

조합형 Fixed Point 알고리즘의 독립성분분석을 이용한 영상의 특징추출

Image Feature Extraction Using Independent Component Analysis of Hybrid Fixed Point Algorithm

조용현*, 강현구**

Yong-Hyun Cho*, Hyun-Koo Kang**

<Abstract>

This paper proposes an efficient feature extraction of the images by using independent component analysis(ICA) based on neural networks of the hybrid learning algorithm. The proposed learning algorithm is the fixed point(FP) algorithm based on Newton method and moment. The Newton method, which uses to the tangent line for estimating the root of function, is applied for fast updating the inverse mixing matrix. The moment is also applied for getting the better speed-up by restraining an oscillation due to compute the tangent line. The proposed algorithm has been applied to the 10,000 image patches of 12x12-pixel that are extracted from 13 natural images. The 144 features of 12x12-pixel and the 160 features of 16x16-pixel have been extracted from all patches, respectively. The simulation results show that the extracted features have a localized characteristics being included in the images in space, as well as in frequency and orientation. And the proposed algorithm has better performances of the learning speed than those using the conventional FP algorithm based on Newton method.

Key Words : independent component analysis, fixed point algorithm, moment, Garbor function, wavelet function, feature extraction

1. 서론

일반적으로 통계학, 신호처리, 그리고 신경망 등에서의 주된 연구는 적당한 변환에 의해서 알맞은 데이터의 표현을 찾는 것이다^[1,2]. 그것

은 데이터의 해석을 용이하게 하는 것으로 데이터의 후속적인 해석을 위해서 이다. 이때 선형변환을 이용하면 문제를 계산적으로나 개념적으로 좀 더 간단하게 만들 수 있으며, 결과의 해석도 용이하게 할 수 있다. 여러 가지 방법과

*정회원, 대구가톨릭대학교 컴퓨터정보통신, 교수, 工博
712-702 경북 경산시 하양읍 금락리 330

**정회원, 영남이공대학 전자정보계열 교수, 工博
705-037 대구광역시 남구 대명 7동 1737번지

* Professor, School of Computer & Information Comm, CUD.

e-mail : yhcho@cuth.cataegu.ac.kr

** Professor, Dept. of Electronics, YCST.

e-mail : hkkang@ync.ac.kr

원리들이 적당한 선형변환을 찾기 위해서 개발되었으나, 그 중에서도 주요성분분석(principal component analysis : PCA)¹⁻³⁾이 가장 널리 이용되고 있다.

이는 데이터의 차원을 감소시키는 선형변환 기법으로 공분산(covariance)을 이용하는 2차원 방법으로 가우스(Gaussian) 분포의 입력 데이터에 대해서는 적당한 것이다. 하지만 일반적으로 통신이나 신호 및 영상 처리 등에서의 입력 데이터는 비가우스 분포로 이런 경우에도 효과적으로 적용될 수 있는 선형변환 방법의 연구가 요구된다.

최근 PCA의 제약을 해결하기 위한 독립성분분석(independent component analysis : ICA)이 제안되었으며, 이는 데이터의 통계적 성질을 고려한 선형변환 기법으로 데이터의 분포정보를 이용하는 다차원 방법이다⁴⁻⁶⁾. 하지만 알려진 ICA 알고리즘들에서는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 구한다든지 고차원의 cumulant나 moment를 구하는 등 복잡한 계산이 요구된다.

따라서 복잡한 계산에 따른 많은 계산시간이 요구되는 수치적 기법에 의한 ICA의 대안으로 간단한 신경망을 이용하여 해결하려는 연구가 활발하게 진행되고 있다. 발표된 신경망을 이용한 ICA 방법으로는 fixed point(FP) 알고리즘, recursive least square 알고리즘, 확률적 기울기를 이용하는 Bell & Sejnowski(BS)알고리즘, 자연기울기(natural gradient)를 이용한 natural gradient 알고리즘 등이 제안되었다^{5,6)}. 하지만 이들 방법들에서도 신경망을 이용하나 학습파라미터의 설정에 따른 제약들은 그대로 내포하고 있어 그에 따른 연구가 절실하다.

