

# 독립성분 분석과 E-M을 이용한 혼합영상의 분리 기법

## (An Image Separation Scheme using Independent Component Analysis and Expectation-Maximization)

오 범 진 <sup>†</sup>   김 성 수 <sup>\*\*</sup>   유 정 응 <sup>\*\*\*</sup>  
(Bum-Jin Oh)   (Sung-Soo Kim)   (Jeong-Woong Ryu)

**요 약** 이 논문에서는, 독립성분분석기법과 EM 기법을 이용한 새로운 혼합영상분리 방법을 제안한다. 독립성분분석기법은 통계적으로 독립된 랜덤변수들의 선형조합으로 측정대상 랜덤신호를 표기하는 여러 통계신호처리 기법 중의 하나로, 정보의 분리, 특징 추출 등의 응용분야에 적용되고 있다. 기술적으로는, 독립성분기법은 주성분 분리기법의 확장이라 볼 수 있고, 근래에 혼합정보의 분리에 관련하여 많이 연구되고 있다. 현재까지의 연구 결과로는 혼합영상의 분리에 있어 독립성분분석기법만으로는 혼합영상분리의 해를 얻지 못하고 있다. 이러한 독립성분분석기법의 약점을 보완하는 방법으로, 최근에 이노베이션 프로세서를 전처리로 하는 독립성분분석기법을 혼합한 시스템을 이용한 혼합영상 분리가 시도되었다. 이노베이션 프로세서를 전처리로 첨가한 혼합영상분리의 과정도 독립성분분석기법만을 사용한 경우 보다는 향상된 혼합영상분리를 하지만, 분류된 영상들이 원래의 혼합 전의 영상과 많이 다른 결과를 내고 있다. 기존의 방법들인 독립성분분석기법이나 이노베이션이 전처리로 적용된 경우에도 혼합이전의 영상간의 상관관계가 클 경우, 혼합영상의 분류가 잘 이루어지지 않는다. 본 논문에서는 이 약점을 보완하기 위하여, EM이론을 기존의 시스템에 전처리로 첨가하여 혼합 영상의 분리를 향상시키고자 하였다. 실험 결과에서는 최근에 연구된 이노베이션의 방법보다 EM을 적용시킨 경우가 향상된 혼합영상의 분리의 결과를 보여 주고 있다.

**키워드** : 독립성분기법, 혼합영상분리

**Abstract** In this paper, a new method for the mixed image separation is presented using the independent component analysis, the innovation process, and the expectation maximization. In general, the independent component analysis (ICA) is one of the widely used statistical signal processing schemes, which represents the information from observations as a set of random variables in the form of linear combinations of another statistically independent component variables. In various useful applications, ICA provides a more meaningful representation of the data than the principal component analysis through the transformation of the data to be quasi orthogonal to each other, which can be utilized in linear projection. However, it has been known that ICA does not establish good performance in source separation by itself. Thus, in order to overcome this limitation, there have been many techniques that are designed to reinforce the good properties of ICA. The innovation process is one of the methods that were employed in image separation using ICA, which improves the mixed image separation. Unfortunately, the innovation process still needs to be studied since it yields inconsistent result due to the randomness of images mixing weights. In order to improve the performance of the innovation process that is attached to the ICA, the expectation and maximization process is added. The results presented in this paper show that the proposed improves the image separation as presented in experiments.

