

독립성분해석 기법과 인근평균 및 정규화를 이용한 영상분류 방법

홍 준식[†]·유정웅^{††}·김성수^{†††}

요약

본 논문에서는 독립 성분 해석(*Independent Component Analysis*, ICA) 기법과 인근 평균 및 정규화를 이용한 영상 분류 방법을 제안하였다. ICA에 잡음을 주어 영상을 분류하였을 때, 잡음에 대한 강인성을 증가시키기 위하여, 제안된 인근 평균 및 정규화를 전처리로 적용하였다. 제안된 방법은 전처리 없이 ICA나 주성분 해석(*Principal Component Analysis*, PCA)을 이용한 것에 비해 잡음에 대한 강인성을 증가시키는 것을 모의 실험을 통하여 확인하였다.

Image classification method using Independent Component Analysis, Neighborhood Averaging and Normalization

Jun Sik Hong[†]·Jeong Woong Ryu^{††}·Sung Soo Kim^{†††}

ABSTRACT

In this paper, we have proposed an image classification method using *independent component analysis* (ICA), *neighborhood averaging* and *normalization*. When we have tried to classify images, the proposed *neighborhood averaging* and *normalization* have been used to increase the degree of tolerance. A set of experiments show that the proposed method has increased the degree of noise tolerance compared with *principal component analysis* (PCA) or ICA without *preprocessing*.

키워드 : 주성분해석(PCA : Principle Component Analysis), 독립성분해석(ICA : Independent Component Analysis), 전처리 : 인근 평균 및 정규화(Preprocessing : neighborhood averaging and normalization), 잡음허용(Noise tolerance), 상관 행렬(Correlation matrix), 최소 제곱 오차(LSE : Least square error)

1. 서론

ICA[1, 2]는 PCA[3]의 확장이다. 독립이 가능하게 *non-gaussian* 랜덤벡터('독립성분')의 선형 결합된 다중차원 랜덤 벡터로 표현되는 통계적 기법이다. ICA는 인수해석 또는 주성분해석(*principal component analysis*, PCA)의 *nongaussian*으로 변환된다. ICA는 데이터 해석, 전원분리 그리고 특징을 추출하는데 주로 응용된다. ICA에서는 2차 명령 모멘트(통계적으로 독립이 가능하게 기초벡터를 결정하기 위해 사용된다.)보다 고차 명령 통계이다[4]. $x_i, i=1, \dots, m$ 은 측정된 신호이고, $s_j, j=1, \dots, n$ 은 제로-평균을 가지는 독립성분이다. ICA의 기초 문제는 식 (1)에서 혼합 행렬 A 를 추정하며, 그리고 독립 성분을 실현하는 것이다.

$$X = AS \quad (1)$$

문제를 위한 하나의 제한이 자연스럽게 $n \leq m$ 이다. $X = (x_1, x_2, \dots, x_m)^T$ 로 표시되는 관측된 m 차원의 랜덤벡터는 입력데이터 또는 영상에서의 화소 명암도 이지만 독립된 것은 아니다[5]. 여기서, $S = (s_1, s_2, \dots, s_n)^T$ 는 선형적으로 변형된 성분 변수의 벡터이다. 이는 $M_{m \times n}$ 에 의해 변환행렬을 다시 나타낼 수 있는데, 선형 변환은 다음과 같이 주어진다.

$$S = MX \quad (2)$$

식 (1)의 관계식을 역으로 하면 식 (2)가 얻어진다. 이때, M 은 A 의 역이다. 이것은 성분들이 *Non-Gaussian*처럼 가능하게 상관없는 방향(*Uncorrelated directions*)에 의해 찾아서 ICA 데이터 모델에 의해 줄일 수 있다는 평가를 증명하였다 [2]. 식 (2)을 $w_i, i=1, \dots, n$ 에 의한 뉴런의 가중치 벡터로, 열이 가중치 벡터인 가중치 행렬 $W = (w_1, w_2, \dots, w_n)$ 에 의해 다시 나타내면 선형관계는 다음과 같이 주어진다[6].

$$S = W^T X \quad (3)$$

† 정회원 : (주)동원 감사

†† 정회원 : 충북대학교 전기공학과 교수

††† 정회원 : 충북대학교 전기공학과 조교수

논문접수 : 2001년 2월 6일, 심사완료 : 2001년 7월 16일

몇몇의 방법은 대조 함수, 특히 미지의 값을 구하기 위해 kurtosis[6-8] $kurt(\nu)$ 를 사용한다. 랜덤 변수 ν 에 의해 kurtosis는 $E\{\cdot\}$ 와 같이 식 (4)로 나타낼 수 있다.

$$kurt(\nu) = (E\{\nu^4\} - 3\{E\{\nu^2\}\})^2 \quad (4)$$

$\nu = D^{-1/2} E^T x$ 에 의해 원래의 데이터를 Whitenning 하고, 여기서 E 는 x 의 고유 벡터의 행렬이고, D 는 $W = [w_1, \dots, w_n]$ 벡터를 구하기 위해 반복적인 처리를 위하여 시작점 ν 와 고유값의 대각 행렬의 곱이다. 여기서 w 는 식 (5)로 나타낼 수 있다.

