

효율적인 학습규칙의 신경망 기반 독립성분분석을 이용한 영상신호의 분리 및 특징추출

Separations and Feature Extractions for Image Signals Using Independent Component Analysis Based on Neural Networks of Efficient Learning Rule

조용현

Yong-Hyun Cho

대구가톨릭대학교 컴퓨터정보통신공학부

School of Computer and Information Comm. Eng., Catholic University of Daegu

yhcho@cuth.cataegu.ac.kr

요 약

본 연구에서는 효율적인 학습규칙의 신경망 기반 독립성분분석기법을 이용한 영상신호의 분리와 특징추출을 제안하였다. 제안된 학습규칙은 할선법과 모멘트를 이용한 조합형 고정점 학습알고리즘이다. 여기서 할선법은 독립성분 상호간의 정보를 최소화하기 위한 목적함수의 최적화 과정에서 요구되는 1차 미분에 따른 계산을 간략화하기 위함이고, 모멘트는 최적화 과정에서 발생하는 발진을 억제하여 보다 빠른 학습을 위함이다. 제안된 기법을 512×512의 픽셀을 가지는 10개의 영상을 대상으로 임의의 혼합행렬에 따라 발생하는 혼합영상의 분리에 적용한 결과, 뉴우턴법에 기초한 기존의 알고리즘과 할선법만에 기초한 알고리즘보다 각각 우수한 분리률과 빠른 분리속도가 있음을 확인하였다. 또한 256×256 픽셀의 10개 지문영상과 480×225 픽셀의 지폐영상에서 선택된 각각 10,000개의 3가지 영상패치들을 대상으로 적용한 결과, 제안된 기법은 뉴우턴법이나 할선법의 알고리즘 보다도 빠른 특징추출 속도가 있음을 확인하였다. 한편 추출된 16×16 픽셀의 160개 독립성분 기저벡터 각각은 영상 각각에 포함된 공간적인 주파수 특성과 방향성을 가지는 경계 특성이 잘 드러나는 국부적인 특징들임을 확인하였다.

Abstract

This paper proposes a separation and feature extraction of image signals using the independent component analysis(ICA) based on neural networks of efficient learning rule. The proposed learning rule is a hybrid fixed-point(FP) algorithm based on secant method and momentum. Secant method is applied to improve the performance by simplifying the 1st-order derivative computation for optimizing the objective function, which is to minimize the mutual informations of the independent components. The momentum is applied for high-speed convergence by restraining the oscillation in the process of converging to the optimal solution. The proposed algorithm has been applied to the composite images generated by random mixing matrix from the 10 images of 512x512-pixel. The simulation results show that the proposed algorithm has better performances of the separation speed and rate than those using the FP algorithm based on Newton and secant method. The proposed algorithm has been also applied to extract the features using a 3 set of 10,000 image patches from the 10 fingerprints of 256x256-pixel and the front and the rear paper money of 480x225-pixel, respectively. The simulation results show that the proposed algorithm has also better extraction speed than those using the another methods. Especially, the 160 basis vectors(features) of 16x16-pixel show the local features which have the characteristics of spatial frequency and oriented edges in the images.

Key Words : Independent Component Analysis, Newton Method, Secant Method, Momentum, Separation and Feature Extraction of Image Signals

1. 서 론

접수일자 : 2003년 2월 15일

완료일자 : 2003년 3월 7일

본 연구는 한국과학재단 목적기초연구(과제번호 : R05-2002-000-00061-0)지원으로 수행되었음.

일반적으로 데이터의 후속적인 해석을 간단하게 하기 위한 선형변환 기법으로 주요성분분석(principal component analysis : PCA)[1-3]이 널리 이용되고 있다. 이는 데이터의

차원을 감소시키는 선형변환 기법으로 공분산(covariance)을 이용하는 2차원 방법이며, 가우스(Gaussian) 분포의 입력 데이터에 대해서는 적당한 것이다. 하지만 통신이나 신호 및 영상 처리 등에서의 일반적인 입력데이터는 비가우스 분포로 이런 경우에도 효과적으로 적용될 수 있는 선형변환 방법의 연구가 요구된다. 최근 PCA의 제약을 해결하기 위해 독립성분분석(independent component analysis : ICA)이 제안되었으며, 이는 데이터의 통계적 성질을 고려한 선형변환 기법으로 데이터의 분포정보를 이용하는 다차원 방법이다[4-8]. 하지만 알려진 수치적 기법의 ICA 알고리즘들에서는 데이터의 통계적 독립성을 판정하기 위하여 확률밀도함수와 역행렬을 구한다든지 고차원의 cumulant나 moment를 구하는 등 복잡한 계산이 요구된다.

한편 복잡한 계산에 따른 많은 계산시간이 요구되는 수치적 기법에 의한 정보처리의 대안으로 최근 입력과 출력 사이에 선형성을 가지는 간단한 신경망을 이용하여 해결하려는 연구가 활발하게 진행되고 있다. 이는 신경망이 대규모의 병렬계산과 분산된 국부적 계산의 특성을 가져 통계적인 기법이나 계산 이론적인 방법의 문제들도 해결할 수 있는 속성이 있기 때문이다[1-4]. 특히 이런 통계적 속성은 비모수적(nonparametric)이면서도 비선형의 모델로 사전지식이 거의 알려지지 않은 시스템의 속성을 부호화하는데 아주 우수한 특성을 가진다.

이러한 신경망이 가지는 우수한 속성을 이용한 ICA에 대한 연구가 최근 활발하게 진행되고 있다. 이는 신경망이 가지는 통계적 기법에 따른 비선형의 모델을 부호화하는 특징을 살려 기존의 수치적 기법들의 제약들을 해결할 수 있기 때문이다. 발표된 신경망을 이용한 ICA 방법으로는 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 자연 기울기(natural gradient)를 이용한 자연기울기 알고리즘 등이 제안되었다[8,9]. 하지만 이들 방법들은 신경망을 이용하지만 신경망 그 자체가 가지는 학습에 따른 제약들은 그대로 내포하고 있어 그에 따른 연구가 절실하다. 현재 가장 널리 이용되는 FP 알고리즘의 경우는 다른 알고리즘에 비해 빠른 수렴속도와 설정되는 파라미터의 수가 적으나 분석된 독립성분이 원래의 신호에 상대적으로 덜 근사화되는 단점이 있다. 또한 확률적 기울기나 자연 기울기를 이용하는 알고리즘은 원 신호를 더 잘 근사화하는 속성을 가지지만 학습속도와 같은 파라미터의 설정이 경험적이며, 그에 따른 수렴속도도 느린 제약을 가진다. 따라서 국내외적으로 알려진 ICA 알고리즘들을 실험적으로 상호비교한 결과들은 발표[8]되고 있으나 궁극적인 개선 방안에 대한 연구결과는 아직까지 미흡한 실정이다.

