

고정점 알고리즘의 ICA-basis에 의한 물체영상의 특징추출

Feature Extraction of Object Images by Using ICA-basis of Fixed-Point Algorithm

조용현, 홍성준*

대구가톨릭대학교 컴퓨터정보통신공학부

Yong-Hyun Cho and Seong-Jun Hong*

School of Computer and Information Communications, Eng., Catholic Univ. of Daegu

E-mail : yhcho@cu.ac.kr

요 약

본 논문에서는 고정점 알고리즘의 독립성분분석을 이용한 물체영상의 특징추출을 제안하였다. 여기서 고정점 알고리즘은 뉴우턴법에 기초한 것으로 빠른 특징추출성능을 얻기 위함이고, 독립성분분석의 이용은 통계적으로 독립인 기저영상을 효과적으로 추출하기 위함이다. 제안된 기법을 Image*after사에서 제공하는 352x264 픽셀의 10개 물체영상을 대상으로 실험한 결과, 빠르면서도 정확한 복원성능과 PCA보다도 개선된 특징 추출성능이 있음을 확인하였다.

1. 서론

최근 형상이나 표면의 검사와 로봇의 눈이나 제품의 선별 등 다양한 분야에 응용되는 물체인식에 대한 연구가 활발하게 진행되고 있다[1,2]. 인간이 물체를 인식하는 데는 먼저, 관심 있는 영역을 선택하고, 선택된 영역으로부터의 특징을 추출하며, 주의를 이동시키고, 마지막으로 추출된 특징들을 융합하는 과정으로 이루어진다. 이러한 과정 중에서도 특징추출은 물체의 인식성능에 가장 큰 영향을 미치는 과정이며, 물체의 속성을 가장 잘 나타내는 특징의 추출은 물체의 인식성능과 압축성능을 개선시킨다.

일반적으로 물체인식에는 크게 특징을 기반으로 한 방법과 영상을 기반으로 하는 방법이 있다[3,4]. 특징을 기반으로 하는 방법은 물체특징과 관련된 정보들을 이용하는 방법이며, 영상을 기반으로 한 방법은 물체 영상 전체를 대상으로 특징을 계산하는 방법이다. 특징 기반 방법에는 입력 물체영상의 주요 부분에 대한 여러 특징점을 추출하는 지역 특징 추출기법과 Garbor 필터를 이용한 기법 등이 있다. 영상 기반 방법은 입력 물체영상에서 직접 물체의 코딩을 얻어내는 외형을 기반으로 한다. 특히 이 방법에는 입력 영상내 상관관계를 제거하여 영상의 진폭 스펙트럼을 획득하는 주요성분분석(principal component analysis : PCA)과 이를 일반화하여 영상의 위상 스펙트럼까지도 고려하는 독립성분분석(independent component analysis : ICA), 신경망, support vector

machine(SVM) 등이 있다[3-6].

PCA와 ICA는 중복신호 제거(redundancy reduction)의 효과가 있어 뇌의 시각 기능을 잘 반영하며 타 방법에 비해 높은 인식률을 얻을 수 있는 장점을 갖고 있다. 특히 PCA는 조밀한 코딩(compact coding)을 유도하여 중복 신호를 제거하며, ICA는 PCA와 달리 드문 코딩(sparse coding)에 의하여 중복 신호를 제거한다. 즉, PCA가 신호의 차원 자체를 줄여 조밀한 코딩을 유도하는데 비해 ICA는 출력 신호의 값을 드물게 나타내는 방법으로 중복 신호를 제거하며 이는 뇌의 기능 모델에 좀 더 가깝다[2]. 따라서 물체 인식을 위한 특징추출에 ICA를 이용하면 PCA와 달리 국부적인 특징(local feature)을 추출할 수 있어 PCA보다 높은 인식률을 얻을 수 있다[6]. 하지만 ICA에서는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 구한다든지 고차원의 cumulant나 moment를 구하는 등 복잡한 계산이 요구되어 PCA보다 계산이 복잡하여 추출시간이 오래 걸리는 제약이 있다.

