

논문 2005-42SP-4-8

# 신경망을 이용한 운행차량의 차종인식 연구

## (A Study on the Model Recognition of Moving Vehicles Using a Neural Network)

이 효 종\*

(Hyo Jong Lee)

### 요 약

산업화가 활발히 이루어지면서 자동차의 수요도 세계적으로 급증하고 있다. 교통제어나 차량에 연관된 범죄 등에서 자동차의 인식에 관한 연구의 중요성 때문에 이에 관련된 연구는 오래 전부터 수행되어왔다. 본 논문에서는 이동차량의 인식 효율성을 높이기 위하여 제조회사별 차종을 인식하는 혁신적인 방법을 제시한다. 차종의 인식은 질감을 이용하여 인식하였다. 차량의 전면부는 모델별로 다르다는데 착안하여 운행차량의 전면부 영역에서 질감을 추출하였다. 획득한 질감 특징을 차종별로 3중신경망에 학습을 시킨 후 인식을 시도하였다. 제안 알고리즘에서 차종의 인식은 95%로 양호하게 나타났다.

### Abstract

The number of vehicles are rapidly increased as modern industrialization is developed worldwide. Vehicle recognition has been studied for a while because many people acknowledged it has critical functions to solve the problems of traffic control or vehicle-related crimes. In this paper a novel method is proposed to recognize vehicles' model corresponding makers in order to increase the efficiency of recognition. Texture features are computed from the frontal image of vehicles. A three-layer neural network was built and trained with the texture features for recognition. The proposed method shows 95% recognition rate for moving vehicles' models.

**Keywords :** Vehicle recognition, neural network, texture, and GLCM

## I. 서 론

오늘날 자동차는 교통과 물류시스템에서 중요한 역할을 하고 있으며, 산업이 발달됨에 따라 양적인 면에서 급증하고 있다. 급증하는 차량으로 야기되는 문제들은 효율적인 영상분석을 통하여 현저하게 줄일 수 있다. 현재 활용되고 있는 관련 기술을 살펴보면 교통량의 측정, 번호판 인식, 승용차나 트럭과 같은 차종의 구분 등이 주류를 이루고 있다. 그러나 이러한 기술은 국소적으로 활용될 수는 있지만 근본적인 문제들을 해결할 수는 없다. 예로써, 교통사고의 목격자들이 뺑소니 차량의 번호판을 알지 못하지만 A사의 검정색 승용차

였다고 증언한다면, 주어진 정보만을 가지고 문제의 차량을 찾아내기는 어렵다. 따라서 차량의 구체적인 특징에 기반을 두어 인식할 필요가 있다. 본 연구에서는 번호판 인식과 더불어 질감을 이용하여 차량의 특정 모델 정보를 인식하는 방법을 제안하였다.

2003년도 국내에서 운행되는 전형적인 차량들을 대상으로, 라디에이터 그릴 부분과 전조등의 일부를 포함하는 차량 전면부를 임계영역으로 선택하여 특징을 추출하였다. 추출된 특징 값들을 신경망에 입력하여 훈련시킨 후 제조 회사별 모델을 인식하도록 하였다. 먼저 차량의 전면부 영상에서 얻어진 GLCM(Gray Level Co-occurrence Matrix)을 사용하여 질감 특성을 추출하였고<sup>[1]</sup>, 그 특징 값들을 입력 값으로 받아들이는 3중신경 회로망을 구성하여 모델 정보에 관한 학습을 시킨 후<sup>[2][3]</sup> 요청된 차량의 정보를 추출하도록 하였다. 제안 방법은 피상적인 차량의 흐름이나 차종을 구분하는 것

\* 정회원, 전북대학교

(Chonbuk National University)

접수일자: 2004년11월30일, 수정완료일: 2005년5월9일

에서 한걸음 더 나아가서, 구체적인 자동차 제조회사별 특정 모델까지 인식할 수 있다는 장점이 있다.

지면이 제한된 관계로 번호판인식에 관한 연구는 따로 분리하였으며, 본 논문에서는 차량 모델의 인식에 중점을 두어 기술하였고, 논문의 구성은 다음과 같다. II장에서 이미 행해진 기존의 관련 연구들을 간략히 소개하였다. III장에서는 도로 영상에서 차량의 영역을 추출하는 일련의 영상처리 기법과 번호판 및 차량의 모델을 결정하는 구체적인 방법을 기술하였다. IV장에서는 실험결과를 설명하고, 최종적으로 V장에서는 결론과 향후연구 방향을 기술하였다.

## II. 관련 연구

차량 정보 추출에서 비교적 일찍 시작된 연구는 차량 번호판의 인식이다. 번호판의 인식은 이미 1990년 이전부터 연구가 되기 시작하였다. 번호판의 인식은 신경망을 통한 학습이나, 번호판 글자의 영역에 따른 패턴인식 기법을 통하여 이루어졌고<sup>[4]</sup>, 절실한 필요성에 부응하여 상용화 단계까지 이른 상태이다<sup>[5][6]</sup>.