본 연구에서는 기존의 신경망이 가지는 학습시간과 학습을 사이의 절충관계를 효과적으로 해결할 수 있는 조합형 알고리즘을 제시한다. 이를 위해 negentropy를 최대화하는 과정에서 기울기 이용법의 그 계산을 간략화 하기 위해 할선법(Secant method)[11]을 이용하며, 또한 기울기의 변화에 따른 경신알고리즘에서 발진을 줄여 더욱 빠른 학습성능의 독립성분분석을 위해 모멘트를 이용하였다. 제안된 기법을 512×512의 픽셀을 가지는 10개의 영상을 대상으로 임의의 혼합행렬에 따라 발생하는 혼합영상의 분리, 256×256 픽셀의 지문영상과 480×225 픽셀의 지폐영상 각각을 대상으로 한 특징추출에 적용하여 그 타당성과 성능을 확인하고자 한다.

2. 고정점 알고리즘에 의한 독립성분분석

ICA는 m개의 입력신호 s로부터 선형적으로 혼합된 n개의 신호 x가 알려져 있을 때, 혼합신호로부터 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

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

로 정의된다. 여기서 n은 보통 입력신호와 구별되지 않기 때문에 생략할 수도 있으며, $A = [a(1), a(2), \dots, a(m)]$ 으로 a(i)는 ICA의 기저벡터(basis vector)이다. 혼합신호를 찾기 위한 ICA의 구성도를 보면 그림 1과 같이 나타낼 수 있다. 그림에서 $x = As$ 이고, $y = Wx$ 이다. 이때 ICA에서는 출력신호 y의 각 요소들이 통계적으로 독립성을 유지해야 하며 직교성의 제약조건은 포함하지 않는다. 따라서 ICA는 출력신호가 독립성을 가지는 조건하에서 혼합행렬과 일치하는 역혼합행렬 W를 찾는 기법이다. 이때 알려진 혼합신호 x를 미리 영평균(zero-mean)과 whitening하면, 신호의 1차와 2차의 통계성에 따른 상관성이 이미 고려되기 때문에 좀 더 효과적으로 ICA를 수행할 수 있다[5].




그림 1. 혼합행렬과 역혼합행렬의 상세 설명도

한편 ICA는 영상의 특징을 추출하는 것에도 이용된다 [7-9]. 이때 원신호 s는 영상패치 x를 형성하기 위한 혼합행렬 A의 가중치를 나타낸다. 결국 s의 선형합성에 의해 x는 형성되므로 s는 영상들의 근거들(causes)이다. 그림 2는 선형 영상합성 모델을 나타낸 것이다. 여기서 s의 열들(columns)은 근거들을 나타내며, A의 행들(rows)은 기저벡터로 구성된 기저함수이고, 그리고 x의 열들은 관찰된 영상패치들이다. 따라서 영상패치 x로부터 ICA를 이용하여 W를 구하면 $W = A^{-1}$ 의 관계에서 W의 행은 A의 열로 이들은 기저벡터인 영상의 특징이 된다.




그림 2. 선형 영상합성 모델

고정점 알고리즘은 신경망이 가지는 병렬성과 분산성, 그리고 더 작은 메모리 요구 등의 제약을 해결하기 위해 제안된 독립성분분석을 위한 알고리즘이다[7, 8]. FP 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 그 수렴속도

가 적어도 2차 함수정도이며, 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 독립성의 정보이론적 척도로 ICA 변환을 찾기 위한 판별로서 자연스럽게 이용될 수 있다. 일반적으로 변수들 상호간의 정보를 표현하는 상호정보는 비가우시성의 척도로 이용되는 negentropy로 정의된다. n개의 랜덤변수 벡터 $y = (y_1, \dots, y_n)^T$ 를 위한 negentropy $J(y)$ 는

$$J(y) = H(y_{gauss}) - H(y) \quad (2)$$

이다. 여기서 $H(y)$ 는 랜덤변수 y 의 엔트로피이며, y_{gauss} 는 가우시 랜덤벡터이다. 이때 negentropy $J(y)$ 를 이용한 상호무관한 n개 랜덤변수 $y_i(i=1, \dots, n)$ 사이의 상호정보 $I(y_1, y_2, \dots, y_n)$ 는

$$I(y_1, y_2, \dots, y_n) = J(y) - \sum_{i=1}^n J(y_i) \quad (3)$$

으로 정의된다. 결국 ICA에서 독립성의 최대화를 위해 식 (3)으로 정의되는 상호정보 $I(y_1, y_2, \dots, y_n)$ 를 최소화하는 것은 negentropy를 최대화하는 것이다. negentropy의 최대화는 식 (3)에서 우측 2번째 항의 최대화로 가능하다. 이를 위한 근사식으로 최대 엔트로피 원리를 이용하면

$$J(y_i) \approx c[E\{G(y_i)\} - E\{G(v)\}]^2 \quad (4)$$

와 같이 정의된다. 여기서 G 와 c 는 각각 비2차 함수와 상수이고, v 는 평균이 0이고 분산이 1인 표준화된 가우시 변수이며, 랜덤변수 y_i 도 평균이 0이고 분산이 1인 변수로 가정한다. negentropy의 근사화를 위한 식 (4)는 ICA 변환을 추정하는 목적함수로 이용될 수 있다. 따라서 ICA에서 독립변수들의 상호간 무관성을 고려한 하나의 독립성분 $y_i = W^T x$ 를 찾기 위한 목적함수 $JG(W)$ 는 식 (4)에 따라

$$JG(W) = [E\{G(W^T x)\} - E\{G(v)\}]^2 \quad (5)$$

로 표현된다. 결국 식 (5)로 정의된 ICA를 위한 목적함수를 최대화하기 위한 방법이 요구된다. 이러한 방법으로 FP 알고리즘이 제안되었다.

