

질감을 이용한 차량모델 인식 알고리즘

이 효종[†]

요약

사회가 발전하면서 자동차의 수요도 세계적으로 급증하고 있다. 교통체어나 차량에 연관된 범죄 등을 해결하는데 자동차의 인식 기술이 중요하기 때문에 이에 관련된 번호판 인식이나 교통량 측정에 관한 연구는 오래 전부터 수행되어왔다. 본 논문에서는 주행차량의 제조회사와 차량 모델을 인식하는 방법을 제시하였다. 차종의 인식은 차량 전면부 영역의 질감을 이용하여 인식하였다. 번호판 상단의 라디에이터 영역에서 질감 특징자를 추출하여 신경망을 통한 차종별 학습을 시켜서 인식을 시도하였다. 제안 알고리즘에서 차종의 정인식은 93.7%, 이종차량의 감별은 99.7%로 양호하게 나타났다.

키워드 : 차량인식, 차종인식, 질감, GLCM

Algorithm Based on Texture for the Recognition of Vehicles' Model

Hyo Jong Lee[†]

ABSTRACT

The number of vehicles are rapidly increased as our society is developed. The 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 vehicle models corresponding makers. Vehicles' models are recognized based on the texture parameters from segmented radiator region above a number plate. A three-layer neural network was built and trained with the texture features for recognition. The proposed method shows 93.7% of recognition rate and 99.7% of specificity for vehicles' model.

Key Words : Vehicle Recognition, Model Recognition, Texture, GLCM

1. 서론

오늘 날 자동차는 교통과 물류시스템에서 중요한 역할을 하고 있으며, 산업이 발달됨에 따라 양적인 면에서 급증하고 있다. 각 가구 당 한대씩 보유하던 추세에서, 각 사람 당 한대씩 보유하는 추세로 증가하는 현실이다. 자동차가 일상 생활에서 차지하는 중요성을 볼 때에 이러한 추세는 계속될 것으로 전망이 된다. 자동차가 생활 중에 활발히 사용되고 양적으로 증가함에 따라 다양한 형태의 문제도 제기되고 있다. 교통사고, 교통체증, 또는 차량을 이용한 다양한 범죄 행위 등은 여러 곳에서 일어나고 있는 문제들이다. 이러한 사회적 문제들은 해결하기 위해서 도로 영상을 분석하여 교통량을 측정하거나[1][2], 차량의 번호를 인식하여 차량을 감지하는 기술이[3][4] 연구되어 왔다.

단순한 차량의 추정이나 번호판 인식에서 한걸음 더 나아

가서 자동차 제조회사별로 생산되는 차량의 모델을 인식하는 기술은 아직까지 소개되지 않고 있다. 이러한 기술은 교통단속, 차량 검색 및 조회, 통행요금 자동징수 및 자동차 관련 범죄의 해결에 필수적인 원천 기술이다. 이를 위해서는 자동차 모델에 따른 고유한 특징(feature) 정보를 추출할 수 있어야 한다.

차량의 특징 정보는 차량의 번호판, 색상 및 구조적 형태 등에서 정량적으로 추출 될 수 있다. 차량의 번호판은 고유 인식자로 활용될 수 있고, 색상은 단순하면서도 차량을 구분할 수 있는 중요한 정보이다. 차량의 구조적 특징은 외곽선을 분석하거나, 차량의 전면에서 가시화되는 전조등의 모양, 전방그릴의 형태, 측면 거울의 형태, 범퍼의 형태 등에 의하여 구분될 수 있다. 그러나 이들 형태를 모두 다루기에는 계산적인 부담이 너무 크다.

본 논문에서는 한국에서 운행되는 차량의 구체적 모델을 인식하는 방법을 제안하였다. 차량의 라디에이터 그릴 부분이나 전조등의 형태들은 차량의 고유 모델을 결정하는 중요한 요소이다. 이와 같은 연구 결과와 기준에 수행된 번호판 인식의 연구나 색상 정보 등을 병행할 경우 주행 차량의 인

* 이 논문은 2002-2003년도 전북대학교 해외연구교수 지원에 의하여 이루어졌다.