본 연구에서는 빠른 실행시간을 가지는 새로운 학습 알고리즘의 독립성분분석 기법을 제안하고 이를 이용한 특징추출에 대하여 제안한다. 제안된 기법은 엔트로피 최적화로부터 유도된 기법으로 그 계산을 간략화 하기 위해 Newton 기법을 이용하며, 기울기의 변화에 따른 경신알고리즘에서 발전을 줄여 더욱 빠른 학습시간을 가지도록 모멘트를 이용한 FP 알고리즘이다. 제안된 기법을 13개의 자연영상들로부터 추출된 영상패치들(image patches)를 대상으로 시

물레이션하여 영상들에 포함된 특징들을 추출하였다.

2. 조합형 알고리즘의 독립성분분석기법

ICA는 m 개의 입력신호 s 로부터 선형적으로 혼합된 n 개의 신호 x 가 알려져 있을 때, 혼합된 신호로부터 역으로 m 개의 독립인 입력신호를 찾는 기법이다. 하지만 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 정의된다. 여기서 n 은 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. 결국 ICA는 알려진 혼합신호로부터 혼합행렬의 역행렬 A^{-1} 을 찾는 기법이다. 혼합행렬 A 와 역혼합행렬 W 에 대하여 상세히 살펴보면 다음 Fig. 1과 같은 구성도로 나타낼 수 있다. 여기서 $x = As$ 이고, $y = Wx$ 이다. 이때 ICA는 출력신호 y 의 각 요소들이 통계적으로 독립성을 유지해야 하며 직교성의 제약조건은 포함하지 않는다. Fig. 1에서 보면 ICA는 출력신호가 독립성을 가지는 조건하에서 혼합행렬과 일치하는 역혼합행렬을 찾는 기법이다. 따라서 ICA는 알려진 혼합신호 x 로부터 출력신호 y 를 찾는 기법으로 궁극적으로는 역혼합행렬 W 을 찾아서 원신호 s 의 근사값을 알아내는 것이다. 이때 미리 영평균(zero-mean)과 whitening된 혼합신호를 이용하면, 신호의 1차와 2차의 통계성에 따른 상관성이 이미 고려되기 때문에 좀 더 효과적으로 ICA를 수행할 수 있다.

