

하이브리드 통계적 특징 모델과 신경망을 이용한 자동차 번호판 인식

(Recognition of License Plates Using a Hybrid Statistical Feature Model and Neural Networks)

유 신 [†] 정 병 준 ^{**} 강 현 철 ^{***}
 (Sheen Lew) (ByeongJun Jeong) (Hyunchul Kang)

요약 자동차 번호판 인식 시스템은 문자 추출, 특징 추출 등의 영상처리와 추출된 문자를 인식하는 인식기로 구성된다. 특징 추출은 문자 영역의 데이터 감소뿐만 아니라 인식 성능을 결정한다. 따라서 본 논문에서는 번호판 인식의 결과에 영향이 큰 숫자 인식, 특히 숫자의 특징 추출에 초점을 두었으며, 데이터의 군집성을 재배치하여 데이터 간의 최적의 산란도를 확보할 수 있는 통계적 특징의 혼합 모델을 제안하고, 이를 다중 퍼셉트론과 LVQ 신경망을 이용하여 유효성을 검증하였다. 제안된 통계적 특징 추출 방법은 번호판 영상이 갖는 정보를 가장 잘 유지하고, 접음과 외부 환경에 강건하며 효과적인 방법임을 보여준다.

키워드 : 자동차 번호판, 통계적 특징, 독립성분분석, 숫자 인식, 신경망

Abstract A license plate recognition system consists of image processing in which characters and features are extracted, and pattern recognition in which extracted characters are classified. Feature extraction plays an important role in not only the level of data reduction but also performance of recognition. Thus, in this paper, we focused on the recognition of numeral characters especially on the feature extraction of numeral characters which has much effect in the result of plate recognition. We suggest a hybrid statistical feature model which assures the best dispersion of input data by reassignment of clustering property of input data. And we verify the effectiveness of suggested model using multi-layer perceptron and learning vector quantization neural networks. The results show that the proposed feature extraction method preserves the information of a license plate well and also is robust and effective for even noisy and external environment.

Key words : license plate, statistical feature, independent component analysis, numeral character recognition, neural network

1. 서 론

· 이 논문은 인천대학교 2008년도 자체 연구비 지원에 의하여 연구되었음

[†] 정 회 원 : 인천대학교 정보통신공학과
 ys9072@paran.com

^{**} 정 회 원 : (주)로봇에버 HRI Lab 연구원
 magicblu@paran.com

^{***} 정 회 원 : 인천대학교 정보통신공학과 교수
 hckang@incheon.ac.kr
 (Corresponding author)

논문접수 : 2009년 9월 11일
 심사완료 : 2009년 10월 9일

Copyright©2009 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지 : 소프트웨어 및 응용 제36권 제12호(2009.12)

영상 인식 시스템은 보안, 감시, 외관 검사, 자동화 등의 다양한 분야에서 사용되고 있다. 이러한 영상 인식 시스템은 전처리, 특징 추출과 인식기로 구성된다. 문자와 같이 구조적 특성을 갖는 경우, 획과 같은 구조적 특징과 이런 특징의 공간상에서의 관계를 이용하여 문자를 인식하기도 한다. 그러나 일정한 구조를 정의하기가 쉽지 않거나, 변형을 허용하는 경우, 통계적인 특징을 많이 사용하며, 대표적인 통계적 특징으로는 주성분분석(principal component analysis, PCA), 선형판별분석(linear discrimination analysis, LDA), 독립성분분석(independent component analysis, ICA) 등이 있다. 본 논문에서는 도로상의 과적 화물 차량을 대상으로 차량

번호판인식을 하는 경우를 위하여, 조명의 변화 등의 일 반적인 승용차량에서의 영상 자체 왜곡뿐만 아니라, 의도적인 물리적 왜곡, 즉 클리핑이나 흐어짐 등의 정도가 큰 경우를 포함한, 보다 다양한 숫자 패턴에 효율적으로 대처하기 위해, 이러한 개별 통계적 특징의 장점을 살리면서, 기존 모델의 단점을 극복하고자 통계적 특징의 혼합 모델을 제안하며, 대표적인 신경망인 다중 퍼셉트론 (multi-layer perceptron)과 교사 학습이 가능하며, 학습이 빠르며, 구현이 용이한 Learning Vector Quantizer를 이용하여 제안한 특징의 유효성을 비교, 검증하고자 한다.

2. 번호판 인식 시스템 개요

차량 번호판의 인식은 차량 전면부 영상으로부터 먼저 번호판 영역의 추출, 문자 추출들을 포함하는 전처리 단계와 문자 분류와 문자 인식을 포함하는 인식단계로 이루어진다. 각 단계는 상호 작용이 가능하도록 구성한다. 즉, 전단계의 오류가 다음 단계에서 판명되어지면 전단계의 작업을 재조정할 수 있도록 하여 인식의 효율을 높일 수 있도록 한다.