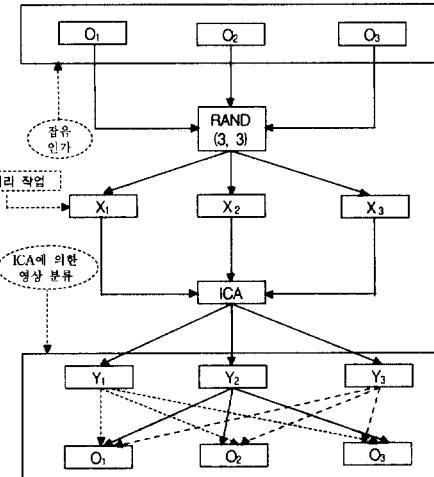
$$w(k+1) = E\{vg(w(k)^T \nu - g'(w(k)^T \nu) W(K)\} \quad (5)$$

여기서, g 는 비선형 함수 $g(u) = \tanh(u)$ 와 같다. W 를 찾은 후에, 독립성분은 선형조합 $s = W^T \nu$ 에 의해 찾을 수 있고, $A = E D^{1/2} W$ 에 의해 혼합 행렬을 찾을 수 있다. ICA는 PCA에 비슷하게 사용된다. 초기 벡터 s 와 상응되는 혼합 행렬 A 를 찾을 수 있다. 초기 벡터의 수는 최초의 스펙트럼의 크기보다 적다. ICA내에서 기초 벡터의 수는 PCA내에서 동일하게 사용된다. 본 연구에서 ICA를 이용하여 영상을 분류할 때, 잡음에 대한 강인성을 증가시키기 위하여 제안된 인근 평균 및 정규화 두 가지 전처리 방법을 적용하여 전처리 없는 PCA와 ICA를 비교하였다. 잡음에 대한 강인성을 살펴보기 위하여 최소제곱오차(Least square error, LSE)를 사용하여 강인성을 측정하였다. 본 논문의 구성은 2장에 잡음에 대한 강인성 고찰을 서술하였고, 3장에서는 인근 평균 및 정규화 전처리 방법을 기술하였다. 그리고 4장에 2차원 영상에 대한 실험 및 결과를 고찰하고, 마지막으로 결론은 5장에서 다루었다.

2. 잡음에 대한 강인성 고찰

원영상에 ICA를 이용하여 영상을 분류할 때 잡음을 주면 어느 정도까지 잡음에 대한 강인성을 가질 수 있는가에 대해 고찰한다. (그림 1)은 잡음에 대한 강인성 고찰을 위한 블록선도를 보여준다. 여기서, O_1, O_2, O_3 는 원영상이고, X_1, X_2, X_3 는 원영상에 임의의 행렬을 곱해서 나타난 혼합 영상이며, Y_1, Y_2, Y_3 는 ICA에 의해 혼합영상을 분류한 영상이다. (그림 1)의 동작은 다음과 같다. 먼저 원영상 O_1, O_2, O_3 에 잡음을 인가하여 임의의 랜덤행렬(3,3)을 곱해서 혼합 영상 X_1, X_2, X_3 을 얻고, 알고리즘[9]을 사용하여 ICA에 의해 혼합영상을 분류한 영상 Y_1, Y_2, Y_3 를 얻는다. 다음에, ICA에 의해 분류한 영상 Y_1, Y_2, Y_3 과 원영상 O_1, O_2, O_3 간의 LSE를 측정하여 잡음에 대한 강인성을 알아본다. 여기서, 우리는 원영상 O_1, O_2, O_3 에 잡음을 점진적으로 증가시켜 전처리 없는 PCA 및 ICA를 통한 영상 분류의 잡음에 대한

강인성 및 ICA기법에 의해 분류되기 전에 즉, 혼합 영상에 인근 평균 및 정규화 전처리 방법을 적용하였을 때 ICA기법을 통하여 분류한 잡음에 대한 강인성을 고찰한다.

