

논문 2009-46SP-2-11

독립성분 분석을 이용한 번호판 숫자 인식

(Recognition of Numeric Characters in License Plate based on Independent Component Analysis)

정 병 준*, 강 현 철*

(ByeongJun Jeong and Hyunchul Kang)

요 약

본 논문에서는 자동차 번호판 숫자의 특징을 추출하기 위해 강화된 독립성분분석(independent component analysis)의 혼합 모델을 제안한다. 독립성분분석은 고차 통계적 특성만을 이용하기 때문에 저차 통계적 특성과 숫자 종류별 상관관계에 대한 특성을 고려하지 못한다. 이러한 독립성분분석의 한계를 극복하기 위해, 본 논문에서는 주성분분석(principle component analysis)과 선형판별분석(linear discriminant analysis)을 조합한 혼합 모델 형태의 독립성분분석을 제안한다. 실험 결과, 제안된 혼합 모델은 독립성분분석이나 다른 혼합 모델들보다 특징 추출과 인식에서 우수한 성능을 보임을 확인하였다.

Abstract

This paper presents an enhanced hybrid model based on Independent Component Analysis(ICA) in order to abstract features of numeric characters in license plates. ICA which is used only in high dimensional statistical features doesn't consider statistical features in low dimension and correlation between numeric characters. To overcome the drawbacks of ICA, we propose an improved ICA with the hybrid model using both Principle Component Analysis(PCA) and Linear Discriminant Analysis(LDA). Experiment results show that the proposed model has a superior performance in feature extraction and recognition compared with ICA only as well as other hybrid models.

Keywords : Statistical Pattern Recognition, Independent Component Analysis, License Plate Recognition

I. 서 론

영상 인식 방법은 원형 정합 방법, 구조적 분석 방법, 특징 기반 방법, 통계적 해석 방법, 신경망을 이용하는 방법 등으로 나누어 볼 수 있다^[1]. 통계적 특징 추출 방법은 입력 데이터의 차원을 보다 더 작은 데이터의 차원으로 줄이면서, 결과 데이터는 입력 데이터가 가지고 있는 특징을 충분히 보존하는 것을 목표로 한다. 대표적인 통계적 특징 추출 방법으로는 주성분분석(PCA: Principal Component Analysis), 선형판별분석(LDA:

Linear Discriminant Analysis), 독립성분분석(ICA: Independent Component Analysis) 등이 있다. 각 특징 추출 방법들에서 발생하는 단점을 보완하고자 개별 특징 추출 방법을 조합한 혼합 모델들이 제시되고 있다. 본 논문에서는 번호판 숫자를 대상으로 각각의 혼합 모델이 갖는 하는 성능을 실험하고, 각 모델의 특징을 비교 분석한다.

II. 통계적 특징추출 모델

1. 주성분분석

주성분분석은 2차적 통계 특성을 이용한 특징 추출 방법이다^[3]. 영상 혹은 신호 데이터가 갖는 공분산이 최대가 되도록 정규 직교화하여 입력 자료의 차원을 줄이고, 효율적인 특징을 추출하며, Karhunen-Loeve 변환

* 정회원, 인천대학교 정보통신공학과
(Dept. of Information and Telecommunication
Eng., University of Incheon)

※ 이 논문은 인천대학교 2007년도 자체연구비 지원에
의하여 연구되었음.

접수일자: 2008년6월18일, 수정완료일: 2009년2월27일

혹은 Hotelling 변환이라고도 한다. 주성분 분석은 원래 변수들의 선형 조합(linear combination)으로 변환시켜서 주성분(PC, Principal Component)이라 부르는 서로 독립적인 변수들을 유도한다. 여기서 각 주성분이 가지는 변이의 크기를 중요도 순서로 정렬하였을 때, 처음 몇 개의 주성분이 원래 자료에 내재하는 총 변이의 가능한 많은 에너지를 보유하도록 함으로써 차원을 축소할 수 있다^[4]. 즉, 전체 영상의 데이터를 가지고 분산이 최대가 되는 고유 방향에 대한 축으로 선형 투영시켜서 차원을 줄이는 방법이다.

PCA 변환을 했을 때 주성분의 최대 수는 입력 영상 벡터의 차원과 같다. PCA에서 고유값(eigenvalue)은 지수 함수와 같이 급속히 감소되기 때문에 마지막 몇몇 주성분들을 생략하더라도 원래 영상과 차이가 적어진다.^[2]

숫자 공간(number space)상의 특징 정보는 인식 단계에서 매우 중요한 요소이다. 학습 집합 내의 공분산 행렬(covariance matrix)은 평균 영상과 각 개인 영상의 차 벡터와 차 벡터를 전치(transpose)시킨 벡터의 내적으로 계산되며, 각 화소들의 상관관계를 나타내는 행렬이 된다.

