

논문 2007-44SP-3-1

고유 숫자를 이용한 번호판 숫자 인식

(Recognition of Numeric Characters in License Plates using Eigennumber)

박 경 수*, 강 현 철*, 이 완 주**

(Kyungsoo Park, Hyunchul Kang, and Wanjoo Lee)

요 약

자동차 번호판을 인식하기 위해서는 차량 영상에서 번호판을 추출하고, 추출된 번호판으로부터 문자를 분리하여야 하고, 각 문자들에 대해서 특징 벡터를 추출하고 신경망을 이용하여 인식한다. 이때 인식의 기준이 되는 특징 벡터의 선정은 테이터양의 감소뿐만 아니라 인식 성능에 많은 영향을 미친다. 본 논문에서는 숫자를 고유 숫자(eigennumber)의 선형 조합으로 분해하여 특징 벡터를 추출하는 새로운 특징 벡터 추출 기법을 제안하고, 자동차 번호판의 숫자 인식에 적용함으로써 그 유효성을 검증하였다. 실험 결과, 고유 숫자 공간상에서 다중 퍼셉트론 신경망을 이용하여 95.3%의 인식률을 보였고, 이는 일반적인 메쉬 특징과 비교하여 약 5%의 향상된 결과이다.

Abstract

In order to recognize a vehicle license plate, the region of the license plate should be extracted from a vehicle image. Then, character region should be separated from the background image and characters are recognized using some neural networks with selected feature vectors. Of course, choice of feature vectors which serve as the basis of the character recognition has an important effect on recognition result as well as reduction of data amount. In this paper, we propose a novel feature extraction method in which number images are decomposed into linear combination of eigennumbers and show the validity of this method by applying to the recognition of numeric characters in license plates. The experimental results show the recognition rate of 95.3% for about 500 vehicle images with multi-layer perceptron neural network in the eigennumber space. Compared with the conventional mesh feature, it shows a better recognition rate by 5%.

Keywords: 번호판 인식, 주성분 분석, 고유 숫자, 신경망

I. 서 론

사람의 시각 능력을 컴퓨터에 부여하고자 하는 컴퓨터 시각 분야의 연구가 오래 전부터 폭넓게 이루어져 왔으며, 최근의 하드웨어 기술의 급격한 발달은 많은 응용영역에서 실용화되어 실생활에 이용되고 있다.^[1] 그

중 한 분야로 자동차 번호판 인식 분야가 있는 데, 지속적으로 증가하는 차량의 수에 반하여 대부분의 차량 관제 및 법규 위반 차량의 적발 등은 주로 인적 자원에 의해 수행되고 있기 때문에 자동차 번호판을 자동으로 인식하는 시스템이 요구되고 있다. 자동차 번호판 인식 시스템은 크게 번호판 영역 추출, 문자 영역 분할, 문자 인식의 세 단계로 구성된다. 이때, 인식 알고리즘의 입력인 특징 벡터의 추출은 인식 성능을 좌우하는 매우 중요한 요소가 된다.

문자의 특징 추출 방법은 특징의 특성에 따라 크게 3 가지로 나눌 수 있다.^[2] 첫째, 영상 패턴의 지역적인 분포를 이용한 특징 추출 방법으로 본 논문에서 제안한 방법과 비교될 메쉬 특징이 있다. 메쉬 특징은 영상을

* 정희원, 인천대학교 정보통신공학과
(Dept. of Information and Telecommunications Eng., University of Incheon)

** 정희원, 용인대학교 컴퓨터정보학과
(Dept. of Computer and Information, Yong-In University)

※ 이 논문은 인천대학교 2006년도 자체연구비 지원에 의하여 연구되었음.

접수일자: 2006년7월7일, 수정완료일: 2007년4월16일

$N \times M$ 의 2차원 국소 영역으로 분할한 후, 각 국소 영역 내에 포함된 문자 정보의 화소수를 계산해서 이 값을 특징으로 사용하는 방식이다. 가장 간단하고 빠른 방법이지만, 문자의 지역적인 정보만 표현하기 때문에 문자의 회전이나 이동, 잡음에 민감한 단점이 있다.