자동차의 형태를 인식하는 것은 단순히 이동하는 물체를 탐지하는 이상의 난이도를 필요로 한다. 자동차 영상은 모양이나 크기에 있어서 각기 다르기 때문이다. 일반적으로 자동차의 형태는 아이겐(Eigen)공간의 분석이나 영상에서 적절한 특징들을 추출하여 인식하는 방법이 적용되어 왔다. Kohtaro<sup>[7]</sup>나 Murase<sup>[8]</sup> 등은 아이겐공간을 분석하여 영상에서 부분적으로 나타나는 객체들을 인식하는 방법을 연구하여 자동차의 영상에 적용하였다. 그러나, 이러한 방법은 기억장치를 많이 필요로 하며, 변화하는 환경에서 인식이 현저히 감소한다는 문제점을 지니고 있다. 이러한 문제를 극복하고자 Hwang<sup>[9]</sup>, Busch<sup>[10]</sup> 및 Kagesawa<sup>[11]</sup> 등은 번호판 영역의 위치에 관한 특징벡터를 형성하여 차량을 감지하거나 인식하는 방법을 시도하였다. Kagesawa 등의<sup>[11]</sup> 경우는 자동차영상의 국부적 특징벡터를 이용하여 최초로 자동차의 모델과 제조회사를 인식하는 방법을 시도했으나, 이진화 영상의 일대일 대응을 시도하여 제한된 입력영상에만 적용되었다.

최근 들어서 자동차의 형태를 인식하는 문제의 중요성이 대두되었고, 자동차의 형태에 기반한 인식 연구가 다양하게 시도되었다. Lee 등은<sup>[12]</sup> 방사형 형태모형을 제안하여 영역분할된 자동차의 외곽선을 기준으로 탐지하는 방법을 제안하였다. Schanz와 Michaelis<sup>[13]</sup>는 스테

레오비전을 이용하여 차량을 감지하였고, Wu<sup>[14]</sup> 등은 다각형으로 차량을 모델화하고 신경망 학습을 통하여 인식하는 기법을 소개하였다. Linmin<sup>[15]</sup>도 차량의 영상을 다각형으로 변형한 후, 형태의 파라미터를 비교하여 차량을 인식하였다. 그러나 이들 연구에서 다루어졌던 대상은 승용차, 봉고, 또는 트럭과 같이 확연히 구분되는 차종을 모델화하고 신경망을 통한 학습이나 템플릿의 비교로 차종들을 인식하고자 한 것이다. 특정차량의 인식기술은 통행료 징수, 교통량 제어, 치안유지 등에 절실히 필요하지만, 아직까지 제조회사별로 생산되어 운행되는 구체적인 자동차들의 인식까지는 연구되지 않는 상태이다.

## III. 영상처리 단계

차량 인식을 위한 방법은 계속해서 입력되는 비디오 영상을 순차적으로 처리하는 전처리의 집합으로 나타낼 수 있다. 첫째는 차량이 관심 영역에 들어와 있는지를 파악하여 차량의 이미지를 분리하는 것이다. 둘째는 번호판 영역을 추출하여 번호판을 인식하고, 셋째는 차량의 색상을 결정하고, 최종적으로 차량의 모델을 인식하는 것이다. 본 장에서는 첫 번째와 세 번째 단계를 중점으로 설명한다.

### 1. 적정 프레임의 선별

차량의 특징을 추출하기 이전에 먼저 도로상에서 설치된 카메라로부터 차량 영상을 입력 받아서 차량의 영역을 분리해야한다. 차량의 영역이 구해진 후에 그 차종을 구별할 수 있는 특징값을 추출 할 수 있다. 한 대의 차량이 카메라의 시야에 들어와서, 다시 벗어날 때까지는, 주행하는 차량의 속도, 카메라의 각도 등에 따라 다르지만 보통 10프레임에서 30프레임에 걸쳐 나타나게 된다.

차량의 정보를 손실하지 않으면서, 차량의 특징을 가장 잘 추출 할 수 있는 프레임 이미지를 추출하는 것이 중요하다. 가급적 근접한 차량의 영상을 획득하기 위해서 경험적으로 결정된 상한선 사이에 차량의 이미지가 들어왔을 때 연속적인 두개의 프레임 이미지를 선택하였다. 이 두 프레임 이미지의 차분 영상을 이용하여 차량 영역을 분할할 수 있으며 그림자 등의 잡음을 제거할 수 있다<sup>[2]</sup>. 그림 1은 위와 같은 방법으로 선택된 연속하는 두 프레임 이미지를 보여주고 있다.

2. 차량 영역의 분리

인접한 두 프레임 이미지의 차분 영상을 구하면 도로와 같이 정지된 부분의 화소값은 이론적으로 0이 되어야 하며, 움직이는 물체의 영역은 상대적으로 큰 절대값으로 표현된다. 8비트의 그레이영상으로 변환시킨 차량 영상을 최근 프레임에서 이전 프레임을 감산하여 차분 영상을 구한다. 이 방법은 차량의 앞쪽에 존재하는 그림자의 영역을 최소화 하고, 또 상대적으로 차량의 특징 정보가 많이 존재하는 차량 전면부의 윤곽을 선명하게 하여주는 장점이 있다.

차분영상이 구해지면 일정 문턱치 값을 차분 영상에 적용하여 이진화 작업을 수행한다. 이진화 작업의 결과로 차량의 윤곽은 선명하게 나타내게 된다. 그림 2는 그림 1에 대한 이진화 영상의 예를 보여주고 있다. 이진화 작업의 문턱치 값은 기상의 변화 상대나 일광 상태의 영향을 받기 때문에 강한 바람이 불어서 카메라가 미세하게 움직이거나 차에서 반사되는 빛이 강할 경우는 화소값이 조금씩 변화한다. 이러한 점을 고려하여 최적의 차량 영역만을 결정할 수 있도록 문턱치값을 적절히 설정하였다. 본 연구의 경우 대략 16에서 18사이에 분포하였다.