$N \times N$ 크기의 2차원 숫자 영상은 $N^2 \times 1$ 의 벡터 a 로 표시할 수 있다. K 개의 입력 벡터 a 들의 집합 A 는 $N^2 \times K$ 크기의 2차원 벡터가 된다. 새로이 구성된 입력 벡터의 전체 행렬 $A = [a_1, a_2, \dots, a_K]$ 의 평균벡터 M 은 식 (1)과 같다.

$$M = \frac{1}{K} \sum_{i=1}^K a_i \tag{1}$$

1차 모멘트에 대한 고려를 통해 1차 정규화(1st order normalization)를 위해서, 평균벡터 M 과 각 영상의 차에 의해 구해진 차벡터 $X = [x_1, x_2, \dots, x_k]$ 는 식 (2)와 같다.

$$X_i = A_i - M \tag{2}$$

차벡터의 공분산 행렬은 식 (3)과 같이 구한다.

$$C = \frac{1}{K} \sum_{i=1}^K x_i x_i^T = X X^T \tag{3}$$

차벡터의 공분산 행렬 C 에 대한 고유치 분해를 하면, K 개의 고유값(eigenvalue) λ_i 와 그에 대응하는 고

유벡터(eigenvector) u_i 로

$$C u_i = \lambda_i u_i \tag{4}$$

분리할 수 있다. 숫자 공간에서의 각 고유치에 대응되는 고유벡터를 고유 숫자(eigennumber)라 할 수 있다.^[18] 또한, 큰 고유값에 대응되는 고유벡터일수록 입력 평균 이미지와 유사하고, 작은 고유값에 대응되는 고유벡터일수록 입력 이미지들에 대해 제거가능하며 통계적으로 무의미한 데이터 성분이 많이 포함되어 있음을 나타낸다.

고유값과 고유벡터로 나눈 결과에 의해 중요성이 높은 고유값 순서에 따른 고유벡터 p 개를 선택하면 식 (5)와 같다.

$$W_{PCA} = [X_{e_{v_1}}, X_{e_{v_2}}, \dots, X_{e_{v_p}}] \tag{5}$$

고유벡터의 개수 선택은 분산과 누적분포를 통해 실험적으로 구한다.

주성분분석의 결과로 얻어진 Y 는 선택된 p 개의 고유값에 대한 숫자 공간상에 임의의 숫자 이미지를 투영하였을 때에 얻어진 특징 벡터를 근거로 재구성된다.

$$Y = X W_{PCA} \tag{6}$$

그림 1은 번호판에서 나타나는 숫자 공간상의 고유벡터들을 모두 보인 것이다. 그림 1은 PCA 고유벡터를 다시 $N \times N$ 의 이미지로 재구성된 것이고, 결과를 통해 순차 정렬하면 첫 벡터는 전체 이미지들을 모두 포함하는 평균 이미지가 되며, 고차항으로 갈수록 전체 벡터에 대한 특징을 갖지 못함을 볼 수 있다.




그림 1. PCA 고유벡터
Fig. 1. PCA eigenvectors.

2. 선형판별분석

선형판별분석은 MDF(Most Discrimination Feature)라 하기도 한다. FLD(Fisher Linear Discriminant) 방법을 도입한 선형판별분석은 개인과 집단의 개념을 도입하여 같은 클래스 내에서의 변화와 다른 클래스 간의 변화의 비를 고려하여 분류한다^[6-7]. 산란행렬(Scatter Matrix)을 구성하는 과정은 같은 클래스 사이(Within Class)의 분산 S_w 을 최소화하고 다른 클래스 사이(Between Class)의 분산 S_b 은 최대화 시키는데 목적이 있다^[5,8]. 클래스 내 분산과 클래스 간 분산을 수식화하면 식 (7)과 식 (8)로 정리된다.

$$S_w = \sum_{i=1}^{N_c} Pr(C_i) E[(v_i - \mu_i)(v_i - \mu_i)^T] \quad (7)$$

$$S_b = \sum_{i=1}^{N_c} Pr(C_i) (\mu - \mu_i)(\mu - \mu_i)^T \quad (8)$$

여기서, μ 는 전체 평균 벡터이고, μ_i 는 i 번째 클래스의 평균벡터이고, v_i 는 i 번째 클래스의 입력벡터이다. $Pr(C_i)$ 는 클래스 C_i 의 선험 확률(a priori probability)을 의미한다.

FLD 기법은 변환행렬 W 의 최적해 W_{opt} 를 구한다.

$$W_{opt} = \operatorname{argmax}_W \frac{|W^T S_b W|}{|W^T S_w W|} \quad (9)$$

최적해 W_{opt} 를 구하는 문제는 고유값 문제 해결에 따라 사상행렬의 값을 구하는 것으로 귀결된다^[5].

$$S_b u_i = \lambda_i S_w u_i \quad (10)$$

구해진 고유값에 따라 정렬하여 q 개의 고유벡터로 구성된 특징벡터 W_{LDA} 를 구하면,

$$W_{LDA} = [u_1, u_2, \dots, u_q] \quad (11)$$

이 되고, LDA에 의해 재해석된 입력 Z 는 식 (12)와 같다.

$$Z = X W_{LDA}^T \quad (12)$$

그림 2는 LDA를 통해 특징 추출된 결과 이미지를 모두 보인 것이다.