따라서 복잡한 계산에 따른 많은 계산시간이 요구되는 수치적 기법에 의한 ICA의 대안으로 간단한 신경망을 이용한 방법으로는 고정점 (fixed point : FP) 알고리즘과 기울기를 이용하는 알고리즘들이 제안되었다[5,6].

본 연구에서는 뉴우턴(Newton)법[4]에 기반한 고정점 알고리즘의 독립성분분석을 이용한 물체의 특징추출을 제안한다. 여기서 뉴우턴법의 FP 알고리즘은 엔트로피 최적화로부터 유도된 빠른 특징추출의 속성을 가지며, 독립성분분석은 복원성능을 개선시키기 위함이다. 제

안된 기법을 Image*after사에서 제공하는 352x264 픽셀의 10개 물체영상[7]을 대상으로 실험하고 whitening과정에서의 주요성분 개수에 따른 복원성능을 분석한다.

2. 뉴우턴법에 기반한 고정점 알고리즘의 ICA

ICA는 은닉신호의 분리(blind source separation : BSS)나 특징추출에 널리 이용되고 있다[5,6].

먼저 BSS의 ICA는 m개의 은닉된 입력신호 s로부터 선형적으로 혼합된 n개의 신호 x가 알려져 있을 때, 혼합된 신호로부터 역으로 m개의 독립인 입력신호를 찾는 기법이다. 하지만 입력신호들을 혼합하는데 이용된 혼합행렬 A는 알려져 있지 않으며, 혼합과정에서 잡음 η가 추가 될 수 있다. 이때 혼합신호와 입력신호와의 관계는 다음과 같다.

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

여기서 η는 보통 입력신호와 구별되지 않기 때문에 생략할 수도 있으며, A=[a(1), a(2), ..., a(m)]으로 a(i)는 ICA의 기저벡터이다. 혼합행렬 A와 역혼합행렬 W에 대하여 살펴보면 다음 그림 1과 같은 구성도로 나타낼 수 있다. 결과적으로 ICA는 입력신호와 출력신호가 일치하도록 하는 즉, y = Wx = WAs에서 W=A⁻¹의 관계를 만족토록 하는 것이다.




그림 1. ICA를 위한 구성도

한편 ICA는 영상의 특징을 추출하는 것에도 이용된다. 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 열들은 근거들을 나타내며, A의 행들은 기저벡터로 구성된 기저함수이고, 그리고 x의 열들은 관찰된 영상패치들이다. 따라서 영상패치 x로부터 ICA를 이용하여 W를 구하면 W = A⁻¹의 관계에서 W의 행은 A의 열로 이들은 기저벡터인 영상의 특징이다.




그림 2. 선형 영상합성 모델

일반적으로 ICA를 좀 더 효과적으로 수행하기 위해 혼합신호의 전처리 과정을 수행한다. 이 과정은 일반적으로 영평균과 whitening 과정이며, 이는 신호의 1차와

2차의 통계성을 고려한 정규화로 학습 알고리즘을 간략화 하기 위함이다[5]. 영평균은 신호벡터 x에서 평균값 x*를 뺀 차를 구함으로써 간단하게 구할 수 있다. 즉, 영평균된 새로운 신호벡터 x는 다음과 같다.

$$x = x - x^* \quad (2)$$

한편, whitening은 데이터 벡터 x의 공분산행렬이 단위행렬값을 갖도록 함으로써 구할 수 있다. 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 V는 다음과 같다.

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

여기서 D는 고유값 λ로 구성되는 대각행렬이며, E는 고유벡터 c로 구성되는 직교행렬이다. 특히 여기에서는 ICA의 계산을 간략화하기 위해 신호의 차원인 주요성분의 개수를 조정한다.