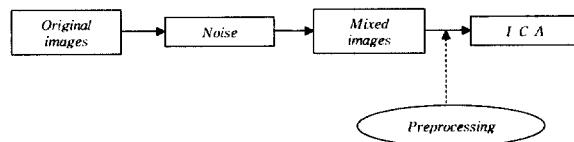


(그림 1) 잡음에 대한 강인성 고찰을 위한 블록 선도

3. 인근 평균 및 정규화 전처리 방법

본 장에서는 ICA의 잡음에 대한 강인성을 증가시키기 위하여 영상 평활화(Image Smoothing)기법 중 공간 영역적 방법인 인근평균 및 정규화 2가지 전처리 방법을 적용하였다. 여기서, 전처리 과정은 ICA에 의해 영상 분류가 되기 전에 즉, 혼합영상(X_1, X_2, X_3)을 입력 벡터로 하여 인근 평균 및 정규화를 이용하여 전처리를 수행한다. 다음에, ICA를 통하여 분류한 잡음에 대한 강인성을 고찰한다((그림 1) 참조).

(그림 2)는 전처리 작업 단계를 보여준다.



(그림 2) 전처리 작업 단계

3.1 인근평균 전처리

원영상 $f(x, y)$ 에 잡음 $n(x, y)$ 을 더함으로써 만든 잡음 영상 $g(x, y)$ 를 고려하면 식 (6)과 같이 나타낼 수 있다.

$$g(x, y) = f(x, y) + n(x, y) \quad (6)$$

여기서, 좌표 (x, y) 의 모든 쌍들에서 잡음은 서로 상관관계가 없고 또 평균값은 0으로 가정하고, 잡음 영상들 $\{g_i(x, y)\}$ 의 합을 더함으로써 잡음 효과들을 감소시킨다. 만약 잡음이 이러한 조건들을 만족시킨다면, 영상 M 개의 상이한 잡음 영상의 평균을 취함으로써 $\bar{g}(x, y)$ 를 구할 수 있다. 따라서, ICA에 의해 영상 분류가 되기 전에 모든

입력 벡터의 화소(x, y)를 중심으로 한 이웃의 국소적 부분 $n \times m$ 화소들을 평균한 값으로 다음과 같이 주어진다.

$$\bar{g}(x, y) = \frac{1}{M} \sum_{(n, m) \in S} f(n, m) \quad (7)$$

여기서, M 은 국소 부분 $n \times m$ 화소의 갯수이며, S 는 이 국소 부분에 속한 화소의 집합을 나타낸다. 이때, $E\{\bar{g}(x, y)\} = f(x, y)$ 이고, $\sigma^2_{\bar{g}(x, y)} = \frac{1}{M} \sigma^2_{n(x, y)}$ 이다. 여기서, $E\{\bar{g}(x, y)\}$ 는 \bar{g} 의 예측값이고, $\sigma^2_{\bar{g}(x, y)}$ 와 $\sigma^2_{n(x, y)}$ 는 좌표 (x, y) 에서의 \bar{g} 과 n 의 분산이다. 평균 영상 내 임의의 점에서의 표준 편차는 식 (8)로 주어진다.

$$\sigma_{\bar{g}(x, y)} = \sqrt{\frac{1}{M}} \sigma_{n(x, y)} \quad (8)$$

식 (7)과 식 (8)은 M 이 증가함에 따라 각 위치 (x, y) 에서 화소값들이 변화성이 감소한다는 것을 보여준다. $E\{\bar{g}(x, y)\} = f(x, y)$ 이기 때문에 이 조건은 평균 처리 과정에서 사용된 잡음 영상들의 수가 증가할수록 $\bar{g}(x, y)$ 가 $f(x, y)$ 에 가까워지는 것을 의미한다.

3.2 정규화 전처리

정규화 전처리 방법은 혼합영상을 입력 벡터로 하여 모든 입력 벡터를 정규화 하여 입력 벡터의 각 성분들을 벡터의 길이로 나누어준다. 이 길이는 모든 벡터 성분의 제곱의 합의 제곱근을 구해주면 구할 수 있는데, 식 (9)와 같이 주어진다.

$$x_i = x_i / (\|x_1\|^2 + \|x_2\|^2 + \dots + \|x_n\|^2)^{1/2} \quad (9)$$

식 (9)에서, 입력 벡터를 같은 방향을 가리키는 단위 벡터로 변환시킨다. 즉, n 차원 공간에서의 단위 길이를 갖는 벡터이다. 따라서, 정규화 전처리를 하기 위한 관계식은 다음과 같이 주어진다.

$$N = X + Q(O - X) \quad (10)$$

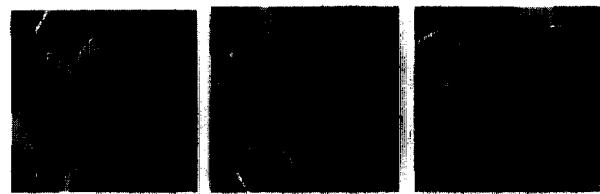
여기서, N 는 ICA를 이용하기 전의 정규화 전처리 값이고, O 는 입력 벡터 즉, 혼합영상이고, X 는 정규화 전처리 방법으로 변환된 입력벡터이며, Q 는 계수로 여기서는 1로 놓았다.