알고리즘의 전체적인 구성은 그림 1과 같다.

전처리 과정으로 서브 샘플링을 한 후, 차영상으로부터 번호판 후보영역을 추출한다. 저주파 영상은 원 영상에 5*5 평활화 필터를 적용하여 얻었다. 이렇게 얻어진 차영상은 밝기 분포에 적응적으로 다중 이중화 영상을 얻기 위해 다중 이진화 임계치로 이진화하였다.

그림 2는 이진화결과를 나타낸다. 이진화된 영상에서 숫자영역에 해당하는 부분을 얻어낸 후, 얻어진 숫자영역이 번호판의 숫자에 해당하는지를 확인하기 위해, 번호판 내에 존재하는 숫자영역들 중에는 적어도 2개 이상의 이웃을 가진 숫자영역이 존재하며, 이웃으로 판별된 숫자영역들의 크기는 동일하고, 이웃이라고 판별된 숫자영역들에서 수직, 수평으로 일정거리 이내에 수직에

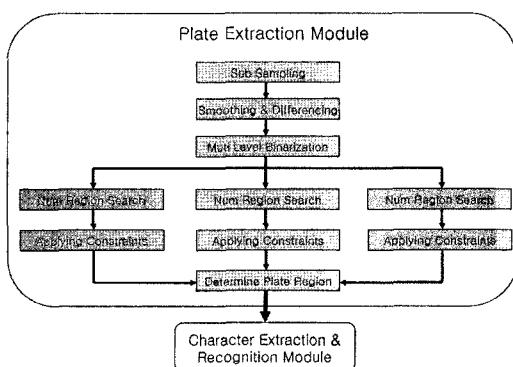


그림 1 번호판 추출 알고리듬 흐름도

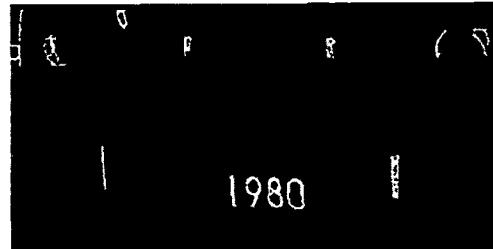


그림 2 추출된 숫자영역 후보

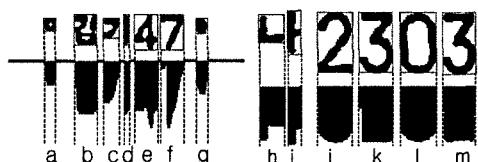
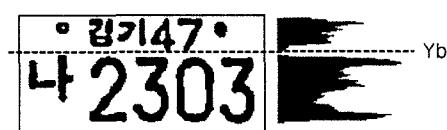


그림 3 문자 영역의 절취

지와 수평에지가 존재한다는 제약조건들을 적용하여 번호판영역을 추출한다. 이진화된 번호판 영상에는 여전히 잡음이 섞여있는 상태이므로 영상 내에서 문자들을 추출해 내는 것이 용이하지 않다.

그림 3은 추출한 번호판 영역으로부터 문자영역을 추출하는 과정으로, 번호판 영상을 6가지 형태로 구분하여 유형별 문자 위치 특성을 고려한 경험적 규칙을 활용함으로써 문자 추출 효율을 높였다. 본 논문에서는 이러한 과정을 통해 추출된 번호판 숫자영역을 대상으로 한 숫자인식을 다루게 된다[1].

3. PCA, ICA, LDA

3.1 PCA

주성분 분석(principal component analysis, PCA)은 고차원의 데이터를 정보의 손실을 최소화하면서 저차원의 데이터로 선형 사상하여 표현하는 방법이다[2].

주성분 분석은 다변량 자료의 총 변이를 주성분이라는 축약된 양을 통해 해석함으로써 다차원 변수들을 단순화 시키고, 서로 상관있는 변수들 간의 내적 구조를 분석하는 데 목적이 있다. 이를 위해 주성분 분석은 고유 영상들의 선형 결합으로 변환시켜서 주성분이라고 부르는 서로 독립적인 변수들을 유도한다. 여기서, 각 주성분이 가지는 변이의 크기를 기준으로 중요도를 생각할 때, 처음 몇 개의 주성분이 원래 자료에 내재하는

총 변이의 많은 부분을 포함하기 때문에 차원의 축약을 기할 수 있다. 즉, 전체 영상의 데이터를 가지고 그것들의 분산이 큰 몇 개의 고유 방향에 대한 축으로 선형 투영하여 차원을 줄이는 방법이다.

PCA 변환을 했을 때 주성분의 최대수는 원래 영상 공간상의 픽셀의 수이다. 그러나 영상의 차원을 줄이기 위해서 몇 개의 주성분들은 생략될 수 있다. 즉, 고유값을 크기가 감소하는 순으로 배열했을 때, 마지막 몇 개의 고유값을 생략하면 정보의 큰 손실 없이 차원을 줄일 수 있다. 특히 PCA에서 고유값은 지수 함수처럼 급속히 감소되기 때문에 마지막 몇몇 주성분들을 생략하더라도 원래 영상과의 오차가 매우 적다.