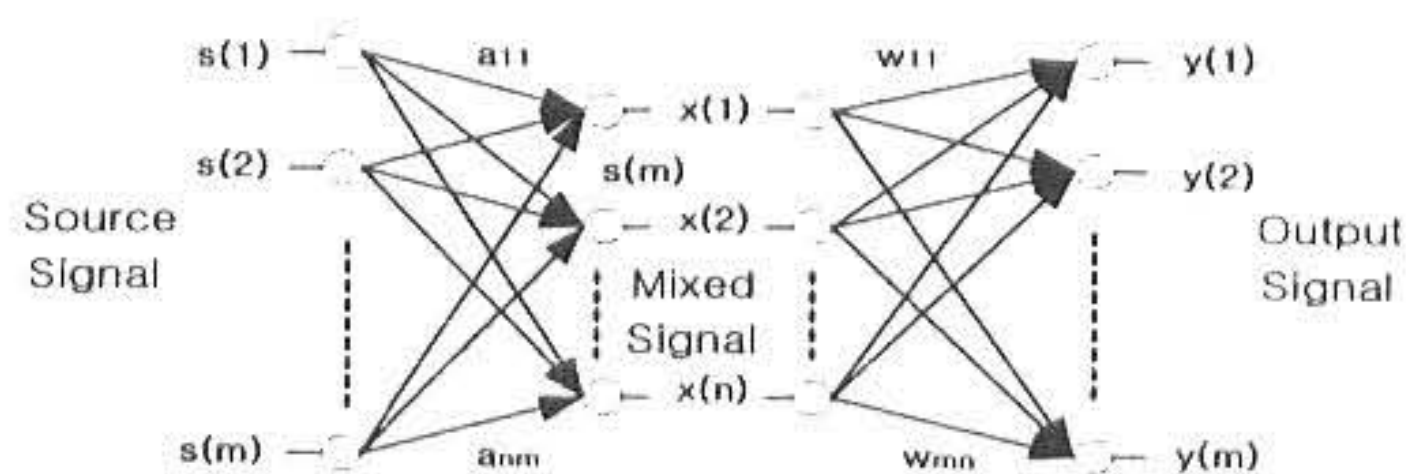


Fig. 1 독립성분분석의 상세 설명도

한편 ICA는 영상의 특징을 추출하는 것에도 이용된다⁷⁻⁹⁾. 이때 원신호 s 는 영상패치 x 를 형성하기 위한 혼합행렬 A 의 가중치를 나타낸다. 결국 s 의 선형합성에 의해 x 는 형성되므로 s 는 영상들의 근거들(causes)이다. Fig. 2는 선형 영상합성 모델을 나타낸 것이다. 여기서 s 의 열들(columns)은 근거들을 나타내며, A 의 행들(rows)은 기저벡터로 구성된 기저함수이고, 그리고 x 의 열들은 관찰된 영상패치들이다. 따라서 영상패치 x 로부터 ICA를 이용하여 W 를 구하면 $W = A^{-1}$ 의 관계에서 W 의 행은 A 의 열로 이들은 기저벡터인 영상의 특징이 된다.

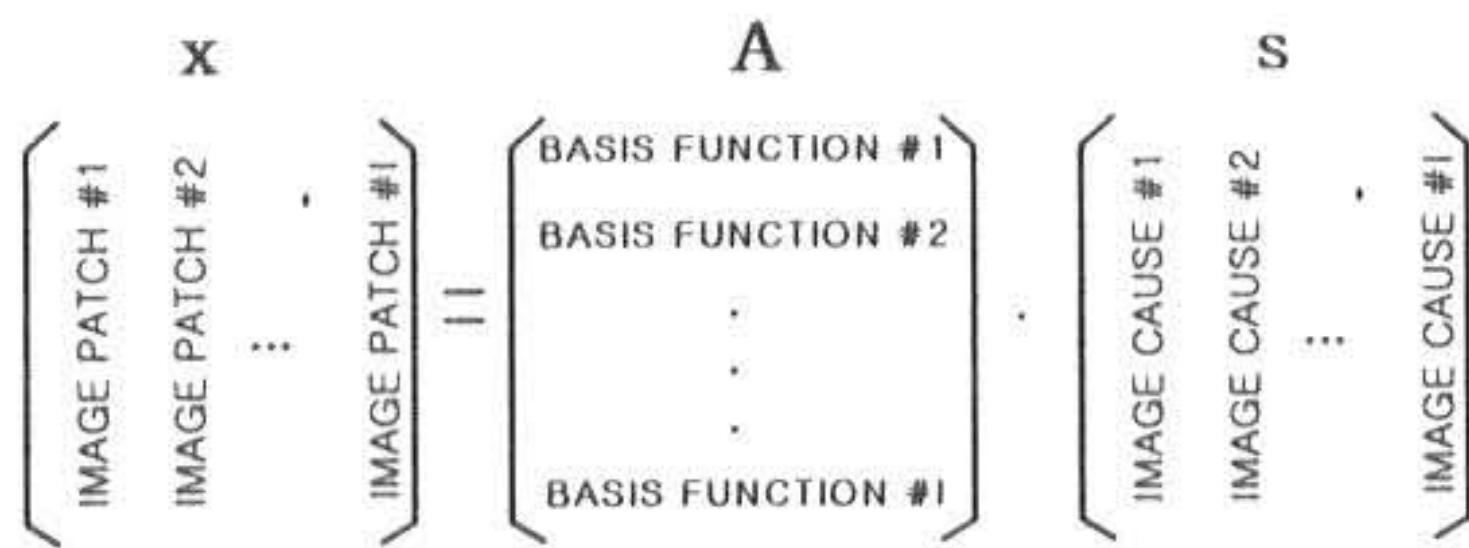


Fig. 2 선형 영상합성 모델

2.1 신호의 영평균과 Whitening

신호의 영평균은 데이터의 1차적 통계성을 고려한 정규화로 학습 알고리즘을 간략하게 하는 기법이다⁴⁻⁶⁾. 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 있다³⁾. whitening은 데이터 벡터 x 의 공분산행렬이 단위행렬값을 갖도록 하는 것이다. 즉, $E\{xx^T\} = I$ 가 되도록 한다. whitening된 벡터의 성분들은 상호간의 상관성이 줄어들어 비상관성이 더 강한 독립조건을 위해 요구되는 전처리 기법이다. 이러한 whitening의 기법으로 PCA가 널리 사용된다. 일반적인 PCA whitening 행렬 V 는

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

이다. 여기서 D 는 고유값 λ 로 구성되는 대각행렬이며, E 는 고유벡터 c 로 구성되는 직교행렬이다. PCA whitening이 가지는 장점은 이미 잘 알려진 표준 소프트웨어를 이용할 수 있는 것이며, 또 다른 장점으로 원 신호, 즉 독립성분의 개수를 추정하는 편리한 수단이 되는 것이다.