FP 알고리즘은 알고리즘의 한 단계에 많은 수의 데이터들이 이용되는 batch mode로 계산을 수행하며, 신경망으로 수행될 수 있는 알고리즘이다. 데이터 벡터 x 가 상관행렬 $E\{xx^T\}=1$ 로 whitening되어 있다고 가정할 때, 하나의 독립성분을 위한 FP 알고리즘을 식 (5)에서 유도할 수 있다. $JG(W)$ 의 최대화는 반드시 $E\{G(W^T x)\}$ 의 최적에서 얻어진다. 이때 Kuhn-Tucker 조건으로부터, $E\{(W^T x)^2\}=1$ 조건하에서 $E\{G(W^T x)\}$ 의 최적은 다음 식

$$E\{xg(W^T x)\} - \beta W = 0 \quad (6)$$

로 얻어진다. 여기서 $g(\cdot)$ 는 비2차 함수 G 의 미분으로 $(\cdot)'$ 와 $\tanh(\cdot)$ 의 함수가 이용된다[5,6]. $\beta = E\{W_0^T xg(W_0^T x)\}$ 인 상수이며, W_0 는 W 의 최적값이다. 따라서 방정식 (6)을 풀기 위해 빠른 수렴속도를 가지는 할선법을 도입한다.

할선법은 현재의 함수 값과 바로 이전의 함수 값을 이용하여 방정식의 근을 구하는 방법이며, 이는 방정식의 해를 직접적으로나 단순한 방법으로 구할 수 없을 때 뉴턴법과 마찬가지로 쉽게 해결할 수 있는 다른 문제로 근사화하는 방

법이다[10]. 여기서는 방정식의 해를 구하는데 있어 뉴턴법에서 처럼 별도의 1차 미분 계산이 요구되지 않는다. 일반적으로 할선법에서는 방정식 $f(W)$ 의 도함수 $f'(W)$ 를 유한상차분으로 근사화하기 위하여 함수의 현재와 이전의 값을 이용한다. 이때 도함수 $f'(W)$ 는 다음과 같이 근사화된다. 즉,

$$f'(W_k) \approx [f(W_k) - f(W_{k-1})] / [W_k - W_{k-1}] \quad (7)$$

이다. 여기서 k 와 $k-1$ 은 각각 현재와 이전의 반복수를 의미한다. 식 (7)의 근사화식을 이용하여 할선법에 기초한 역혼합행렬 W 의 경신 반복식은

$$W_{k+1} = W_k - f(W_k)(W_k - W_{k-1}) / [f(W_k) - f(W_{k-1})] \quad (8)$$

와 같이 나타낼 수 있다. 식에서는 W 의 경신을 위해 2개의 초기값인 W_k 와 W_{k-1} 를 요구한다. 하지만 이들 값들은 별도로 설정되는 것이 아니며 계산과정에서 생성되는 값들이다. 결국 식 (8)로 표현되는 할선법에서는 별도의 1차 미분 계산이 요구되지 않아 계산적으로 좀더 효율적이다.

할선법에 기초한 경신 반복식 (8)을 이용하여 방정식(6)의 근을 구함으로써 역혼합행렬 W 를 구할 수 있다. 결국 β 를 W_0 대신에 W 의 현재값으로 나타낸 역혼합행렬 W 를 위한 학습과정은

$$\begin{aligned} f(W^*) &= [E\{xg(W^{*T}x)\} - \beta W^*] \\ f(W) &= [E\{xg(W^T x)\} - \beta W] \\ W^* &= W - f(W) / \{f(W) - f(W^*)\} \\ W^* &= W^* / \|W^*\| \end{aligned} \quad (9)$$

와 같다. 여기에서 W^* 은 바로 전에 계산된 W 의 값이고, W^* 은 W 의 새롭게 경신된 값이며, $\beta = E\{W^T xg(W^T x)\}$ 이다. 결국 식 (9)는 할선법에 기초를 둔 ICA를 위한 FP 알고리즘이다.

한편 식 (9)에서의 근사화값 계산에서 W 가 최적해로 수렴할 때 발진이 일어날 수도 있다. 따라서 수렴에 따른 발진을 막아 줄 수만 있다면 좀 더 빠르게 최적해로 수렴시킬 수 있을 것이다. 이를 위해 본 논문에서는 W 를 계산할 때 이전 변화의 속성을 반영하는 모멘트를 추가하였다. 이렇게 하면 할선법이 가지는 빠른 수렴속성을 그대로 살리면서도 최적해로의 수렴에서 발생하는 발진을 억제시켜 더욱 빠른 속도의 독립성분분석이 가능하다. 제안된 할선법과 모멘트에 기초한 역혼합행렬 W 의 경신식은 식 (9)의 3번째 식만 변형된

$$W^* = W - f(W) / \{f(W) - f(W^*)\} + \alpha(W^* - W) \quad (10)$$

이 된다. 여기서 α 는 모멘트이다.

제안된 할선법과 모멘트에 기초를 둔 FP 알고리즘의 역혼합행렬 W 를 경신하는 과정을 요약하면 다음과 같다.

- 단계 1 : $W(0) = \text{rand}()$ 로 설정한다.
 - 단계 2 : $W = W(0) / \|W(0)\|$ 의 값을 계산한다.
 - 단계 3 : $W^* = 0$ 로 설정한다.
 - 단계 4 : $\|W - W^*\| > \epsilon$ 이고 $\|W + W^*\| > \epsilon$ 이면 다음 식에 따라 W 를 계산하고, 그렇지 않으면 과정을 종료한다.
- (1) β , $f(W^*)$, 그리고 $f(W)$ 를 계산한다.
 - (2) $W^* = W - f(W) / \{f(W) - f(W^*)\} + \alpha(W^* - W)$ 를 계산한다.
 - (3) $W^* = W$ 로 둔다.
 - (4) $W = W^* / \|W^*\|$ 를 계산한다.