· 이 논문의 제 2 저자는 2002년도 충북대학교 신진교수연구 지원에 의하여 연구하였음

<sup>†</sup> 정 회 원 : 국립한밭대학교 전자공학과 교수  
ds3iba@hanmail.net

<sup>\*\*</sup> 정 회 원 : 충북대학교 전기공학과 교수

sungkim@ebucc.chungbuk.ac.kr

<sup>\*\*\*</sup> 비 회 원 : 충북대학교 전기공학과 교수

iwryu@vod.chungbuk.ac.kr

논문접수 : 2002년 6월 17일

심사완료 : 2002년 10월 18일

**Key words** : Mixed Image Separation, Independent Component Analysis, Innovation Process Expectation and Maximization

**1. 서론**

독립성분분석기법[1, 2, 3]은 통계적인 기법으로, 독립된 정보와 다른 정보들 사이의 상관관계를 변환하는 기술이다. 이 기법은 주로 숨은 정보의 분리 및 특징 추출 등에 적용되어 영상 및 음성 처리 등에 많이 응용되고 있다[4-9]. 본 논문에서는 기존의 알고리즘에 비교하여, 상대적으로 더 향상된 혼합영상의 분리를 하고자 하였다. 간략히 기술하면, 다음과 같이 원래의 정보를 획득하지 못하고 관측된 정보만으로, 원래의 정보를 추정하는 것이라 할 수 있다. 즉 혼합된 영상 정보에서 원래의 영상에 대한 정보를 알 수 없는 경우, 원래의 영상을 분리를 통하여 찾아 가는 것이다. 독립성분분석기법과 이노베이션의 관계를 다음과 같이 간략히 살펴 볼 수 있다[10].

임의의 관측된  $m$ 개의 랜덤변수  $x_1, x_2, \dots, x_m$ 가 제로 평균을 갖고 미정의 관측되지 않는 통계적으로 독립적인  $n$ 개의 변수들  $s_1, s_2, \dots, s_n$ 의 선형조합으로 나타낼 수 있다면, 관측된 변수를 벡터  $x = (x_1, x_2, \dots, x_m)^T$ 로 나타내고 미정의 성분변수를 벡터  $s$ 에 적용해서 선형관계

$$x = As \tag{1}$$

로 표현할 수 있다.

여기서  $A$ 는  $m \times n$ 미지의 행렬이고, 혼합행렬이라 부른다.

독립성분분석기법의 목적은 조합  $x$ 의 관측에서 혼합행렬  $A$ 와 독립성분요소  $s$ 를 찾아내는 것이다. 독립성분분석기법에서, 독립성의 가정은, 잘 알려져 있는 것처럼 시스템 인식에 있어서도 중요한 사항이다.

또한, 이러한 통계적 독립성이 요구되는 랜덤변수가 되어야 한다는 가설의 조건을 완화 시키는 방향으로, 랜덤변수 대신에 이노베이션의 개념을 도입시킨 시간종속 스토캐스틱 프로세스가 혼합영상의 분류에 고려되었다. 스토캐스틱 프로세스에서의 이노베이션 프로세서는 대략적으로 주어진 고정된 시점에서의 새로운 정보가 프로세서에 주어지는 것인데, 이는 통계적 독립성을 갖는 랜덤 변수라는 가정보다 약화된 가정으로서, 이노베이션 프로세스의 성분들이 독립적이면 시간에 종속적인 시스템 모델에서 시스템 인식에 충분한 조건이 되고 있다. 이러한 가정을 통하여 정의된 시스템의 혼합 행렬  $A$ 는 이노베이션 프로세서를 전처리 과정으로 독립성분분석 기법에 적용하여 원래의 영상 정보를 추정한다. 이노베이션에 대한 자세한 설명은 2장에서 설명하겠다.

하지만, 유감스럽게도 이노베이션 프로세서에 의한 추정은 혼합된 영상들로부터 원래의 이미지를 분리하기엔 충분하지가 않다. 이 논문에서는 이러한 이노베이션 프로세서에 Expectation Maximization(EM)을 이노베이션의 전처리 과정으로 시스템에 첨가시킴으로서 혼합영상분리를 향상 시키는 새로운 기법을 제시하였다. EM에 관한 사항은 3장에서 간략히 기술하고 있다. 4장에서는 EM이 전처리로 첨부된 분리 시스템의 특성에 대하여 기술하고 있다. 5장에서는 제안된 시스템의 시뮬레이션 결과를 보여주고, 6장에서는 결론을 제시하고 있다.

