

# 차량 헤드라이트 특징과 동질성 정보를 이용한 차종 인식

김민호<sup>†</sup>, 최두현<sup>\*\*</sup>

## 요 약

본 논문에서는 차량의 헤드라이트 영상에 Scale Invariant Feature Transform(SIFT) 알고리즘을 적용하여 획득한 특징점을 이용하여 차량의 모델을 인식하는 차종 인식 방법을 제안한다. 보다 정확도 높은 차종 인식을 구현하기 위해서 특징점들의 분포로부터 동질성(homogeneity)을 계산하여 인식 정확성의 척도로 두었다. 제안한 방법의 성능을 평가하기 위해 국내 54종의 차량 영상으로부터 촬영된 400장의 실험 영상을 이용해 실험한 결과, 제안한 방법은 90%의 인식률과 16.45의 평균 동질성을 보였다.

## A Vehicle Model Recognition using Car's Headlights Features and Homogeneity Information

Mih-Ho Kim<sup>†</sup>, Doo-Hyun Choi<sup>\*\*</sup>

## ABSTRACT

This paper proposes a new vehicle model recognition using scale invariant feature transform to car's headlights image. Proposed vehicle model recognition raises the accuracy using "homogeneity" calculated from the distribution of features. In the experiment with 400 test images taken from 54 different vehicles, proposed method has 90% recognition rate and 16.45 homogeneity.

**Key words:** Vehicle Model Recognition(차종 인식), Car Headlights(차량 헤드라이트), SIFT(크기 불변 특징 변환)

## 1. 서 론

오늘날 자동차는 산업화와 함께 수요가 폭발적으로 증가해 왔으며, 가정과 공장에서의 차량 의존도도 점점 더 높아져 가고 있다. 통계청에 의하면 국내에서 운용되는 자동차의 수는 1996년 5만대를 시작으로 2010년 약 1800만대로 증가하였다[1]. 급증하는 차량은 교통과 물류 시스템의 발달에 큰 역할을 하고 있지만 동시에 환경오염과 교통사고 등의 역기능도 발생시킨다. 특히, 뺑소니, 음주 운전, 과속 운전 등의

역기능은 차량 증가에 비례하여 증가하고 있다. 차량과 관련된 역기능들을 감시하는 데에는 많은 인력과 비용이 드는데 영상처리를 통한 영상분석으로 제한된 인력 문제를 해결하고 소모되는 비용을 상당히 줄일 수 있다[2]. 현재 자동차와 관련된 영상 분석 기술들에는 차량 번호판 인식, 교통량 측정 및 분석, 차종 인식 등이 있다. 이 중 차종 인식은 차량 범죄 관련 연구의 기반이 되는 기술로서 번호판 인식과 함께 오래전부터 연구되고 있다. 자동차는 일반적으로 배기량에 따라 경형, 소형, 중형, 대형으로 나뉘고

※ 교신저자(Corresponding Author): 최두현, 주소: 대구광역시 북구 산격동 1370번지 경북대학교 전자공학부(702-701), 전화: 053)950-7576, FAX: 053)950-5505, E-mail: dhc@ee.knu.ac.kr  
접수일: 2011년 5월 24일, 수정일: 2011년 7월 16일

완료일: 2011년 9월 2일  
<sup>†</sup> 준회원, 경북대학교 대학원 전자전기컴퓨터학부 박사과정 (E-mail: birdnamul@ee.knu.ac.kr)  
<sup>\*\*</sup> 정회원, 경북대학교 전자공학과 부교수

사용 목적에 따라 승용, 승합, 화물, 특수, 이륜으로 나뉜다[1]. 본 논문에서는 국내의 차량들이 서로 다른 모델의 헤드라이트를 장착한다는 정보를 바탕으로 입력된 차량 영상에서 차량 헤드라이트 영역을 추출하고, 추출된 영역에 SIFT 알고리즘을 적용하여 특징점(특징정보)을 획득한다. 이후, 획득한 특징점들을 사전에 준비한 차량 헤드라이트 특징 데이터베이스와 비교하여 차종을 인식하고 입력된 차량 영상의 특징점 분포와 데이터베이스의 특징점 분포 사이의 동질성을 계산하여 정인식된 차량의 인식 효율성을 확인한다. 본 논문의 구성은 다음과 같다. 2장에서는 기존의 차종 인식 연구들을 소개하였고, 3장에서는 차종 인식을 위한 전처리에 대해 설명하였다. 4장에서는 제안된 차종 인식 과정과 실험 결과를 제시하며, 5장에서는 결론을 맺는다.