두 번째로 구조적인 방법으로 문자의 전역적인 정보와 지역적인 정보를 같이 표현할 수 있는 장점이 있다. 예로, 획 간의 교차점, 끝점, 흘, 획 간의 연결성, 획의 위치 등을 이용하여 문자의 특징을 표현한다. 세 번째로 영상 변환을 이용한 방법으로 공간 영역에서 주파수 영역으로 변환시켜서 특징을 추출하기 때문에 계산량은 많지만 속도는 조금 느리지만, 문자의 변환이나 회전 같은 영향에 민감하지 않은 장점이 있다.

본 논문에서는 높은 차원의 영상 데이터로부터 특징 벡터의 차원수를 효율적으로 줄일 수 있는 주성분 분석 기법^[3]을 통해 고유 숫자로 분해하고, 고유 숫자 공간으로 각 학습 패턴들을 투영시킴으로써 숫자의 특징 벡터를 추출하는 기법을 제안한다. 추출된 특징 벡터들을 입력으로 역전과 알고리즘을 이용하여 학습을 하고, 다중 퍼셉트론 네트워크를 이용하여 숫자를 인식하였다.

II. 고유 숫자

1. 주성분 분석

주성분 분석(principal component analysis, PCA)은 고차원의 데이터를 정보의 손실을 최소화하면서 저차원의 데이터로 선형 사상하여 표현하는 방법이다. 주성분 분석은 Karhunen-Loeve 변환 또는 Hotelling 변환이라고 불리 우기도 한다.^[4]

주성분 분석은 다변량 자료의 총 변이를 주성분이라고 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 투사 시켜서 차원을 줄이는 방법이다.

PCA 변환을 했을 때 주성분의 최대수는 원래 영상 공간 상의 픽셀의 수이다. 그러나 영상의 차원을 줄이기 위해

서 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 행렬(covariance matrix)은 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)를 하며, 큰 고유값(eigenvalue)에 대응되는 고유벡터 일수록 숫자와 유사하고, 작은 고유값에 대응되는 고유벡터 일수록 잡음 성분이 많이 포함되어 있다.

PCA 변환을 통해 입력 벡터의 차원을 감소하는 것은 데이터 분포에 대한 정보를 그대로 유지하면서 계산상의 부하를 감소시키고 잡음 제거, 데이터 압축과 같은 효과를 갖는다. PCA 변환의 특성상, 영상의 회전에는 무관하지만 크기에 영향을 받는다. 그러나 각 집단 간의 관계를 고려하지 않고, 전체 데이터의 분산을 최대로 하는 방향으로만 선형 투사하기 때문에 집단 간의 겹침이 발생하는 단점을 가지고 있다. 본 논문에서는 이런 클래스간의 분류 문제를 신경망을 이용하여 해결한다.

2. 고유 숫자를 이용한 숫자 인식

본 논문에서는 외부의 환경적 변수가 많은 번호판의 숫자를 인식하기 위해서 잡음과 훼손에 비교적 강한 주성분 분석 기법을 이용해서 특징 벡터를 추출한다. 추출된 특징 벡터를 다중 퍼셉트론 신경망의 입력으로 하여 숫자를 인식한다.

가. 고유 숫자

PCA 변환은 전체 숫자 영상의 통계적 특성을 이용해서 학습 영상의 전체적 특성을 표현하는 고유 영상(eigen image)으로 분해한다. 그리고 이 고유 영상의 선

$$\text{[Image]} = a_1 \times \text{[Image]} + a_2 \times \text{[Image]} + a_3 \times \text{[Image]} + \dots + a_n \times \text{[Image]}$$

그림 1. 고유 숫자의 선형 결합

Fig. 1. Linear combination of eigennumber.

형 조합으로 임의의 숫자 영상을 표현한다. 본 논문에서는 이 고유 영상을 고유 숫자(eigennumber)라고 정의 한다. 그림 1은 숫자 영상 '0'을 고유 숫자들의 선형 조합으로 나타낸 것이다. 이때, 각 고유 숫자의 계수가 바로 본 논문에서 사용한 특징 벡터이다.