**2. 이노베이션을 사용한 독립성분 기법**

통계적인 프로세서  $s(t)$ 가 주어지면, 그것의 이노베이션 프로세서  $\hat{s}(t)$ 는 과거의 정보가 주어질  $s(t)$ 의 가장 좋은 조건 확률의 기대 값과  $s(t)$ 와의 오차로 아래와 같이 정의 된다[10].

$$\hat{s}(t) = s(t) - E(s(t)|t, s(t-1), s(t-2), \dots) \tag{2}$$

여기서,  $\hat{s}(t)$ 는 시간  $t$ 에서 얻을 수 있는 프로세서에 관한 정보를 나타내고 있다. 식 (2)에 의해 유일성(Uniqueness)을 갖고 정의되는 이노베이션 프로세서의 추정(Estimation)은 조건 확률의 값을 근사화 함으로서 얻을 수 있다. 예를 들어, 시간  $t$ 가 지난 후 주어진  $s(t)$ 의 최소 자승법에 근거를 둔 최적의 값을 선택하는 것이다. 이것은 기본적으로 회귀(Regression) 문제로서, 일반적으로, 많은 경우 통상적으로 선형 자동회귀(Auto-regression) 모델에 의해 근사화 될 수 있다. 매우 간단한 경우로, 차분 프로세서(Difference Process)  $\Delta s(t) = s(t) - s(t-1)$ 에 의해서 이노베이션 프로세서의 적당한 근사 값을 얻을 수 있다. 일반적으로, 비선형 예측은 다중인식 이나 방사상의 기본함수에 의하여 근사화 될 수 있다.

식 (1)에 주어진 독립성분분석기법 (ICA) 데이터 모델을 추출하는 이노베이션 프로세서의 개념을 고찰하면, 다음과 같다.

$$x(t) = As(t) \tag{3}$$

식 (1)의 ICA 데이터 모델의 해석에 식 (3)을 적용하면, 측정된 데이터는 통계적 처리인  $x(t)$ 와 선형적 조합  $x(t) = As(t)$ 로 표현된다. 이러한 이노베이션 기법의 개념은 혼합 모델(3)의 추정에서 아래와 같이 활용될 수 있다. 즉, 관측된 정보  $x(t)$ 와 구하려는 정보  $s(t)$ 가 식 (4)와 (5)로 표기된다.

$$\hat{x}(t) = A\hat{s}(t) \quad (4)$$

여기서  $A\hat{s}(t) = x(t) - E(x(t)|t, s(t-1), s(t-2), \dots)$  (5)이다. 식 (5)에서 검출하려는 변수( $s(t-1), s(t-2), \dots$ )에 포함되어 있는 정보량은 ( $x(t-1), x(t-2), \dots$ )에 포함된 정보량과 같으므로 A의 가역성(Invertibility)의 특성에 의해  $A\hat{s}(t)$ 는  $x(t)$ 의 이노베이션을 나타내는데, 이것은 랜덤벡터  $s(t)$ 에 요구되는 인식 가능성(Identifiability) 조건을 이노베이션 프로세서가 충분히 만족시킨다는 것을 의미하고 있다[10].

여기에서 정의한  $\hat{s}(t)$ 는 독립적(Independent)이고, 정적(Stationary)이고, 에르가릭(Ergodic)의 특성을 갖는다고 가정한다[1,2]. 이것은  $s(t)$ 의 독립성이 이노베이션  $\hat{s}(t)$ 의 독립성을 암시함으로써, 시스템 인식(Identification)의 조건을 일반화한 것이다. 검출하려는 원래의 정보가 통계적인 독립성을 갖고 있기 때문에 이노베이션의 독립성을 암시하고 있다. 이는 이노베이션이 통계적으로 독립된 프로세서를 나타내는 특성이 본래의 처리보다 더 독립적이게 한다는 것을 나타내고 있다.

그러므로, 시스템 모델의 추정에 있어서의 정확성은 식 (5)의 성분  $s_i$ 의 독립성과 비가우시안성이 증가함에 따라 증가된다. 이러한 특성은 이노베이션이 혼합 행렬의 더 나은 예측을 가능하게 한다[5].

