

# ICA 기반 인수부호를 이용한 물체영상의 특징추출

조용현, 홍성준 ◦

대구가톨릭대학교 컴퓨터정보통신공학부

e-mail:yhcho,sjishong@cu.ac.kr

## Feature Extraction of Object Images by Using ICA-based Factorial Code

Yong-Hyun Cho, Seong-Jun Hong ◦

School of Computer and Information Communications. Eng.,

Catholic Univ. of Daegu

### 요 약

본 논문에서는 독립성분분석에 기반한 인수부호를 이용한 물체영상의 특징추출을 제안하였다. 효과적인 독립성분분석을 구현을 위해 입출력 사이의 상호정보를 최대화하는 자율학습의 알고리즘을 이용하였으며, 통계적으로 독립인 계수로 구성된 인수부호를 효과적으로 추출하기 위해 독립성분분석의 이용하였다. 제안된 기법을 Imageafter사에서 제공하는 352x264 픽셀의 18개 물체영상을 대상으로 실험한 결과, 빠르면서도 정확한 복원성능과 PCA보다도 개선된 특징 추출성능이 있음을 확인하였다.

### 1. 서론

인간이 물체를 인식하는 데는 먼저, 관심 있는 영역을 선택하고, 선택된 영역으로부터의 특징을 추출하며, 주의를 이동시키고, 마지막으로 추출된 특징들을 융합하는 과정으로 이루어진다[1]. 이러한 과정 중에서도 특징추출은 물체의 인식성능에 가장 큰 영향을 미치는 과정이며, 물체의 속성을 가장 잘 나타내는 특징의 추출은 인식성능과 압축성능에 많은 영향을 미친다.

일반적으로 물체인식에는 크게 특징을 기반으로 한 방법과 영상을 기반으로 하는 방법이 있다[2-4]. 특징을 기반으로 하는 방법은 물체특징과 관련된 정보들을 이용하는 방법이며, 영상을 기반으로 한 방법은 물체영상 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[4-6].

PCA와 ICA는 중복신호를 제거하는 효과가 있어 뇌의 시각 기능을 잘 반영하며 타 방법에 비해 높은 인식률을 얻을 수 있는 장점을 갖고 있다. 특히 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 물체인식을 위한 특징추출에 ICA를 이용하면 PCA와 달리 국부적인 특징(local feature)을 추출할 수 있어 PCA 보다 높은 인식률을 얻을 수 있다[6]. 하지만 ICA에서는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 구한다든지 고차원의 모멘트를 구하는 등 복잡한 계산이 요구되는 제약이 있다. 따라서 복잡한 계산에 따른 많은 계산시간이 요구되는 수치적 기법에 의한 ICA의 대안으로 입출력 사이의 상호정보를 극대화하는 알고리즘을 이용한 방법이 제안되었다[6].

본 연구에서는 상호정보의 최대화를 위한 자율학습의 독립성분분석에 의한 인수부호를 이용하여 물체의 특징추출을 제안한다. 여기서 자율학습의 알고리즘은 입출력 사이의 상호정보 최대화로부터 유도된 정확한 특징추출의 속성을 가지며, 인수부호의 이용은 복원

성능을 개선시키기 위함이다. 제안된 기법을 Imageafter사에서 제공하는 352x264 픽셀의 18개 물체영상[7]을 대상으로 실험하고 특징영상의 개수에 따른 복원성능을 분석한다.

**2. 자율학습 알고리즘의 ICA에 의한 인수부호 추출**

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

먼저 BSS를 위한 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 η이 추가 될 수 있다. 이때 혼합신호와 입력신호와의 관계는 다음과 같다.

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

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<sup>-1</sup>의 관계를 만족토록 하는 것이다.




그림 1. ICA를 위한 구성도

한편 ICA는 영상의 특징을 추출하는 것에도 이용된다. 이때 원 신호 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<sup>-1</sup>의 관계에서 W의 행은 A의 열로 이들은 기저벡터인 영상의 특징이다.