숫자 공간(number space)상의 특징 정보는 인식 단계에서 매우 중요한 요소이다. 학습 집합 내의 공분산 행렬은 평균 영상과 각 개인 영상의 차 벡터와 차 벡터를 전치시킨 벡터의 내적으로 계산되며, 각 화소들의 상관관계를 나타내는 행렬이다. 공분산 행렬에서 구한 고유값(eigenvalue)은 분산을 의미하며, 각 고유치에 대응되는 벡터를 고유벡터(eigenvector)라 하며, 큰 고유값에 대응되는 고유벡터 일수록 숫자와 유사하고, 작은 고유값에 대응되는 고유벡터 일수록 잡음 성분이 많이 포함되어 있다.

$$C = \frac{1}{M} \sum_{i=1}^M \Phi_i \Phi_i^T \quad (1)$$

식 (1)의 C 는 $N^2 \times N^2$ 의 고차 행렬이다. 식 (1)에서 M 개의 고유값 λ_i 와 그에 대응하는 고유벡터 u_i 는 식 (2)에 의해서 구할 수 있다.

$$Cu_i = \lambda_i u_i \quad (2)$$

고유벡터의 개수 선택은 분산과 누적분포를 통해 실증적으로 구했다. 표 1은 고유 숫자의 개수에 따른 설명력을 나타낸 것으로, 표 1에서 보는 것과 같이 고유 숫자의 개수가 100개만 되더라도 전체 학습 패턴의 93.53%를 설명하고 있는 것을 알 수 있다. 본 논문에서는 자동차 번호판의 인식률을 높이기 위해 영상 데이터의 차원의 축약 보다는 각 숫자의 특징 정보를 잘 표현할 수 있는 고유 숫자의 개수 설정에 비중을 두어, 99.52%를 설명할 수 있는 400개의 고유 숫자를 선택하였다.

표 1 고유 숫자의 개수에 따른 설명력

개수	100	200	300	400	4096
설명력(%)	93.53	96.71	98.43	99.52	100

3.2 ICA

ICA는 PCA의 고유성분에 대한 특성 모델을 비가우시안 통계적 특성을 통해 다차원 분해 및 투영을 하고 이를 극복하고자 하는 방법이라 할 수 있다[3]. 이를 기

학적으로 고려하여 보면 PCA가 전치(translational)에 대한 특성을 이용하여 이미지 간의 특성을 저차 성분만으로 분해함으로써, 차원의 감소를 수반하여 고려할 수 있음을 알 수 있다. 이런 특성은 고차 통계적 특성을 고려하지 않음을 의미한다. 이런 특성을 극복하기 위해 ICA는 고차 통계적 특성을 이용하여 이미지 간 독립성을 확보하고 이미지의 특성을 분해하며 이는 결국 기하학적으로 이미지의 공간적인 상관관계를 고려하여 회전에 강건한 특성을 가질 수 있도록 하고 있다. ICA를 효과적으로 수행하기 위해 혼합 신호를 대상으로 영 평균과 백색화의 전처리 과정을 수행한다. 이는 신호의 1차와 2차의 통계적 특성을 고려한 정규화로 학습 알고리즘을 간략화하기 위해서 사용된다. 먼저 영 평균(centring)은 1차 정규화로 신호 벡터 x 에서 평균값 x' 를 뺀 차로 구한다. 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. 주성분분석에서 사용하는 고유벡터 분해를 이용하여 2차 정규화를 한다.

$$\tilde{x} = ED^{-1/2} E^T x \quad (3)$$

직교 특성을 가지도록 고유치 분해에 의해 구성된 새로운 행렬 \tilde{A} 를 정의하면,

$$E[\tilde{x}\tilde{x}^T] = \tilde{A}E[ss^T]\tilde{A}^T = \tilde{A}^T = I \quad (4)$$

이 되며, 본 논문에서는 고정점 알고리즘을 이용하여 ICA의 해를 구하였다. 고정점 알고리즘에서 도함수 계산의 제약을 해결하기 위한 근사화 기법으로는 할선법을 사용하였으며, 최종 생신식은 식 (5)와 같다.

$$W_{k+1} = W_k - f(W_k) \frac{W_k - W_{k-1}}{f(W_k) - f(W_{k-1})} \quad (5)$$

본 논문에서는 3차 함수를 이용하여 구현한다. 할선법을 이용한 최종 생신된 특징 추출 벡터 $W_{ICA} = w$ 가 되며, ICA에 의해 재해석된 입력은 식 (6)과 같다.

$$P = W_{ICA} X \quad (6)$$

3.3 LDA

LDA모델은 PCA, ICA 모델들과는 달리 산란행렬(scatter matrix)을 구성하는 과정에서 같은 특징 값들의 간격은 최소화하고, 다른 특징들 간의 간격은 최대화시키는 방향으로 선형 변환한 후, 산란행렬을 학습함으로써 이미지간의 상관관계를 제거한다. 이는 결과적으로 기하학적으로 특징의 공간적 배치에 대한 크기에 대한 정규화 된 특성을 고려하는 방법이라 할 수 있다[4].