나. 고유 숫자 공간

크기가 $N \times N$ 인 2차원 숫자 영상은 $N^2 \times 1$ 크기의 벡터로 표현할 수 있고, 학습 집합(training set) 내의 M 개의 숫자 벡터 ($\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M$)에 대한 평균 영상(mean image) 벡터는

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (1)$$

이 된다. 여기서 Ψ 는 각 숫자 패턴들의 평균 영상으로 $N^2 \times 1$ 벡터이고, Γ_n 은 학습 집합 내의 각 숫자 영상이며, M 은 숫자 영상의 총 개수이다. 본 논문에서 사용한 숫자 영상의 크기는 64×64 이고, 총 500개를 사용 하였다. 그림 2는 학습 집합 내의 숫자 영상 500개에 대해서 식(1)을 적용하여 얻은 평균 영상을 확대한 것이다.

각각의 숫자 영상 벡터에 대한 평균 영상 벡터와의 차 벡터는 식(2)와 같이 구할 수 있다.

$$\Phi_i = \Gamma_i - \Psi \quad (2)$$

그림 3은 식(2)를 이용하여 얻어진 숫자 0 ~ 9 영상에 해당하는 차영상의 일부를 보여주고 있다.

이때, 이미지들의 편차로 이루어진 행렬 Φ_i 와 Φ_i^T

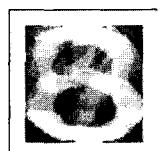


그림 2. 평균 영상

Fig. 2. Mean image.

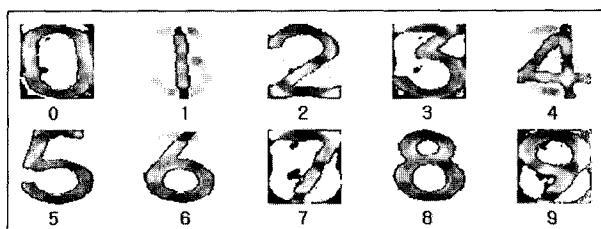


그림 3. 차영상

Fig. 3. Difference image.

의 내적으로 계산된 공분산 행렬 C 는 식 (3)처럼 구할 수 있다. 이 공분산 행렬을 이용하여 고유값과 고유벡터를 구해서 이미지를 선형 결합의 형태로 만든다. 공분산 행렬은 변수들 간의 상관관계를 나타내는 행렬로, 항상 대칭 행렬(symmetric matrix)이 된다. 따라서 계산되는 고유값은 실수 범위를 갖는다.

$$C = \frac{1}{M} \sum_{i=1}^M \Phi_i \Phi_i^T \quad (3)$$

위에서, C 는 $N^2 \times N^2$ 의 고차 행렬이다. 위의 식 (3)에서 M 개의 고유값 λ_i 와 그에 대응하는 고유벡터 u_i 는 식(4)에 의해서 구할 수 있다.

$$Cu_i = \lambda_i u_i \quad (4)$$

실제 실험에서 사용한 숫자 영상의 크기는 64×64 로 공분산 행렬의 크기는 4096이다. 그러므로 공분산 행렬은 최대 4096개의 고유값과 이에 대응하는 4096차원의 4096개의 고유벡터가 존재한다. 행렬의 차원이 너무 크기 때문에 직접법(direct method)으로는 고유치를 계산 할 수가 없다. 따라서, 다양한 고유치 근사 반복법들 중에 메모리와 시간을 고려해서 Jacobi 방법을 이용하여 고유치와 고유벡터를 계산한다.

Jacobi 방법은 대칭 행렬을 입력으로 하고, 상사 변환(similarity transform)을 반복적으로 수행해서 대상행렬을 대각 행렬로 만든다. 이때, 대각선의 원소가 바로 공분산 행렬의 모든 고유값이 된다. 이 방법은 다른 방법들에 비해 계산이 간단하기 때문에 시간과 메모리를 최소화 시키면서 고유치와 고유벡터를 구할 수 있는 장점이 있다. 따라서 영상의 크기에 의존하던 고유치의 계산은 영상 데이터의 개수에 의존하기 때문에 시간과 메모리가 크게 줄어든다.