LDA의 결과 이미지는 동일 문자 사이의 유사성이 다른 문자의 유사성에 비해 높도록 숫자 공간상에서 입력 특징들의 상관관계를 변경한 것으로 동일 문자에 있




그림 2. LDA 결과 이미지
Fig. 2. LDA result images.

어 매우 유사한 형태의 결과 이미지를 볼 수 있다.

3. 독립성분분석

독립성분분석은 통계적으로 독립성이 잠재된 변수를 사용하여 모델링하는 방법이며^[9], BSS(Blind Source Separation)와 특징 추출에 사용된다. n 개의 독립성분 s_i 로 이루어진 n 개의 선형 혼합 벡터 x_1, x_2, \dots, x_n 있다고 가정하면,

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n, \quad \text{for all } j \quad (13)$$

식 (13)과 같이 x_n 은 독립성분 s_i 로 구성된 랜덤 변수라 가정되고 관계를 정리하면 식 (14)와 같다^[10].

$$x = A \cdot s + n = \sum_{i=1}^m a_i s_i + n \quad (14)$$

원 신호 s 는 영상 패치 x 를 형성하기 위해 혼합행렬 A 의 가중치를 주어 x 를 나타낸다. 즉, s 의 선형 합성에 의하여 x 가 형성된다. 그래서 s 를 영상의 근거(causes)라 한다. x, s 와 출력 신호는 모두 독립된 성분임을 가정하여 독립성분분석을 한다. 출력신호 $y = Wx$ 이 되고, $y = WAs$ 가 되어, $x = W^{-1}y$ 의 관계를 갖는다. 즉, $A = W^{-1}$ 면 이상적으로 원래 값을 만들 수 있다. 관찰된 영상의 패치로서 기저벡터 W 는 영상의 특징으로 찾고자 하는 값이고, W 는 이미 알고 있는 값 y 성분들이 최대한 독립적으로 만드는 과정으로 구한다^[13]. 여기서 A 는 $n * n$ 의 역행렬이 존재하는 정방행렬이고, 각 열벡터를 독립성분분석의 기저 벡터 또는 기저 함수라고 한다. 결국 독립성분분석은 독립이 아닌 기저 A 를 사용하는 입력 데이터 x 를 A 의 역이며 독립인 기저 W 를 사용하여 선형 독립인 독

립 성분 데이터 y 를 얻고자 한다. 또한 W 는 상호정보를 최소화함으로써 독립성을 가지도록 최적화 기법으로 갱신하여 찾는다.

ICA를 효과적으로 수행하기 위해 혼합 신호를 대상으로 영 평균과 백색화의 전처리 과정을 수행한다^[11]. 이는 신호의 1차와 2차의 통계적 특성을 고려한 정규화로 학습 알고리즘을 간략화하기 위해서 사용된다. 먼저 영 평균(centering) \tilde{x} 는 1차 정규화로 신호 벡터 x 에서 평균값 x' 를 뺀 차로 구한다.

$$\tilde{x} = x - x' \tag{15}$$

백색화(whitening)는 2차 정규화로 혼합신호 x 를 선형 변환하여 성분이 비상관성을 갖고, 그 단위 분산이 되도록 한다. 즉, x 의 공분산 행렬이 단위행렬이 되도록 한다.

$$E[\tilde{x}\tilde{x}^T] = I \tag{16}$$

PCA에서 사용하는 고유벡터 분해를 이용하여 2차 정규화를 한다.

$$E[\tilde{x}\tilde{x}^T] = EDE^T \tag{17}$$

여기서 E 는 $E[\tilde{x}\tilde{x}^T]$ 의 고유벡터로 구성된 직교행렬이고, D 는 고유값 λ 로 구성된 대각행렬이다.

$$\tilde{x} = ED^{-1/2}E^Tx \tag{18}$$

\tilde{A} 라는 새로운 혼합 행렬을 정의하면,

$$x = As \tag{19}$$

$$\tilde{x} = ED^{-1/2}E^Tx = ED^{-1/2}E^TAs = \tilde{A}s \tag{20}$$

여기서,

$$E[\tilde{x}\tilde{x}^T] = \tilde{A}E[ss^T]\tilde{A}^T = \tilde{A}^T = I \tag{21}$$

이 되고, \tilde{A} 는 직교 특성을 가지고 있다. 또한, 백색화를 통해 추정하는 파라미터의 수를 감소시키는 효과를 가진다.