4. 모의 실험 및 결과

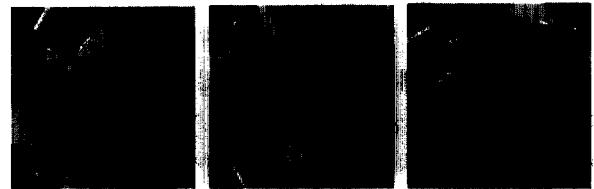
본 장에서는 영상 분류에 있어서 잡음에 대한 2차원 영상의 실험을 위하여 256×256 크기의 "Lena"영상을 이용하였으며, $N(m, \sigma^2)$ 의 가우시안 분포특성을 유지하고 원영상에 잡음이 인가되었을 때, 평균을 일정하게 하고($m=0$), 분산을 변화($\sigma^2 : 0 \sim 1$)시켜 가면서 분류된 영상의 강인성을 살펴보기 위하여 LSE를 적용하였다. (그림 3)은 형태를 변형시킨 원영상을, (그림 4)는 잡음[N(0, 0.54)]을 주었을 때의 혼합 영상을 나

타내었다. 서로 다른 패턴사이에서 정보를 처리하기 위해 템플리트 정합[10] 또는 원형 정합(Prototype matching)[11]을 이용하는데, 이는 대지의 패턴과 주어진 원형 패턴과의 사이에 상관 계수를 구하고 그 중에서 상관계수가 큰 것을 잘 정합되는 것으로 선택한다. 따라서, 상관계수가 클수록 영상 정보의 상호 관계를 더 약화시키는 작용을 하기 때문에 정합이 잘되어 잡음에 대한 강인성을 증가시킨다. (그림 3)에서 원영상 신호간의 종속이 어떻게 나타나는지 상관행렬을 계산하였다.

$$\begin{bmatrix} 1.0000 & 0.1915 & -0.0178 \\ 0.1915 & 1.0000 & -0.0845 \\ -0.0178 & -0.0845 & 1.0000 \end{bmatrix} \quad (11)$$



(그림 3) 원영상



(그림 4) 잡음[N(0, 0.54)]을 주었을 때의 혼합 영상

4.1 PCA 및 ICA의 잡음에 대한 강인성 측정

PCA 및 ICA에 의해 분류한 영상 Y_1, Y_2, Y_3 와 원영상 O_1, O_2, O_3 간의 LSE를 측정하여 잡음에 대한 강인성을 알아본다. (그림 5)는 잡음[N(0, 0.4)]을 주었을 때의 PCA에 의해 분류된 영상을, (그림 6)은 ICA에 의해 분류된 영상을, (그림 7)은 잡음[N(0, 0.53)]을 주었을 때의 ICA에 의해 분류된 영상을 각각 나타내었다.



(그림 5) 잡음[N(0, 0.4)]을 주었을 때의 PCA에 의해 분류된 영상



(그림 6) ICA에 의해 분류된 영상



(그림 7) 잡음[N(0, 0.53)]을 주었을 때의 ICA에 의해 분류된 영상

<표 1>과 <표 2>에서 OR는 원영상, H_1, H_2, H_3 는 형태를 변형시킨 원영상((그림 3)참조), S_1, S_2, S_3 는 ICA에 의해 분류된 영상을, 측정값은 ICA에 의해 분류된 영상과 형태를 변형시킨 원영상간의 LSE값을 나타낸 것이다. 본 장에서는 영상 분류에 있어서 잡음에 대한 장인성을 살펴보기 위하여 LSE를 사용하여 비교하였다.