그림 2. 선형 영상합성 모델

일반적으로 ICA를 좀 더 효과적으로 수행하기 위하여 신호의 영평균과 whitening의 전처리 과정을 수행한다. 이는 신호의 1차와 2차의 통계성을 고려한 정규화로 학습 알고리즘을 간략화 하기 위함이다[5]. 영평균은 신호벡터 x에서 평균값 x\*를 뺀 차 x = x - x\*로 계산된다. 또한 whitening은 데이터 벡터 x의 공분산행렬이 단위행렬값 즉, E{xx<sup>T</sup>}=I가 되도록 한다. whitening된 성분들은 상호간의 상관성이 줄어들며, 이는 비상관성이 좀더 강한 독립조건을 위해 요구되는 전처리 기법으로 PCA가 널리 사용된다. 특히 PCA는 ICA의 계산을 간략화하기 위해 신호의 차원감소를 위해서도 이용된다.

한편 상호정보 최대화로부터 유도된 자율학습의 규칙을 따르는 ICA는 성분의 정확한 분석이 가능한 알고리즘이다[6]. 이는 입출력 사이의 상호관계를 비선형 뉴런을 통해 최적의 정보전달을 수행하는 원리로부터 유도되는 학습알고리즘이다.

입력신호 x와 출력신호 y의 관계는 s자형 비선형 특성의 전달함수를 가지는 경우를 고려하면 다음 식 (2)와 같다. 즉

$$\mathbf{u} = \mathbf{W}\mathbf{x} + \mathbf{W}_0, \quad \mathbf{y} = \mathbf{g}(\mathbf{u}) = \frac{1}{(1+e^{-u})} \quad (2)$$

여기서 u는 가중합 벡터이고, W와 W<sub>0</sub>는 각각 가중치와 초기가중치 행렬이다. 식 (2)에서 입력과 출력 사이의 정보전달을 최대화하기 위한 최적의 가중치는 입력의 확률밀도와 비선형 함수의 기울기가 가장 잘 정합될 때 얻어진다. 이때 x와 y사이의 상호정보 I(y,x)는

$$I(\mathbf{y},\mathbf{x}) = H(\mathbf{y}) - H(\mathbf{y}|\mathbf{x}) \quad (3)$$

로 주어지며, 여기서 H(y|x)는 조건엔트로피이다. 식 (3)에서 상호정보의 최대화는 조건 엔트로피가 고정될 때 출력 엔트로피를 최대화함으로써 구할 수 있다. 결국 W에 대한 I(y,x)의 최대화는 W에 대한 H(y)의 최대화로 가능하며, 이때 최적의 가중치는 W에 대한 H(y)의 기울기상승에 의해서 구할 수 있다. 즉 ∂I(y,x)/∂w = ∂H(y)/∂w이다. 따라서 가중치 행렬 W의 경신규칙은

$$\Delta \mathbf{W} = \frac{\partial}{\partial w} H(\mathbf{y}) \mathbf{W}^T \mathbf{W} = (\mathbf{I} + \mathbf{y}' \mathbf{u}'^T) \mathbf{W} \quad (4)$$

와 같다. 여기서 y = [g(u<sub>1</sub>) ... g(u<sub>m</sub>)]<sup>T</sup>이고, y' = [y'<sub>1</sub> ... y'<sub>m</sub>]<sup>T</sup>이며, T는 전치를 나타낸다. 또한 출력 요소의 미분은

$$y_i' = \frac{\partial}{\partial y_i} \frac{\partial y_i}{\partial u_i} = \frac{\partial}{\partial u_i} l_n \frac{\partial y_i}{\partial u_i} \quad (5)$$

로 표시된다. 식 (5)에서 식 (3)의 비선형 전달함수가 이용되면  $y_i' = (1 - 2y_i)$ 이다.

한편 영상 내에 존재하는 통계적으로 독립인 계수로 구성된 인수부호를 효과적으로 추출하기 위해서 이용되는 ICA의 구성은 그림 3과 같다. 여기에서 행은 다른 픽셀을 나타내고, 열은 다른 영상을 나타내는 데이터 행렬을 구성한다. 이런 구조에서 필터는 영상들이며, 행렬 A의 열은 새로운 기저영상의 집합을 형성하고, 각 영상을 재구성하기 위한 계수들은 ICA 출력의 열에 포함된다.




그림 3. 인수부호 추출을 위한 ICA 구조

그림 3의 구조를 바탕으로 한 영상의 분석모델을 나타내면 그림 4와 같다. 여기서 데이터집합 내에 각 영상은 행렬 A상에서 기초가 되는 기저영상들의 선형결합이며, 기저영상들은 각각 독립 영상들의 근거 집합과 관계가 있다. 또한 영상의 근거들은 학습된 필터들의 행렬에 의해 복구될 수 있다.