위의 과정에서 벡터 x 는 whitening된 신호벡터이며, ϵ 은 1보다 작은 임의의 값이다. 특히 경신의 식에서 $g(\cdot)$ 는 비

선형함수이며 일반적으로 $(\cdot)^3$ 과 $\tanh(\cdot)$ 의 함수들을 이용한다. 비선형함수의 선택은 $\tanh(\cdot)$ 의 대칭적인 알고리즘의 경우에 supergaussian의 분포속성을 가지는 신호들은 분리할 수 없다는 것만 제외하면 어느 함수나 무방하다. 그러나 일반적으로 $(\cdot)^3$ 함수는 학습속도가 빠르며, $\tanh(\cdot)$ 함수는 좀 더 안정한 특성을 가진다. 본 연구에서는 상대적으로 이들 함수에 따른 분리성능은 거의 유사한 특성을 가짐을 확인하였다.


3. 시뮬레이션 결과 및 분석

제안된 학습알고리즘의 신경망 기반 ICA의 타당성과 성능을 평가하기 위하여 임의의 혼합행렬에 따라 발생하는 혼합영상들의 분리와 지문영상들 및 지폐영상들의 특징추출을 대상으로 각각 시뮬레이션 하였다. 혼합영상으로부터 영상의 분리성능을 평가하기 위해 각 데이터의 절대합오차(absolute sum error : ASE)를 정의하여 원 신호와 복원된 신호의 정합성을 각각 비교하였다. 이때 절대합오차 $ASE = \frac{1}{N} \sum |x_i - y_i|$ 로 하였으며, 여기서 x_i 와 y_i 는 각각 원 신호와 복원된 신호의 i 번째 값이며, N 은 픽셀의 총 수이다. 또한 영상분리의 학습 종료조건으로는 역혼합행렬 W 의 변화량 ϵ 이 0.0001 이하일 때나 하나의 영상을 분리하는데 소요되는 학습반복수가 100회 이상일 때로 하였으며, 특징추출에서는 방정식 (6)으로 표현된 복잡함수의 변화량이 0.0001이하일 때나 학습반복수가 100회 이상일 때로 하였다. 또한 비선형 함수 $g(\cdot)$ 는 $(\cdot)^3$ 으로 하였다. 실험은 펜티엄IV-2.2G 컴퓨터 상에서 Matlab 5.1로 실행하였다.


3.1 혼합영상분리

풍경화, 레나, 로즈, 바다, 그리고 서류꽂이 등의 512×512 픽셀 2차원의 데이터를 가지는 10개의 원 영상들로부터 임의의 혼합행렬로부터 생성된 10개의 복합영상을 대상으로 실험하였다. 그림 3은 실험에 이용된 풍경화, 레나, 로즈, 바다, 서류꽂이, 나무무늬, 우산, 적벽돌, 벽돌타일, 그리고 철대문의 10개 원 영상과 임의의 혼합행렬로부터 생성된 10개의 복합영상을 각각 나타낸 것이다. 특히 그림 3(b)는 그림 3(a)로부터 10×10 의 랜덤값을 가지는 혼합행렬 A 로부터 생성된 복합영상들이다. 그림에서는 혼합된 영상들 각각으로부터 원 영상들에 대한 정보들을 발견할 수 없으며, 실험에서는 혼합된 영상을 영평균과 whitening한 후 입력신호로 이용하였다.

그림 4는 그림 3(b)의 복합영상들을 대상으로 각각 뉴우턴법, 할선법, 할선법과 모멘트의 FP 알고리즘 각각을 수행한 후 분리된 10개의 영상들이다. 여기서도 모멘트 $\alpha = 0.002$ 로 하였다. 그림에서 보면 지문 분리에서와 같이 원 영상과 분리된 영상들 사이의 순서는 일치되지 않아 ICA가 영상의 분리순서는 고려하지 않음을 알 수 있다. 뉴우턴법의 FP 알고리즘으로 수행된 그림 4(a)를 보면 나무무늬, 우산, 바다, 로즈, 레나, 벽돌타일, 서류꽂이, 그리고 철대문, 할선법의 FP 알고리즘 그림 4(b)에서는 레나, 벽돌타일, 로즈, 서류꽂이, 그리고 철대문 영상의 경우가 원 영상과 반대의 부호를 가진다. 또한 할선법과 모멘트의 FP 알고리즘 그림 4(c)에서도 레나, 벽돌타일, 우산, 바다, 철대문, 그리고 서류꽂이 영상들이 원 영상과 반대의 부호를 가진다. 이 결과 역시 ICA에서 독립성분을 추출할 때 순서뿐만 아니라 부호도 고려하지 않는 속성이 반영된 것이다. 한편 복원된 분리영상은 각각 혼



(a) 원 영상




(b) 복합영상


그림 3. 512×512 픽셀의 10개 독립영상

합된 영상에서의 독립성분이며, 풍경화를 비롯한 10개의 독립영상 각각을 찾아내는데 소요되는 알고리즘의 학습반복수에서 뉴우턴법의 알고리즘은 7, 14, 1, 15, 10, 59, 11, 63, 47, 그리고 4회 각각 수행되었고, 할선법의 알고리즘은 10, 14, 6, 8, 4, 12, 5, 1, 6, 그리고 7회 각각 수행되었으며, 할선법과 모멘트의 알고리즘은 9, 11, 7, 4, 5, 10, 5, 1, 7, 그리고 8회 각각 수행되었다. 이는 512×512 픽셀을 가지는 10개의 영상을 분리하는데 각각의 알고리즘은 총 231회, 73회, 그리고 67회 반복수행 되었음을 의미한다. 여기서도 독립성분분석을 위한 신경망의 학습에서 할선법의 알고리즘이 뉴우턴법의 알고리즘에 비해 약 3.16배 정도 빠른 분리속도가 있다. 또한 할선법과 모멘트의 조합형 알고리즘은 할선법의 알고리즘보다 약 1.09배 정도 빠른 분리속도를 보인다. 결국 뉴우턴법과 할선법 각각의 알고리즘보다 할선법과 모멘트의 조합형 알고리즘이 가장 빠른 분리속도가 있음을 알 수 있다.