### 3. EM 알고리즘

Expectation Maximization(EM) 알고리즘[11-14]은 본래의 관심의 대상이 되는 정보가 직접적으로 얻어지지 않고, 다른 관측 가능한 변수를 통하여 획득할 수 있는 경우에, 관심의 대상이 되는 정보를 관측 가능한 변수의 공간을 통하여 추정하는 통계적 방법이다. EM의 장점은 관측 가능한 변수의 공간에 1-1의 관계로 관심의 대상이 되는 정보가 관계되어 있지 않더라도, 원하는 정보를 추정할 수 있다는 점이다. 즉, 관측 가능한 샘플 공간을 Y라 하고, Y의 부분 공간인 관측된 정보 공간




그림 1 Many-to-One 매핑의 도해

을  $y \in R^m$ 라 하면, 샘플 공간 Y와 관계를 갖는 공간을 X라 놓고, 공간 X의 관측된 정보공간과의 관계를 갖는 부분 공간을  $x \in R^m$ ,  $m < n$ 라고 하자. 여기서,  $x$ 는 직접 관측되지 않으며, 관측 가능한  $y$ 와의  $y=y(x)$ 의 many to one 매핑의 관계를 통하여 관측될 수 있다.

그림 1에서 관측된  $y$ 는  $x$ 의 부분 공간  $x(y)$ 를 결정함을 보여준다. 여기서 관측되는 공간  $y \in R^m$ 을 불완전한 데이터 공간이라 하고, 이 불완전한 공간을 구성하는 랜덤변수의 확률 밀도  $g(y)$ 를 불완전한 공간의 확률밀도 함수라 한다. 이에 반하여, 구하려는 정보 공간  $x$ 를 완전한 데이터라 하고, 이 완전한 데이터를 구성하는 랜덤변수들의 확률밀도  $f(x)$ 를 완전한 데이터의 확률밀도 함수라 한다. 일반적으로 이 두 공간의 확률밀도 함수는 임의의 관련된 변수를 통하여 연결되어 있다.

위의 관계를 매개 변수  $\theta$ 를 사용하여 나타내면 다음과 같다. 완전한 데이터의 확률밀도함수는  $f_X(x|\theta) = f(x|\theta)$ 이고 여기서  $\theta \in \Theta \subset R^r$ 는 밀도의 파라미터 집합이다. 불완전한 데이터의 확률밀도함수는  $g(y|\theta) = \int_{x(y)} f(x|\theta) dx$ 로 나타내어 진다. 여기서, 매개 변수의 값을 구하기 위한 변수로서, 매개 변수를 조건으로 하는 식  $l_y(\theta) = g(y|\theta)$ 를 라이칼리후드(Likelihood) 함수,  $L_y(\theta) = \log g(y|\theta)$ 를 대수 라이칼리후드(Log Likelihood) 함수라 놓자. 목표는  $\log f(x|\theta)$ 을 최대화 하는  $\theta$ 를 찾는 것이다.

이러한 과정을 하나로 묶은 알고리즘은 다음과 같이, 주어진 데이터  $y$ 와  $\theta$ 의 예측값으로  $\log f(x|\theta)$ 의 예측값의 최대화를 통해서 찾는 것으로 나타내어 질 수가 있다.  $\theta^{(k)}$ 를  $k$ 번째 반복에서의 파라미터 예측 값이라 하자. 그러면 다음 식을 계산할 수 있다.

$$Q(\theta | \theta^{(k)}) = E[\log f(x|\theta) | y, \theta^{(k)}] \quad (8)$$

그 다음, 식 (9)와 같이  $\theta$ 가  $Q(\theta | \theta^{(k)})$ 를 최대화 하게 선택한다.

$$\theta^{(k+1)} = \arg \max_{\theta} Q(\theta | \theta^{(k)}) \quad (9)$$

우선, EM알고리즘은  $\theta^{(k)}$ 을 초기값으로 취하고 E-step이라 정의된 Expectation 과정 (8)과 M-step이라 정의된 Maximization 과정 (9)를 반복 수행한다. 일반적으로, 여기서 사용한  $\theta$ 는 패밀리[11,12]에 대한 변수로 이루어진 벡터이다. 위의 E step과 M-step으로 이루어진 EM알고리즘의 매 반복 때마다, 비슷하지 않음의 정도(Unlikelihood)에 관한 정보가 부분(Local) 정보 공간에서의 최대점에 도달할 때까지 반복된다.