다음 단계로 차분 이진영상의 수평 및 수직 프로젝션을 구하여 구체적인 차량 영역을 결정한다. 이진 영상에서의 수평 및 수직 프로젝션은 모든 행과 열에 화소값이 0인 개수를 측정하여 구할 수 있다. 수평 프로젝션의 분포는 차량의 전후 영역을 구분하는 반면, 수직 프로젝션은 차량의 좌우 영역에 대한 정보를 가지고 있다. 먼저 수직 프로젝션을 취하여 차량의 좌우 영역을 결정하고, 차량의 좌우 영역 한도 내에서 수평 프로젝션을 구하여 차량의 전후 영역을 결정하여 차량의 인접영역을 결정하였다. 그림 3은 수평 및 수직 프로젝션에서 차량의 인접영역을 결정하는 과정을 보여주고 있다.

차량의 이동방향이 카메라의 촬영 방향과 정확히 일치되고 있지 않기 때문에 차분 영상의 번호판 기준선이 영상의 기준선과 평행하지 않게 된다. 이런 문제는 번호판 영역이나 라디에이터 그릴 영역을 추출하는데 있



그림 1. 선별된 인접 프레임의 이미지  
Fig. 1. Examples of selected adjacent frames.

어서 오류의 가능성을 제공한다. 특히 번호판 추출 후 번호판에 있는 숫자 인식에 있어서 좋지 않은 영향을 미친다. 또한, 6절에서 다루는 영상의 텍스춰값은 방향성에 민감하기 때문에 모든 영상에 대하여 일관성 있는 전처리 과정이 필요하다.

차량의 기울어진 정도는 Hough 변환<sup>[16][17]</sup>을 이용하여 구하고, 회전변환을 통해 기울어진 정도만큼 반대 방향으로 회전시켜 보정할 수 있다. 본 연구에서는 차분 이진 영상의 하부 점들 즉, 차량 범퍼 부분의 픽셀들을 선택하여 기울기를 결정하고 임의의 수평선분과의 기울어진 각을 측정하였다.

좌표가  $(x_1, y_1)$ 인 점  $P_1$ 을  $\theta$ 각만큼 반시계방향으로 회전시킬 경우  $z$  축을 중심으로 회전하는 점  $P_2$ 의 좌표  $(x_2, y_2)$ 는 식 (1)과 같이 정의 된다.

$$\begin{pmatrix} x_2 \\ y_2 \end{pmatrix} = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ y_1 \end{pmatrix} \quad (1)$$

따라서 회전변환을 위하여 차량 영역 영상의 중앙을 회전 중심점으로 설정하였다. 만일 중앙점  $P_0$ 의 좌표가  $(x_0, y_0)$ 라고 한다면, 회전변환 후 구해지는 점  $P_2$ 의 좌



그림 2. 차분 영상의 이진화 영상  
Fig. 2. Binary images of differential frames.




그림 3. 수평/수직 프로젝션 영상과 인접영역의 결정  
Fig. 3. Segmentation by horizontal/vertical projections.




그림 4. 차량의 원영상과 Hough변환을 통하여 수정된 영상의 비교

Fig. 4. Comparison of the original image and its result image by Hough transform.

표는 식 (2)와 같이 수정된다.

$$\begin{pmatrix} x_2 - x_0 \\ y_2 - y_0 \end{pmatrix} = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix} \begin{pmatrix} x_1 - x_0 \\ y_1 - y_0 \end{pmatrix} \quad (2)$$

식 (2)를 적용하여 기울어진 번호판이 지면에 대하여 평행하도록 보정할 수 있으며, 그림 4는 기울어진 차량의 이미지를 반듯하게 회전시킨 결과를 보여주고 있다.

### 3. 관심영역의 추출

과거 연구에서 차량 윤곽선을 구하여<sup>[14][15]</sup> 차종인식을 시도하였다. 그러나 자동차의 윤곽선은 비슷한 모델이 흔히 존재하기 때문에, 이러한 방법으로는 구체적인 차량의 제조사별 모델을 인식할 수 없다. 본 논문에서는 차량의 제조회사별 모델 정보를 위한 특징 값을 구하기 위해 자동차의 질감 특성을 사용하였다. 어떠한 영상에 주기성이나 방향성이 있다면 질감 에너지를 이용하여 구분 지을 수 있기 때문이다.

차량의 윤곽선에 의한 구분과 달리, 차량 앞부분의 전조등, 라디에이터 그릴 부분의 패턴은 차종별로 거의 고유한 외관을 가지고 있기 때문에, 전조등이나 라디에이터 그릴 영역은 다양한 질감을 나타낸다.

질감 특징은 전조등의 일부와 라디에이터 그릴 부분을 포함한 번호판 바로 윗부분 영역으로 설정하였다. 기준으로 번호판의 중심 좌표를 구하고, 전조등의 일부와 라디에이터 그릴 영역을 포함하도록 그 좌표를 적당한 좌표로 이동시킨 후에 적절한 크기로 관심영역을 추출하였다. 그림 5는 질감 특징을 위해 추출된 관심영역을 보여 주고 있다.

### 4. 질감 특성

질감특성은<sup>[1][16]</sup> 일반 영상처리에서 활발히 사용되는데, 차량의 모델을 식별하기 위해 적용하였다. 먼저 특정 화소별로 정규화하여 이중명암행렬인 GLCM



그림 5. 질감특징을 위해 추출된 관심영역 영상  
Fig. 5. Region of interest for texture features.

(Gray Level Co-occurrence Matrix)을 생성한다.