그림 5는 혼합된 10개의 영상을 대상으로 제안된 알고리즘, 할선법의 알고리즘, 그리고 뉴우턴법의 알고리즘을 각각 20회 시행하여 분리하는데 가장 오래 걸리는 로즈영상의 학습반복수를 나타낸 것이다. 제안된 알고리즘의 모멘트는 0.002로 하였다. 그림에서 학습반복수를 보면 뉴우턴법의 알고리즘은 최소 1에서 최대 55회의 범위로 총 706회이고, 할선법의 알고리즘은 최소 1에서 최대 18회의 범위로 총 160회이며, 제안된 알고리즘은 최소 1에서 최대 14회의 범위로 총 126회이다. 이들의 평균 학습반복수는 각각 약 35.3, 8회, 그리고 약 6.3회 정도로 제안된 알고리즘은 뉴우턴법과 할선법의 알고리즘에 비해 각각 약 5.6배와 약 1.3배 정도 개선된 분리속도가 있다. 또한 할선법의 알고리즘 역시 뉴우턴의



(a) 뉴우턴법의 FP 알고리즘



(b) 할선법의 FP 알고리즘



(c) 제안된 FP 알고리즘

그림 4. 512×512 픽셀의 10개 분리된 영상




그림 5. 로즈영상의 분리에 따른 학습반복수

알고리즘에 비해 약 4.4배 정도 분리속도가 개선되었다. 특히 뉴우턴법의 알고리즘은 할선법에 기초한 2개의 알고리즘에




그림 6. 모멘트의 변화에 따른 학습반복수

비해 시행에 따른 학습반복수의 변화가 심함을 알 수 있다. 이는 뉴우턴법의 알고리즘 성능이 할선법에 기초한 알고리즘 보다 설정되는 역혼합행렬의 초기값에 더욱 더 의존함을 보여 준 것이다. 결국 제안된 알고리즘과 할선법의 알고리즘은 뉴우턴법의 알고리즘보다 임의로 설정되는 초기값에도 덜 의존하는 속성이 있다. 한편 제안된 알고리즘도 할선법에 기초한 알고리즘으로 할선법의 알고리즘과 유사한 변화 속성을 보이나 모멘트의 추가로 역혼합행렬의 경신에서 학습반복수의 감소와 더불어서 초기값의 설정에도 상대적으로 다소 덜 의존함을 알 수 있다.

그림 6은 그림 3(b)의 복합영상들을 대상으로 제안된 조합형 FP 알고리즘에서 모멘트 α 값을 0에서 1까지 변화시키에 따른 학습반복수 k 를 나타낸 것이다. 결과는 각각의 모멘트에 대해 20번씩 학습과정을 반복하여 그 평균을 나타낸 것이다. 그림에서 모멘트 $\alpha=0$ 은 기존의 할선법의 FP 알고리즘이다. 여기에서는 모멘트가 0일 때보다 모멘트의 값이 0.07이상일 때는 상대적으로 많은 학습반복수를 보였으며, 모멘트의 값이 0.001에서 0.06사이일 때 상대적으로 개선된 학습성능을 보였다. 실험에서 모멘트의 값이 0.001에서 0.06사이일 때 평균 학습반복수는 약 92.4회 정도로 0일 때의 약 97.4회 보다 약 1.1 배 정도 개선된 학습성능이 있음을 확인하였다.

표 1은 10개의 혼합된 영상에 대해 뉴우턴법의 FP 알고리즘, 할선법의 FP 알고리즘, 그리고 할선법과 모멘트의 제안된 FP 알고리즘을 각각 20번씩 반복 실험하여 대응되는 원영상과 복원된 영상에 대한 픽셀 단위의 절대합오차 ASE, 학습반복수 k , 그리고 분리에 소요된 CPU 시간 t 각각의 평균을 나타낸 것이다. 여기에서도 제안된 알고리즘의 모멘트는 0.002로 하였다. 실험에서 뉴우턴법의 알고리즘 경우, 영상의 분리를 위한 20회 시행 중 8회가 종료조건을 만족하지 못하여 전체 10개의 영상을 분리하는데 실패하였다. 하지만 학습반복수에 따른 종료조건을 무시하고 실험을 반복한 결과 최대 42,756회까지 소요되는 비현실적인 수렴시간을 보였다. 할선법의 알고리즘에서는 20회 시행 모두에서 영상의 분리가 이루어졌다. 이는 뉴우턴법의 알고리즘에서 기울기인 도함수의 값이 0에 수렴될 경우 역혼합행렬의 경신과정에 0으로 나누어지는 결과가 발생되어 비현실적인 수렴현상으로 추정된다. 한편 표에서 뉴우턴법의 알고리즘 결과는 추가시행을 실시하여 학습의 종료조건을 만족한 경우에 대한 결과이다. 표 1의 10개 영상 중에서 각각 적벽돌, 벽돌타일, 철대문의 절대합오차들을 살펴보면, 다른 영상들에 비해 상대적으로 큰 값을 가진다. 이는 다른 영상들에 비해 이들 3가지 영상들은 다른 영상에 비해 독립성이 상대적으로 낮은 영상이며, 그에 따라서 분리성능도 상대적으로 떨어짐을 보여주는 것이다. 한편 10개 영상 모두에 대한 3가지 알고리즘의 각각의 절대합오차는 약 3.6, 약 2.39, 그리고 약 2.19로 제안된

표 1. 뉴우턴법, 할선법, 제안된 고정점 알고리즘 각각에 의한 영상분리결과

입력 영상	뉴우턴법의 FP 알고리즘			할선법의 FP 알고리즘			제안된 FP 알고리즘		
	절대합 오차, ASE	학습 반복수, k	분리 시간, t	절대합 오차, ASE	학습 반복수, k	분리 시간, t	절대합 오차, ASE	학습 반복수, k	분리 시간, t
풍경화	0.29	28.15	69.25	0.09	12.75	39.86	0.06	12.01	38.57
레나	0.27	12.42	20.55	0.11	13.93	43.55	0.14	14.88	47.79
로즈	0.32	34.08	83.84	0.07	7.89	24.67	0.08	11.32	36.35
바닥	0.31	8.57	21.08	0.25	11.02	34.45	0.21	8.04	25.82
서류꽃이	0.38	26.41	64.97	0.22	8.86	27.7	0.22	5.29	16.99
나무무늬	0.39	16.29	40.07	0.31	11.03	34.48	0.3	13.1	42.07
우산	0.3	8.63	21.23	0.24	7.97	24.92	0.23	4.73	15.19
적벽돌	0.42	21.15	52.03	0.36	3.14	9.82	0.31	3.27	10.5
벽돌타일	0.45	10.76	26.47	0.33	9.01	28.17	0.26	9.54	30.64
철대문	0.47	12.24	30.11	0.41	10.58	33.08	0.38	7.68	24.66
계	3.6	178.87	429.6	2.39	96.18	300.07	2.19	89.86	288.58