고정점 알고리즘은 엔트로피 최대화에 기초하여 신호 내에 포함된 상호정보를 최소화한다^[10, 13]. 신호 내에 포함된 상호 정보를 최소화함으로써 ICA의 해를 구하는 기법이다. 특히 알고리즘 내에서 한 번의 연산을 위해 많은 계산을 필요로 하여 수치해석적인 접근을 통해 해

결하고자 한다. 기존의 뉴턴법을 이용한 고정점 알고리즘에서 목적함수의 근을 구하기 위해 1차 미분인 도함수 계산 제약을 해결하기 위해 근사화 접근 방법인 할선법을 이용한다.

$$f'(W_k) \simeq \frac{f(W_k) - f(W_{k-1})}{W_k - W_{k-1}} \tag{22}$$

따라서 최종 갱신식은 식 (23)과 같다.

$$W_{k+1} = W_k - f(W_k) \frac{W_k - W_{k-1}}{f(W_k) - f(W_{k-1})} \tag{23}$$

할선법의 근사화는 식 (22)와 같이 현재와 이전의 함수 결과의 변위 차분을 이용한다. 따라서 역혼합행렬 W 의 갱신식은 식 (23)과 같다. 할선법의 근사화로 구해진 갱신식은 미분계산을 제거함으로써 실제 계산량이 줄어드는 효과를 얻을 수 있다. $f(\cdot)$ 함수와 β 의 식은 식 (24)와 식 (25)로 표현된다.

$$f(w) = E[(xg(w^Tx)) - \beta w] \tag{24}$$

$$\beta = E[W_0^T xg(W_0^T x)] \tag{25}$$

할선법을 이용한 고정점 알고리즘의 역 혼합행렬 W 의 갱신과정은 표 1과 같다.

갱신의 식에서 사용되는 $g(\cdot)$ 는 비선형 함수로 학습 속도가 뛰어난 3차 함수나 안정적인 수렴을 보이는

표 1. 혼합행렬 갱신과정
Table 1. Process of updating Mixed matrix.

단계	연산 과정
1	$w(0) = random()$ 으로 설정
2	$w = \frac{w(0)}{\ w(0)\ }$ 의 값을 계산
3	$w' = 0$ 으로 설정
4	$\ w - w'\ > \epsilon$ 이고, $\ w + w'\ > \epsilon$ 이면, a. $\beta, f(w'), f(w)$ 를 계산 b. $w'' = w - f(w) \frac{w - w'}{f(w) - f(w')}$ 를 계산 c. $w' = w$ 로 설정 d. $w = \frac{w''}{\ w''\ }$ 로 설정
5	단계 4를 만족하지 않으면 종료




그림 3. ICA 결과 이미지
Fig. 3. ICA result images.

$\tanh(\cdot)$ 함수를 이용한다. 입력 데이터의 특징에 따라 수렴속도와 안정도 중에서 무엇을 우선할지에 따라 비선형함수를 선택한다.

본 논문에서는 실시간 번호판 숫자 인식 시스템의 특징추출부로서 독립성분분석을 이용하고자 하므로 3차 함수를 사용한다. 할선법을 이용한 최종 갱신된 특징추출 벡터 $W_{ICA} = w$ 가 되며, ICA에 의해 재해석된 입력은 식 (26)과 같다.

$$P = W_{ICA} X \tag{26}$$

ICA 결과 이미지를 모두 보이면 그림 3과 같다. 그림 3은 ICA 결과 이미지로 입력 이미지들이 갖는 특성과 무관한 결과를 보이며, 전체적으로 어두워지는 결과를 보이는데 이는 초기 1, 2차 정규화를 통해 계조도가 낮아지기 때문이고, 개별 이미지들이 매우 어둡거나 밝은 이미지의 결과를 보이는 이유는 입력 이미지들이 갖는 상관관계를 최대한으로 함으로써 데이터들의 밝기 값의 치우침이 발생하기 때문이다.

III. 혼합 특징추출 모델

앞 장에서 언급된 PCA, LDA, ICA가 가지고 있는 특징을 분석하고, 이들의 혼합 모델이 갖는 성능을 평가하고 한다. 성능 평가를 위한 입력 이미지는 자동차 번호판에서 추출된 64 * 64 크기의 이미지 500장에서 특징 추출 혼합 모델이 어떤 성능을 보이는지 판별하기 위해 임의로 선택된 각 숫자별 이미지 10장씩 100장으

로 특징 추출 모델의 특성을 파악하고자 한다. 따라서 실험에 사용되는 입력 행렬 X 은 $100 * 4096$ 이 된다.

1. PCA+LDA 혼합 모델

PCA의 경우, 주성분 축으로 전체 입력 데이터를 투영함으로써, 데이터의 2차적 통계 특성을 이용하여 데이터의 에너지 집중화를 하고, 이를 통해 효율적인 데이터 재표현 방법이다. 2차적 통계 특성을 이용한 특징추출은 전체 데이터의 에너지를 보존하는 방법에 있어서는 효율적인 결과를 얻을 수 있다. PCA의 특성 및 이하에 나오는 판별 측정(distance measure)은 통계적 특성의 성능을 판단하는 대표적인 방법들인 Hamming distance, Euclidean distance, Cosine distance를 이용한다.