GLCM은 통계적 접근방법으로 질감을 계산하는 수단으로서 비슷한 그레이 레벨 값을 가지는 화소들의 빈도정보를 나타내고 있다. 앞서 설명한 바와 같이 관심 영역이 추출되면, 그 영역을 8비트의 그레이영상으로 변환하였다. 이 영상에서 두 화소의 거리가 d만큼 떨어져 있는 경우가 얼마나 존재하는가로 영상의 패턴을 구분할 수 있다. 예를 들어 거리가 5만큼 떨어져 있는 모든 화소쌍 중에서 화소 간격이 레벨 0에서 레벨 255까지의 경우 모두 몇 개인지 알아내는 것이다. 어떤 영상에서 화소거리를 d로 했을 때의 GLCM 행렬을 G라 했을 때,  $G[i,j]$ 는 그 영상 내에서 레벨이 i인 한 화소에서 거리 d만큼 떨어진 다른 한 화소의 레벨이 j인 모든 경우의 수를 총 화소수로 나눈 분포 확률값을 나타낸다.

실제 그레이 영상의 레벨은 256레벨이므로 GLCM 행렬의 데이터는 상당히 크다. 그러나 질감은 밝기의 대조, 규칙성 및 통계적 특성으로 크게 3가지 변수로 측정할 수 있다. 밝기의 대조에 의한 것으로는 콘트라스트, 이질성(dissimilarity), 그리고 동질성(homogeneity), 영상에 존재하는 규칙성으로는 GLCM의 관성(momentum)과 엔트로피, 그리고 통계적 특성에 의해서는 GLCM의 평균, 분포, 그리고 상관관계(correlation) 등으로 나타낼 수 있다. 자동차의 그릴영역에 대하여 모든 GLCM을 계산할 경우, 계산량에 비하여 차종 간의 변별력은 크게 향상되지 않는다. 따라서 본 연구에서는 계산량을 최소화하면서 차량의 모델들을 변별하는 특성이 높은 있는 콘트라스트, 동질성, 엔트로피, 그리고 모멘텀의 4가지 질감 특성으로 선정하였다.

#### 가. 콘트라스트

GLCM 행렬 G로부터 콘트라스트는 식 (3)과 같이 정의된다.

$$Contrast = \sum_i \sum_j |i - j|^2 G[i, j] \quad (3)$$

식 (3)에서 콘트라스트는 그레이 레벨들 사이의 명암도 차이를 측정한다. 콘트라스트는 GLCM의 대조를 의

미하기 때문에 비슷한 레벨의 두 화소는 콘트라스트가 작은 것이고, 레벨 차이가 큰 두 화소는 콘트라스트가 큰 것이다. 식 (3)에서는 콘트라스트가 큰 경우를 더욱 강조하기 위해서, 행렬 G에 콘트라스트 값이 큰 원소들이 많을 때 차수가 2차인 가중치를 도입하였다. 행렬 G의 주 대각선상의 값들은 콘트라스트가 없고, 주 대각선으로부터 멀리 떨어져 있는 화소 쌍일수록 콘트라스트가 크므로  $|i-j|^2$ 의 가중치를 주었다.  $i$ 와  $j$ 가 같을 때 즉, 주 대각선의 원소 값들은 같은 레벨의 화소 쌍들을 나타내고, 따라서 0의 가중치가 주어진다.  $i$ 와  $j$ 의 차이가 1일 때 그 화소 쌍에는 작은 콘트라스트가 존재하고 1의 가중치가 주어진다.  $i$ 와  $j$ 의 차이가 2일 때는 차이가 1일 때보다 콘트라스트가 증가하고 4의 가중치가 주어진다.  $i$ 와  $j$ 의 차가 커질수록 가중치는 지수 함수적으로 증가하게 된다. 즉 화소거리 d의 모든 화소 쌍에 대해 명암도 차이가 큰 화소 쌍들이 많이 존재하면 식 (3)의 콘트라스트는 증가하고, 명암도 차이가 작은 화소 쌍들이 많이 존재하면 식 (3)의 콘트라스트는 감소하게 된다.

나. 동질성(Homogeneity)

식 (4)는 GLCM 행렬 G로부터 질감의 유사성을 측정하는 동질성을 정의하고 있다.

$$Homogeneity = \sum_i \sum_j \frac{G[i, j]}{1 + |i - j|^2} \quad (4)$$

가중치가 주 대각선으로부터 멀어질수록 감소한다면, 화소 쌍들의 콘트라스트가 작을 때 그 식의 값은 증가하게 된다. 동질성은 가중치들이 주 대각선으로부터 멀어질수록 지수 함수적으로 감소하도록 가중치를 설정하였다. 즉 동질성에서는 콘트라스트 가중치의 역의 값으로 가중치를 설정하여 콘트라스트의 특성과 반대의 특성을 갖는다. 즉 화소거리 d의 모든 화소 쌍에 대해 명암도 차이가 큰 화소 쌍들이 많이 존재하면 식 (4)의 동질성 값은 작아지고, 명암도 차이가 작은 화소 쌍들이 많이 존재하면 동질성 값은 증가하게 된다.

다. 엔트로피

식 (5)는 GLCM 행렬 G로부터 엔트로피를 구하는 식을 정의하였다.

$$Entropy = - \sum_i \sum_j G[i, j] \log G[i, j] \quad (5)$$

엔트로피는 영상에서 그레이 레벨의 무질서도를 나타낸다.  $\log(0)$ 의 값을 0으로 처리하면 GLCM 행렬  $G[i, j]$ 는 분포확률이기 때문에  $0 \leq G[i, j] \leq 1$ 의 조건을 만족하여야 한다. 따라서,  $\log(G[i, j])$  값은 항상 0, 또는 음수값을 갖게 되기 때문에 각 항을 양수로 만들어 주기 위해 식 (5)에 -1을 곱하여 양수처리 하였다. 식 (5)에서  $G[i, j]$  값이 작을수록  $\log G[i, j]$  값의 절댓치는 커지게 된다. 따라서  $G[i, j]$ 가 작을수록 가중치  $-\log G[i, j]$ 는 커지게 되고, 이때 가중치는 지수함수적으로 증가하게 되므로 항 전체의 값  $-G[i, j] \log G[i, j]$ 은 커지게 된다. 행렬 G가 값이 작은 원소들을 많이 가질 때, 즉 무질서도가 커질 때 전체적인 엔트로피 값은 증가하게 되는 것이다.