† 종신회원 : 전북대학교 전자정보공학부 교수
논문접수 : 2004년 12월 6일, 심사완료 : 2005년 4월 25일

식을은 현저하게 향상될 수 있다. 차량 전면부 영역에서 GLCM (Gray Level Co-occurrence Matrix)을 사용하여 질감 특성을 추출하고[5], 이를 질감 특징값을 신경망을 통하여 훈련시킨 후 특정 차량을 인식하도록 하였다[6]. 제안 방법은 단순한 차량의 흐름이나 번호판을 인식하는 방법과 달리 구체적인 자동차 제조 회사와 그 회사의 특정 모델까지 인식할 수 있는데 큰 의미가 있다.

본 논문의 구성은 다음과 같다. 2절에서 이미 행해진 기존의 관련 연구들을 간략히 소개하였다. 3절에서는 도로 영상에서 차량의 영역을 추출하는 일련의 영상처리 기법을 기술하였다. 4절에서는 차량의 모델을 결정하는 방법을 설명하였다. 5절에서는 실험결과를 설명하고, 최종적으로 6절에서는 결론과 함께 향후 연구방향을 기술하였다.

2. 관련 연구

차량정보에서 가장 기본적이면서 손쉽게 연구될 수 있는 것은 차량의 번호판 인식에 관한 연구이다. 차량 번호판의 인식은 이미 1990년 이전부터 연구가 되기 시작하였다. 전형적인 번호판의 인식은 번호판 영역을 분할하여 신경망을 통한 학습이나, 번호판 글자의 영역에 따른 패턴인식 기법을 통하여 차량의 번호를 인식하였다[1][2].

도로 영상을 분석하여 차량의 흐름 및 교통의 혼잡도에 관한 연구도 활발히 수행되었다. 이들 연구의 목적은 기존에 수행된 루프탐지기법이나 센서의 사용을 피하고 영상처리기법을 이용하여 도로 영상에서 교통량의 측정과 도로상황의 혼잡도의 계산에 활용하였다. Ikeda 등은[3] 실시간으로 도로 영상에서 배경영상을 차분시켜서 차량영역을 확보한 후에 이진화를 시켜서 교통차량의 양을 측정하였다. Nishiyama 등은[4] 도로와 차량의 밝기를 256등급으로 표시하여 도로의 밝기를 기준으로 하여 차량 이미지의 밝기가 상대적으로 밝고 어두운 특성을 이용하여 교통량을 추적하고 혼잡도를 계산하였다.

일반적으로 자동차의 형태는 아이겐(Eigen)공간의 분석이나 영상에서 적절한 특징들을 추출하여 인식하는 방법이 적용되어 왔다. Kohtaro[7]나 Murase[8] 등은 아이겐 공간을 분석하여 영상에서 부분적으로 나타나는 객체들을 인식하는 방법을 연구하여 자동차의 영상에 적용하였다. Kagesawa 등은[9] 자동차 영상의 국부적 특징벡터를 이용하여 최초로 자동차의 모델과 제조회사를 인식하는 방법을 시도했으나, 이진화 영상의 일대일 대응이 필요하여 제한된 입력영상에만 적용되었다.

최근 들어서 자동차의 형태를 인식하는 문제의 중요성이 대두되었고, 자동차의 형태에 기반한 인식 연구가 다양하게 시도되었다. Lee 등은[10] 방사형 형태모델을 제안하여 영역 분할된 자동차의 외곽선을 기준으로 탐지하는 방법을 제안하였다. Schanz와 Michaelis[11]는 스테레오비젼을 이용하여 차량을 감지하였고, Wu[12] 등은 다각형으로 차량을 모델화하고 신경망 학습을 통하여 인식하는 기법을 소개하였다.

Linmin[13]도 차량의 영상을 다각형으로 변형한 후, 형태의 파라메터를 비교하여 차량을 인식하였다. 그러나, 여기에서 나루어졌던 대상은 승용차, 봉고, 또는 트럭과 같이 기능상 차이가 나는 차종의 인식이었다. 모든 차종에 관한 인식기술이 통행료 자동 징수, 교통량 제어, 치안유지 등에 절실히 필요하지만, 아직까지 제조회사별로 생산되어 운행되는 자동차 모델의 인식에 관한 연구는 이루어지지 않은 상태이다.