그림 4는 내림차순으로 정렬된 주성분들 중에서 저차 항의 주성분이 모든 통계적 판별 방법에서 많은 에너지를 포함하고 있는 것을 알 수 있다. 또한 판별 측정 판별 방법으로 Hamming distance와 Euclidean distance 방법에서 좀 더 확연한 데이터의 에너지 집중 현상을 볼 수 있다. 정규화 판별 측정 방법인 Cosine distance 방법에 있어서도 다른 측정 방법에 비해 낮은 에너지 집중 현상을 볼 수 있다.

주성분분석에서 특징벡터의 수 선택은 전체 특징벡터들이 갖는 에너지의 누적 분포인 특징벡터의 누적분




그림 4. PCA 거리
Fig. 4. PCA Distance (a) Hamming distance, (b) Euclidean distance, (c) Cosine distance.

표 2. 고유벡터 수에 따른 CDF
Table 2. CDF according to numbers of eigenvector.

고유벡터 수	CDF(%)
20	90.1204
41	95.0331
67	98.0800

포함수(CDF, Cumulative distribution function) 결과를 통해 얻는다.

표 2는 누적분포함수 값 중 일부에 대한 수치이다. 본 실험에서는 주성분분석의 특징벡터에 대한 누적밀도함수가 갖는 에너지를 98%이상 포함하는 특징벡터들만을 선택하고자 특징 벡터 수는 67개를 선택한다. 따라서, 주성분분석 결과인 고유벡터 가중 행렬(Principle Components Weighted Matrix) W_{PCA} 은 $4096 * 67$ 이 된다.

통계적 특징 추출 방법에서 에너지 보존만큼 입력 데이터의 상관관계의 고려 또한 특징 추출 기법에서 중요하게 고려되어야 할 사항이다. 이를 위해 PCA를 통해 2차 통계적 특징 추출된 결과에 LDA와 ICA를 수행한다.

PCA와 LDA의 혼합모델 PCA+LDA는 2차적 통계 특징 추출된 결과 영상을 각 클래스별 상관관계가 최소가 되게 하고, 클래스 내 상관관계는 최대가 하는 효과를 나타내게 된다. PCA 결과이며, LDA 입력 행렬인 V 를 정리하면 다음과 같다.

$$V = X W_{PCA} \tag{28}$$

PCA를 통해 1차적 통계 특성이 고려된 영상 V 를 LDA의 입력으로 이용한 PCA+LDA 혼합 모델의 결과 영상 K 는 식 (29)와 같다. 결과 영상인 그림 5는 PCA의 모든 주성분을 이용하였을 때의 PCA+LDA 혼합 모델의 결과를 나타내었다.

$$K = V W_{LDA}^T = X W_{PCA} W_{LDA}^T \tag{29}$$

PCA+LDA 혼합 모델은 LDA만을 이용한 그림 2에 비해 동일 문자들 사이의 유사성이 더욱 높아진 결과를 확인할 수 있다.

PCA+LDA 혼합 모델에 대한 성능 평가하면 그림 5와 같다.

LDA의 입력 행렬(PCA 결과) V 의 크기는 $100 * 67$ 이므로, 원래 PCA의 입력 대비 1.636%의 데이터 양이 줄어든 상태이다. 따라서 PCA+LDA 혼합 모델은 PCA만을 이용한 결과인 그림 4에 비해 그림 6과 같이 에너지의 집중도가 더 높아진 결과를 보임을 알 수 있다.

표 3은 PCA+LDA의 특징 벡터 수에 따른 전체 에너지의 포함 정도에 대한 성능을 나타내는 것이다. LDA 단계에서의 특징벡터의 수의 선택이 입력의 67개와 차이가 없는 65개에서 98%정도의 에너지를 포함한 결과




그림 5. PCA+LDA 혼합 모델 결과 이미지
Fig. 5. PCA+LDA Hybrid model result images




그림 6. PCA+LDA 거리
Fig. 6. PCA+LDA distance (a. Hamming distance, b. Euclidean distance, c. Cosine distance)

표 3. 특징벡터 수에 따른 CDF
Table 3. CDF according to numbers of feature vector.

특징벡터 수	CDF(%)
59	91.0026
64	96.9915
65	97.7496

를 보인다. 따라서 클래스별, 혹은 특징별 상관관계를 줄이고자하는 특징 추출 방법인 LDA는 2차적 통계적 상관관계가 제거된 이후에는 데이터의 압축이나 감소는 크게 고려되지 않게 된다.

본 논문에서는 추가적인 에너지 감소의 특성을 고려하기보다는 LDA 결과에 의한 통계적 특성의 효율성만을 고려하고자 추가적인 데이터 감소를 시키지 않았다.