독립성분분석을 위한 FP 알고리즘은 신경망이 가지는 병렬성과 분산성, 그리고 더 작은 메모리 요구 등의 제약을 해결하기 위해 제안된 알고리즘이다[6]. FP 알고리즘은 엔트로피 최적화 방법으로부터 유도된 기법으로 지금까지 알려진 기법 중 가장 빠른 학습속도를 가진다. 이는 신호 내에 포함된 상호정보를 최소화 함으로써 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. n개의 랜덤변수 벡터 y = (y₁, ..., y_n)^T를 위한 negentropy J(y)는 다음과 같다.

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

여기서 H(y)는 랜덤변수 y의 엔트로피(entropy)이며, y_{gauss}는 가우스 랜덤벡터이다. 이때 negentropy J(y)를 이용한 상호무관한 n개 랜덤변수 y_i(i=1, ..., n) 사이의 상호정보 I(y₁, y₂, ..., y_n)는 다음과 같다.

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

결국 ICA에서 독립성을 최대화하기 위해 식 (5)로 정의되는 상호정보 I(y₁, y₂, ..., 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 다음과 같다.

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

여기서 G와 c는 각각 비2차 함수와 상수이고, v는 평균이 0이고 분산이 1인 표준화된 가우스 변수이며, 랜덤변수 y_i도 평균이 0이고 분산이 1인 변수로 가정한다

다. negentropy의 근사화를 위한 식 (6)은 ICA 변환을 추정하는 목적함수로 이용될 수 있다. 따라서 ICA에서 독립변수들의 상호간 무관성을 고려한 하나의 독립 성분 $y_i = \mathbf{W}^T \mathbf{x}$ 를 찾기 위한 목적함수 $J_G(\mathbf{W})$ 는 식 (6)에 따라 다음과 같다.

$$J_G(\mathbf{W}) = [E(G(\mathbf{W}^T \mathbf{x})) - E(G(v))]^2 \quad (7)$$

결국 식 (7)로 정의된 ICA를 위한 목적함수를 최대화하기 위한 방법이 요구된다. 이러한 방법으로 FP 알고리즘이 제안되었다[6].

FP 알고리즘은 알고리즘의 한 단계에 많은 수의 데이터들이 이용되는 batch mode로 계산을 수행하며, 신경망으로 수행될 수 있는 알고리즘이다. 데이터 벡터 \mathbf{x} 의 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 다음의 값으로 얻어진다.

$$E(\mathbf{x}g(\mathbf{W}^T \mathbf{x})) - \beta \mathbf{W} = 0 \quad (8)$$

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 (8)을 풀기 위해 빠른 수렴속도를 가지는 뉴우턴법을 도입한다. 이를 위해 식의 좌변항을 $F(\mathbf{W})$ 로 나타내고, 그것의 Jacobian matrix $JF(\mathbf{W})$ 를 구하면 다음과 같다.

$$JF(\mathbf{W}) = E(\mathbf{x}\mathbf{x}^T g'(\mathbf{W}^T \mathbf{x})) - \beta \mathbf{I} \quad (9)$$

한편 데이터 벡터 \mathbf{x} 가 이미 whitening되어 있어 뉴우턴법에 따른 해를 구하는데 이용되는 $JF(\mathbf{W})$ 의 역행렬을 간단하게 계산하기 위해 식 (9)의 우변 첫째 항을 다음과 같이 근사화할 수 있다.

$$E(\mathbf{x}\mathbf{x}^T g'(\mathbf{W}^T \mathbf{x})) = E(\mathbf{x}\mathbf{x}^T)E(g'(\mathbf{W}^T \mathbf{x})) = E(g'(\mathbf{W}^T \mathbf{x}))\mathbf{I} \quad (10)$$

식 (10)을 식 (9)에 대입하면 Jacobian matrix는 대각선 행렬이 되어 쉽게 역행렬을 계산할 수 있다. 따라서 β 를 \mathbf{W}_0 대신에 \mathbf{W} 의 현재값으로 나타내면 근사화된 반복기법의 역혼합행렬 \mathbf{W} 를 구하는 뉴우턴법은 다음과 같다.