3. 영상처리단계

차량 인식을 위한 방법은 입력되는 비디오영상을 순차적으로 처리하는 단계별 처리의 집합으로 나타낼 수 있다. 첫째 단계는 차량이 관심 영역에 들어와 있는지를 파악하여 차량의 이미지를 분리하는 것이다. 둘째는 번호판 영역을 기준으로 차량 전면부 영상에서 질감특징을 구하여 최종적으로 차량의 모델을 결정하는 것이다.

3.1 적정 프레임의 선별

차량의 특징을 추출하기 이전에 먼저 도로상에서 설치된 카메라로부터 차량 이미지를 입력 받아서 차량 영역을 분리해야한다. 차량의 영역이 구해진 후에 그 차종을 구별할 수 있는 특징값을 추출할 수 있다. 설치된 카메라에서 촬영되는 영상들은 보통 초당 30프레임 이내의 이미지들로 구성된다. 한 대의 차량이 카메라의 시야에 들어올 때부터 카메라의 시야에서 벗어날 때 까지는, 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. 차량의 앞쪽 범퍼 및 번호판이 카메라의 아래쪽 시야에서 사라지기 전의 프레임 이미지가 일반적으로 선명한 번호판 영역을 보여주고 있다. 따라서, 영상의 하단에서부터 경험에 의하여 결정한 상한선 사이에 차량의 이미지가 들어오는 연속적인 두개의 프레임 이미지를 선택하였다. 이 두 프레임 이미지의 차분 영상을 이용하여 차량 영역을 분할할 수 있으며 그림자 등의 잡음을 제거할 수 있다[4]. 위와 같은 방법으로 선택된 연속하는 두 프레임 예를 (그림 1)에 나타내었다.



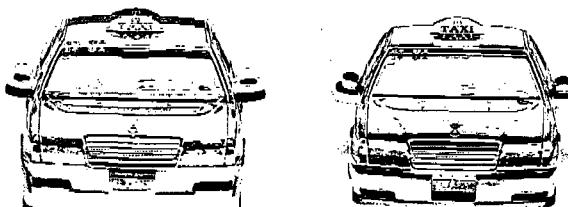
(그림 1) 선별된 두 프레임의 이미지

3.2 차량 영역의 분리

고정된 카메라에서 촬영되는 영상에서 변환되는 영역은 주행하고 있는 차량의 영역이라고 가정할 수 있다. 인접한

두 프레임 이미지의 차분 영상을 구하면 도로와 같이 정지된 부분의 화소값은 이론적으로 0이 되어야 하며, 움직이는 물체의 영역은 상대적으로 큰 절대값으로 표현된다. 이를 위해서 먼저 24비트로 표현된 프레임 이미지를 8비트의 그레이 영상으로 변환시킨다. 그런 후에 시간적으로 최근 프레임에서 이전 프레임을 감산하여 차량의 앞쪽에 존재하는 그림자의 영역을 최소화 하고, 또 상대적으로 차량의 특징 정보가 많이 존재하는 차량 전면부의 윤곽을 선명하게 구할 수 있다.

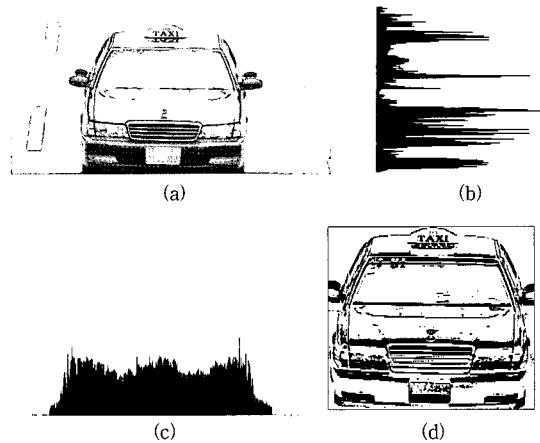
차분영상이 구해지면 일정 문턱치 값을 차분 영상에 적용하여 이진화 작업을 수행한다. 이진화 작업의 결과는 차량의 윤곽을 선명하게 나타내게 된다. (그림 2)는 (그림 1)에 대한 이진화 영상의 예를 보여주고 있다. 문턱치 값은 기상의 변화 상태나 조명 상태 등을 고려하여 설정되어야 한다. 예를 들어서 강한 바람이 불어서 카메라가 미세하게 움직이거나 차에서 반사되는 빛이 강할 경우는 화소값이 조금씩 변화한다. 바람이 불어서 카메라가 고정되지 않고 흔들리는 경우에는 배경의 화소값이 증가하고, 특히 차선과 같이 불필요한 객체의 경계부분이 뚜렷하게 나타나게 된다. 잡음이 많은 차분영상은 다음에 수행하게 되는 프로젝션의 계산에서 잘못된 영역을 유도하게 되는 요인이 된다. 이러한 점을 고려하여 최대한 차량 영역의 정보를 잃지 않고 최적의 차량 영역만을 결정할 수 있도록 문턱치값을 설정하였다.