위의 Jacobi 방법을 이용해서 구한 고유벡터들은 서로 직교(orthogonal)한다. 더 중요한 것은 이 고유값들이 학습 집합의 분산에 관한 크기를 알려주고 있다. 결과적으로 고유값이 클수록 그 고유값에 대응하는 고유벡터가 주요한 성분인 것이다.

고유 벡터 u_i 의 각 행은 학습 패턴 내의 숫자를 기술할 수 있는 고유 벡터가 된다. 본 논문에서 이 고유 벡터를 고유 숫자(eigennumber)라고 정의한다. 이 고유 숫자 공간(eigennumber space)을 이용해서 학습 집합 내에 있는 각 숫자 영상들을 표현한다. 다시 말해, 학습 집합 내에 있는 모든 숫자 영상들을 고유 숫자들의 선

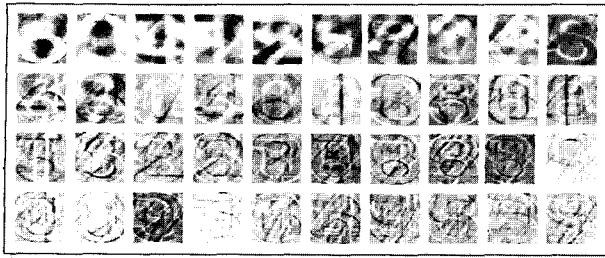


그림 4. 고유 숫자

Fig. 4. Eigennumber.

형 조합으로 나타낸다. 이때, 각각의 숫자가 숫자 공간상에서 어떠한 가중치를 가지고 선형 조합으로 이루어지는지 그 가중치를 구하는 것이 중요한데, 여기서 구한 가중치를 특징 벡터로 사용한다.

식(5)은 신경망의 입력으로 사용하는 가중치를 구하는 식을 나타낸다. 학습 합집 내의 특정 숫자 영상 Γ_i 를 고유 숫자 공간상에 투영했을 때, 전체 고유 숫자 u_k^T 에 대한 숫자 영상의 특징 정보를 w_{ik} 라고 하면, 특징 벡터는 식(5)과 같다.

$$w_{ik} = u_k^T (\Gamma_i - \Psi), \\ (k = 1, 2, 3, \dots, M) \quad (5)$$

특징 벡터 $\Omega_i^T = [w_{i1}, w_{i2}, w_{i3}, \dots, w_{iM}]$ 는 입력 숫자 이미지에 대한 고유 숫자 공간상의 위치를 나타내고, Ω 의 각 요소들은 고유 숫자 공간으로의 투영을 통해 구한다.

그림 4는 실제 실험에서 Jacobi 방법을 이용해서 구한 고유 벡터를 고유 공간상에 투영시킨 고유 숫자들 중 처음 40개를 보여주고 있다. 이 고유 숫자는 고유값이 큰 것에 대응되는 고유벡터부터 내림차순으로 정렬되어 있기 때문에 좌측상단 일수록 중요하고, 우측하단 일수록 그 중요성이 감소한다.

다. 고유숫자의 선정

선정된 고유 숫자의 개수는 특징 벡터의 수와 같기 때문에 각 숫자의 특징을 잘 표현할 수 있는 고유 숫자를 선정하는 것은 매우 중요한 문제이다. 너무 많은 고유 숫자를 선정할 경우, 오히려 인식과정에서 잡음으로 취급될 수 있고, 인식 시간도 오래 걸린다. 반면에, 너무 작은 고유 숫자는 각 숫자의 특징을 충분히 표현하지 못하기 때문에 인식률이 저하되는 문제가 발생한다. 또한, 숫자 영상의 크기에 따라 고유 숫자의 개수가 달라진다. 본 논문에서는 고유치의 누적을 계산해서 전체

고유치의 합에 대해 차지하는 비중을 나타내는 설명력을 구해서 고유 숫자의 개수를 선정한다.

$$\text{설명력 (\%)} = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^M |\lambda_i|} \times 100 \quad (6)$$

여기서, λ_i 는 공분산 행렬의 고유치를 나타내고, M 은 공분산 행렬의 총 고유치 개수이다. m 은 인식에 사용되는 특징 벡터의 수로, 선정된 고유치의 개수를 의미한다.