#### 4. 독립성분해석기법과 이노베이션의 전처리로서의 EM

혼합 영상을 분리하기 위한 기존의 연구가 독립성분해석기법을 많이 사용하여 연구되어 왔음에도 불구하고, 혼합음성의 분류에서와 같이 혼합영상의 분리는 어려움을 겪어 왔다. 이러한 시점에서 이노베이션의 이론이 접목됨으로서, 독립성분 기법과 이노베이션을 함께 적용시킨 시스템이 구축되었다. 기존의 방법은 혼합되기 전의 원래의 영상들 사이의 상관관계에 따라 결과에서 많은 변화를 보여준다. 이노베이션의 과정에서는 분리대상의 영상들 사이의 통계적인 독립성을 전제 조건이 약화된다.

새로이 제안된 시스템에서 첨가된 EM의 특성은, 이노베이션의 과정 이전의 전 처리 과정으로서의 혼합된 영상을 좀 더 분리시키는 역할을 한다. 이 전처리 과정에서, EM의 특성인 정보의 분리 기능이 영상들의 집합인 혼합영상들에 적용되어, 이노베이션과 독립성분 기법의 과정을 통한 정보의 분리를 더 원활하게 하는 것이다. 제안된 시스템의 중요 개념을 그림 2에 블록 다이어그램으로 나타내었다.




그림 2 EM과 이노베이션, 그리고 독립성분 기법을 사용한 혼합영상분리 시스템

#### 5. 실험

여러개의 영상이 랜덤하게 혼합되어 있는 경우에, 원래의 영상을 분리해내는 목적으로, EM을 첨가한 새로운 시스템을 구성하였다. 새로이 제안된 시스템은 기존의 독립성분해석기법을 사용하여 구성된 시스템의 경우와 독립성분해석기법에 이노베이션을 사용한 경우와 새로이 제안된 시스템의 차이점을 실험 결과의 영상으로 그림 3에 나타내었다. 네 개의 혼합되기 이전의 영상으로 그림 3에 7개의 얼굴 그룹이 있다. 첫째 열에 나타난 네

개의 영상들이 혼합되기 전의 영상들이다. 둘째 열의 영상들은 네 개의 혼합된 영상들이다. 세 번째 열의 영상들은 독립성분 기법만을 사용하여 얻어진 분류된 데이터 자체로 표기된 영상들이다. 네 번째 열의 영상들은 이노베이션 프로세서를 거쳐서 나온 영상들은 데이터 자체로 보인 영상들이다. 다섯 번째 열의 영상은 독립성분기법을 통하여 얻어진 영상들을 그레이레벨을 스케일링하여 나타낸 것이다. 여섯 번째 열의 영상들은 이노베이션 프로세서와 독립성분 기법을 사용하여 얻어진 영상들이고, 마지막 일곱 번째의 열에 보인 영상들은 독립성분 기법과 이노베이션 그리고 EM알고리즘을 종합적으로 적용하여 혼합된 영상이 분리된 결과이다.

영상의 분리의 질은 원래의 영상들 간의 비슷한 정도에 밀접한 관계가 있다. 실험에 사용된, 노이즈 없는 얼굴들 사이의 상관관계 계수들이 표 1에 나타나 있다.

표 1 잡음이 없는 영상들 간의 상관관계

	얼굴 1	얼굴 2	얼굴 3	얼굴 4
얼굴 1	1.000	0.7542	0.6763	0.6495
얼굴 2	0.7542	1.000	0.7148	0.7167
얼굴 3	0.6795	0.7148	1.000	0.8463
얼굴 4	0.6495	0.7167	0.8463	1.000

상관 관계 계수는 영상들 사이의 친밀성(비슷한 정도)을 나타내고 있는데, 수치가 작을수록 분리가 손쉬워진다.