(그림 2) 차분 영상의 이진화 영상

차분이진 영상을 구한 후에는 프로젝션을 적용하여 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. 일반적으로 수직 프로젝션을 취하여 차량의 좌우 영역을 먼저 결정하고, 차량의 좌우 영역 한도 내에서 수평 프로젝션을 구하여 차량의 전후 영역을 결정하여 차량의 경계영역을 결정하였다.

(그림 3)은 수평 및 수직 프로젝션에서 차량의 인접영역을 결정하는 과정을 보여주고 있다. 수직 프로젝션은 일반적으로 단순한데 반하여, 수평 프로젝션은 차량의 중심 부분에서의 프로젝션 값이 차량의 전후 부분의 값에 비해 작은 특성을 보인다. 여기에서 (그림 3) (a)는 인접 프레임으로부터 선택된 영상을 나타내고, (그림 3) (b)는 차량의 전후 영역의 근거가 되는 수평 프로젝션, (그림 3) (c)는 차량의 좌우 영역의 근거가 되는 수직 프로젝션, 그리고 (그림



(그림 3) 수평/수직 프로젝션 영상과 경계영역의 결정

3) (d)는 수평과 수직 프로젝션의 영역 결정을 고려하여 최종적으로 구한 차량의 경계영역을 나타내고 있다.

3.3 영상의 수평화

차량의 진입 방향에 따라서 차량의 번호판이 지면과 평행하지 않을 수가 있다. 이러한 영상은 번호판 인식에서도 치명적일 수 있으며, 질감 특징값에 변화를 줄 수가 있다. 따라서 차량의 기울어진 정도를 Hough 변환[14]을 이용하여 구하고, 회전변환을 통해 기울어진 정도만큼 반대 방향으로 회전시켜 보정할 수 있다. Hough 변환을 통해 영상 내의 점들이 형성하는 직선의 방정식을 구할 수 있으므로, 차량의 기울기와 평행한 선분을 찾아내면 차량의 기울기 또한 알아 낼 수 있다. 따라서 차량의 기울기를 측정하기 위해서 차량의 기울기와 평행한 선분을 구성하는 점들을 선택해야 한다. 본 연구에서는 차분이진 영상의 하부 점들 즉, 차량의 범퍼 부분의 일렬로 정렬된 화소들을 선택하였다.

기울어진 각이 측정되면 회전변환을 적용하여 원 영상을 원하는 각도만큼 회전시켜 정렬할 수 있다. 좌표가 (x_1, y_1) 인 점 P_1 을 θ 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 좌표는 식 (2)와 같이 수정된다.

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



(그림 4) 차량의 원영상과 Hough변환을 통하여 보정된 영상의 비교

(그림 4)는 기울어진 차량의 이미지를 반듯하게 회전시킨 결과를 보여주고 있다.

4. 차량의 모델 결정

차량의 모델을 자동차의 윤곽선에 의거하여[12][13] 구분하는 방법이 시도되었다. 그러나 자동차의 윤곽선은 유사한 모델에서 변별력이 없어서, 이러한 방법으로는 구체적인 차량의 제조사와 모델을 인식하기에는 어려움이 있다. 본 논문에서는 차량의 모델 정보를 위한 특징 값을 구하기 위해 자동차의 질감 특성을 사용하였다. 임의의 영상이 주기성이나 특정 방향성이 있다면 질감 에너지를 이용하여 구분지울 수 있다. 질감을 계산하는 영역은 번호판 위의 지역으로 국한시켰다. 이 지역은 라디에이터나 후드의 환기장치가 있어서 차량별로 고유한 모습을 지니고 있기 때문이다. 차량의 모델을 결정하는 순서를 이번 절에서 설명한다.