산란행렬을 구성하는 과정은 같은 클래스 내(within class)의 분산 S_w 을 최소화하고 다른 클래스 사이(between class)의 분산 S_b 은 최대화 시키는데 목적이 있다. 클래스 내 분산과 클래스 간 분산을 수식화하면 식

(7)과 식 (8)로 정리된다.

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

v_i : i 번째 클래스의 입력 벡터

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

μ : 전체 평균 벡터, μ_i : i 번째 클래스의 평균 벡터

여기서, μ 는 전체 평균 벡터이고, μ_i 는 i 번째 클래스의 평균 벡터이고, v_i 는 같은 클래스의 입력 벡터이다. $Pr(C_i)$ 는 클래스 C_i 의 선형 확률(a priori probability)이며, FLD(Fisher linear discriminant classifiers)를 사용한 기법은 변환 행렬 W 의 최적해 W_{opt} 를 구한다. 최적해 W_{opt} 를 구하는 문제는 고유값 문제 해결에 따라 사상행렬의 값을 구하는 것으로 귀결된다.

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

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

$$W_{LDA} = [u_1, u_2, \dots, u_q] \quad (10)$$

식 (10)이 되고, LDA에 의해 재해석된 입력 Z 는 식 (11)과 같다.

$$Z = X W_{LDA}^T \quad (11)$$

4. 혼합 모델

일반적으로 사용되는 통계적 특징 모델인 PCA, LDA, ICA가 가지고 있는 특징의 특성에 따라 발생되는 문제점을 해결하기 위해 이들의 혼합 모델을 이용하여 특징을 추출한다. 즉, PCA, ICA, LDA의 순차적인 적용을 통해 각 통계적인 특징 추출 방법이 갖는 단점을 모두 제거하고자 하는 것이 혼합 모델이다[5,6]. 이는 각각의 ICA, LDA, PCA 모델의 측면에서 별개로 접근하여 처리하게 되면, 영상에 있어 기본적으로 고려하는 기하학적 3대 요소인 회전(rotation), 크기(scale), 전치(translation)를 각기 따로 고려하게 되는 것이며, 개별적인 영상 요소를 고려하는 것이 이미지의 특징 추출 단계에서 복합적이거나 혼합적으로 이를 요소를 고려하는 것 보다, 이미지가 가지는 기하학적인 특징을 효율적으로 고려하는 것이라 할 수 없다. 특징 추출의 기본적인 성능은 기존의 이미지가 가지는 특성을 가장 잘 표현할 필요가 있을 뿐 아니라, 원래 데이터에 대한 설명력을 충분히 가져야 한다. 설명력의 근거를 이미지의 기하학적 해석에 의한 특징 추출에 관점에서 보면 혼합 모델은 개별 모델에 비하여 그 성능적인 측면에서 장점을 가질 수 있게 된다. 이러한 혼합모델은 2차적 통계

특성을 고려하기 위하여, PCA의 가중 행렬 W_{PCA} 을 결정하고 개별 벡터간의 상관관계를 제거하기 위해 ICA의 가중 행렬 W_{ICA} 를 구하고, 각 클래스간의 분산을 최대화하는 LDA 가중 행렬 W_{LDA} 을 혼합하는 것이다.

PCA+ICA+LDA 혼합 모델의 결과 R 는 식 (12)와 같다.

$$\begin{aligned} R &= I W_{LDA} = V W_{ICA}^{-1} W_{LDA}^T \\ &= X W_{PCA} W_{ICA}^{-1} W_{LDA}^T \end{aligned} \quad (12)$$

PCA+ICA+LDA 혼합 모델은 입력 데이터 다양한 특징을 대부분 포함하면서도 데이터량을 줄이고, 문자의 종류별 특성과 개별 문자의 특성이 모두 고려됨으로써 특징을 효율적으로 표현할 수 있다.