$$\begin{aligned} \mathbf{W}^* &= \mathbf{W} - [E(\mathbf{x}g(\mathbf{W}^T \mathbf{x})) - \beta \mathbf{W}] / [E(g'(\mathbf{W}^T \mathbf{x})) - \beta], \\ \mathbf{W}^* &= \mathbf{W} / \|\mathbf{W}\| \end{aligned} \quad (11)$$

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 (11)은 뉴우턴법에 기초를 둔 ICA를 위한 FP 알고리즘이다. 또한 식 (11)의 첫째식 양쪽에 $\beta - E(g'(\mathbf{W}^T \mathbf{x}))$ 를 곱해 구해지는 더욱 간단한 뉴우턴법의 FP 알고리즘은 다음과 같다.

$$\mathbf{W} = E(\mathbf{x}g(\mathbf{W}^T \mathbf{x})) - E(g'(\mathbf{W}^T \mathbf{x}))\mathbf{W}, \mathbf{W}^* = \mathbf{W} / \|\mathbf{W}\| \quad (12)$$

위의 과정에서 벡터 \mathbf{x} 는 whitening된 신호벡터이며, ϵ

은 1보다 작은 임의의 값으로 실험에서는 0.0001로 하였다. 특히 경신의 식에서 $g(\cdot)$ 는 비선형 함수이며 일반적으로 $(\cdot)^3$ 과 $\tanh(\cdot)$ 의 함수값을 가진다. 본 연구에서는 $\tanh(\cdot)$ 함수를 적용하였다.

따라서 뉴우턴법의 FP 알고리즘 ICA에 의한 물체의 특징추출 과정을 요약하면 다음의 그림 3과 같다. 여기서 추출된 물체의 특징은 다음 단계의 인식에서 이용될 수 있다.




그림 3. 뉴우턴의 FP 알고리즘 ICA에 의한 특징추출과정

3. 시뮬레이션 결과 및 고찰

제안된 특징추출 기법의 타당성과 성능을 확인하기 위하여 Image*after사에서 제공되는 물체영상[7]을 대상으로 실험하였다. 특징추출에 대한 복원성능을 평가하기 위해 원 영상의 픽셀값 x_i 와 복원된 영상의 픽셀값 y_i 사이의 절대평균합오차 amse(absolute mean sum error) $= (1/N^2) \sum_{i=1}^{N^2} |x_i - y_i|$ 를 정의하였으며, 여기서 N^2 은 전체 픽셀수이다. 실험은 펜티엄 IV-2.2G 컴퓨터상에서 Matlab 5.1로 실행하였다.

그림 4는 특징추출에 이용된 물체영상들이다. 그림 4(a)는 실험에 이용된 352x264 픽셀의 10개 원 영상을 나타낸 것이며, 그림 4(b)는 이들의 평균영상이고, 그림 4(c)는 원 영상에서 평균영상을 뺀 영평균된 물체 영상들을 각각 나타낸 것이다.

그림 5는 기저벡터에 의한 7개의 기저영상에 의해 복원된 10개의 물체영상들을 나타낸 것이다. 이는 10개 물체영상 중에서 7개의 특징영상을 추출한 것으로

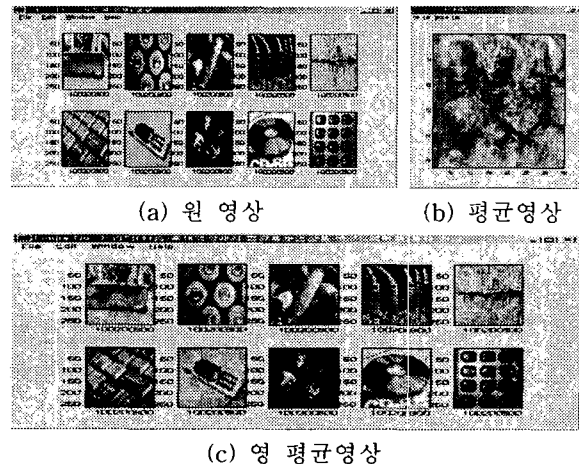




그림 4. 10개의 물체영상

로 차원감소에 따른 데이터의 압축효과를 보여 준 것이다. 하지만 육안으로 볼 때, 그림 5(a)로부터 복원된 그림 5(b)의 얼굴영상에는 많은 잡영이 존재함을 알 수 있다. 이는 기저벡터의 수를 줄인 것에 대한 결과이다.