2. 관련 연구

현재까지의 차종 인식에 대한 연구는 크게 두 가지 방향으로 나눌 수 있다. 비교적 초창기의 차종 인식 방법들은 차량 영상의 전역 정보를 이용하여 차량 종류를 인식하였으나 최근 들어 차량 영상에서 국부 영역을 추출하여 차종을 인식하는 방법이 주로 연구되고 있다. Limin[3], Wu[4], Lee[5] 등은 차량 영상의 전역 정보를 이용하여 차종 인식하였다. Limin은 주성분분석(PCA: principal components analysis)을 이용하여 영상의 차원을 낮춘 영상에서 차량의 측면과 정면의 윤곽선을 검출한 후 shape model vector라는 개념을 도입하여 차종 인식을 시도하였고, Wu 등은 45도 각도에서 촬영한 차량 영상에서 윤곽선을 검출한 후 신경망(neural network)을 이용하여 차종 인식을 시도하였다. Lee 등은 차량의 측면 윤곽선을 추출한 후 사전에 준비된 차량 윤곽선 템플릿과 비교하여 차종을 인식하였다. Limin, Wu, Lee 등의 방법들은 대부분의 차량이 비슷한 외형을 가지고 있기 때문에 차량의 크기는 구별할 수 있으나 구체적인 제조사별 모델을 파악하는데 한계가 있고, 차량 영상의 크기에 따라 소형차를 중형차로, 승합차를 승용차로 인식하는 단점이 있다. Hwang[6] 등은 차량 전체 윤곽선으로 차종을 추정하는 것에서 오는 오류를 줄이고자 차량 전체 윤곽선이 아닌 여러 블록으로 영상을 영역 분할 한 후, 블록들의 데이터 값을

support vector machine(SVM)을 바탕으로 데이터베이스와 비교하여 차종을 분류하는 방법을 시도하였다. Kagesawa[7] 등은 100개의 차량 영상을 준비하고 eigen-space에 기반하여 차량 영상의 국부 특징(local feature)을 추출한 다음 이를 데이터 셋으로 두었다. 이후 적외선 카메라로부터 감지된 자동차 영상에서 국부 특징을 추출한 다음 데이터 셋과의 비교를 통해 차량 인식을 하였다. 이[8]는 차종 인식을 위해 차량의 특징으로 차량의 전면부 영상에서 얻어진 GLCM(gray level co-occurrence matrix)을 사용하였다. 이[8]는 GLCM을 통해 추출된 질감 특성을 입력 값으로 받아들이는 3중 신경회로망을 구성하고 이를 통해 차량을 인식하는 방법을 제안하였다. 이[8]가 제안한 방법은 이전의 방법들보다 인식률이 높고 구체적인 차량 모델 인식을 시도하였으나 비슷한 질감 특성을 가진 차량에서는 인식률이 떨어지는 단점이 있다.

3. 차종 인식을 위한 전처리 단계

차량의 종류를 인식하기 위해 필요한 전처리 단계는 신규 차량 영상 확보, 차량 번호판 영역 추정, 차량 헤드라이트 관심 영역 추출, SIFT를 이용한 특징 벡터 추출 및 데이터베이스 비교 등 4단계로 이루어진다. 특징 벡터 데이터베이스는 사전에 확보된 다량의 차량 헤드라이트 영상으로부터 사전에 구축된다. 그림 1은 제안한 차종 인식 방법의 흐름도이다.