2. PCA+ICA 혼합모델

PCA+ICA는 PCA의 결과 행렬 V 가 ICA의 입력이 되고, ICA를 통해 얻어지는 결과로 가중 행렬 W_{ICA} 를




그림 7. PCA+ICA 혼합 모델 결과 이미지
Fig. 7. PCA+ICA Hybrid model result images.

통해 구한다. 이는 2차 통계적 특성이 고려된 상태에 고차 통계적 특성을 이용하여 입력 데이터 사이의 상관 관계를 제거할 수 있다. 상관관계가 제거됨은 중복성이 제거된 것이고, 입력 데이터 각각이 가지고 있는 부분적인 특징이 남아 있음을 의미한다^[15].

PCA+ICA 혼합 모델의 결과 I 는 식 (30)과 같다.

$$I = V W_{ICA}^{-1} = X W_{PCA} W_{ICA}^{-1} \quad (30)$$

PCA+ICA 혼합 모델의 결과 이미지는 그림 7과 같다. 입력 영상과 매우 유사한 형태를 가지고 있다.

하지만, PCA를 통해 영상이 갖는 에너지가 감소된 특성을 갖는 가중 행렬이 고려되기 때문에 전체적으로 노이즈와 같은 부분적 훼손이 일어난 것과 같은 결과를 보인다. 또한 ICA의 문자간 독립성을 최대가 되도록 하는 가중행렬이 고려되어 오히려 일부 문자들 간의 구별이 모호해지거나, 다른 문자들과 오히려 더 유사해지는 결과를 보인다.

3. PCA+ICA+LDA 혼합 모델

PCA, ICA, LDA의 순차적인 적용을 통해 각 통계적인 특징 추출 방법이 갖는 단점들을 모두 제거하고자 하는 혼합 모델이다^[14].

2차적 통계 특성이 고려되고 개별 벡터간의 상관관계를 없애는 PCA+ICA 혼합 모델 I 의 결과에 각 클래스간의 분산을 최대화하는 LDA 가중행렬 W_{LDA} 을 혼합하는 것이다. PCA+ICA+LDA 혼합 모델의 결과 R 는 식 (31)과 같다.

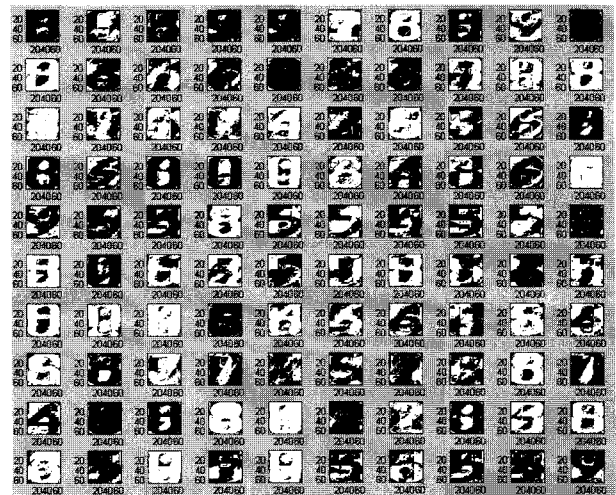


그림 8. PCA+ICA+LDA 혼합 모델 결과 이미지
Fig. 8. PCA+ICA+LDA Hybrid model result images

$$\begin{aligned} R &= I W_{LDA} = V W_{ICA}^{-1} W_{LDA}^T \\ &= X W_{PCA} W_{ICA}^{-1} W_{LDA}^T \end{aligned} \quad (31)$$

PCA+ICA+LDA 혼합 모델은 PCA+ICA 혼합 모델의 결과에 다시 LDA를 통해 문자간의 특성이 최대한 고려되도록 하는 모델이다. 이를 통해 문자간의 다른 특성만이 남게 된다.

그림 8과 같이 원 입력 영상의 시각적 결과와 매우 다른 결과를 보이지만, PCA+ICA+LDA 혼합 모델은 입력 데이터 특징을 포함하면서도 데이터량을 줄이고, 문자의 종류별 특성과 개별 문자의 특성이 모두 고려되기 때문에 효과적 특징 추출을 할 수 있다.

IV. 실험

제시된 통계적 특징 추출 방법들과 각 혼합 모델을 실제 번호판 특징 추출에 적용하여 성능 평가하여 최적의 통계적 특징 추출 모델을 선택하고자 하였다.