4.1 관심 영역 추출

차량의 윤곽선에 의한 구분과 달리, 차량 앞부분의 전조등, 라디에이터 그릴 부분의 패턴은 각 차종마다 거의 고유한 외관을 가지고 있기 때문에, 다양한 질감에너지를 내포하고 있다. 질감 특성을 구하기 위해 전조등의 일부와 라디에이터 그릴 부분을 포함한 번호판 바로 윗부분 영역으로 설정하였다. 번호판이 구해진 후 번호판의 중심 좌표를 구하고, 그 좌표를 관심영역을 찾기에 적당한 좌표로 이동시킨 후에 전조등의 일부와 라디에이터 그릴 영역을 포함하도록 적당한 크기로 관심영역을 추출하였다. (그림 5)는 질감 특성을 위해 추출된 관심영역의 예를 보여 주고 있다.



(그림 5) 질감특성을 위해 추출된 관심영역

4.2 질감 특징

일반 영상처리에서 활용되는 질감 특성을[5][16] 차량의 모델을 식별하는 경우에 적용할 수 있다. 먼저 특정 화소별로 정규화시켜 생성한 이중명암행렬인 GLCM을 생성한다. GLCM은 비슷한 그레이 레벨 값들을 가지는 화소들의 위치에 대한 정보를 나타내고 있다. 그레이 영상에서 두 화소의 거리 d 만큼 떨어져 있는 경우가 얼마나 존재하는지를 계산한다. 예를 들어 거리가 5만큼 떨어져 있는 모든 화소 쌍 중에서 한 화소는 레벨 0에서 레벨 255까지의 경우가 모두 몇 개인지 알아내는 것이다. 어떤 영상에서 화소거리를 d 로 했을 때의 GLCM 행렬을 G 라 했을 때, $G[i, j]$ 는 그 영상 내에서 레벨이 i 인 한 화소에서 거리 d 만큼 떨어진 다른 한 화소의 레벨이 j 인 모든 경우의 수를 총 화소수로 나눈 분포 확률값을 나타낸다.

실제 그레이 영상의 레벨은 256레벨이므로 GLCM 행렬의 테이터는 상당히 크다. 그러나, 질감은 크게 세 가지, 즉 밝기의 대조, 규칙성 및 통계적 특성으로 측정 될 수 있다. 본 연구에서는 계산량을 최소화하면서 차량의 모델들을 변별하는 특성이 높은 있는 콘트라스트, 동질성, 엔트로피, 그리고 모멘텀, 4종의 질감 특성을 질감 서술자로 선정하였으며 식 (3)-(6)에 정의하였다.

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

콘트라스트는 식 (3)에서와 같이 GLCM 행렬 G 로부터 유도된다. 콘트라스트는 그레이 레벨들 사이의 명암도 차이를 측정한다. 콘트라스트는 GLCM의 대조를 의미하기 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 G 에 콘트라스트 값이 큰 원소들이 많을 때 차수가 2차인 가중치를 도입하였다. 행렬 G 의 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 d 의 모든 화소 쌍에 대해 명암도 차이가 큰 화소 쌍들이 많이 존재하면 식 (3)의 콘트라스트는 커지고, 명암도 차이가 작은 화소 쌍들이 많이 존재

하면 식 (3)의 콘트라스트는 감소하게 된다.

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

식 (4)는 동질성을 정의한다. 동질성은 가중치가 주 대각선으로부터 멀어질수록 감소한다면, 화소 쌍들의 콘트라스트가 작을 때 그 식의 값은 커지게 된다. 동질성은 가중치들이 주 대각선으로부터 멀어질수록 지수 함수적으로 감소하도록 가중치를 설정하였다. 즉 콘트라스트 가중치의 역의 값으로 가중치를 설정하여 콘트라스트의 특성과 반대의 특성을 갖는다. 즉 화소거리 d 의 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.

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

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

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

식 (6)의 모멘텀은 에너지라고도 불리는데 영상에서 그레이 레벨의 획일성을 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. 행렬 G 가 여러 원소에 대해 고루 값을 갖지 않고 특정한 원소에서 큰 값을 가질 때 모멘텀 값은 증가한다. 즉 영상이 복잡하지 않고 단조롭고 균일 할수록 큰 모멘텀의 값을 갖게 된다.