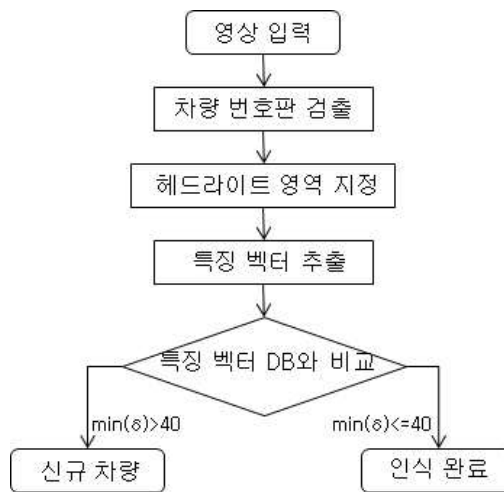


그림 1. 제안한 방법의 흐름도

3.1 신규 차량 영상 확보

본 논문에서는 고정된 CCD 카메라를 이용하여 차량 영상을 확보하였다. 실험에 사용된 카메라는 관공서에 설치된 카메라로 차량의 진입여부를 중력 센서를 이용하여 확인한 다음 1초 간격으로 3번의 촬영을 한다. 촬영 장소가 관공서인 관계로 오전 5시부터 오후 18시까지의 영상이 촬영되었고 총 54종의 차량에 대한 영상이 확보되었다. 확보된 영상들은 해의 위치에 따라 다양한 명암을 가졌다. 촬영된 차량들을 살펴보면 마티즈, 모닝, 아반떼와 같은 소형차에서부터 소나타, SM5와 같은 중형차 및 에쿠스, 그랜저와 같은 대형차에 렉스턴, 무쏘와 같은 SUV 차량 등 다양한 차량들이 포함되었다. 차량 번호판 검출에 쓰인 영상은 3번의 촬영으로 확보된 영상 중 차량이 없는 배경 영상과 가장 히스토그램의 변화 차이가 큰 영상을 선정하였다. 이는 고정된 카메라로 촬영한 영상에서는 배경의 변화가 적음을 고려할 때 차량의 전면부가 많이 포함된 영상은 히스토그램의 변화가 크다는 점을 고려한 결과이다. 그림 2는 한 차량에 대해 촬영된 3장의 영상을 보여준다. 그림 2에서 좌측의 영상은 차종 인식에 사용된 영상이고 우측의 두 영상은 차종 인식에 사용되지 않은 영상이다. 선정된 영상에서 차량 번호판 영역을 추정하고 차량 헤드라이트 관심 영역 추출하는 것은 다음 절에서 설명한다.



그림 2. 차종 인식에 사용된 차량 영상(좌)과 사용되지 않은 차량 영상(우)

3.2 차량 번호판 영역 검출 및 차량 헤드라이트 관심 영역 추출

차량 헤드라이트는 제조사별 차량 모델마다 다른 형태를 가지고 있어 입력된 신규 차량 영상에서 곧바로 헤드라이트 영역을 추출하는 것은 어렵다. 그에 반해 차량 번호판은 정해진 규격과 형태를 가지고

있어 차량 헤드라이트를 추출하는 것보다 비교적 용이하다. 본 논문에서는 차량 헤드라이트 관심 영역을 추정된 차량 번호판 영역 위치 정보와 차량 크기 비율을 이용하여 추정한다. 차량 번호판 영역은 김[9] 등이 제안한 코너 검출 템플릿을 이용한 차량 번호판 추출 알고리즘을 이용하여 검출하였다. 김[9]은 PPHT (progressive probabilistic Hough transform)를 적용하여 번호판 테두리 영역 후보들을 검출하고, 테두리의 네 모서리 특징을 반영한 코너 검출 템플릿을 적용함으로써 네 코너 위치를 찾고 이를 연결해 번호판 영역을 검출하였다. 허프 변환(Hough transform)은 변환 특성에 의해 여러 직선을 검출하는 데 그림 3과 같은 모서리 특징을 반영한 코너 템플릿을 이용하면 번호판 테두리 영역 검출 정확도를 높일 수 있다. 제안한 코너 템플릿은 가로, 세로 각각 17픽셀의 크기를 가졌다. 파란색 영역으로 표시된 픽셀을 기준으로 흰색 영역 픽셀에서는 상하좌우 한 픽셀 사이에 명암도 128 이상의 값을 가지고 동시에 검은색 영역 픽셀에서는 상하좌우 두 픽셀 사이에 명암도 128 이상의 값을 가지면 그 때의 파란색 픽셀을 모서리로 결정한다. 여러 모서리 후보가 나올 경우 정한 문턱치(threshold) 값을 만족하는 픽셀이 가장 많은 경우로 선정하였다. 그림 4(a)와 그림 4(b)에 각각 개정 전 번호판(2006년 11월 이전)과 개정 후 번호판(2006년 11월 이후)에 대한 차량 헤드라이트 관심 영역 추출을 보였다. 대형 화물, 특수, 이륜 목적의 차량 이외의 국내에서 생산되는 차량 모델들의 헤드라이트 크기는 개정 전 번호판 크기의 가로 2배, 세로 3배보다 작은 크기를 가지고 개정 후 번호판의 경우 가로 1.2배, 세로 4배보다 작은 크기를 가진다. 위치적으로 볼 때 번호판 영역을 기준으로 왼쪽에서부터 위쪽 방향으로 앞에서 소개한 크기 비율 안에 포함된다. 다시 말해서, 그림 4(a)에서 작은 사각형을 번호판 영역으로 볼 때 큰 사각형은 작은 사각형의 가로 2배, 세로 3배이고 그림 4(b)에서 큰 사각형은 작은 사각형의 가로 1.2배, 세로 4배이다. 본 논문에서는 그림 4(a)와 그림 4(b)의 큰 사각형 영역을 차량 헤드라이트 관심 영역으로 두었다. 그림 4(b)에서는 헤드라이트 관심 영역이 작은 사각형의 3배 크기에 모두 포함되나, 일부 차종은 세로 방향으로 조금 더 긴 헤드라이트를 장착하기 때문에 헤드라이트 관심 영역을 작은 사각형의 4배 크기로 설정하였다. 헤드라이