$$E = \sqrt{\sum \sum (S_i - H_j)^2} \quad (12)$$

여기서, $S_i (i=1, 2, 3)$ 은 ICA에 의해 분류된 영상 및 정규화 전처리를 통한 ICA에 의해 분류된 영상을 나타내며, $H_j (j=1, 2, 3)$ 은 형태를 변형시킨 원영상이다. (그림 1)의 □에서 Y_1, Y_2, Y_3 가 O 에 정합되기 위해서는 Y_1, Y_2, Y_3 의 LSE 중 최소 값에 의해 결정된다. 이렇게 하여 Y_1, Y_2, Y_3 가 O_1, O_2, O_3 에 중복되어 정합되기 전의 LSE를 구하여 잡음에 대한 장인성을 측정한다. 따라서, 식 (12)에 의해 LSE를 구하여 측정한 결과를 <표 1>과 <표 2>에 보여준다. 아래의 <표 1>과 <표 2>는 각각 PCA 및 ICA에서 잡음에 따른 영상 분류를 나타낸다. <표 1>에서, $N(0, 0)$ 일 때, H_2 와 S_1 과의 LSE값은 $3.3607 e^{+004}$ 이고, H_3 와 S_2 와의 LSE값은 $3.3609 e^{+004}$ 이며, H_1 과 S_3 와의 LSE값은 $3.3515 e^{+004}$ 이므로 영상 분류가 됨을 알 수 있다. 계속해서 분산을 변화시켜 LSE값을 구하여 영상 분류를 알 수 있다. 그러나, $N(0, 0.41)$ 인 경우 H_3 와 S_1 과의 LSE값은 $3.3500 e^{+004}$ 이고, H_1 과 S_2 와의 LSE값은 $3.3507 e^{+004}$ 이며, H_1 과 S_3 와의 LSE값은 $3.3576 e^{+004}$ 이므로 S_2 와 S_3 은 H_1 에 중복되어 정합이 되므로 $N(0, 0.41)$ 에서는 영상 분류가 되지 않았고, 그 이상에 대하여는 분류가 되지 않았다(<표 1> 참조). 따라서, PCA에 대한 잡음에 대한 장인성은 모의 실험 결과 $N(0, 0.4)$ 에서 볼 수 있다. <표 2>에서도 동일한 방법으로 LSE값을 구하여 영상 분류를 알 수 있다. 그러나, $N(0, 0.54)$ 인 경우 H_2 와 S_1 과의 LSE값은 $3.3608 e^{+004}$ 이고, H_3 와 S_2 와의 LSE값은 $3.3610 e^{+004}$ 이며, H_2 와 S_3 의 LSE값은 $3.3517 e^{+004}$ 이므로 S_1 과 S_3 는 H_2 에 중복되어 정합이 되므로 $N(0, 0.54)$ 에서는 영상 분류가 되지 않았고, 그 이상에 대하여는 분류가 되지 않았다(<표 2> 참조). 따라서, ICA에 대한 잡음에 대한 장인성은 모의 실험 결과 $N(0, 0.53)$ 에서 볼 수 있다. <표 1>과 <표 2>에서 모의 실험 결과, ICA가 PCA에 비해 잡음에 대한 장인성이 크게 나타났는데 이는 원영상 신호간에 상관계수가 크기 때문에 정합이 잘 되었기 때문이다.

<표 1> PCA에서 잡음에 따른 영상 분류

잡음	영상종류 OR PCA	LSE (e^{+004})		
		S_1	S_2	S_3
$N(0, 0)$	H_1	3.3612	3.3668	3.3515
	H_2	3.3607	3.3719	3.3649
	H_3	3.3725	3.3609	3.3612
$N(0, 0.1)$	H_1	3.3510	3.3619	3.3657
	H_2	3.3551	3.3623	3.3520
	H_3	3.3609	3.3500	3.3614
$N(0, 0.2)$	H_1	3.3553	3.3619	3.3518
	H_2	3.3509	3.3630	3.3653
	H_3	3.3604	3.3501	3.3613
$N(0, 0.3)$	H_1	3.3613	3.3506	3.3649
	H_2	3.3618	3.3556	3.3516
	H_3	3.3500	3.3615	3.3616
$M(0, 0.4)$	H_1	3.3612	3.3719	3.3576
	H_2	3.3607	3.3670	3.3709
	H_3	3.3725	3.3610	3.3610
$N(0, 0.41)$	H_1	3.3614	3.3507	3.3576
	H_2	3.3618	3.3556	3.3710
	H_3	3.3500	3.3615	3.3610
$N(0, 0.5)$	H_1	3.3613	3.3557	3.3710
	H_2	3.3608	3.3507	3.3577
	H_3	3.3725	3.3617	3.3614

<표 2> ICA에서 잡음에 따른 영상 분류

잡음	영상종류 OR ICA	LSE (e^{+004})		
		S_1	S_2	S_3
$N(0, 0)$	H_1	3.3716	3.3606	3.3569
	H_2	3.3675	3.3602	3.3705
	H_3	3.3617	3.3725	3.3611
$N(0, 0.1)$	H_1	3.3509	3.3619	3.3656
	H_2	3.3550	3.3623	3.3520
	H_3	3.3609	3.3500	3.3614
$N(0, 0.2)$	H_1	3.3510	3.3620	3.3657
	H_2	3.3551	3.3624	3.3520
	H_3	3.3609	3.3500	3.3614
$N(0, 0.3)$	H_1	3.3553	3.3619	3.3518
	H_2	3.3509	3.3630	3.3653
	H_3	3.3604	3.3501	3.3613
$N(0, 0.4)$	H_1	3.3510	3.3620	3.3658
	H_2	3.3551	3.3624	3.3521
	H_3	3.3609	3.3500	3.3614
$N(0, 0.5)$	H_1	3.3511	3.3621	3.3658
	H_2	3.3552	3.3625	3.3521
	H_3	3.3609	3.3500	3.3614
$N(0, 0.51)$	H_1	3.3553	3.3619	3.3518
	H_2	3.3509	3.3630	3.3653
	H_3	3.3604	3.3501	3.3613
$N(0, 0.52)$	H_1	3.3511	3.3620	3.3658
	H_2	3.3551	3.3624	3.3521
	H_3	3.3609	3.3500	3.3614
$N(0, 0.53)$	H_1	3.3672	3.3606	3.3518
	H_2	3.3716	3.3596	3.3653
	H_3	3.3621	3.3724	3.3613
$N(0, 0.54)$	H_1	3.3613	3.3719	3.3651
	H_2	3.3608	3.3670	3.3517
	H_3	3.3725	3.3610	3.3616
$N(0, 0.6)$	H_1	3.3554	3.3607	3.3518
	H_2	3.3510	3.3596	3.3654
	H_3	3.3604	3.3724	3.3613