그림을 통하여서도 각 혼합 모델간의 특성차이를 알 수 있도록 하였다. 그림 4에 PCA+LDA를 나타내었다. 이는 PCA만을 이용한 결과 보다 에너지의 집중도가 높아짐을 알 수 있다. 그림 5에는 PCA+ICA를 나타내었다. 이는 PCA를 통해 영상이 갖는 에너지가 감소된 특성을 갖는 가중 행렬이 고려됨으로 인해 전체적으로 노이즈와 같은 부분적 희손이 일어난 것과 같은 결과를 보인다. 또한 ICA의 문자간 독립성을 최대가 되도록 하는 가중 행렬이 고려되어 오히려 일부 문자들 간의 구별이 모호해 지거나, 다른 문자들과 오히려 더 유사해지는 결과를 보인다. 그림 6의 PCA+ICA+LDA 혼합모델은 PCA+ICA 혼합모델의 결과에 다시 LDA를 통해 문자간의 특성이 최대한 고려 되도록 한 모델로서 문자간의 다른 특성만 남게 된다. 그림의 결과를 통하여 데이터의 양은 줄이고, 문자의 종류별 특성과 개별 문자의 특성이 모두 고려됨으로써 효과적 특징 추출을 함을 알 수 있다.

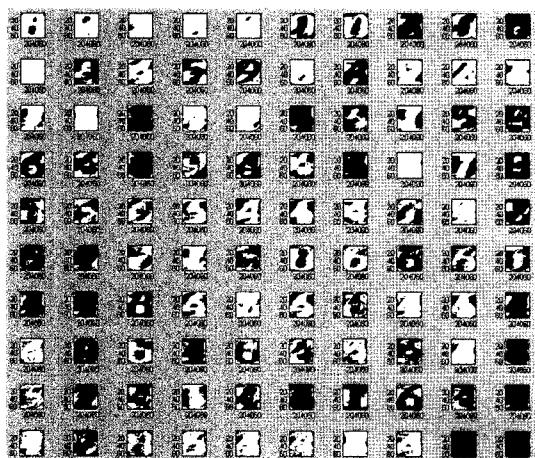


그림 4 PCA+LDA 혼합 모델 결과 이미지

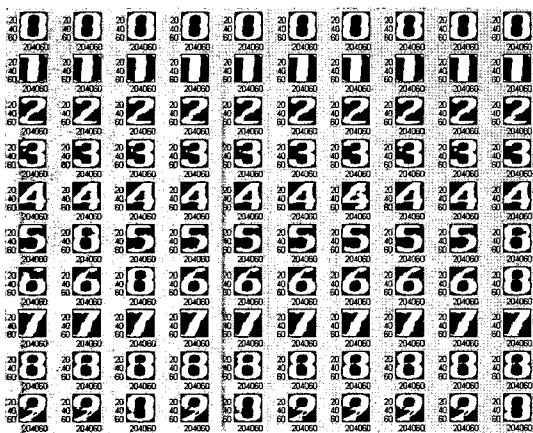


그림 5 PCA+ICA 혼합 모델 결과 이미지

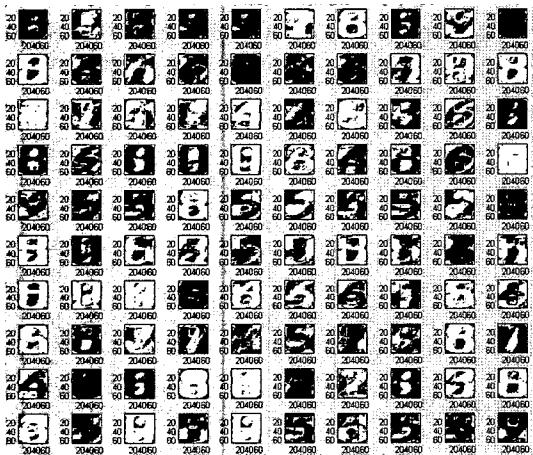


그림 6 PCA+ICA+LDA 혼합 모델 결과 이미지

아울러 기존 모델에 비하여 혼합 모델이 갖게 되는 장점은 그림 7에 나타난 각 개별 모델의 분산 값의 그래프를 통해서도 알 수 있다. 그림 7에서 PCA와 LDA의 경우, 단일 모델을 적용하였을 때도 데이터 에너지 집중화를 통해 데이터가 감소함을 알 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 최대화 하더라도 큰 성능 개선을 보이지 못하고, PCA보다 다소 개선된 결과를 보여준다. PCA+ICA 혼합 모델은 분산의 CDF를 보면 거의 선형적 형태를 보이고 있어 PCA+ICA+LDA 혼합 모델과 유사한 결과를 보여주고 있다.