두 가지 방법 모두 고유치의 크기를 기준으로 고유 숫자의 개수를 선정하는 데 있어서, 고유값들은 모두 1 이상이 되어야 한다. 그 이유는 하나의 고유값이 변수 1개 이상의 분산을 설명하는데, 해당 고유값이 1 이하가 되면 1개의 변수에 해당하는 분산도 설명해 주지 못한다는 의미이기 때문에 고유치의 의미는 없는 것이다. 실제 실험에서 총 4096개의 고유치중, 처음 480개의 고유치가 1이상이었다.

표 1은 고유 숫자의 개수에 따른 설명력을 나타낸 것이다. 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 선정에 비중을 두었다. 그래서 99.52%를 설명하는 400개의 고유 숫자를 선정하였다.

표 1. 고유 숫자의 개수에 따른 설명력

Table 1. Explanation by number of eigennumber.

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

라. 숫자 인식

본 논문에서는 자동차 번호판 인식 시스템의 인식 알고리즘으로 다층 퍼셉트론 신경망을 이용하였다. 신경망은 학습 과정을 거친 후에 정해진 조건하에서 강건하게 동작한다는 장점이 있다. 신경망의 학습은 역전파 알고리즘을 이용한다.

역전파 알고리즘은 모든 입력 패턴에 대해 발생하는 오차 합수를 최소화하는 방향으로 가중치(weight)를 조정하는 전형적인 지도 학습 알고리즘으로 다층의 전방향(feedforward) 신경 회로망을 학습시키기 위한 알고

리즘으로 델타 학습법칙(delta rule)을 일반화 혹은 확장시킨 것이다.^[5]

역전파 알고리즘의 기본 원리는 다음과 같다. 먼저 입력과 신경망의 가중치와 곱하고 더하는 과정을 몇 번 반복하면 입력의 결과값인 출력값이 나온다. 이때 출력값은 학습 데이터에 주어진 목표값(target value)과 다르게 되는데, 결국 신경망에서는 출력값과 목표값과의 오차가 발생한다. 오차에 비례하여 출력층과 은닉층을 이어주는 가중치가 갱신되고, 그 다음 은닉층과 입력층을 이어주는 가중치가 갱신된다. 가중치를 갱신시키는 방향이 신경망의 처리 방향과 반대이기 때문에 역전파 알고리즘이라고 한다.

학습이 끝난 후의 인식은 다층 퍼셉트론 신경망을 이용하였다. 다층 퍼셉트론 신경망은 단층 퍼셉트론 신경망의 한계점을 극복하기 위하여 입력층과 출력층 사이에 한 개 이상의 은닉층(hidden layer)을 사용하는 다층 네트워크로 구성된다.

인식 과정은 다음과 같다. 테스트 영상에 대한 특징 벡터가 입력층으로 들어가 입력층과 은닉층을 연결하는 가중치와 곱해지고 각 노드에서 더해진다. 은닉층에서의 출력은 다시 출력의 입력으로 들어가 은닉층과 출력층을 연결하는 가중치와 곱해져 실제 출력값을 계산한다. 계산된 10개의 출력 노드중 입력 패턴에 해당하는 출력 노드는 1에 가까운 값을 갖고, 그 외의 노드들은 0에 가까운 값을 갖는다. 그래서 1에 가까운 값을 갖는 출력 노드의 클래스 번호를 인식 결과로 출력한다.

신경망을 이용한 방법은 학습 과정을 거친 후에는 처리 속도가 빠르고, 어느 정도의 잡음에 대한 유연성을 가지고 있다. 그리고 숫자 공간상에서 학습을 수행하기 때문에 숫자 공간에서 인식을 다루는데 아주 효과적이다.

III. 인식 실험 및 결과 고찰

실험에 사용한 영상은 1300×1024 크기로 고속도로 틀케이트로 진입하는 차량을 대상으로 취득한 영상을 사용하였다. 그림 5는 입력 차량 영상, 추출된 번호판 영상, 그리고 실험 과정을 보여주는 화면창이다. 신경망의 학습을 위한 영상은 64×64 크기로 각 숫자당, 50개로 총 500개를 사용하였다.