4.2 제안한 기법의 잡음에 대한 강인성 측정

본 절에서는 잡음에 대한 강인성을 증가시키는 방법으로 제안한 기법의 인근평균 및 정규화를 이용하여 잡음에 대한 강인성을 고찰하였다. (그림 8)은 잡음[N(0, 0.66)]을 주었을 때의 인근 평균 전처리를 통한 ICA에 의해 분류된 영상을, (그림 9)는 잡음[N(0, 0.75)]를 주었을 때의 정규화 전처리를 통한 ICA에 의해 분류된 영상을 각각 보여준다.



(그림 8) 잡음[N(0, 0.66)]을 주었을 때의 인근평균 전처리를 통한 ICA에 의해 분류된 영상



(그림 9) 잡음[N(0, 0.75)]을 주었을 때의 정규화 전처리를 통한 ICA에 의해 분류된 영상

아래의 <표 3>과 <표 4>는 각각 인근평균 및 정규화 두 가지 전처리를 통한 ICA에서 잡음에 따른 영상 분류를 나타낸다. <표 3>과 <표 4>에서 OR는 원영상, H_1, H_2, H_3 는 형태를 변형시킨 원영상(그림 3) 참조), S_1, S_2, S_3 는 ICA에 의해 분류된 영상을, 측정값은 ICA에 의해 분류된 영상과 형태를 변형시킨 원영상간의 LSE값을 나타낸 것이다. <표 3>에서, $N(0, 0)$ 일 때, H_3 와 S_1 과의 LSE값은 $3.3617e^{+004}$ 이고, H_2 와 S_2 와의 LSE값은 $3.3602e^{+004}$ 이며, H_1 과 S_3 와의 LSE값은 $3.3569e^{+004}$ 이므로 영상 분류가 됨을 알 수 있다. 계속해서 분산을 변화시켜 LSE값을 구하여 영상 분류를 알 수 있다. 그러나, $N(0, 0.67)$ 인 경우 H_2 와 S_1 과의 LSE값은 $3.3608e^{+004}$ 이고, H_3 와 S_2 와의 LSE값은 $3.3610e^{+004}$ 이며, H_2 와 S_3 와의 LSE값은 $3.3516e^{+004}$ 이므로 S_1 과 S_3 는 H_2 에 중복되어 정합이 되므로 $N(0, 0.67)$ 에서는 영상 분류가 되지 않았고, 그 이상에 대하여는 분류가 되지 않았다(<표 3> 참조). 따라서, 인근 평균 전처리를 통한 잡음에 대한 강인성은 모의 실험 결과 $N(0, 0.66)$ 에서 볼 수 있다. 그러나, 영상의 화소의 합성이 크기 때문에 다음에 언급되는 정규화 전처리에 비해 평활화 효과는 증대하나 반면에 영상의 선명도가 흐려짐을 (그림 8)에서 볼 수가 있다. <표 4>에서도 동일한 방법으로 LSE값을 구하여 영상 분류를 알 수 있다. $N(0, 0.76)$ 인 경우 H_2 와 S_1 과의 LSE값은 $3.3509e^{+004}$ 이고, H_2 와 S_2 와의 LSE값은 $3.3595e^{+004}$ 이며, H_1 과 S_3 의 LSE값은 $3.3517e^{+004}$ 이므로 S_1 과 S_2 는 H_2 에 중복되어 정합이 되므로 $N(0, 0.76)$ 에서는

영상 분류가 되지 않았고, 그 이상에 대하여는 분류가 되지 않았다(<표 4> 참조). 따라서, 정규화 전처리를 통한 잡음에 대한 강인성은 모의 실험 결과 $N(0, 0.75)$ 에서 볼 수 있다. <표 3>과 <표 4>에서 모의 실험 결과, 제안한 기법의 잡음에 대한 강인성은 전처리 없는 PCA 및 ICA에 비해 더 좋은 분리 특성을 지니고 있음을 모의 실험을 통해 확인할 수 있었다.