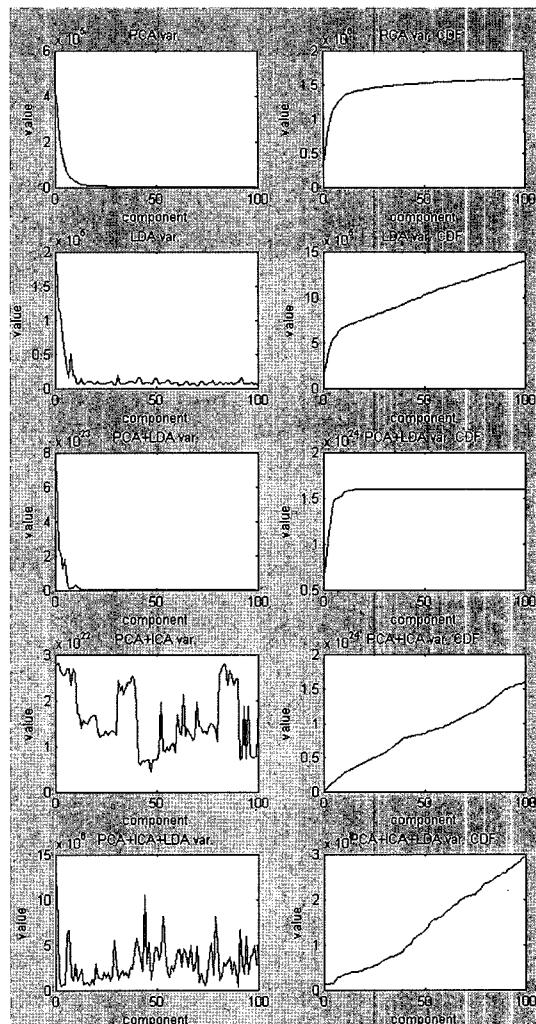


그림 7 특징추출 방법별 분산과 분산 CDF

하지만, 각 벡터들이 유사성이 떨어질수록 더 산란된 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.

5. 신경망

5.1 Learning Vector Quantization

LVQ 신경망은 지도 학습(supervised learning)과 비지도 학습(unsupervised learning)이 모두 가능한 방식으로, 학습이 빠르고, 연산양이 적어 실시간성을 갖는 신경망이다[7]. 입력 벡터 x 가 신경망에 입력되면, 중심 벡터와 x 의 유클리디언 거리를 기반으로 출력 뉴런들이 경쟁을 벌여 입력 벡터와의 거리가 가장 작은 한 개의

뉴런이 출력되며, 이 뉴런을 승리 뉴런이라 한다. 뉴런에 클래스가 할당된 경우, 승리 뉴런의 클래스가 출력이 된다. LVQ 신경망은 경쟁 시 신경망이 형성하는 결정 경계를 베이시안 최적 결정 경계에 접근하도록 고안된 방법이며, LVQ 신경망의 교사 학습 알고리즘으로는 LVQ1, LVQ2, LVQ3 등 여러 가지 학습 알고리즘이 있다.

본 논문에서는 LVQ2 학습 알고리즘을 이용하여 신경망을 학습한다. LVQ2는 두 개의 중심 벡터에 의해 형성되는 결정 경계를 베이시안 최적 경계에 가까워지도록 하기 위해 한 번에 두 개의 출력 뉴런의 연결 벡터를 갱신하는 방법이다.

LVQ2의 학습 과정은 다음과 같다. 입력 벡터 x 에 대해 두 개의 승리 뉴런(class i , class j)의 중심 벡터, 즉 벡터 x 와 거리가 가장 가까운 두 개의 중심 벡터 $v_i(t)$ 와 $v_j(t)$ 를 찾는다. 가중치 벡터들은 x 의 승리 뉴런의 중심 벡터 클래스가 $v_i(t)$ 와는 다르고 $v_j(t)$ 와 같은 경우에만 갱신되며 갱신하는 방법은 식 (13)과 식 (14)로 표현된다. 이때 식 (13)의 $+a$ 를 increasing rate, 식 (14)의 $-a$ 를 decreasing rate라 한다.

$$v_i(t+i) = v_i(t) + \alpha(t)(x - v_i(t)) \quad (13)$$

$$v_j(t+i) = v_j(t) - \alpha(t)(x - v_j(t)) \quad (14)$$

이때 입력 벡터 x 는 $v_i(t)$ 와 $v_j(t)$ 의 원도우 안에 존재하여야 한다. 입력 벡터 x 가 원도우 내부에 존재하는지의 여부는 두 가중치 벡터 사이의 길이에 대한 원도우의 상대적인 폭을 w 라고 할 때, 식 (15)에 의해 결정 경계 s 가 결정된다.

$$\min\left(\frac{d_i}{d_j}, \frac{d_j}{d_i}\right) > s, s = \frac{1-w}{1+w} \quad (15)$$

LVQ 신경망 학습을 통해 최적의 클래스 중심 벡터를 찾을 수 있다. 학습된 클래스의 중심 벡터와 입력 벡터 간의 유clidean 거리 d_i, d_j 를 비교하여 번호판 문자인식에 적용한다.

5.2 다층 퍼셉트론

다층 퍼셉트론(multi-layer perceptron, MLP)에서 일반적으로 많이 사용하는 학습 알고리즘은 역전파 알고리즘(back-propagation algorithm)으로 이는 목표 출력과 네트워크의 실제 출력 차의 자승의 합을 목적 함수로 하여 그 목적 함수의 최소치를 스텝 폭 고정의 최급 강하법(steepest descent method)으로 구하는 것이다 [8]. 최소치를 계산하는 알고리즘은 이외에도 Newton's method, conjugate gradient method, Levenberg-Marquardt algorithm과 같은 간접 탐색법과 nongradient인 Powell 방법과 같은 직접 탐색법으로 나뉜다.