(a) 7개의 기저영상



(b) 10개의 복원영상


그림 5. 기저영상과 복원된 물체영상

한편 표 1은 기저벡터의 개수에 따라 절대평균합오차를 나타낸 것으로 복원성능을 나타낸 것이다. 여기서는 기저벡터인 기저영상의 수가 증가함에 따라 절대평균합오차로 표시되는 복원성능은 개선되다 다시 저하됨을 알 수 있다. 이는 기저영상의 개수인 특징벡터 수의 지나친 증가는 오히려 과학습에 의해 복원성능이 저하됨을 알 수 있다. 따라서 본 연구에서는 기저영상의 수를 복원성능이 가장 우수한 9개일 때를 기준으로 실험하였다.


표 1. 기저영상 개수의 변화에 따른 절대평균합오차

기저영상 수	1	2	3	4	5	6	7	8	9	10
절대평균 합오차	.4. 7295 e-04	2. 5022 e-04	2. 3757 e-04	2. 5220 e-04	2. 4975 e-04	3. 5560 e-05	3. 8344 e-05	6. 8057 e-06	1. 3530 e-17	4. 7603 e-05

그림 6은 복원성능이 가장 우수한 기저벡터인 기저영상의 수가 9개일 경우 PCA와 ICA-basis 각각의 이용에 따른 고유복원 물체영상을 나타낸 것이다. 그림 6(a)와 (b)를 단순히 육안으로 비교하면 보면 거의 차이가 없으며, 2가지 방법 다 매우 우수한 복원성능이 있음을 알 수 있다. 하지만 이들의 복원성능을 나타내는 절대평균합오차는 각각 1.0300e-012와 1.3669e-017로 ICA-basis가 PCA보다 약 10⁵배 정도 개선된 복원성능이 있음을 알 수 있다.



(a) PCA



(b) ICA-basis

그림 6. 9개의 기저영상에 대한 복원 물체영상

이상의 실험결과에서 고정점 알고리즘의 ICA-basis를 이용하면 물체영상의 특징을 효과적으로 추출할 수 있다. 또한 단순한 PCA 보다도 개선된 복원성능을 가진 특징들의 추출이 가능함도 알 수 있다.

5. 결론 및 향후과제

본 논문에서는 고정점 알고리즘의 독립성분분석을 이용한 물체영상의 특징추출을 제안하였다. 여기서 고정점 알고리즘은 뉴턴법에 기초한 것으로 빠른 특징추출성능을 얻기 위함이고, 독립성분분석의 이용은 통계적으로 독립인 basis 영상을 효과적으로 추출하기 위함이다.

제안된 기법을 Image*after사에서 제공하는 352x264 픽셀의 10개 물체영상을 대상으로 실험한 결과, 빠르면서도 정확한 복원성능과 PCA보다도 개선된 특징 추출성능이 있음을 확인하였다.

향후 제안된 방법을 좀 더 큰 규모의 문제와 다양한 분야에의 응용에 대한 연구가 계속 진행되어야 할 것이다.

6. 참고문헌

- [1] J. T. Tou and R. C. Gonzalez, 'Pattern Recognition Principles,' Addison-Wesley Pub., London, 1974
- [2] B. A. Draper, K. Baek, M. S. Barlett, and J. R. Beveridge, " Recognizing Faces with PCA and ICA," Computer Vision and Imaging Understanding 91, pp.115-137, 2003
- [3] N. Kambhatla and T. K. Leen, 'Dimension Reduction by Local PCA,' Neural Computation 9, pp. 1493-1516, 1997
- [4] 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
- [5] P. Comon, "Independent Component Analysis A New Concept?," Signal Processing, vol.36, No.3, pp.287-314, Apr.1994
- [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] "Imageafter Object Databases," <http://www.imageafter.com/category.php?category=objiects>