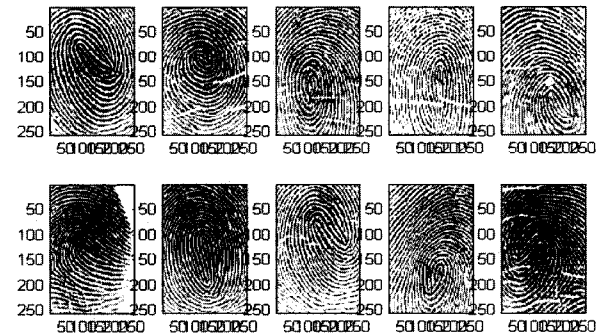
알고리즘은 뉴우턴법과 할선법에 비해 각각 약 1.64배와 약 1.09배 정도 개선된 성능이 있다. 또한 할선법은 뉴우턴법에 비해 약 1.51배 정도 개선된 성능이 있다. 학습반복수와 분리 시간에서 보면, 뉴우턴법은 약 178.87과 약 429.6, 할선법은 약 96.18과 약 300.07, 그리고 제안된 알고리즘은 약 89.86과 약 288.58 정도이다. 먼저 학습반복수에서는 제안된 알고리즘이 뉴우턴법과 할선법에 비해 각각 약 1.99배와 약 1.07배 정도 개선되었으며, 분리시간에서는 각각 약 1.49배와 약 1.04배 정도 개선되었다. 또한 할선법은 뉴우턴법에 비해 약 학습반복수와 분리시간에서 각각 약 1.86배와 약 1.43배 정도 개선되었다. 따라서 제안된 조합형 알고리즘은 뉴우턴법의 알고리즘이나 할선법의 알고리즘보다 개선된 분리성능과 분리속도가 있으며, 할선법의 알고리즘도 뉴우턴법의 알고리즘보다 우수한 분리성능과 빠른 분리속도를 가짐을 알 수 있다. 결국 할선법과 모멘트의 조합형 알고리즘이 할선법의 알고리즘이나 뉴우턴법의 알고리즘보다 분리성능과 분리속도에서 가장 우수한 성능이 있음을 확인할 수 있다. 한편 표 1에서 알고리즘 각각의 1회 수행 CPU 시간을 보면, 뉴우턴법은 약 2.46, 할선법은 약 3.13, 그리고 제안된 알고리즘은 약 3.21 정도로 뉴우턴법이 가장 빠름을 알 수 있다. 이는 뉴우턴법이 할선법보다 빠른 계산속성이 있음을 보여주는 것이며, 제안된 알고리즘에서는 과거의 속성을 반영하는 모멘트 항의 계산이 요구되어 상대적으로 할선법보다 더 느린 계산 시간을 가진다. 하지만 분리를 위한 학습반복수의 감소로 전체적인 분리속도에서는 제안된 알고리즘, 할선법의 알고리즘, 그리고 뉴우턴법의 알고리즘 순으로 분리속도를 보였다.

3.2 영상의 특징추출

제안된 ICA 알고리즘에 의한 특징추출의 타당성과 성능을 평가하기 위해 지문영상과 지폐영상들을 대상으로 실험하였다. 실험에서는 256×256 픽셀의 10개 지문영상과 480×225 픽셀의 전·후면 지폐영상 각각으로부터 임의로 추출된 영상패치들을 대상으로 알고리즘들을 수행하였다. 실험을 위 추출된 영상패치들은 각각 10,000개의 16×16 픽셀로 구성되었으며, 이들로부터 16×16 픽셀의 160개 독립성분 기저벡터인 특징벡터들을 각각 추출하였다. 160개의 특징벡터로 차원을 감소시킨 것은 영상에 포함된 잡음을 줄이기 위함이다 [7-9].

그림 7은 실험에 이용된 10개의 지문영상과 전·후면 지폐영상들을 나타낸 것이다.

그림 8은 지문영상과 지폐영상 각각을 대상으로 제안된 고정점 알고리즘의 독립성분분석을 수행하여 종료조건이 만족될 때 추출된 16×16 픽셀의 160개 특징들을 행렬로 나타낸 것이다. 실험에서 역혼합행렬 W의 초기값은 0과 1사이의 무작위 값으로 하였으며, 모멘트 0.002로 하였다. 그림에서 추출된 각 특징벡터는 역혼합행렬 W의 열이며, 좌측에서 우측으로, 그리고 위에서 아래로 순서화됨을 알 수 있다. 한편




(a) 지문영상




(b) 전·후면 지폐영상


그림 7. 지문과 지폐영상



(a) 지문영상



(b) 전면 지폐영상



(c) 후면 지폐영상

그림 8. 지문영상 및 지폐영상으로부터 추출된 16×16 픽셀의 160개 특징벡터들

그림에서 보면 먼저 영상의 특징을 나타내는 기저벡터들은 분명히 공간과 주파수적으로 국부화되어 있으며, 또한 방향성을 가짐을 알 수 있다. 이는 추출된 특징들이 공간성, 방향성, 그리고 주파수 3가지 파라미터에 대해 국부성을 가지며, 영상처리에서 가장 널리 이용되는 Gabor 함수[5,7-9]와 아주 유사한 결과를 나타냄을 알 수 있다. 이는 제안된 ICA에 의한 특징추출은 Gabor 함수에 의한 특징추출과 아주 근사적인 기법임을 의미한다. 또한 ICA를 이용한 특징추출은 공간상에서의 국부성을 나타내지 못하는 푸리에(Fourier) 기저함수나 주파수와 방향성에서 국부성을 나타내지 못하는 pixel-by-pixel 표현보다도 우수한 기법임을 알 수 있다. 특히 그림에서 보면 추출된 특징들에서는 막대모양으로 표현된 영상의 가장자리가 잘 표현됨을 알 수 있다. 한편 여기에서는 기저벡터의 크기가 달라도 얼마간 동일한 특징을 나타냄을 확인할 수 있다. 이는 wavelet 함수와의 관계를 보여주는 것으로,