역전파 알고리즘의 문제점으로는 지역 최소점으로 잘못 수렴되거나, 훈련 시간이 많이 소요되는 것이 있다.

초기 상태에 대한 선택에 따라 발산이나 진동을 하는 문제점을 해결하고자 경험적 기술과 수치 최적화 기술로 구분하여 연구되고 있다. 경험적 기술로는 학습률을 가변하는 방법, 모멘텀법, 변수들의 재 스케일링, 다층 신경회로망의 구조적으로 접근하여 은닉층과 개별층의 수를 조절하는 방법이 있다.

특히 모멘텀법은 오차 함수가 2차 함수로 충분히 균사할 수 있는 영역에서는 비선형 최적화법을 이용하는 방법으로 수렴 시간이 오래 걸린다는 단점이 있지만, 알고리즘이 간단하며 설정하는 파라미터의 수가 적은 특징을 보여 많은 응용에서 사용된다.

6. 실험

본 논문에서 제시하는 통계적 특징의 유효성을 검증하기 위하여 통계적 특징 추출 혼합 모델을 실제 번호판 특징 표현에 적용하고 추출된 특징 추출 결과를 신경망에 입력하여 성능 평가를 하였다. 통계적 특징 추출에서 상관관계를 고려한 PCA+LDA+ICA 혼합 모델을 통해 클래스 혹은, 개별 이미지 간의 중복성을 제거함으로써 상관관계를 더욱 효과적으로 제거된 것을 확인할 수 있었다. 인식 성능 분석에 사용한 영상은 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. 신경망의 파라미터로 학습률을 0.01, 모멘텀을 0.90로 설정하였다.

자동차 번호판 숫자 영상을 대상으로 하였을 때의 인식률을 분석하면, 혼합 모델들이 단일 모델에 비해 전체적으로 높은 인식 성능을 보이며, 세 가지 혼합 모델 중 PCA+ICA 혼합 모델과 PCA+LDA+ICA 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 우수함을 의미하며, 따라서 이미지별로 효과적으로 특징이 추출되어 인식에 있어서도 보다 좋은 결과를 나타낸 것이다. 실험 결과는 인식 방법에 따라 표 2와 표 4, 표 5에 정리하였다.

표 2의 다층 퍼셉트론 신경망의 인식 결과는 PCA+ICA의 혼합 모델이 가장 좋은 성능을 보임을 알 수 있다.

표 3에는 LVQ에 사용된 상세 파라메터를 나타내었다. Case A는 가중치 행렬(weighted matrix)의 증가 갱신율(increase update rate)이 감소 갱신율(decrease update rate) 보다 낮은 경우를 말하며, Case B는 반대의 경우를 말한다. 먼저 표 4의 결과를 얻은 후, 이를 바탕으로 반복 횟수의 최적화를 통해 거의 동일한 결과를 얻으면서도, 실행 시간은 대폭 줄일 수 있었다.

표 2 다중 퍼셉트론 인식 결과

Feature Model	Result	%	MSE	Epochs
PCA	164/200	82	0.0534	X
LDA	157/200	78.5	0.0574	X
PCA+LDA	196/200	98	0.0332	X
PCA+ICA	200/200	100	0.0001	483
PCA+ICA +LDA	200/200	100	0.0013	454

표 3 LVQ 학습 파라메터

competitive layer (subclass) : 80 * 300,
linear layer (target class) : 10 * 1

LVQ Learning parameter	α inc	α dec	epochs
case A	0.015	0.2	200
case B	0.5	0.2	100

표 4 LVQ 인식 결과 : Case A

Model \	Result	%	Dimension Reduction	Processing Time (sec)
PCA	184/200	92	=98%	9.125
LDA	184/200	92	0%	156.907
PCA+LDA	179/200	89.5	=98	9.219
PCA+ICA	180/200	90	=98%	9.109
PCA+ICA +LDA	181/200	90.5	=98%	9.016

표 5 LVQ 인식 결과 : Case B

Model \	Result	%	Dimension Reduction	Processing Time (sec)
PCA	165/200	82.5	=98%	5.110
LDA	186/200	93	0%	80.485
PCA+LDA	163/200	81.5	=98%	5.062
PCA+ICA	180/200	90	=98%	5.125
PCA+ICA +LDA	185/200	92.5	=98%	5.094

BP-MLP와 LVQ의 인식 결과를 비교, 정리하면, PCA+ICA+LDA 혼합 모델이 시간과 인식 성능을 고려했을 때에 가장 우수하다. 인식률만 보면, LDA 단일 모델이 가장 높은 인식 결과를 보이지만 원 영상의 모든 요소를 이용하여, 가장 긴 처리 시간(약 16 배)이 소요된다. 따라서 처리 시간에 대비한 인식 성능은 결코 높다 할 수 없다.