2.2 조합형 fixed point 알고리즘

독립성분분석을 위한 fixed point 알고리즘은 신경망이 가지는 병렬성과 분산성, 그리고 더 작은 메모리 요구 등의 제약을 해결하기 위해 제안된 알고리즘이다⁵⁾. FP 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 그 수렴속도가 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 비가우스성의 척도로 이용되는 negentropy로 정의된다. n 개의 랜덤변수 벡터 $y = (y_1, \dots, y_n)^T$ 를 위한 negentropy $J(y)$ 는

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

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

$$I(y_1, y_2, \dots, y_n) = J(y) - \sum_{i=1}^n J(y_i) \quad (5)$$

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

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

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 추정하는 목적함수로 이용될 수 있다. 따라서 ICA에서 독립변수들의 상호간 무관성을 고려한 하나의 독립성분 $y_i = \mathbf{W}^T \mathbf{x}$ 를 찾기 위한 목적함수 $J_G(\mathbf{W})$ 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 n 개의 독립성분 모두에 대해서 확장하면

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

로 된다. 여기서 \mathbf{w}_i 는 역혼합행렬 \mathbf{W} 의 행벡터 중 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 기울기 하강에 기초를 둔 기법들이다. 하지만 이들 알고리즘에서는 학습율의 설정에 따라 수렴이 느리거나 학습이 이루어지지 않는 제약들이 있다. 이러한 기울기하강에 기초한 알고리즘들의 제약들을 해결하기 위한 대안으로 FP 알고리즘이 제안되었다⁵⁾.

FP 알고리즘은 알고리즘의 한 단계에 많은 수의 데이터들이 이용되는 batch mode로 계산을 수행하며, 신경망으로 수행될 수 있는 알고리즘이다. 데이터 벡터 \mathbf{x} 가 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. $J_G(\mathbf{W})$ 의 최대화는 반드시 $E\{G(\mathbf{W}^T \mathbf{x})\}$ 의 최적에서 얻어진다. 이때 Kuhn-Tucker 조건으로부터, $E\{(\mathbf{W}^T \mathbf{x})^2\} = \|\mathbf{W}\|^2 = 1$ 조건하에서 $E\{G(\mathbf{W}^T \mathbf{x})\}$ 의 최적은 다음 식

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

로 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)를 풀기 위해 빠른 수렴속도를 가지는 Newton의 기법을 도입한다. 이를 위해 식의 좌변항을 $F(\mathbf{W})$ 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 Newton의 기법에 따른 해를 구하는데 이용되는 $JF(\mathbf{W})$ 의 역행렬을 간단하게 계산하기 위해 식 (10)의 우변 첫째 항은 다음과 같이 근사화될 수 있다. 즉,

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

이다. 식 (11)을 식 (10)에 대입하면 Jacobian matrix는 대각선 행렬이 되어 쉽게 역행렬을 계산할 수 있다. 따라서 β 를 \mathbf{W}_0 대신 \mathbf{W} 의 현재값으로 나타내면 근사화된 반복기법의 역혼합행렬 \mathbf{W} 를 구하는 Newton 기법은

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

와 같이 정의된다. 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 Newton 기법에 기초를 둔 ICA를 위한 FP 알고리즘이다. 또한 식 (12)의 첫째식 양쪽에 $\beta - E\{g'(\mathbf{W}^T \mathbf{x})\}$ 를 곱해 구해지는 더욱 간단한 Newton 기법의 FP 알고리즘은

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

으로 된다.