주파수와 기저벡터에 의해 대치되는 면적은 서로 종속적임을 의미한다[9]. 하지만 wavelet이 영상의 수직과 수평의 2가지 방향특징만을 나타내는데 비해 ICA는 대각선의 방향을 포함한 보다 많은 방향특징을 가지며, wavelet은 위상차이를 가지지 않지만 ICA에서는 매우 다른 위상도 가짐을 알 수 있다. 따라서 ICA에 의한 영상의 특징추출은 Gabor 함수와 유사한 성능을 가지며, wavelet 함수보다는 우수한 성능이 있음을 알 수 있다. 특히 본 연구에서의 신경망 기반 ICA 기법은 기존의 수치적 기법에 의해 수행되는 Gabor 함수나 wavelet에 비해 계산이 간단하여 상대적으로 빠르게 특징을 추출할 수 있다.




그림 9. 전면 지폐영상의 특징추출에 따른 학습반복수

그림 9는 전면 지폐영상을 대상으로 제안된 알고리즘, 할선법의 알고리즘, 그리고 뉴우턴법의 알고리즘을 종료조건을 만족할 때까지 각각 20회 시행하여 특징을 추출하는데 소요된 학습반복수를 나타낸 것이다. 여기서도 제안된 알고리즘의 모멘트는 0.002로 하였다. 그림 9에서는 시행에 따른 3가지 알고리즘의 학습반복수는 전체적으로 유사한 변화형태를 보인다. 또한 특징추출에서 학습반복수를 보면 뉴우턴법의 알고리즘은 최소 20회에서 최대 71회의 범위로 총 890회, 할선법의 알고리즘은 최소 20회에서 최대 56회의 범위로 총 688회, 그리고 제안된 알고리즘은 최소 20에서 최대 47회의 범위로 총 622회 소요되었다. 이들의 평균 학습반복수는 각각 약 44.5회, 약 34.4회, 그리고 약 31.1회 정도로 제안된 알고리즘은 뉴우턴법과 할선법의 알고리즘에 비해 각각 약 1.4배와 약 1.1배 정도 개선된 분리속도가 있다. 또한 할선법의 알고리즘 역시 뉴우턴의 알고리즘에 비해 약 1.3배 정도 분리속도가 개선되었다. 여기에서도 그림 5의 영상분리에서처럼 뉴우턴법의 알고리즘은 할선법에 기초한 2개의 알고리즘에 비해 시행에 따른 학습반복수의 변화가 상대적으로 심함을 알 수 있다. 따라서 뉴우턴법의 알고리즘 성능이 할선법에 기초한 알고리즘보다 설정되는 역혼합행렬의 초기값에 더욱 더 의존하며, 제안된 알고리즘도 할선법에 기초한 알고리즘으로 할선법의 알고리즘과 유사한 변화 속성이 있음을 확인할 수 있다.

그림 10은 그림 7(b)의 전면 지폐영상을 대상으로 제안된 조합형 FP 알고리즘에서 모멘트 α 값을 0에서 1까지 변화시킴에 따른 학습반복수 k를 나타낸 것이다. 여기서도 결과는 각각의 모멘트에 대해 20번씩 학습과정을 반복하여 그 평균을 나타낸 것이다. 그림에서 모멘트 $\alpha=0$ 은 기존의 할선법의 FP 알고리즘이다. 모멘트가 0일 때보다 모멘트의 값이 0.05이상일 때는 상대적으로 많은 학습반복수를 보였으며, 모멘트의 값이 0.001에서 0.04사이일 때 상대적으로 개선된 학습성능을 보였다. 실험에서 모멘트의 값이 0.001에서 0.04사이일 때 평균 학습반복수는 약 31.2회로 0일 때의 약 34.4회 보다 약 1.1




그림 10. 모멘트의 변화에 따른 학습반복수

배 정도 개선된 학습성능이 있음을 확인하였다.

표 2는 지문영상과 지폐영상에 대해 뉴우턴법의 FP 알고리즘, 할선법의 FP 알고리즘, 그리고 할선법과 모멘트의 제안된 FP 알고리즘을 각각 20번씩 반복 실험하여 종료조건을 만족할 때까지의 학습반복수 k 와 특징추출에 소요된 CPU 시간 t 각각의 평균을 나타낸 것이다. 여기에서도 제안된 알고리즘의 모멘트는 0.002로 하였다. 실험에서도 뉴우턴법의 알고리즘 경우, 지문영상의 특징추출을 위한 20회 시행 중 3회가 종료조건 2가지 중 어느 것도 만족하지 못하여 특징을 추출하는데 실패하였다. 하지만 학습반복수에 따른 종료조건을 무시하고 실험을 반복한 결과 최대 258회까지 소요되는 비현실적인 수렴시간을 보였다. 할선법의 알고리즘과 제안된 알고리즘에서는 20회 시행 모두에서 영상의 분리가 이루어졌다. 이 또한 뉴우턴법의 알고리즘에서 기울기인 도함수의 값이 0에 수렴될 경우 역혼합행렬의 경신과정에 0으로 나누어지는 결과가 발생되어 비현실적인 수렴현상으로 추정된다. 한편 표에서도 뉴우턴법의 알고리즘 결과는 추가시행을 실시하여 학습의 종료조건을 만족한 경우에 대한 결과이다. 표 2에서 지문영상의 경우, 학습반복수와 추출시간에서 보면, 뉴우턴법은 약 35.85와 약 178.89, 할선법은 약 28.73과 약 148.82, 그리고 제안된 알고리즘은 약 25.42와 약 137.67 정도이다. 먼저 학습반복수에서는 제안된 알고리즘이 뉴우턴법과 할선법에 비해 각각 약 1.41배와 약 1.13배 정도 개선되었으며, 특징추출 시간에서는 각각 약 1.3배와 약 1.08배 정도 개선되었다. 또한 할선법은 뉴우턴법에 비해 약 학습반복수와 추출시간에서 각각 약 1.25배와 약 1.2배 정도 개선되었다. 따라서 제안된 조합형 알고리즘은 뉴우턴법의 알고리즘이나 할선법의 알고리즘보다 개선된 특징추출속도가 있으며, 할선