<표 3> 인근 평균 전처리를 통한 ICA에서 잡음에 따른 영상 분류

잡 음	영 상 종 류 ICA OR	LSE (e+004)		
		S_1	S_2	S_3
$N(0, 0)$	H_1	3.3716	3.3606	3.3569
	H_2	3.3675	3.3602	3.3705
	H_3	3.3617	3.3725	3.3611
$N(0, 0.1)$	H_1	3.3509	3.3619	3.3656
	H_2	3.3550	3.3623	3.3520
	H_3	3.3609	3.3500	3.3614
$N(0, 0.2)$	H_1	3.3510	3.3620	3.3657
	H_2	3.3551	3.3624	3.3520
	H_3	3.3609	3.3501	3.3615
$N(0, 0.3)$	H_1	3.3553	3.3619	3.3518
	H_2	3.3509	3.3630	3.3653
	H_3	3.3604	3.3501	3.3613
$N(0, 0.4)$	H_1	3.3672	3.3606	3.3518
	H_2	3.3716	3.3596	3.3653
	H_3	3.3621	3.3725	3.3613
$N(0, 0.5)$	H_1	3.3612	3.3668	3.3515
	H_2	3.3607	3.3719	3.3649
	H_3	3.3725	3.3609	3.3612
$N(0, 0.6)$	H_1	3.3554	3.3620	3.3518
	H_2	3.3510	3.3630	3.3654
	H_3	3.3605	3.3501	3.3613
$N(0, 0.65)$	H_1	3.3511	3.3621	3.3659
	H_2	3.3552	3.3625	3.3522
	H_3	3.3611	3.3502	3.3616
$N(0, 0.66)$	H_1	3.3612	3.3719	3.3576
	H_2	3.3608	3.3670	3.3710
	H_3	3.3725	3.3611	3.3610
$N(0, 0.67)$	H_1	3.3612	3.3719	3.3650
	H_2	3.3608	3.3670	3.3516
	H_3	3.3725	3.3610	3.3616
$N(0, 0.7)$	H_1	3.3553	3.3606	3.3708
	H_2	3.3510	3.3596	3.3572
	H_3	3.3605	3.3725	3.3613

<표 4> 정규화 전처리를 통한 ICA에서 잡음에 따른 영상 분류

잡 음	영 상 종 류 ICA OR	LSE (e+004)		
		S_1	S_2	S_3
$N = [0,0]$	H_1	3.3510	3.3619	3.3657
	H_2	3.3550	3.3623	3.3520
	H_3	3.3609	3.3500	3.3614
$N = [0,0.1]$	H_1	3.3553	3.3619	3.3518
	H_2	3.3509	3.3630	3.3653
	H_3	3.3604	3.3501	3.3613
$N = [0,0.2]$	H_1	3.3510	3.3620	3.3657
	H_2	3.3551	3.3624	3.3520
	H_3	3.3609	3.3501	3.3615
$N = [0,0.3]$	H_1	3.3672	3.3606	3.3518
	H_2	3.3716	3.3596	3.3653
	H_3	3.3621	3.3725	3.3613
$M = [0,0.4]$	H_1	3.3554	3.3620	3.3518
	H_2	3.3510	3.3630	3.3654
	H_3	3.3605	3.3501	3.3613

N = [0,0.5]	H ₁	3.3612	3.3668	3.3515
	H ₂	3.3607	3.3719	3.3649
	H ₃	3.3725	3.3609	3.3612
N = [0,0.6]	H ₁	3.3613	3.3506	3.3649
	H ₂	3.3618	3.3556	3.3515
	H ₃	3.3500	3.3615	3.3616
N = [0,0.7]	H ₁	3.3612	3.3719	3.3576
	H ₂	3.3608	3.3670	3.3710
	H ₃	3.3725	3.3611	3.3610
N = [0,0.75]	H ₁	3.3554	3.3518	3.3621
	H ₂	3.3510	3.3654	3.3629
	H ₃	3.3605	3.3611	3.3501
M = [0,0.76]	H ₁	3.3553	3.3606	3.3517
	H ₂	3.3509	3.3595	3.3653
	H ₃	3.3604	3.3724	3.3612
N = [0,0.8]	H ₁	3.3612	3.3719	3.3650
	H ₂	3.3608	3.3670	3.3516
	H ₃	3.3725	3.3611	3.3616