표 2는 E-M을 진행할 때 얻어진 영상들에 주어진 가중치이다. 이미지들은 이노베이션과 E-M의 가중치를 이용하여 분리된다. 마지막 열에 보여준 얼굴들을 보면, 이노베이션과 E-M을 이용하여 얻은 얼굴들이 다른 경우보다 더 좋은 분리가 됨을 보여 주고 있다.

표 2 EM 알고리즘에 의해 얻어진 가중치

	EM에서 산출된 각 데이터 사이의 가중치			
얼굴 1	0.6290	0.3815	0.3255	0.2971
얼굴 2	0.1831	0.1074	0.0948	0.0936
얼굴 3	0.4625	0.2780	0.2410	0.2216
얼굴 4	0.3480	0.2099	0.1796	0.1747

혼합되지 않은 영상들인 첫째 열의 영상에 여섯 번째와 일곱 번째의 열들에 나타난 결과 영상들이 독립성분해석기법만을 이용한 경우인 다섯 번째 열의 영상들보다 상대적으로 혼합전인 원 영상에 더 가까운 형태로 나타나고 있다. 그 중에서도, 일곱 번째 열의 첫째와 두

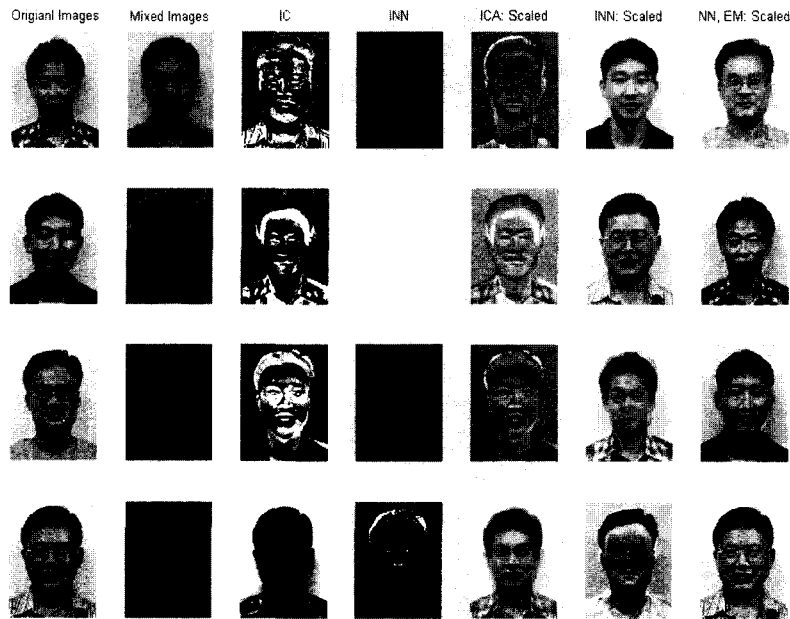


그림 3 실험에 사용된 영상과 결과영상들: Original Images(혼합영상의 제작에 사용된 영상들), Mixed Images(혼합영상들), IC(독립성분해석기법만을 적용하여 분류된 영상데이터), INN(이노베이션이 전처리 과정으로 적용된 분류영상 데이터), ICA-Scaled(ICA의 분류된 결과물을 그레이 스케일한 결과영상), INN-Scaled(INN의 결과물을 그레이 스케일한 결과영상들), NN-EM(EM과 이노베이션이 전처리 과정으로 적용되어 분류된 데이터의 스케일된 영상들)

번째의 영상은 독립성분해석기법과 이노베이션, 그리고 EM결합시킨 시스템의 결과가 여섯 번째 열의 독립성분해석기법과 이노베이션을 결합한 시스템의 결과 보다 상대적으로 좀 더 명확한 분리를 해 내고 있는 것을 보여주고 있다.

