 레나, 2개의 얼굴(2)와 (1), 그리고 4개의 지문(2), (4), (3), (1) 순으로 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 더 보여 주는 것이다. 여기에서도 신호에서처럼 기존의 ICA와 제안된 ICA를 각각 20회 실행하였을 때, 기존의 ICA에서는 알고리즘의 수행 때마다 분석순서가 달라지나 제안된 ICA에서는 항상 일정한 분석순서가 유지되었다.



(a) 할선법의 고정점 알고리즘



(b) 제안된 고정점 알고리즘

그림 6. ICA에 의해 분리된 8개 영상

표 2도 혼합영상을 대상으로 기존 할선법의 FP 알고리즘 ICA와 제안된 FP 알고리즘의 ICA를 각각 20회 반복 시행한 후, 학습반복수 itr, CPU시간으로 정의된 분리시간 t, 그리고 평균절대오차 MAE의 평균을 나타낸 것이다. 표에서도 8개의 영상을 분리하는데 기존의 ICA나 제안된 ICA 모두의 수행 학습반복수는 총 56.9회로 1개의 영상을 분리하는데 평균 약 7.1회 정도이다. 이 또한 제안된 알고리즘의 ICA에서도 기존 ICA의 고정점 알고리즘을 그대로 이용하기 때문이다. 하지만 분리시간에서 기존 ICA는 총 73.97초로 평균 약 9.25초 소요된 반면, 제안된 ICA에서는 총 79.66초로 평균 약 9.96초 정도가 소요되었다. 이 역시 제안된 ICA에서는 후처리 과정으로 침도를 계산하고 그에 따라 신호를 정렬하는데 총 약 5.69초 정도 더 소요되었음을 알 수 있다. 그러나 원영상과 분리된 영상의 평균절대오차에서 두 알고리즘의 ICA는 각각 총 9.23으로 1개 영상에 대해서는 평균 약 1.15 정도의 동일한 정합성을 나타냄을 알 수 있다. 여기에서도 지문(1) 영상의 분리시간이 가장 오래 걸리며, 정합도에서는 레나

가 가장 낮아 지문(1)과 레나 영상은 다른 영상들과 유사성이 많은 것으로 추측된다.

표 2. 8개의 혼합영상 분리에 따른 결과

원 영상	할선법의 고정점 알고리즘 ICA			제안된 고정점 알고리즘 ICA		
	학습 반복수,n	분리 시간,t	평균절대 오차,MAE	학습 반복수,n	분리 시간,t	평균절대 오차,MAE
벽지	8.5	11.05	0.89	8.5	11.9	0.89
지문(1)	9.0	11.7	0.03	9.0	12.6	0.03
얼굴(1)	8.0	10.4	0.83	8.0	11.2	0.83
지문(2)	7.0	9.1	0.86	7.0	9.8	0.86
얼굴(2)	7.1	9.23	2.24	7.1	9.94	2.24
지문(3)	8.0	10.4	0.03	8.0	11.2	0.03
레나	8.3	10.79	3.1	8.3	11.62	3.1
지문(4)	1.0	1.3	1.25	1	1.4	1.25
계	56.9	73.97	9.23	56.9	79.66	9.23
평균	7.1	9.25	1.15	7.1	9.96	1.15

이상의 혼합신호와 혼합영상을 각각 대상으로 한 분리실험을 통하여, 제안된 ICA는 계산의 용이성을 가지는 침도를 이용하여 성분의 분석순서를 고려치 않는 기존 ICA의 제약을 효과적으로 해결할 수 있음을 알 수 있었다. 특히 제안된 ICA는 유사한 침도값을 가지는 성분끼리의 군집화가 가능하여 여러 가지 신호나 영상을 식별하거나 분류하는데 효과적인 수단으로 적용될 수도 있을 것이다.

4. 결 론

본 논문에서는 할선법의 고정점 알고리즘에 침도를 추가하여 군집성을 고려한 독립성분분석을 제안하였다. 여기에서 할선법의 고정점 알고리즘은 기존 뉴우턴법의 고정점 알고리즘에서 요구되는 복잡한 도함수의 계산과정을 간략화 함으로써 성분의 빠른 분석과 좀 더 우수한 분석성능을 얻기 위한 것이고, 침도의 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 단순히 할선법에 기초한 FP 알고리즘의 ICA에서 알고리즘의 수행 때마다 랜덤하게 변하는 분석순서의 제약을 해결할 수 있었다. 특히 군집화의 속성을 가진 제안된 독립성분분석은 신호나 영상의 분류나 식별에도 적용될 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 Analysis," *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. W. Hines, '*MATLAB Supplement to Fuzzy and Neural Approaches in Engineering,*' John Wiley & Sons, Inc., June 1997.

저 자 소 개

조용현(趙鏞鉉)

2004년4월, 퍼지 및 지능시스템학회 논문지 제 13권, 제 2호. pp.200-208 참조

e-mail : yhcho@cu.ac.kr