5. 결 론

본 논문에서 인근 평균 및 정규화와 독립성분해석, 혼합한 영상 분류 방법을 제안하였다. 이 제안된 방법은 전처리 없이 ICA나 PCA를 이용한 것에 비해 잡음에 대한 강인성을 증가시킨다. 영상에 잡음이 인가된 경우, PCA는 N(0, 0.4), ICA는 N(0, 0.53)까지의 분류가 가능함을 보였다. ICA를 이용한 영상 분류 방법은 PCA에서 보다 더 잡음에 강인한 성질을 내포하고 있는데, 이는 PCA보다 ICA가 영상 정보의 상호 관계를 더 약화시키는 작용을 하기 때문이다. 이러한 특성은 모의 실험을 통해 확인되었다. 이 방법을 더 개선시키는 방법으로 인근평균 및 정규화 두 가지 전처리를 적용하였다. 잡음에 대한 강인성은 전처리 없는 PCA 및 ICA에 비해 더 좋은 분류 특성을 지니고 있음을 모의 실험을 통해 확인할 수 있었다. 제안된 인근 평균 전처리는 N(0, 0.66)까지, 정규화 전처리는 N(0, 0.75)까지 영상 분류가 됨을 실험에서 보이고 있다. 정규화 전처리는 인근 평균 전처리 보다 잡음에 대한 강인성을 향상시키는 결과를 보여 주었다. 인근 평균에 비해 평활화 효과는 감소하나, 반면에 영상의 선명도가 선명함을 알 수 있었다. 원영상 신호간에 상관행렬의 결합이 클수록 잡음에 대한 강인성은 크게 나타나는 것으로 확인되었다. 본 논문에서 모의 실험으로 사용한 영상은 상관행렬의 결합이 크므로 잡음에 대한 강인성은 크게 나타났다. 상관계수가 클수록 영상 정보의 상호 관계를 더 약화시키는 작용을 하기 때문에 정합이 잘되어 잡음에 대한 강인성을 증가시킨다. 원영상에 상관행렬을 크게 할 수 있다면 영상 분류의 허용을 크게 할 수 있으므로 영상인식, 통신위성, 의학 신호처리 등 응용이 예상되며 때문에 이 문제에 대한 지속적인 연구가 필요하다.

참 고 문 헌

- [1] P. Comon, "Independent Component Analysis - a new concept?", *signal processing* 36, pp.287-314, 1994.
- [2] E. Oja, "The nonlinear PCA learning rule in independent

component analysis," *Neurocomputing* Vol.17, No.1, pp.25-46, 1997.

- [3] J. Parkkinen, T. Jaaskelainen, "Color Representation Using Statistical Pattern Recognition," *Applied Optics*, Vol.26, No. 19, pp.4240-4245, 1987.
- [4] C. Jutted and J. Herault, "Blind separation of sources, part I : An adaptive algorithm based on neuromimetic architecture," *Signal Processing*, 24 : pp.1-10, 1991.
- [5] P. Pajunen, "Blind source separation using algorithmic information theory," *Neurocomputing*, 1998.
- [6] N. Delfosse and P. Loubaton, "Adaptive blind separation of independent sources : a deflation approach," *Signal Processing* Vol.45, pp.59-83, 1995.
- [7] D. Donoho, "On minimum entropy deconvolution," In *Applied Time Series Analysis II*, pp.565-608. Academic Press, 1981.
- [8] P. J. Huber, "Projection pursuit," *The Annals of Statistics*, 13(2) : pp.435-475, 1985.
- [9] A. Hyvärinen and E. Oja, "A fast fixed-point algorithm for independent component analysis," *Neural Computation* Vol. 9, No.7, pp.1483-1492, 1997.
- [10] A. Rosenfeld and A. Kak, "Digital picture processing," New York : Academic, 2nd ed., 1982.
- [11] W. E. L. Grimson, T. Lozano-Pérez and D. P. Huttenlocher, "Object Recognition by Computer : The Role of Geometric Constraints," Cambridge, MA : MIT Press, 1990.



홍 준 식

e-mail : jnskhong@dreamwiz.com
 1986년 명지대학교 전기공학과 학사
 1993년 연세대학교 전기공학과 석사
 1999년 충북대학교 전기공학과 박사과정
 수료
 1989년 ~ 현재 (주)동원 감사

관심분야 : 영상처리, 신호처리, 패턴인식



유 정 용

e-mail : jwry@engine.chungbuk.ac.kr
 1965년 한양대학교 전기공학과 학사
 1976년 단국대학교 전기공학과 석사
 1987년 단국대학교 전기공학과 박사
 1979년 ~ 현재 충북대학교 전기공학과 교수
 관심분야 : 영상처리, 신호처리, 패턴인식



김 성 수

e-mail : sskim@engine.chungbuk.ac.kr
 1983년 충북대학교 전기공학과 학사
 1989년 University of Arkansas - Fayetteville 석사
 1997년 University of Central Florida박사
 1999년 ~ 현재 충북대학교 전기공학과 조교수
 관심분야 : 영상처리, 신호처리, 패턴인식