## 6. 결론

이 논문에서, 독립성분해석기법과 시간중속 통계프로세서를 이용하는 이노베이션을 전처리로 하는 기존의 혼합영상분리 시스템에 다른 하나의 이노베이션의 전처리 과정으로서 EM을 첨가함으로써 혼합영상의 분리결과를 향상시켰다. 기존의 이노베이션 프로세서는 ICA 데이터 모델의 통계적 프로세서의 전처리 과정으로서 혼합 정보의 분리를 더 정확하게 수행하지만 아직도 많은 경우의 혼합영상 분리에 실패를 하고 있다. 이러한 단점들을 제거하기 위하여, 통계적 방법 중에 하나인 EM 알고리즘을 기존의

혼합영상 시스템에 전처리 과정으로 접목시켜, 분리되지 않는 경우의 결함을 제거하는데 적용하였다. 본 논문의 연구결과로서 EM을 사용한 새로운 혼합영상의 분리 시스템이 가능성 있는 방안으로 제시되었지만, 앞으로 이 분야에 더 많은 연구가 더 필요하다.

## 참고 문헌

- [1] J.-F. Cardoso and B. Hwang Laheld, "Equivariant adaptive source separation," IEEE Trans. on Signal Processing, vol.44 no.12, pp.3017-3030, 1996.
- [2] P. Comon, "Independent component analysis-a new concept?," Signal Processing, 36, pp.2910-2943, 1996.
- [3] N. Delfosse and P. Loubaton, "Adaptive blind separation of convolutive mixtures," In Proc. ICASSP'96, pp.2940-2943, 1996.
- [4] S. Haykin, Adaptive Filter Theory, Prentice Hall

International, 3rd edition, 1996.

[5] A. Hyvärinen. Independent component analysis by minimization of mutual information, Technical Report A46, Helsinki University of Technology, Laboratory of Computer and Information Science, 1997.

[6] A. Hyvärinen and E. Oja, "A fast fixed point algorithm for independent component analysis," *Neural Computation*, vol.9, no.7, pp.1483-1492, 1997.

[7] C. Jutten and J. Herault, "Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture," *Signal Processing*, vol.24, pp.1-10, 1991.

[8] P. Pajunen, "Blind source separation using algorithmic information theory," *Neurocomputing*, 1998.

[9] H.-L. Nguyen Thi and C. Jutten, "Blind source separation for convolutive mixtures," *Signal Processing*, vol.45, pp.209-229, 1995

[10] A. Hyvärinen, "Independent Component Analysis for Time-dependent Stochastic Processes," *ICANN '98*, pp. 541-546, 1998.

[11] R.O. Duda and P.E. Hart, *Pattern Classification and Scene Analysis*, Wiley, 1973.

[12] P.J. Bickel and K.A. Doksum, *Mathematical Statistics*, Holden-Day, 1977.

[13] L. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *P. IEEE*, vol. 77, no. 2, pp-257-286, 1989.

[14] Todd K. Moon, "The Expectation Maximization Algorithm," *IEEE Signal Processing Magazine*, pp 47-60, Nov. 1996.



유 정 응

1965.2 한양대학교 전기공학과(공학사)  
1976.2 단국대학교 전자공학과(공학석사). 1987.2 단국대학교 전자공학과(공학박사). 1979.3 ~ 현재 충북대학교 전기공학과 교수. 관심분야는 자동제어, 인공지능, 적응제어



오 범 진

1982.2 숭실대학교 전기공학과(공학사)  
1984.2 숭실대학교 전기공학과(공학석사)  
2001.2 충북대학교 전기공학과(박사과정 수료). 1984.3- 현재 국립한밭대학교 전자공학과 겸임교수. 관심분야는 인공지능 패턴분류, 마이크로프로세서



김 성 수

1983.2 충북대학교 전기공학과(B.S). 1989.8 University of Arkansas Fayetteville(M.S.). 1997.12 University of Central Florida (Ph.D.). 1998.3 ~ 1999.3 시스템공학연구소/전자통신연구원. 1999.3 ~ 2001.8 우석대학교 전기공학과 조교수. 2001.9 현재 충북대학교 전기공학과 조교수. 관심분야는 웨이브렛, 데이터 압축, 정보이론

야는 웨이브렛, 데이터 압축, 정보이론