라. 모멘텀

식 (6)은 GLCM 행렬 G로부터 모멘텀을 구하는 식을 나타낸다.

$$Momentum = \sum_i \sum_j G[i, j]^2 \quad (6)$$

모멘텀은 에너지라고도 불리는데 영상에서 그레이 레벨의 확일성을 측정한다. 위 식에서 모멘텀은  $G[i, j]$ 의 값을 직접 차수가 2차인 가중치로 사용한다. 식 (5)와 비교해보면 모멘텀은 엔트로피와 상반된 특징을 갖는 것을 알 수 있다. GLCM 행렬 G가 여러 원소에 대해 고루 값을 갖지 않고 특정한 원소에서 큰 값을 가질 때 모멘텀 값은 커진다. 즉 영상이 복잡하지 않고 단조롭고 균일 할수록 큰 모멘텀의 값을 갖게 된다.

마. 질감특성의 계산

GLCM 행렬은 실제로 계산하는데 있어 많은 메모리를 요구하며 더불어 많은 계산량을 요구한다. 이 문제를 해결하기 위해서 Unser는<sup>[18]</sup> 히스토그램의 합과 차에 의하여 질감을 계산하는 변형 방법을 제안하였다. 이는 정확도에서 약간 뒤떨어지지만 메모리의 요구량은  $10^{-2}$ 에 불과하다. 합 히스토그램 S는 영상 내에서 거리 d 만큼 떨어져 있는 모든 화소 쌍의 합에 대한 히스토그램이며, 차 히스토그램 D는 마찬가지로 거리 d만큼 떨어져 있는 모든 화소 쌍의 차에 대한 히스토그램으로 정의된다.

앞서 기술된 네 개의 질감 특성은 오직 이 두 히스토그램만을 사용하여 근사 값으로 계산할 수 있다. 실제 GLCM의 계산을 하지 않고, 각 질감 서술자들이 필요

로 하는 256 x 256 의 2차원 배열 대신에 두 개의 511 크기의 1차원 배열들을 사용하여 계산되기 때문에 훨씬 효율적이다. 식 (3)부터 식 (6)에서 정의된 질감 특징들을 합/차 히스토그램  $S(i)$ 와  $D(j)$ 를 이용하여 근사값으로 계산할 수 있도록 식 (7)부터 식 (10)까지에 변화시킨 개념을 다시 정의하였다.

$$\text{Contrast} = \sum_j j^2 D(j) \quad (7)$$

$$\text{Homogeneity} = \sum_j \frac{D(j)}{1+j^2} \quad (8)$$

$$\text{Entropy} = - \sum_i S(i) \log S(i) - \sum_j D(j) \log D(j) \quad (9)$$

$$\text{Energy} = \sum_i S^2(i) \sum_j D^2(j) \quad (10)$$

위 식들은 근사값에 의하여 계산을 수행하기 때문에 오차를 포함하여 정확도에서 조금 뒤떨어지지만 실행 속도의 향상은 적어도 20배 이상 향상 된다. 이와 같이 정의된 질감 특징자들을 수평, 수직 방향과 두 대각선 방향으로 하여 총 4개의 질감 서술자를 구하였다.

## 5. 차종의 인식

차량 종류의 학습과 인식을 위하여 하나의 은닉층을 가지는 역전파 3중 신경회로망을 그림 6과 같이 구성하였다. 입력층은 학습을 위한 데이터를 받아들이는 부분으로, 본 논문에서는 차종의 학습 및 인식을 위해 식 (7)-(10)으로 정의된 질감 특징을 네 방향에서 계산한 총 16개의 질감 특징 값을 입력으로 사용하였다. 입력으로 사용되는 16개의 질감 특징 값들은 화소 거리  $d$ 를 1로 설정한 경우의 GLCM으로부터 구해진 값들이다. 출력층은 최종적으로 실험에 사용한 24종의 차량을 나타내는 노드로 구성이 되어있다. 은닉층은 학습의 수렴 시간과 정확도를 고려하여 150개 노드로 설정하였다.

## IV. 실험 및 고찰

### 1. 실험 환경

실험을 위하여 시내 외곽에서 실제 이동하는 차량들을 주간에 촬영하였다. 도로 바닥으로부터 카메라 렌즈까지의 높이는 대략 6m를 유지하였다. 차선의 너비는 약 3m이었고, 촬영 범위는 주행하는 개별 차량의 인식에 관한 문제를 다루는 점을 고려하여 하나의 차선에 국한 시켰다. 이때 차선의 양 끝이 영상의 아래쪽 두 모서리에 맞물리도록 설정하였다.

도로 영상은 Sony TRV900(6mm) 디지털 비디오 캠




그림 6. 차량 모델 인식을 위한 신경망 구조  
Fig. 6. Architecture of a neural network used.