표 2. 뉴우턴법, 할선법, 제안된 고정점 알고리즘 각각에 의한 특징추출결과

입력 영상	뉴우턴법의 FP 알고리즘		할선법의 FP 알고리즘		제안된 FP 알고리즘	
	학습 반복수, k	추출 시간, t	학습 반복수, k	추출 시간, t	학습 반복수, k	추출 시간, t
지문영상	35.85	178.89	28.73	148.82	25.42	137.67
전면 지폐영상	44.58	193.13	34.42	171.78	31.13	164.52
후면 지폐영상	42.37	183.56	36.83	183.81	32.49	171.71

법의 알고리즘도 뉴우턴법의 알고리즘보다 빠른 추출속도를 가짐을 알 수 있다. 결국 할선법과 모멘트의 조합형 알고리즘이 할선법의 알고리즘이나 뉴우턴법의 알고리즘보다 특징추출 시간에서 가장 우수한 성능이 있음을 확인할 수 있다. 또한 표 2에서도 알고리즘 각각의 1회 수행 CPU 시간을 보면, 뉴우턴법은 약 4.99, 할선법은 약 5.18, 그리고 제안된 알고리즘은 약 5.42 정도로 뉴우턴법이 가장 빠름을 알 수 있다. 이 또한 표 1에서와 유사한 결과를 보인다. 한편, 전·후 지폐영상 각각의 특징추출에서도 지문영상에서처럼 제안된 알고리즘이 가장 빠른 특징추출 속도를 가지며, 할선법의 알고리즘이 뉴우턴법의 알고리즘보다도 빠른 특징추출 속도가 있다.

이상의 영상분리와 특징추출에 대한 실험결과로부터 독립성분분석을 위한 할선법의 FP 알고리즘은 뉴우턴법의 FP 알고리즘보다 개선된 속도와 성능이 있으며, 임의로 설정되는 역혼합행렬의 초기값에도 상대적으로 적게 의존함을 확인하였다. 또한 할선법과 모멘트에 의한 조합형 FP 알고리즘은 할선법에 의한 FP 알고리즘보다도 개선된 속도와 성능이 있다. 따라서 신경망 기반 독립성분분석에서 할선법과 모멘트를 이용한 제안된 조합형 FP 알고리즘은 독립성분분석을 이용한 영상분리와 특징추출을 위한 효과적인 대안이 될 수 있다.

4. 결론

본 연구에서는 할선법과 모멘트에 기초한 조합형 고정점 알고리즘의 신경망 기반 독립성분분석기법을 제안하고, 이를 혼합영상의 분리와 영상의 특징추출에 적용하였다. 여기서 할선법은 negentropy 최대화 과정서 함수 값만을 이용함으로써 계산을 간략하게 하여 역혼합행렬의 경신속도를 빠르게 하기 위함이고, 모멘트는 학습과정에서 발생하는 발진을 억제하여 보다 빠른 학습속도를 얻기 위함이다.

제안된 기법을 512×512 의 픽셀의 10개 영상을 대상으로 임의의 혼합행렬에 따라 발생하는 혼합영상의 분리와 256×256 픽셀의 10개 지문영상과 480×225 픽셀의 각각 전·후 지폐영상의 특징추출에 적용하였다. 영상분리에서는 제안된 알고리즘이 뉴우턴법에 기초한 기존의 알고리즘과 할선법만에 기초한 알고리즘보다 각각 우수한 분리성능과 빠른 분리속도가 있음을 확인할 수 있다. 또한 특징추출에서도 제안된 알고리즘은 뉴우턴과 할선법에 기초한 알고리즘보다 빠른 추출시간을 가짐을 확인하였다. 한편 독립성분분석은 영상 각각에 포함된 공간적인 주파수 특성과 방향성을 가지는 경계 특성이 잘 드러나는 국부적인 특징들을 추출할 수 있으며, 제안된 알고리즘은 학습에서 역혼합행렬의 초기값에도 덜 의존함을 확인하였다.

향후 좀 더 다양하고 규모가 큰 문제를 대상으로 하는 연구와 독립성분분석의 성능을 더욱 더 개선시키기 위한 연구가 남아 있다.

참고문헌

[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] J. Karhunen and J. Joutsensalo, "Generation of Principal Component Analysis, Optimization Problems, and Neural Networks," *Neural Networks*, vol. 8, No. 4, pp. 549-562, 1995

[4] P. Comon, "Independent Component Analysis A New Concept?", *Signal Processing*, vol. 36, No. 3, pp. 287-314, Apr. 1994

[5] T. W. Lee, *Independent Component Analysis : Theory and Applications*, Kluwer Academic Pub., Boston, 1998

[6] 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

[7] S. Roberts and R. Everson, *Independent Component Analysis : Principles and Practice*, Cambridge Univ. Press, 2001

[8] A. Hyvarinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, John Wiley & Sons, Inc., 2001

[9] A. J. Bell and T. J. Sejnowski, "Edges are 'Independent Components' of Natural Scenes", *Advances in Neural Information Processing Systems 9*, MIT Press, 1996

[10] K. Atkinson, *Elementary Numerical Analysis*, John Wiley & Sons, Inc., New York, 1993

저 자 소 개



조용현(趙鏞鉉)

1979년 2월 : 경북대학교 공과대학
전자공학과(공학사)

1981년 2월 : 경북대학교 대학원
전자공학과(공학석사)

1993년 2월 : 경북대학교 대학원
전자공학과(공학박사)

1983년 9월~1984년 2월 : 삼성전자(주)
사원

1984년 3월~1987년 2월 : 한국전자통신연구소 연구원

1987년 3월~1997년 2월 : 영남이공대학 전자과 교수

1997년 3월~현재 : 대구가톨릭대학교 컴퓨터정보통신공학부
교수

관심분야 : 신경망, 병렬분산처리, 신호처리, 영상인식, 교환
기 등

e-mail : yhcho@cataegu.ac.kr