4.3 차종의 인식

차량 종류의 인식을 위하여 번호판 인식과 유사한 하나의 은닉층을 가지는 역전파 3층 신경회로망을 구성하여 학습을 시켰다. 입력층은 학습을 위한 데이터를 대입하는 부분으로, 본 논문에서는 차량 종류의 학습 및 식별을 위해 식 (3)-(6)으로 정의된 질감 특징자를 네 방향에서 계산하여 총 16 개의 질감 특징 값을 입력으로 사용하였다. 입력으로 사용되는 16개의 질감 특징 값들은 화소 거리 d 를 1로 설정한

경우의 GLCM으로부터 구해진 값들이다. 최종적으로 실험에 사용한 차량의 종류는 24종을 선별하였기 때문에 출력층의 노드수를 24로 설정하였다.

5. 실험 및 결과

5.1 실험 환경

실험에 사용한 데이터는 시내 외곽에서 실제 이동하는 차량들을 주간에 촬영하였다. 도로 바닥으로부터 카메라 렌즈 까지의 높이는 대략 6m를 유지하였다. 차선의 너비는 약 3m였고, 촬영 범위는 주행하는 개별 차량의 인식에 관한 문제를 다루는 점을 고려하여 하나의 차선에 국한시켰다. 이때 차선의 양 끝이 영상의 아래쪽 두 꼭지 점에 맞물리도록 설정하였다.

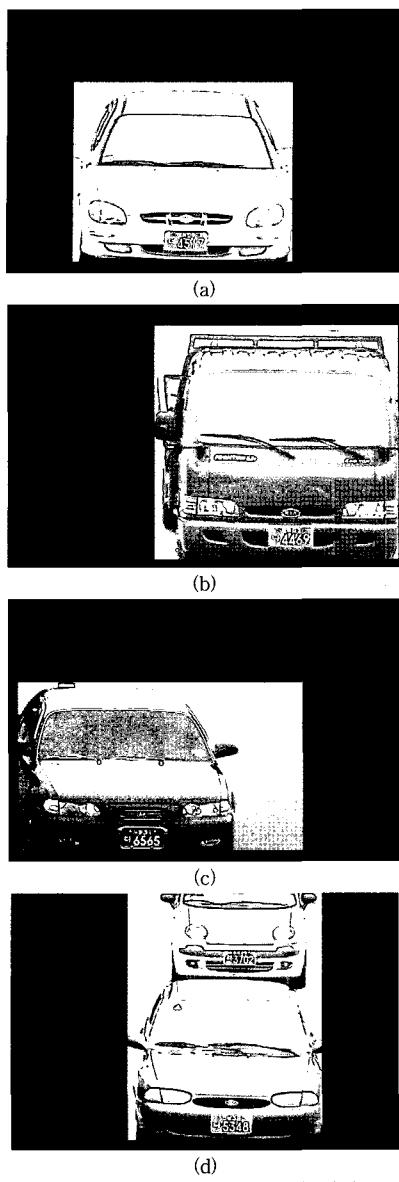
도로 영상은 Sony TRV900(6mm) 디지털 비디오 캠코더를 사용하여 수집하였다. 초점은 일반적으로 도로상의 카메라들이 고정되어 있음을 감안하여, 캠코더 역시 삼각대에 고정하여 수동으로 촬영하였다. 촬영 각도는 수평 위치에서 지면을 향하여 약 10도 정도 기울인 상태로 설정하였다. 촬영 대상 차량은 소형 승용차, 중형 승합차뿐만 아니라 트럭도 포함하였다. 먼저 획득된 영상중에서 차선을 지키지 않았거나 5톤 이상의 대형 트럭과 같이 화면 전체를 차지하는 차량과 같은 불량 영상의 차량은 제외하였다. 영상의 획득이 양호하게 되었어도 동일 차종의 영상의 수가 8대 미만인 차량은 신경망 학습에서 충분한 학습이 이루어지지 않아서 실험에서 제외하였다. 최종적으로 24종의 차량에 대한 415 개의 영상이 실험에 적용되었다.

번호판의 문자와 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. PC의 운영체제는 Windows 2000이고 프로그램의 개발은 Visual C++ 6.0을 이용하였다.