그림 3. 번호판 검출에 사용된 코너 검출 템플릿



그림 4. 차량 헤드라이트 관심 영역 (a) 개정 전 번호판(2006년 11월 이전), (b) 개정 후 번호판(2006년 11월 이후)

트 관심 영역을 한정하는 이유는 차량 전체 영상에서 특징점을 추출하여 비교하는 것보다 한정된 영역에서 비교하는 것이 속도 및 비용 면에서 유리하기 때문이다. 다음절에서는 추출된 헤드라이트 관심 영역에 SIFT 알고리즘을 적용하여 특징 벡터를 추출하는 방법을 설명한다.

### 3.3 SIFT를 이용한 특징 벡터 추출 및 데이터베이스 구축

SIFT는 크기가 변화하는 영상에서 강건한(robust) 특징(feature)을 추출하는 특징 추출 알고리즘이다. 본 논문에서 차종 인식을 위해서 사용하는 차량 헤드라이트 영상은 카메라와 차량 간의 거리에 따라 크기의 변화가 크다. 따라서 크기에 불변한 특징을 추출하는 알고리즘이 필요한데 SIFT는 그에 매우 적합한 알고리즘이다. SIFT는 영상의 특징점을 찾기 위해 2차원 가우시안 필터를 이용하여 크기 공간을 구축한 다음 필터의  $\sigma$ (표준 편차)를 크기 요소로 두고 이  $\sigma$ 를 변화시켜 여러 장의 가우시안 영상들을 획득한다. 인접한 가우시안 영상들을 차 연산하여 가우시안 차 연산 영상(DOG : difference of gaussian)들을

획득하고 이들로부터 가우시안 차 연산 영상 크기 공간도 구축한다. 크기 공간에서 특징점을 찾기 위해서 기준 영상 내에서의 점을 기준으로 이웃 8점과 인접한 상하 영상의 각각 9개의 점으로부터 최대값과 최소값을 구한다. 이를 반복하여 최종적으로 가장 안정한 점을 선택하게 된다[10,11]. 그림 5(a)는 DOG를 구성하는 과정이고, 그림 5(b)는 특징점 후보 선정을 보여준다. 본 논문에서는 그림 5(c)와 같은 구조의 4x4x8차원의 SIFT 서술자(descriptor)를 사용하여 특징 벡터를 정의하였다. 그림 6(a)는 본 논문의 실험에서 특징 벡터 데이터베이스 구축을 위해 사용한 차량 우측 헤드라이트 영상으로 3.1절에서 확보한 신규 차량 영상 중 신호 대 잡음비가 좋은 영상들이다. 본 논문에서는 54종의 차량들에 대한 특징 벡터 데이터베이스를 구축하였다. 그림 6(b)는 그림 6(a)의 영상들에 SIFT를 적용하여 얻은 특징 벡터들을 모은 특징 벡터 데이터베이스이다. 실험에는 54종의 헤드라이트 영상을 사용하였으나 그림 6에서는 이 중 일부인 16종에 대한 차량 헤드라이트 영상과 데이터베이스를 나타내었다. 구축된 데이터베이스를 이용하여 차종 인식하는 방법은 다음 장에서 소개한다.