코더를 사용하여 수집하였다. 초점은 일반적으로 도로상의 카메라들이 고정되어 있음을 감안하여, 캠코더 역시 삼각대에 고정하여 수동으로 촬영하였다. 촬영 각도는 수평 위치에서 지면을 향하여 약 10도 정도 기울인 상태로 설정하였다. 촬영 대상 차량은 소형 승용차, 중형 승합차뿐만 아니라 트럭도 포함하였다. 먼저 획득된 영상 중에서 차선을 지키지 않았거나 5톤 이상의 대형 트럭과 같이 화면 전체를 차지하는 차량은 제외하였다. 영상의 획득이 양호하게 되어도 동일 차종의 영상의 수가 8대 미만인 차량은 신경망 학습에서 충분한 학습이 이루어지지 않아서 실험에서 제외시켰다. 따라서 24종의 차량에 대한 415개의 영상이 실험에 적용되었다.

질감특성을 이용하여 차종을 인식하기 위한 신경 회로망 학습은 IBM 슈퍼컴퓨터 IBM RS/6000 SP 9076-550을 사용하였다. 학습이 종료된 후 차종의 인식 실험은 Pentium 4(1.5GHz, 512Mbyte RAM)를 사용하였다. 본 연구에서는 알고리즘의 설정에 중점을 두었고, 학습이 종료된 상태에서 차량 한 종을 인식하는 실험에 소요되는 평균시간은 2.4초가 소요되었다.

### 2. 차량 영역 추출

실험을 위해서 세 시간 분량의 영상을 앞서 기술한 조건으로 도로에 나가 촬영하였다. 640x480 크기의 입력 프레임은 프레임그래버를 통하여 초당 약 28프레임의 속도로 입력 영상을 받아들였다.

그림 7은 III장 2절에서 설명한 방법으로 도로 영상으로부터 차량 영역을 추출할 때의 결과의 일부를 보여주고 있다. 그림 7(a)와 7(b)는 각각 소형 승용차와 트럭의 차량 영역 추출 결과를 정확하게 찾아낸 결과를 보




그림 7. 차량 영역 검출의 결과  
Fig. 7. Extraction results of segmented car.

여준다. 그림 7(c)는 우측으로 치우친 영상을 거의 정확하게 찾은 경우이며, 그림 7(d)는 두 대의 차량이 연속으로 진입하여 제안 알고리즘이 실패한 경우를 보여주고 있다. 그러나 모든 경우에서 번호판과 라디에이터 그릴 영역의 인식은 정확하게 수행되어 차량 영역은 올바르게 분할되었다. 그러나 그림 7(d)의 경우 뒤쪽에서 운행하는 차량은 인식이 될 수 없었다. 이와 같이 차량 영역이 제대로 되지 않은 경우는 0.25%로 미미하였기 때문에 최종 차종인식의 성능은 차량 영역검출의 결과에 의존하지 않는다고 가정하였다.

### 3. 차종의 인식

차종의 모델 인식을 위하여 획득한 차량 전면부 영상에서 질감특성을 구하였다. 양호한 차종 변별자는 동일한 차종에서는 유사한 값을 나타내면서 다른 차종에서는 확연히 구분할 수 있어야 한다. 16개의 질감특성은 일반적으로 양호한 변별력을 보여주지만 일부 질감특성은 다른 차종에서도 유사한 값을 보여주기 때문에 혼합하여 사용하여야 한다. 그림 8은 10종의 차량 모델에 따른 콘트라스트와 동질성의 특징을 수평, 수직 및 두 대각선의 4 방향에서 구하여 진 것을 그래프로 나타낸 것이다. 콘트라스트는 수직 방향의 질감이 양호한 변별력을 지니고 있는 반면 동질성은 수평방향이 상대적으로 양호한 것을 보여준다.

III장 5절에서 설명한 바와 같이 입력층-은닉층-출력층의 구조가 16 x 150 x 24인 3중 신경망회로를 통하여 학습한 결과로 생성된 질감특징별 차종의 가중치를 이용하여 차량의 인식 실험을 시도하였다. 인식 효율성을 측정하기 위하여 인식률 (sensitivity)과 강건률 (specificity)을 식 (11)과 같이 정의하였다.




그림 8. 차종별 특징값의 예  
Fig. 8. Example of texture parameters.

표 1. 차량의 인식결과

Table 1. Result of vehicle recognition.

차종	차량수	정인식	오인식	인식률	강건률
포터	50	50	3	100	99.2
프린티어1	15	14	3	93.3	99.3
스타렉스	30	26	2	86.7	99.5
프린티어2	27	27	1	100	99.7
EF소나타	21	21	0	100	100
소나타2	17	16	2	94.1	99.5
신EF 소나타	24	24	3	100	99.2
세피아1	14	12	1	85.7	99.8
카니발	23	21	1	91.3	99.7
크레도스1	17	16	0	94.1	100
그레이스	16	14	0	87.5	100
그랜저XG	18	17	0	94.4	100
무쏘2	18	16	1	88.9	99.8
이스타나	10	10	1	100	99.8
신 그랜저	14	14	1	100	99.8
갤로퍼1	15	15	1	100	99.8
프레지오	12	10	0	83.3	100
포텐샤	14	13	1	92.9	99.8
엑센트	13	10	1	76.9	99.8
SM5	17	16	2	94.1	99.5
에쿠스	7	7	1	100	99.8
렉스틴	6	5	0	83.3	100
라노스	9	8	1	88.9	99.8
다이너지티	8	7	0	87.5	100
합계	415대	389대	26대	93.7%	99.7%

$$Sensitivity = \frac{TP}{TP + FN} \times 100 \quad (11)$$

$$Specificity = \frac{TN}{TN + FP} \times 100$$

여기에서 TP(True Positive)는 차종을 정확하게 인식한 차량의 수, TN(True Negative)은 이중 차량을 이중의 차량으로 인식한 수, FN(False Negative)은 동종의 차량이지만 이중의 차량으로 인식한 수, 그리고 FP(False Positive)는 이중의 차량을 동종의 차량으로 인식한 수를