5.2 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 6)은 3.2절에서 설명한 방법으로 도로 영상으로부터 차량 영역을 추출할 때의 결과의 일부를 보여주고 있다. (그림 6) (a)와 (b)는 각각 소형 승용차와 트럭의 차량 영역 추출 결과를 정확하게 찾아낸 결과를 보여준다. (그림 6) (c)는 좌측으로 치우친 영상을 거의 정확하게 찾은 경우이며, (그림 6) (d)는 두 대의 차량이 연속으로 진입하여 제안 알고리즘이 실패한 경우를 보여주고 있다. 그러나 모든 경우에서 번호판과 라디에이터 그릴 영역의 인식은 정확하게 수행되어 정확한 프레임을 찾아서 정확한 차량 영역이 이루어졌다고 해석하였다. 그러나 (그림 6) (d)의 경우 뒤쪽에서 인식된 차량은 인식이 될 수 없었고 번호판 추출도 될 수



(그림 6) 차량 영역 검출의 결과

없었다. 이와 같이 차량 영역이 제대로 되지 않은 경우는 0.25%로 미미하였기 때문에 최종 차종인식 성능은 차량 영역검출의 결과에 의존하지 않는다고 가정하였다.

5.3 차종의 인식

4.3절에서 설명한 바와 같이 입력층-은닉층-출력층의 구조가 16x150x24인 3층 신경망회로를 통하여 학습한 결과로 생성된 질감특성자별 차종의 가중치를 이용하여 차량의 인식 실험을 시도하였다. 인식 효율성을 측정하기 위하여 인식률(sensitivity)과 강건률(specificity)을 식 (7)과 같이 정의하였다.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \times 100 \quad (7)$$

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

여기에서 TP(True Positive)는 차종을 정확하게 인식한 차량의 수, TN(True Negative)은 이종의 차량을 이종의 차량으로 인식한 수, FN(False Negative)은 동종의 차량이지만 이종의 차량으로 인식한 수, 그리고 FP(False Positive)는 이종의 차량을 동종의 차량으로 인식한 수를 의미한다. 식 (7)에서 보는 바와 같이 인식률은 동종으로 분류한 차량 중에서 얼마나 참된 동종의 차량인지를 나타내는 반면, 강건률은 이종 차량으로 분류된 차량 중에서 얼마나 참된 이종 차량인지를 나타낸다. 따라서, 인식률과 강건률 모두 100%에 가까울수록 좋다.

<표 1>은 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 인식되었다. 오히려 3대의 다른 차종을 봉고프런티어1로 인식한 것을 보여주고 있다. 인식률은 식 (7)에 나와 있는 바와 같이 총 차량 중에서 올바르게 인식된 차량의 백분율을 보여주며, 강건률은 다른 차량을 다른 차량으로 인식하는 백분율을 보여주고 있다. <표 1>에서 보는 바와 같이 인식률은 93.7%, 강건률은 99.7%로 나타나고 있어서 양호한 결과를 보여주고 있다.

<표 1> 학습에 사용한 차량의 인식 결과

차 종	차량수	정인식	오인식	인식률	강건률
포터	50	50	3	100	99.2
프런티어1	15	14	3	93.3	99.3
스타렉스	30	26	2	86.7	99.5
프런티어2	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
렉스턴	6	5	0	83.3	100
라노스	9	8	1	88.9	99.8
다이너스티	8	7	0	87.5	100
합계	415대	389대	26대	93.7%	99.7%

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, 많이 획득된 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 특징값의 분포가 인식률에 영향을 주고 있음을 말해주는 것이다. 다이너스티와 렉스턴의 경우, 데이터의 수가 10개 미만으로 적지만 특징 값들이 한곳에 집중적으로 뭉쳐 있기 때문에 다른 차종과의 구분이 명확하여 양호한 인식률을 나타내고 있다. 그러나 엑센트의 경우는 데이터 수가 다이너스티나 렉스턴 보다는 많지만, 다이너스티나 렉스턴처럼 특징 값들이 한곳에 집중적으로 뭉쳐 있지도 않았고, 또 포터처럼 데이터 수가 많지도 않아서 특징 값들이 여러 곳에 하나씩 떨어져서 존재하는 경우가 많았다. 그렇기 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 질감특성자의 분포가 독자적으로 특징을 나타내는 영역을 활용하는 방법이다. 이에 대한 연구는 인식률을 향상시키는 방향으로 추진될 수 있을 것이다.