인식률을 테스트하기 위해 실제 자동차 번호판 인식 프로그램에 기준의 지역적인 특징기법으로 가장 널리 쓰이는 메쉬 특징과 본 논문에서 제안한 알고리즘을 비

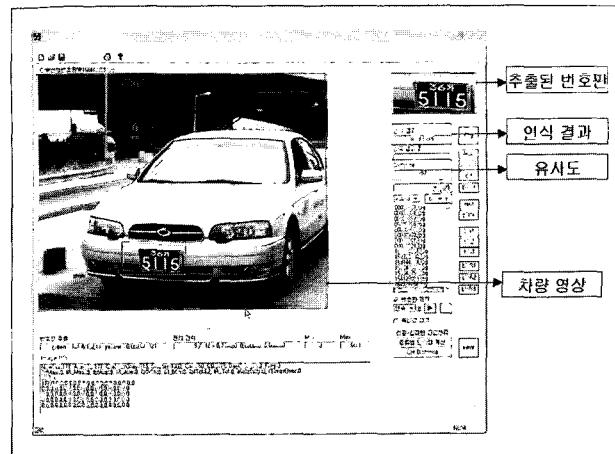


그림 5. 입력 영상과 추출된 번호판 영상, 인식 결과를 보여주는 화면 창

Fig. 5. The display window showing input image, license plate extracted, and the recognition result.

표 2. 번호판 인식 성공 개수 및 인식률 비교

Table 2. Comparison number of recognized license plate and recognition rate.

Measure	자가용	영업용	
Mesh+NN	개수	283	171
	인식률	94.3	85.5
고유숫자+N	개수	293	186
	인식률	97.6	93

교 수행하였다. 최종 인식은 육안으로 인식결과와 영상을 비교하여 전체 번호판의 글자 및 숫자들을 모두 정인식한 경우를 성공한 것으로 간주하였다.

표 2는 본 연구에서 차량 영상을 대상으로 인식률을 테스트 한 결과이다. 테스트는 자가용 영상 300개와 영업용 영상 200개를 합쳐 총 500개를 사용하였다. 표 2에서 볼 수 있듯이 메쉬 특징을 사용했을 때의 인식률은 89.9%이고, 고유 숫자 특징을 이용했을 때는 95.3%로 본 논문에서 제안한 방법이 더 높은 인식률을 나타내는 것을 알 수 있다. 또한 자가용 번호판보다 비교적 훼손이 많은 영업용 번호판에 대한 인식률 향상이 메쉬 특징보다 더 두드러지게 나타난 것을 알 수 있다.

이는 영상의 공간 영역이 아니라, 숫자를 가장 잘 표현할 수 있는 숫자 공간에서 숫자들을 표현해서 신경망을 이용해 학습함으로써 외부 환경의 영향이나 훼손된 번호판이라 할지라도 조금 더 유연하게 인식을 수행했다는 것을 나타낸다.

오인식의 경우들을 살펴보면, 구형 번호판의 훼손에 의한 오인식이 가장 많았고, 번호판이 휘어져 있거나

밝기 차이가 낮은 번호판에서의 오인식들이 있었다. 또 한 영업용 번호판의 경우 대부분 번호판의 상태가 좋지 않기 때문에 잡음이 많이 섞여 있는 문자들에서 특징 추출을 하다 보니 인식이 안 되는 경우들이 많다.

IV. 결 론

본 논문에서는 영상의 통계적 특성을 이용하는 PCA 변환을 통해 생성된 고유 숫자(eigennumber) 공간에서 특징 벡터를 추출하고, 다층 퍼셉트론 신경망을 이용하여 번호판의 숫자를 인식하는 방법을 제안한다.

기존의 특징 추출 기법들은 지역적인 특징 추출 기법으로 조명의 변화나 외부 환경에 영향을 많이 받는 번호판을 인식하기에는 다소 부적합하다. 또한 이미지 공간 영역에서 직접 인식을 하기 때문에 데이터 차원이 높고 많은 계산을 필요로 한다. 따라서 정보의 손실을 최소로 하면서 효율적으로 데이터 차원을 줄일 수 있는 PCA 변환을 이용하였다.