모든 특징 추출 모델이 훈련 반복 횟수에 민감하지 않는 결과를 보였으며, PCA+ICA+LDA 혼합 모델의 경우, 학습 성능은 학습 반복수에 반비례하였다.

LVQ의 학습 시에는 가중치 행렬의 증가 개선율이 감소 개선율보다 낮은 경우, 단일 특징 추출 모델의 성능이 더 좋아지는 경향을 보이고, 반복 횟수에 무관한 성

능을 보였으며, 가중치 행렬의 증가 개선율이 감소 개선율 보다 높은 경우, PCA+ICA+LDA 혼합 모델만이 파라메터에 관계없이 성능이 좋아짐을 알 수 있다. 따라서 LVQ는 모델에 따라 표 4, 5에서와 같이 성능뿐 만이 아니라 시간 면에서 탁월한 성능을 보였다.

7. 결 론

본 논문에서는 숫자의 특징 추출을 위하여 데이터간의 최적의 산란도를 확보할 수 있는 통계적 특징의 혼합 모델을 제안하였으며, 이는 특징 값의 차원을 감소시키면서도, 개별 문자간의 고유 특징 성분을 잘 유지하여, 화물 차량의 차량 번호판과 같이, 왜곡의 정도가 심한 경우의 입력 영상에 대하여서도 강건함을 갖게 됨으로써, 자동차 번호판 숫자인식에 효과적인 방법임을 실험을 통해 검증하였다. 아울러 최종 인식 프로세스를 BP-MLP와 LVQ를 각각 사용하여 비교하였으며, BP-MLP는 성능 면에서 탁월함을 보였고, LVQ 망은 성능 뿐만 아니라 속도 면에서도 좋은 성능을 보였다. 모델 선택에 따라 다소 인식 성능의 저하가 있는 경우도 있었으나, 이는 입력 데이터의 감소로 인한 정보손실에 따른 것 이므로, 처리시간이 민감한 경우, LVQ 망의 선택도 가능함을 알 수 있었다. 이를 통해 특징모델과 인식 신경망의 선택에 따른 인식률과 프로세싱 타임에 대한 성능차이가 확인되었다. 추후 과제로는 보다 다양한 신경망 모델이나 SVM(Support Vector Machine) 등을 이용한 인식 시스템에 적용하는 것과 비교 분석한 각 모델들의 성능 평가 등의 확장된 분석 연구가 필요하다.

참 고 문 현

- [1] K. Park, H. Kang, W. Lee, "Recognition of Numerical Characters in License Plates using Eigennumbers," *Journal of the IEEK*, vol.44 SP, no.3, pp.266-273, 2007. (in Korean)
- [2] 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.
- [3] A. Hyvärinen, "Fast and Robust Fixed-Point Algorithm for Independent Component Analysis," *IEEE Trans. on Neural Networks*, vol.10, no.3, pp. 626-634, 1999.
- [4] H. C. Kim, D. Kim, S. Y. Bang, "Extensions of LDA by PCA mixture model and class-wise features," *Journal of KIISE : Software and Applications*, vol.32, no.8, pp.781-788, 2005.
- [5] K. C. Kwak and W. Pedrycz, "Face Recognition Using an Enhanced Independent Component Analysis Approach," *IEEE Trans. on Neural Networks*, vol.18, no.2, March 2007.

- [6] B. J. Jeong and H. Kang, "Recognition of Numeric Characters in License Plate Based on Independent Component Analysis," *Journal of the IEEK*, vol.46 SP, no.2, pp.209-217, 2009.3. (in Korean)
- [7] T. Kohonen, J. Hunninen, J. Kangas, J. Kaaksonen, and K. Torkkola, "LVQ_PAK: The Learning Vector Quantization Program Package," *Technical Report A30*, Helsinki Univ. 1996.
- [8] A. K. Rigler, J. M. Irvine and T. P. Vogl, "Rescaling of variables in back propagation learning," *Neural Networks*, vol.3, no.5, pp.461-573, 1990.

유 신

인천대학교 정보통신공학과 학사(1998년)
 석사(2000년) 졸업. 2000년~현재 인천대학교 정보통신공학과 박사과정. 관심분야는 영상 통신, 영상 압축, 패턴 인식, 컴퓨터 비전



정 병 준

인천대학교 정보통신공학과 학사(2007년)
 석사(2009년) 졸업. 2009년~현재 (주)로봇에버 HRI Lab. 연구원. 관심분야는 영상 처리, 패턴 인식, 컴퓨터 비전



강 현 철

연세대학교 전자공학과 학사(1982년), 박사(1989년) 졸업. 1990년~현재 인천대학교 정보통신공학과 교수. 관심분야는 화상통신, 패턴인식, 컴퓨터비전