그림 4. 인수부호 추출에 의한 영상분석

따라서 입력력 사이의 상호정보를 최대화하는 자율 학습의 ICA 알고리즘에 기반을 둔 물체의 특징추출 과정은 다음의 그림 5와 같다. 여기서 추출된 특징은 물체영상의 인수부호이다.




그림 5. 자율학습의 ICA에 의한 특징추출과정

### 3. 시뮬레이션 결과 및 고찰

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

그림 6은 특징추출에 이용된 물체영상들이다. 그림 6(a)는 실험에 이용된 352x264 픽셀의 18개 원 영상을 나타낸 것이며, 그림 6(b)는 이들의 평균영상이고, 그림 6(c)는 원 영상에서 평균영상을 뺀 영평균된 물체영상들을 각각 나타낸 것이다.




(a) 원 영상 (b) 평균영상




(c) 영 평균된 영상

그림 6. 18개의 물체영상

그림 7은 기저벡터에 의한 10개의 인수부호에 의해 구성된 특징영상으로부터 복원된 18개의 물체영상을 나타낸 것이다. 이는 18개 물체영상 중에서 10개의 특징영상을 추출한 것으로 차원감소에 따른 데이터의 압축효과를 보여 준 것이다. 하지만 육안으로 볼 때, 그림 7(a)로부터 복원된 그림 7(b)의 물체영상에는 많은 잡영이 존재함을 알 수 있다. 이는 특징영상의 수를 줄인 것에 대한 결과이다.



(a) 10개의 특징영상



(b) 18개의 복원영상

그림 7. 특징영상과 복원된 물체영상

한편 표 1은 특징영상의 개수에 따른 절대평균합오차의 변화를 나타낸 것이다. 여기서는 특징영상의 수가 증가함에 따라 절대평균합오차로 표시되는 복원성능은 개선되다 다시 저하됨을 알 수 있다. 이는 특징벡터수의 지나친 증가는 오히려 과학습에 의해 복원성능이 저하됨을 알 수 있다. 따라서 본 연구에서는 기저영상의 수를 복원성능이 가장 우수한 17개 일 때를 기준으로 실험하였다.

표 1. 특징영상 개수의 변화에 따른 절대평균합오차

특징영상수	1	2	3	4	5	6	7	8	9	
절대평균 합오차	PCA	41.85	37.35	34.15	31.28	28.45	26.18	23.86	21.52	19.37
	ICA	4.35e-04	3.71e-04	3.71e-04	3.70e-04	2.65e-04	2.15e-04	2.14e-04	2.13e-04	2.06e-04
특징영상수	10	11	12	13	14	15	16	17	18	
절대평균 합오차	PCA	17.36	15.43	13.01	10.82	8.19	5.78	3.09	4.38e-012	7.45
	ICA	2.05e-04	1.50e-04	1.48e-04	1.47e-04	8.18e-05	6.29e-05	5.93e-05	3.98e-017	4.72e-05

그림 8은 복원성능이 가장 우수한 특징영상의 수가 17개일때 PCA와 ICA 각각의 이용에 따라 복원된 물체영상을 나타낸 것이다. 그림 8(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 절대



(a) PCA



(b) ICA

그림 8. 17개의 특징영상으로 복원된 물체영상

평균합오차는 각각 4.3787e-012와 3.9824e-017로 ICA가 PCA보다 약 10<sup>5</sup>배 정도 개선된 복원성능이 있음을 알 수 있다.

이상의 실험결과에서 자율학습의 ICA 알고리즘에 의한 인수부호의 추출을 이용하면 물체영상의 특징을 효과적으로 추출할 수 있다. 또한 단순한 PCA보다도 개선된 복원성능을 가진 특징들의 추출도 가능함을 알 수 있다.

#### 4. 결론

본 논문에서는 독립성분분석에 기반한 인수부호를 이용하여 물체영상의 특징을 추출하는 방법을 제안하였다. 여기서 효과적인 독립성분분석을 구현을 위해 입력력 사이의 상호정보를 최대화하는 자율학습의 알고리즘을 이용하였으며, 통계적으로 독립인 계수로 구성된 인수부호를 효과적으로 추출하기 위해 독립성분분석의 이용하였다.

제안된 기법을 Imageafter사에서 제공하는 352x264 픽셀의 18개 물체영상을 대상으로 실험한 결과, 빠르면서도 정확한 복원성능과 PCA보다도 개선된 특징추출성능이 있음을 확인하였다.

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

#### 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=objects>