제안한 고유 숫자를 이용한 특징 추출 알고리즘은 숫자 이미지를 기술할 수 있는 고유 숫자 공간을 구성하고, 학습 패턴들을 고유 숫자 공간으로 투영시켜 나온 가중치를 특징 벡터로 하였다. 그러나 PCA 변환의 특성상, 영상의 회전에는 무관하지만 크기에 영향을 받고, 고유벡터간의 분산이 큰 방향에 대해서만 고려하기 때문에 클래스간의 중첩 문제가 발생하는 문제점들을 가지고 있다. 따라서 전처리 과정을 통해 영상의 크기를 정규화하고, 역전파 학습 알고리즘을 이용하여 클래스를 분류하고 다층 퍼셉트론 신경망으로 인식을 수행하였다.

인식 실험에서 살펴보았듯이 제안된 번호판 인식 알고리즘은 95.3%의 안정적인 성능을 보였다. 그리고 4096차원의 이미지 데이터를 400차원으로 줄임으로써 데이터 감축과 동시에 처리 속도를 향상시켰다. 이미지 데이터가 4096차원일 때 인식에 소요되는 시간은 평균 0.27초였고, 400차원일 때에는 평균 0.02초의 시간이 소요되었다.

향후 과제로는 부분적으로 훼손된 영상까지도 PCA 변환을 통해 인식을 수행할 수 있게 하는 연구가 필요하다.

참 고 문 헌

- [1] 이완주, “차량번호판 인식기 구현에 관한 연구”, Bull Nat. Sci., Yong-In Univ., Vol. 8, No. 2, FEB. 2004
- [2] 고일주, “문자의 외곽 정보를 이용한 특징 추출 방법”, 숭실대학교 석사학위논문, 1993, 2.
- [3] M. Turk and A. Pentland, “Eigenfaces for Recognition”, Journal of Cognitive Neuroscience, Vol. 3, No. 1, pp 71-86, Mar. 1991.
- [4] C. J. Shang and K. Brown, “Principal Feature-Based Texture classification with Neural Networks”, Pattern Recognition, Vol. 27, No. 5, pp.675-687, 1994.
- [5] Martin T. Hagan, Howard B. Demuth, Mark Beale, Neural network Design, Chapman & Hall, pp. 11_01- 11_47, 1996.
- [6] P. N. Belhumeur, J. P. Hespabha, and D. J. Kriegman, “Eigenfaces vs. Fisherfaces : Recognition using class specific linear projection,” IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 19, No. 7, pp. 711-720, July 1997.
- [7] A. M. Martinez and A.C. Kak, “PCA versus LDA,” IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 23, No. 2, pp. 228-233, 2001.
- [8] B. Lee, et al, “Adaptive Local Binarization Method for Recognition of Vehicle License Plates,” Combinatorial Image Analysis, LNCS 3322, pp. 645-655, Springer-Verlag, 2004.
- [9] 김지운, “조명변화에 강한 PCA를 사용한 얼굴 인식 기술에 관한 연구”, 연세대학교 석사학위논문, 2000. 2.

저 자 소 개



박 경 수(정희원)
2004년 인천대학교 전자공학과
학사 졸업.
2006년 인천대학교 정보통신
공학과 석사 졸업.
2006년 (주)에스오넷 개발팀
연구원.

<주관심분야 : 영상처리, 패턴인식, 신경회로망>



이 완 주(정희원)
1987년 연세대학교 전자공학과
학사 졸업.
1995년 연세대학교 전자공학과
박사 졸업.
1995년 용인대학교 컴퓨터
정보학과 교수.

<주관심분야 : 영상처리, 패턴인식, 객체 추적>



강 현 철(정희원)
1982년 연세대학교 전자공학과
학사 졸업.
1989년 연세대학교 전자공학과
박사 졸업.
1990년 ~ 현재 인천대학교
정보통신공학과 교수

<주관심분야 : 화상통신, 패턴인식, 컴퓨터비전>