한편 식 (12)과 (13)의 우측 둘째 분모항들의 계산을 보면 Newton 기법에서 접선을 구하기 위한 기울기로 함수 $g(\mathbf{W}^T \mathbf{x})$ 의 1차 미분이 요구된다. 여기서는 함수의 미분에 따라 \mathbf{W} 가 최적해로 수렴할 때 발진이 일어날 수도 있다. 따라서 수렴에 따른 발진을 막아 줄 수만 있다면 좀 더 빠르게 최적해로 수렴시킬 수 있을 것이

다. 이를 위해 본 논문에서는 W 를 계산할 때 이전 변화의 속성을 반영하는 모멘트를 추가하였다. 이렇게 하면 Newton 기법이 가지는 빠른 수렴속성을 그대로 살리면서도 최적해로의 수렴에서 발생하는 발진을 억제시켜 더욱 빠른 속도의 독립성분분석이 가능하다. 제안된 모멘트를 이용한 역혼합행렬 W 의 최종계산식은 식 (13)을 변형한

$$\begin{aligned} W' &= E(xg(W^T x)) - E(g'(W^T x))W + a(W^* - W), \\ W^* &= W' / \|W'\| \end{aligned} \quad (14)$$

로 정의된다. 여기서 a 는 모멘트이다.

제안된 조합형 FP 알고리즘의 역혼합행렬 W 를 경신하는 과정을 요약하면 다음과 같다.

- 단계 1 : 초기 역혼합행렬 $W(0)$ 를 임의의 값 rand()로 설정한다.
- 단계 2 : $W = W(0) / \|W(0)\|$ 의 값을 계산한다.
- 단계 3 : $W_{old} = 0$ 로 설정한다.
- 단계 4 : $\|W - W_{old}\| > \epsilon$ 이고 $\|W + W_{old}\| > \epsilon$ 이면 다음 식에 따라 W 를 계산하고, 그렇지 않으면 과정을 종료한다.
 - (1) $W_{old} = W$ 를 계산한다.
 - (2) $W' = E[xg(W^T x)] - E[g'(W^T x)]W + a(W^* - W)$ 를 계산한다.
 - (3) $W^* = W' / \|W'\|$ 를 계산한다.

위의 과정에서 벡터 x 는 whitening된 신호벡터이며, ϵ 은 1보다 적은 임의의 값으로 실험에서는 0.0001로 하였다. 특히 경신의 식에서 $g(\cdot)$ 는 비선형 함수이며 일반적으로 $(\cdot)^3$ 과 $\tanh(\cdot)$ 의 함수가 이용된다^{5,6)}. 본 연구에서는 상대적으로 이들 함수에 대한 분리성능이 유사함을 확인하였고, 여기서는 $\tanh(\cdot)$ 함수를 적용한다.

3. 시뮬레이션 결과 및 분석

제안된 ICA 알고리즘의 타당성과 성능을 평가하기 위해 자연영상들의 특징추출을 위한 시뮬레이션을 하였다. 시뮬레이션에서는 13개의 독립된 자연영상으로부터 선택된 10,000개의 영

상패치들을 대상으로 제안된 알고리즘을 수행하였다. 시뮬레이션은 펜티엄IV-1.5G 컴퓨터 상에서 Matlab 5.1로 실행하였다.

Fig. 3은 13개의 자연영상들 중에서 일부인 6개의 영상만을 나타낸 것이다. 그림에서 보면 자연영상 각각에서의 공통된 특징들은 발견할 수 없다. 또한 Fig. 3 (a)는 가로가 세로보다, (b)는 세로가 가로보다 픽셀수가 많은 영상들이다. 시뮬레이션에서는 이들로부터 12x12 픽셀의 영상패치 10,000개를 추출하여 12x12 픽셀의



Fig. 3. 13개 자연영상들 중 6개의 영상에 144개 특징벡터와 16x16의 160개 특징벡터들을 각각 추출하였다. 144개와 160개의 특징벡터로 차원을 감소시킨 것은 영상에 포함된 잡음을 줄이기 위함이다^{8,9)}.