표 2. 인식에 따른 상관관계  
Table 2. Recognition correlation.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	
1	50																								
2		14																	1						
3	1	1	26				1						1												
4				27																					
5					21																				
6						16									1										
7							24																		
8			1					12								1									
9			1						21												1				
10		1								16															
11				1							14				1										
12												17									1				
13							2						16												
14														10											
15															14										
16																15									
17						1											10						1		
18									1									13							
19	2					1													10						
20								1												16					
21									1												7				
22																		1				5			
23		1																						8	
24																					1				7

의미한다. 식 (11)에서 보는 바와 같이 인식률은 동종으로 분류한 차량 중에서 얼마가 참된 동종의 차량인지를 나타내는 반면, 강건률은 실제 이종 차량 중에서 얼마가 참된 이종 차량인지를 나타낸다. 따라서, 인식률과 강건률을 모두 100%에 가까울수록 좋다.

표 1은 24종의 차량 415대를 이용한 인식 실험의 결과를 보여주고 있다. 정인식은 차량의 모델을 정확하게 인식한 차량의 수이며, 오인식은 다른 차량을 해당 차량으로 인식한 차량의 수를 나타낸다. 예를 들어서 봉고 프런티어1의 경우 총 15대의 차량이 실험에 사용되었으나 그중 14대만이 바르게 인식되었으며 한대는 다른 차량으로 인식되었고, 오히려 다른 차종의 3대를 봉고프런티어1로 인식한 것을 보여주고 있다. 인식률은 식 (11)에 나와 있는 바와 같이 총 차량 중에서 올바르게 인식된 차량의 백분율을 보여주며, 강건률은 이종 차량을 다른 차량으로 인식하는 백분율을 보여주고 있다. 표 1에서 보는 바와 같이 인식률은 93.7%, 강건률은 99.7%의 양호한 결과로 나타나고 있다.

표 2는 구체적으로 해당 차량이 어떻게 인식되고 있는지의 상호관계를 보여주고 있다. 첫 번째 행과 열에 기입된 1부터 24까지의 번호는 표 1에 나와 있는 차종들을 포터부터 다이너스티까지 순서대로 표시한 것이다. 가로 행은 미인식 차량을 포함하여 정확한 차종을

나타내고 있으며, 세로 열은 오인식을 포함하여 인식된 차종을 나타내고 있다. 예를 들어 세 번째 행의 스타렉스는 총 30회에 걸쳐서 출현했으나 26회는 제대로 스타렉스라고 인식하였고, 나머지 4회의 경우는 포터, 봉고, 신EF 소나타와 무쏘로 인식이 된 것을 보여준다. 오히려 세피아(8행)와 카니발(9행)을 스타렉스로 인식한 것이 세 번째 열에 나타나있다. 따라서 표 2의 대각선 위치에 나타난 숫자가 정확하게 인식된 차량의 수를 나타내주고 있다.

24종의 차량 중에서 정확하게 모든 차량을 인식한 차종은 포터 외 8종이며 오인식이 한대도 발생되지 않는 차종은 소타타 외 7종에 이르고 있다. 도로에서 획득한 영상은 각 차종별로 학습에 사용된 횟수가 다르다. 그러나 학습을 많이 시킨 영상이 꼭 높은 인식률을 보여주고 있지는 않다. 30대의 영상으로 학습에 훈련한 스타렉스는 인식률이 86.7%인 반면, 10대 이하의 영상으로 학습한 에쿠스나 이스타나의 경우 100%의 인식률을 보여주고 있다.

이것은 학습에 사용된 데이터의 수 외에도 특징 값의 분포가 인식률에 영향을 주고 있음을 의미한다. 다이너스티와 렉스턴의 경우, 데이터의 수가 10개 미만으로 적지만 특징 값들이 한곳에 집중적으로 뭉쳐 있기 때문에 다른 차종과의 구분이 명확하여 양호한 인식률을 나



타내고 있다. 그러나 엑센트의 경우는 데이터 수가 다 이너스티나 렉스텐 보다는 많지만, 다이너스티나 렉스텐처럼 특징 값들이 한곳에 집중적으로 뭉쳐 있지도 않았고, 또 포터처럼 데이터 수가 많지도 않아서 특징 값들이 여러 곳에 하나씩 떨어져서 존재하는 경우가 많았기 때문에 인식률이 저조하였다.

인식률을 향상시키기 위해서는 물론 각 차종별로 학습에 사용하는 데이터의 수를 증가시켜 충분한 학습을 시키는 방안이 고려될 수 있다. 또 다른 방법은 각 차종별로 질감특징의 분포가 독자적인 영역을 나타나게 하는 방법이다. 이에 대한 연구는 인식률을 향상시키는 방향으로 추진될 수 있을 것이다.

## V. 결 론

교통량의 제어나 교통관련 시스템의 자동화를 위해서는 번호판과 차종의 인식은 필수적이다. 차량의 인식을 위해서 이동 차량의 추정이나 번호판 문자 인식과 같은 연구가 시도되었으나, 구체적인 제조회사별 모델의 인식은 시도되지 않았다. 본 논문에서는 차량 전면부의 질감 특징값을 이용하여 차종 식별을 할 수 있는 방법을 최초로 제안하였다.