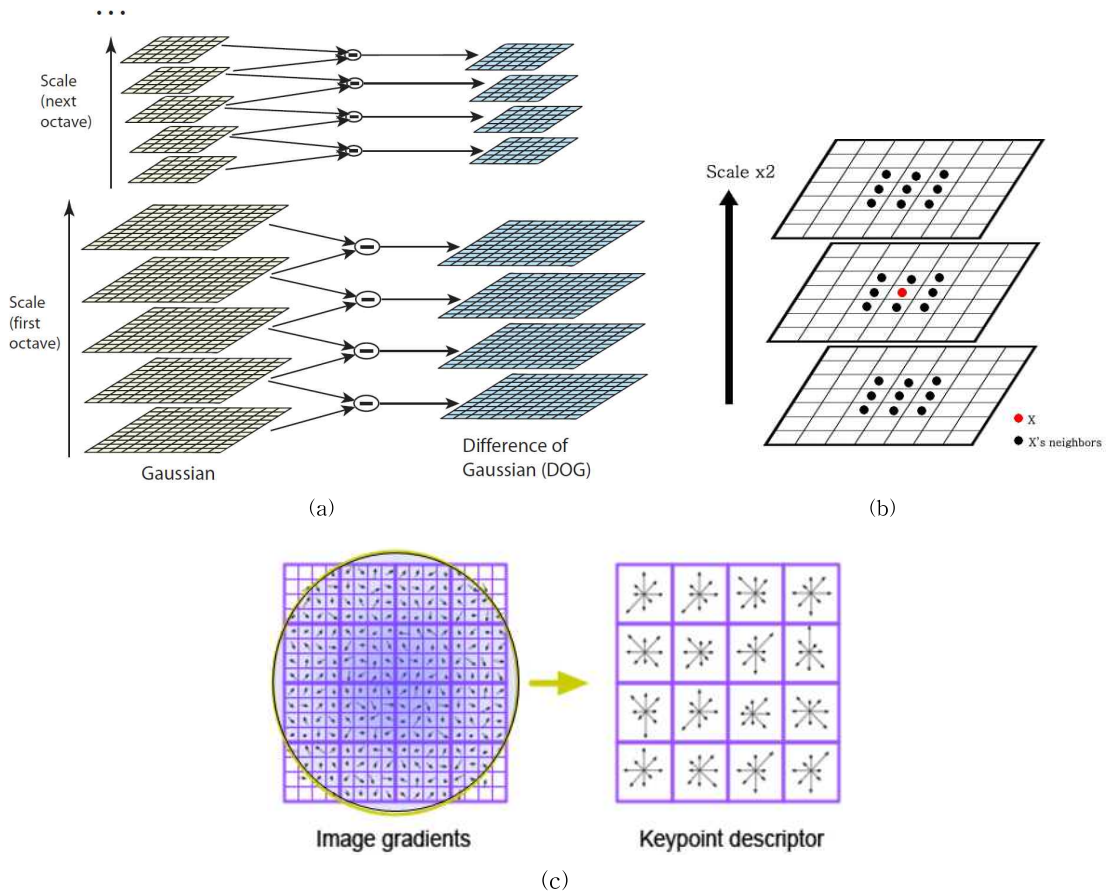


그림 5. DOG 구성 과정 및 특징점 후보 선정 과정[10,11] (a) DOG 구성 과정, (b) 특징점 후보 선정 과정, (c) 4×4×8차원의 SIFT 서술자




그림 6. 차량 헤드라이트 영상 및 특징 벡터 데이터베이스 (a) 실험에 사용된 차량 우측 헤드라이트 영상, (b) 구축된 특징 벡터 데이터베이스

#### 4. 차종 인식 및 실험 결과

카메라로부터 새로운 차량 영상이 입력되면 차량 번호판 영역 추정, 차량 헤드라이트 관심 영역 추출, SIFT를 이용한 특징 벡터 추출 과정을 거치고, 추출된 특징 벡터와 구축된 특징 벡터 데이터베이스의 비교를 통해 차종을 결정한다. 앞서 소개하였듯이, 특징 벡터는 4×4×8차원의 방향을 가진 스칼라 값으로 표현되는데, 본 논문에서는 신규 영상의 특징 벡터들과 데이터베이스의 특징 벡터들 사이의 유클리드 거리의 합을 인식기로 두었다. 본 논문에서 제안하는 차종 인식 방법은 실시간 구현 및 적용을 목표로 두고 있기 때문에 LDA, SVM 등의 인식기보다 비교적 속도가 빠르고 다중 비교에 강점을 가지는 유클리드 거리를 인식기로 결정하였다. 또한, 유클리드