6. 결 론

교통량의 제어나 교통관련 시스템의 자동화를 위해서는 번호판과 차종의 인식은 필수적이다. 차량의 인식을 위해서 이동 차량의 추정이나 번호판 문자 인식과 같은 연구가 이미 진행되어오고 있다. 그러나, 구체적인 제조회사별 모델의 인식은 시도되지 않았다. 본 논문에서는 차량 전면부의 질감 특징 값들이 차종 식별을 위해 사용 될 수 있음을 최초로 제안하였다.

차종 식별을 위한 차량의 특징으로는 질감 특성자를 도입하였고, 질감으로써 차량의 고유한 특징을 가장 잘 나타낼 수 있는 관심 영역을 결정하였다. 그리고 관심 영역으로부터 GLCM을 이용하여 그 차량의 특징을 나타내는 질감 특징 값을 계산하였고, 그 값을 역전파 알고리즘을 적용한 신경 회로망에 입력 시켜서 차량의 제조회사와 모델을 인식하였다.

제안 알고리즘의 성능을 측정하기 위해서 도시 외곽에서 운행 중인 800여대에 이르는 차량들의 영상을 획득하여 개별 차종의 인식에 관한 실험을 하였다. 먼저 차량의 위치가 차선을 기준으로 유효범위 내에서 운행 중인 차량 415대를 선정하여 결과를 측정하였다. 제조회사별 차종의 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 인식률

이 충분한 데이터를 확보한 경우에는 더 향상될 수 있을 것으로 예상된다.

향후 연구에서 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 특성자의 계산 방법을 개선하는 것이다. 현재는 일부 차종에 있어서 이종간의 차량들도 비슷한 질감 특성자의 값으로 표현되어서 오인식을 하게 된다. 이들 취약점에 대한 개선이 있을 경우 인식률은 더욱 향상될 것으로 기대한다.

참 고 문 헌

- [1] Wu Wei, Yuzhi Li, Mingjun Wang, and Zhongxiang Huang, "Research on number-plate recognition based on neural networks", Proceedings of the 2001 IEEE Signal Processing Society Workshop on Neural Networks for Signal Processing XI, pp.529-538, 2001.
- [2] R.Parisi, E.Di Claudio, G.Lucarelli and G.Orlandi "Car Plate Recognition by Neural Networks and Image Processing" Proceedings of the IEEE International Symposium on Circuits and Systems, Vol.3, pp.195-198, 1998.
- [3] Toru Ikeda, Shinichi Ohnaka, and Masanori Mizoguchi, "Traffic measurement with a roadside vision system-individual tracking of overlapped vehicles", Proceedings of International Conference on Pattern Recognition, Vol.3, pp. 859-864, 1996.
- [4] K. Nishiyama, K. Kato, T. Hineno, and T. Negishi, "Image processing system for traffic measurement", Proceedings on the Industrial Electronics, Control and Instrumentation.
- [5] J. R. Parker "Algorithms for Image Processing and Computer Vision" Wiley Computer Publishing, 1998.
- [6] Richard O. Duda, Peter E. Hart, David G. Stork "Pattern Classification" Wiley Interscience.
- [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] Masataka Kagesawa, Shinichi Ueno, Katsushi Ikeuchi, and Hiroshi Kashiwagi, "Local-Feature Based Vehicle Recognition Infra-Red Images Using Parallel Vision Board", Proceedings of the IEEE International Conference on Intelligent Robots and systems, pp.1828-1833, 1999.
- [10] 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.
- [11] A. Schanz, C. Knoepfle, and B. Michaelis, “Robust Vehicle Detection at large Distance Using Low Resolution Cameras”, Proceedings of the IEEE Intelligent Vehicles Symposium, pp. 267-272, 2000.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] R.Parisi, E.Di Claudio, G.Lucarelli and G.Orlandi “Car Plate Recognition by Neural Networks and Image Processing” Proceedings of the IEEE International Symposium on Circuits and Systems, Vol.3, pp.195-198, 1998.
- [16] I. Pitas, “Digital Image Processing Algorithms and Applications”, Wiley Inter-Science, 2000.



이 효 종

e-mail : hlee@chonbuk.ac.kr

1986년 University of Utah대학 컴퓨터과학과(학사)

1986년 University of Utah대학 컴퓨터과학과(공학석사)

1991년 University of Utah대학 컴퓨터과학과(공학박사)

1991년~현재 전북대학교 전자정보공학부 교수

관심분야: 영상처리, 의용영상처리, 병렬처리, 알고리즘 개발