차종별 모델 식별을 위한 차량의 특징으로는 질감 서술자를 도입하였다. 질감으로써 차량의 고유한 특징을 가장 잘 나타낼 수 있는 관심 영역을 결정한 후, 관심 영역으로부터 GLCM을 이용하여 그 차량의 특징을 나타내는 질감 특징 값들을 계산하였다. 그 값들을 역전파 알고리즘을 적용한 신경 회로망에 입력 시켜서 차량의 제조회사와 모델을 인식하였다.

제안 알고리즘의 성능을 측정하기 위해서 도시 외곽 도로에서 운행 중인 차량들의 영상을 획득한 후, 차량의 위치가 차선을 기준으로 유효범위 내에서 운행 중인 차량 415대를 선정하여 실험하였다. 제조회사별 차종 모델의 인식은 24종의 실험 영상의 경우 약 94%의 양호한 인식률을 나타내었다. 일부 차량의 경우 획득 영상의 수가 부족하여 충분한 학습이 이루어지지 않았기 때문에 제안 알고리즘의 인식률이 충분한 데이터를 확보한 경우에는 더 많은 모델을 인식할 수 있을 것이다.

향후 연구에서는 현재의 인식률을 높이기 위하여 두 가지 방법을 고려할 수 있다. 첫째는 신경망 학습을 위해 풍부한 자료를 사용하는 방법이 우선 되어야 한다. 둘째는 차종별 고유특성을 나타내는 질감 서술자의 계산 방법을 개선하는 것이다. 현재는 일부 차종에 있어

서 이종간의 차량들도 비슷한 질감 서술자의 값으로 표현되어서 오인식을 하게 된다. 이들 취약점에 대한 개선이 있을 경우 인식률이 향상될 것으로 기대한다.

## 참 고 문 헌

- [1] J. R. Parker "Algorithms for Image Processing and Computer Vision," Wiley Computer Publishing, 2002.
- [2] Hoon Lee, "A Study on the Recognition of Vehicles on the Road," Chonbuk National University Department of Electronics Engineering M.S. Thesis, February 2002.
- [3] Richard O. Duda, Peter E. Hart, David G. Stork "Pattern Classification," Wiley Interscience.
- [4] R. A. Lotufo, A. D. Morgan, and A. S. Johnson, "Automatic number-plate recognition," IEE Colloquium on Image Analysis for Transport Applications, February 1990.
- [5] Neuricam, "Number Plate Recognition System NC6000 Data Sheet," <http://www.neuricam.com>, 2002.
- [6] Choudhury A. Rahman, Wael Badawy, and Ahmad Radmanesh, "A Real Time Vehicle's License Plate Recognition System," Proceedings of the IEEE Conference on Advanced Video and Signal Based Surveillance, 2003.
- [7] Kohtaro Ohba and Katsushi Ikeuchi, "Detectability, Uniqueness, and Reliability of Eigen Windows for Stable Verification of Partially Occluded Objects," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 9, pp. 1043-1048, 1997.
- [8] H. Murase and S. Nayar, "Visual Learning and Recognition of 3D Objects from Appearance," *International Journal of Computer Vision*, Vol 14, pp. 5-24, 1995.
- [9] W. Hwang and H. Ko, "Real-time Vehicle Recognition Using Local Feature Extraction," *Electronics Letters*, Vol. 37, No. 7, pp. 424-425, March, 2001.
- [10] Christoph Busch, Ralf Dörner, Christian Freytag, Heike Ziegler, "Feature Based Recognition of Traffic Video Streams for Online Route Tracing," Proceedings of the IEEE Conference on Vehicular Technology Conference, pp. 1790-1794, 1999.
- [11] Masataka Kagesawa, Shinichi Ueno, Katsushi Ikeuchi, and Hiroshi Kashiwagi, "Local-Feature Based Vehicle Recognition In Infra-Red Images Using Parallel Vision Board," Proceedings of the

- IEEE International Conference on Intelligent Robots and systems, pp. 1828-1833, 1999.
- [12] Kyoung-Mi Lee and W. Nick Street, "Automatic Image Segmentation and Classification Using On-line shape Learning," Proceedings of the IEEE Workshop on Applications of Computer Vision, pp. 64-70, 2000.
- [13] A. Schanz, C. Knoepfel, and B. Michaelis, "Robust Vehicle Detection at large Distance Using Low Resolution Cameras," Proceedings of the IEEE Intelligent Vehicles Symposium, pp. 267-272, 2000.
- [14] Wei Wu, Zhang QiSen, and Wang Mingjun, "A Method of Vehicle classification Using Models and Neural Networks," Proceedings of the IEEE Conference on Vehicular Technology Conference, Vol. 4, pp. 3022-3026, 2001.
- [15] Xia Limin, "Vehicle Shape Recovery and Recognition Using Generic Models," Proceedings of the 4th World Congress on Intelligent control and Automation, pp. 1055-1059, 2002.
- [16] I. Pitas "Digital Image Processing Algorithms and Applications," Wiley Inter-Science, 2000.
- [17] Wang Shaolin and Zheng Xiaosong, "Hough Transform: It's Application to the Linearly Moving Point Targets Detection," Proceedings of the IEEE International Symposium on Speech, Image Processing and Neural Networks, pp. 795-797, 1994.
- [18] Unser, M, "Sum and Difference Histograms for Texture Classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol 8, pp. 118-125, 1986.

---

 저 자 소 개
 

---



이 효 종(정회원)

1991년~현재 전북대학교 교수

1986년 University of Utah 전산학과 학사졸업.

1988년 University of Utah 전산학과 석사졸업.

1991년 University of Utah 전산학과 박사졸업.

&lt;주관심분야 : 영상처리, 병렬 및 분산 처리, 의료영상&gt;