그림 9와 같이 PCA와 LDA의 경우, 단일 모델을 적용하였을 때도 데이터 에너지 집중화를 통해 데이터의 감소를 할 수 있다. 하지만, 통계적 특징 추출에서 상관관계를 고려한 PCA+LDA, PCA+ICA 혼합 모델을 통해 클래스 혹은, 개별 이미지 간의 중복성을 제거함으로써 상관관계를 더욱 효과적으로 제거된 것을 확인할 수 있다. 물론, PCA+LDA 혼합 모델의 경우, 이미 PCA 단계에서 데이터 압축이 일어났으므로, 데이터의 클래스 간, 클래스 내 분산을 최대하더라도 큰 성능 개선을 보이지

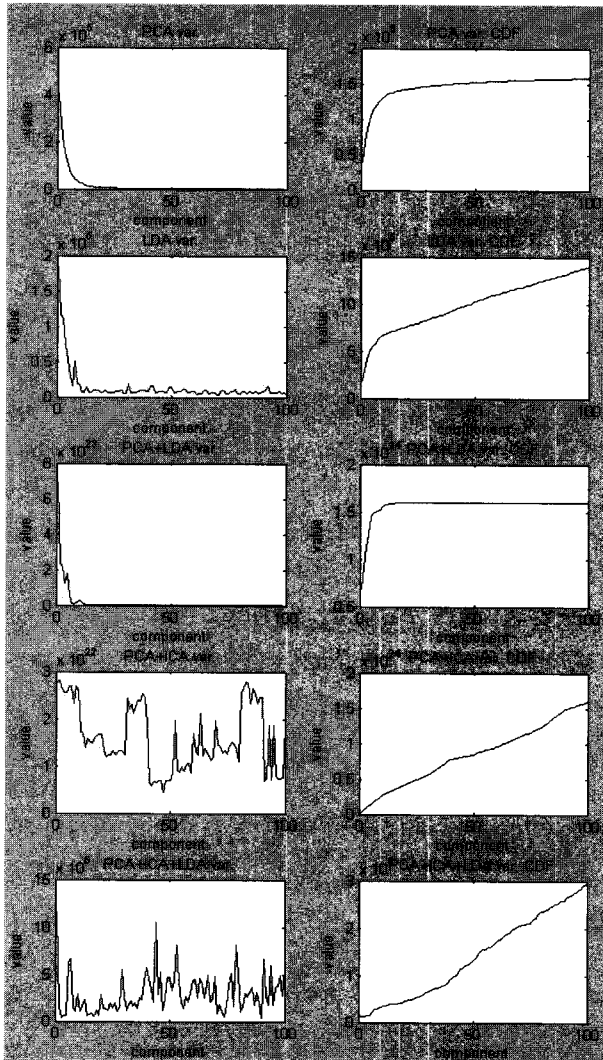


그림 9. 특징추출 방법별 분산과 분산 CDF 비교
 Fig. 9. Comparison of variance and variance's CDF from the feature abstraction models.

못하고, 다소 PCA보다 개선된 결과를 보여준다.

PCA+ICA 혼합 모델은 분산의 CDF를 보면 거의 선형적 형태를 보이고 있어 PCA+ICA+LDA 혼합 모델과 유사한 결과를 보여주고 있다. 하지만, 각 벡터들이 유사성이 떨어질수록 더욱더 산란된(scattered) 값을 보이는 분산 그래프를 비교하여 보면 PCA+ICA+LDA 혼합 모델의 결과가 PCA+ICA 혼합 모델보다 더 산란되어 있으며 이는 더 효과적으로 상관관계를 제거하였음을 알 수 있다.

앞의 특징들에 대한 고찰을 기반으로 각 특징 추출 모델들을 인식기에 적용하였다. 적용한 인식기는 신경망 모델 중 하나인 다층 퍼셉트론(Multi-Layer Perceptron)을 사용하였으며, 알고리즘은 역전파(Back-Propagation) 알고리즘을 이용하였다.^[18] 인식 성능을 분석하

표 4. 특징 추출 모델들의 신경망 인식 성능
 Table 4. Recognition performance of neural network of feature abstraction models.

특징 추출 모델	인식결과	인식률(%)	MSE
PCA	164/200	82	.0534
LDA	157/200	78.5	.0574
PCA+LDA	196/200	98	.0332
PCA+ICA	200/200	100	.0001
PCA+ICA+LDA	200/200	100	.0013

고자 사용 영상을 무작위로 선택된 자동차 영상에서 숫자별 50개씩을 선택한 총 500개의 숫자 영상을 대상으로 하였으며, 이 중 300개의 숫자 영상을 학습 데이터로 사용하고, 나머지 200개 숫자 영상을 인식 성능을 측정할 테스트 데이터로 사용하였다.

표 4는 신경망의 파라미터로 학습률 0.01, 모멘텀 0.90을 준 인식기에서의 결과이다. 자동차 번호판 숫자 영상을 대상으로 하였을 때의 인식률을 보면, 혼합모델들이 단일 모델에 비해 전체적으로 높은 인식 성능을 보이며, 세 가지 혼합모델 중 PCA+ICA 혼합 모델과 PCA+ICA+LDA 혼합 모델이 입력된 이미지 200장 모두를 인식하는 성능을 보인다.