Fig. 4는 13개의 자연영상을 대상으로 제안된 fixed point 알고리즘의 독립성분분석을 이용하여 추출된 12x12 픽셀의 144개 특징들을 행렬로 나타낸 것이다. 각 특징벡터는 역혼합행렬 W 의 열이며, 좌측에서 우측으로, 그리고 위에서 아래로 순서화됨을 알 수 있다. 실험에서 모멘트 a 는 0.01로 하였으며, 역혼합행렬 W 의 초기값은 0과 1사이의 무작위 값으로 하였다. 여기서 모멘트 a 는 0.001에서 0.1사이의 변화범위에서는 모멘트를 이용하지 않는 기존의 fixed point 알고리즘보다 약 1.42배 정도 빠른 수렴속도를 보였다. 한편 그림 4를 살펴보면 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 함수⁷⁻⁹⁾와 아주 유

사한 결과를 나타낼 수 있다. 결국 제안된 ICA에 의한 특징추출은 Gabor 함수에 의한 특징추출과 아주 근사적인 기법임을 의미한다. 또한 ICA를 이용한 특징추출은 공간상에서의 국부성을 나타내지 못하는 푸리에(Fourier) 기저 함수나 주파수와 방향성에서 국부성을 나타내지 못하는 pixel-by-pixel 표현보다도 우수한 기법임을 알 수 있다. 특히 추출된 특징들에서는 막대로 표현된 영상의 가장자리가 잘 표현됨을 알 수 있다. 한편 여기에서는 기저벡터의 크기가 달라도 얼마간 동일한 특징을 나타낼 수 있다. 이는 wavelet 함수와의 관계를 보여주는 것으로, 주파수와 기저벡터에 의해 대치되는 면적은 서로 종속적임을 의미한다. 하지만 wavelet이 영상의 수직과 수평의 2가지 방향특징만을 나타내는데 비해 ICA는 대각선의 방향을 포함한 보다 많은 방향특징을 가지며, wavelet은 위상차이를 가지지 않지만 ICA에서는 대단히 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.




Fig. 4 13개 자연영상들로부터 추출된 12x12 픽셀의 144개 특징벡터

Fig. 5는 13개의 자연영상을 대상으로 제안된 fixed point 알고리즘의 독립성분분석을 이용하여 추출된 16x16 픽셀의 160개 특징들을 행렬로 나타낸 것이다. 그림 4와 비교하면 특징들의

차원을 증가시킨 것으로 이는 전처리 과정에서 수행되는 PCA에 의한 차원감소를 적게 한 경우이다. 여기에서도 모멘트 α 는 0.01로 하였다. 그림 5에서 보면 그림 4보다 좀 더 명확한 특징속성을 알 수 있다. 이는 전자에 비해 영상의 특징 수를 증가했기 때문이다. 여기에서도 전 실험에서 얻어진 유사한 특징벡터의 속성들을 확인할 수 있다. 여기에서도 모멘트를 이용한 fixed point 알고리즘은 기존의 모멘트를 이용하지 않는 fixed point 알고리즘에 비해 약 1.47배 정도 빠른 수렴속도를 보였다.




Fig. 5 13개 자연영상들로부터 추출된 16x16 픽셀의 160개 특징벡터

이상에서의 결과들로부터 제안된 신경망 기반 ICA에 의한 영상의 특징추출은 성능에서는 Gabor 함수와 유사하나 계산적으로는 효과적임을 알 수 있다. 특히 제안된 뉴턴법과 모멘트에 기초한 조합형 고정점 알고리즘의 ICA는 모멘트를 고려하지 않는 기존 알고리즘에 비해 특징추출속도에 있어 개선된 성능이 있음을 확인하였다.

4. 결론

본 연구에서는 Newton 기법과 모멘트를 조합한 fixed point 알고리즘의 신경망 기반 독립성분분석기법에 의한 영상의 특징추출을 제안하였다. 여기서 Newton 기법은 함수의 접선에 기초를 둔 해를 구하는 방법으로 역혼합행렬의 빠른 경신을 위함이고, 모멘트는 접선을 구하는 과정에서 함수의 기울기변화 계산으로 발생하는 발진을 줄여 좀 더 빠른 학습을 위함이다.

13개의 자연영상들로부터 10,000개의 영상패치를 추출하여 실험한 결과, 기존의 fixed point 알고리즘보다 빠른 추출시간이 있으며, 특징추출 성능에서는 Gabor 함수와 유사하고, wavelet 함수보다는 우수한 속성이 있음을 확인할 수 있었다. 또한 계산부하에서 제안된 기법은 Gabor 함수를 이용할 때보다 능률적임을 확인하였다.

향후 모멘트의 적용조정과 좀 더 다양하고 큰 규모의 문제에 적용하는 연구가 남아 있다.

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) 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

(2002년 10월 17일 접수, 2003년 1월 20일 채택)