이는 두 혼합모델이 특징 추출에 대한 분산의 산란정도를 분석했던 결과와 같이 입력 이미지간의 산란정도가 다른 모델에 비해 우수함에 따라 효과적인 각 이미지별 특징 추출되어 인식에 있어서도 보다 좋은 결과를 보임을 나타낸 것이다.

V. 결 론

PCA를 통한 2차 통계적 특징 추출 이후에, ICA의 적용은 각 입력 이미지 사이의 독립성분을 찾아 상관관계를 줄이고자 하는 특징 추출 방법으로써 LDA를 적용한 것에 비해 더 세분화되고, 개별적 통계적 상관성을 제거하는 방법이다. 따라서 2차 통계적 특성이 제거된 번호판 이미지의 특징 추출 후에 ICA를 적용함으로써 개별 이미지가 가지고 있는 상관관계를 보다 효율적으로 제거할 수 있다. PCA+ICA 혼합 모델 이후에 LDA를 적용함으로써 보다 개별 숫자들의 산란성이 높아진 결과를 얻을 수 있다.

추후 과제로 어떤 특징 추출 모델들이 부분적으로 훼손된 번호판의 숫자 영상을 대상으로 하는 인식 시스템에서 최적의 성능을 보이는지 확인하여야 한다.

참 고 문 헌

[1] C. J. Shang and K. Brown, "Principal Feature-Based Texture classification with Neural Networks," *Pattern Recognition*, Vol. 27, No. 5, pp.675-687, 1994.

[2] 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

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

[4] Martin T. Hagan, Howard B. Demuth, Mark Beale, *Neural network Design*, Chapman & Hall, pp.11_01-11_47, 1996.

[5] Aleix M. Martinez and Avinash C. Kak, "PCA versus LDA," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 2, pp.228-233, February 2001.

[6] P. N. Belhumeur, J. P. Hespanha, D. J. Kriegman, "Eigenfaces vs. fisherfaces: recognition using class specific linear projection," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 19, pp. 711-720, 1997.

[7] W. Zhao, R. Chellappa, and A. Krishnaswamy, "Discriminant Analysis of Principal Components for Face Recognition," *Third IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 336-341, April 1998.

[8] Jian Yang, Jing-yu Yang, "Why can LDA be performed in PCA transformed space?," *Pattern Recognition*, Vol. 36, pp. 563-566, 2003

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

[10] S. Roberts and R. Everson, *Independent Component Analysis*, John Wiley & Sons, Inc. 2001.

[11] A. Hyvarinen, and E. Oja, "Independent Component Analysis: Algorithms and Application," *Neural Networks*, Vol. 12, pp 411-430, 2000.

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

[13] A. Hyvarinen, "Fast and Robust Fixed-Point Algorithm for Independent Component Analysis," *IEEE Trans. on Neural Networks*, Vol. 10, No 3, pp 626-634, 1999

[14] K.-C. Kwak, W. Pedrycz, "Face Recognition Using an Enhanced Independent Component Analysis Approach," *IEEE Trans. on Neural Networks*, Vol. 18, No. 2, March 2007

[15] I. Dagher and R. Nachar, "Face Recognition Using IPCA-ICA Algorithm," *IEEE Trans. on PAMI*, Vol. 28, No. 6, June 2006

[16] S. Sener, M. Unel, "A New Affine Invariant Curve Normalization Technique Using Independent Component Analysis," *The 18th International Conference on Pattern Recognition*, 2006

[17] Fizwan A. Choudrey, *Variational Methods for Bayesian Independent component Analysis*, Ph.D thesis, University of Oxford, 2002.

[18] 박경수, 강현철, 이완주, "고유 숫자를 이용한 번호 판 숫자 인식," *전자공학회논문지*, 44권, SP편 3호, pp.1-7, 2007.

[19] 김종선, 이준호, "개선된 ICA 기저영상을 이용한 국부적 왜곡에 강인한 얼굴 인식," *정보과학회논문지*, 33(5), 2006.

[20] 정병준, 강현철, "FP-ICA를 이용한 자동차 번호판 숫자의 특징 추출," *한국통신학회 하계종합학술발표회*, 33, pp.337, 2007.

[21] 조용현, 윤중환, 박용수, "조합형 학습알고리즘의 신경망을 이용한 데이터의 효율적인 특징추출," *정보처리학회논문지*, 8B(2), pp.130-136, 2002.

[22] 김현철, 김대진, 방승양, "PCA 혼합 모형과 클래스 기반 특징에 의한 LDA의 확장," *정보과학회논문지*, 소프트웨어 및 응용 32(8), pp.781-788, 2005.

저 자 소 개



정 병 준(정회원)
 2007년 인천대학교 정보통신 공학과 학사 졸업
 2009년 인천대학교 정보통신 공학과 석사 졸업
 <주관심분야 : 영상처리, 패턴인식, 컴퓨터 비전>



강 현 철(정회원)-교신저자
 대한전자공학회 논문지 44권 SP편 3호 참고