드 거리를 인식기로 사용하면 새로운 차량 특징 벡터 정보가 입력되더라도 새로이 학습과정을 거치지 않고 쉽게 특징 벡터 데이터베이스를 갱신할 수 있는 장점이 있다. 일반적으로 SIFT로 획득한 특징벡터를 비교하는 데는 차원 개수에 따른 회전을 고려하여 데이터베이스와 비교하지만, 차량 영상은 회전 변화가 거의 없으므로 +/- 3°의 회전만 고려하여 비교하였다. 제한한 차종 인식은 식 (1)에 따라 차종 인식 여부를 판단한다. 식 (1)에서  $V_i$ 는 입력된 차량의 특징 벡터이고,  $V_{db}(n)$ 는 준비된 특징 데이터베이스이다.  $n$ 은 특징 벡터 데이터베이스의 차량 모델 번호이다.  $\delta(n)$ 은 입력된 차량의 특징 벡터들과  $n$ 번 차량 특징 데이터베이스 사이의 유클리드 거리이다.  $\delta(n)$  중  $\delta$ 의 값이 최소가 되는  $n$ 으로 차량의 종류를 결정한다[1]. 54종 차량의 실험결과에 따르면 차종 인식이 정확하게 이루어졌을 때는  $\delta(n)$ 의 모든 최소값이 40이하였다.  $\delta(n)$ 의 최소값이 20에서 40사이 일 때는 다른 차량으로 오인식한 경우가 발생하였고,  $\delta(n)$ 의 최소값이 40이 넘는다면 신규 차량 모델로 판단하고 그 때의 특징 벡터를 특징 벡터 데이터베이스에 포함

한다.

$$\delta(n) = \text{Euclidean}(V_i, V_{db}(n)) \quad (1)$$

where

- $V_i$  : features extracted from an input image
- $V_{db}(n)$  : features in the database for vehicle model  $n$

전체 54종의 차량 중 20종의 차량 400대에 대해 제안한 방법을 통해 차종 인식한 결과를 표 1에 보았다. 20종의 차량들은 소형차, 중형차, 대형차, SUV차량 등이 다양하게 배정되었다. 표 1에서 정인식(True Positive)은 차종을 정확하게 인식한 것을 의미하고, 오인식(False Negative)은 동종 차량을 이종의 차량으로 인식한 경우를 의미한다. 그림 7은 새로운 차량이 입력되었을 때 차종 인식을 한 결과이다.

본 논문에서는 인식의 효율성을 측정하기 위해서 인식률과 평균 동질성을 정의하였다. 인식률은 전체 차량 중 정인식된 차량에 대한 확률을 의미하고, 평균 동질성  $m_h$ 는 정인식된 차량들이 얼마나 정확하게 인식되었는지를 보여준다. 평균 동질성  $m_h$ 는 식 (2)

표 1. 차종 인식 결과

차 종	차량수	정인식(TP)	오인식(FN)	인식률	평균 동질성(mh)
그랜저 XG	20	17	3	85%	16.551
그레이스	20	20	0	100%	13.96
레간자	20	20	0	100%	12.6724
렉스톤	20	20	0	100%	18.3354
로체	20	19	1	95%	18.6032
마티즈	20	20	0	100%	6.9914
무쏘	20	16	4	80%	18.1227
봉고3	20	14	6	70%	20.6541
산타페 신형	20	18	2	90%	18.2394
쏘나타 뉴 EF	20	19	1	95%	17.2245
쏘나타 트랜스폼	20	19	1	95%	16.3384
쏘렌토	20	13	7	65%	23.4648
아반떼 HD	20	16	4	80%	23.6764
에쿠스	20	19	1	95%	19.1115
오피러스 뉴	20	19	1	95%	16.2258
제네시스	20	20	0	100%	8.1377
투싼	20	16	4	80%	19.6004
프라이드	20	17	3	85%	14.0725
i30	20	20	0	100%	10.5749
SM5 뉴	20	18	2	90%	16.3974
합 계	400	360	40	90%	16.45




그림 7. 차종 인식 결과

와 같이 계산된다. 식(2)에서  $\sigma_s$ 는 입력 차량의 특징 점들과 매칭(matching)되는 특징 데이터베이스 특징 점들 사이를 연결하는 선분의 기울기 값의 표준편차를 의미하고,  $\sigma_l$ 은 선분 길이 값의 표준편차를 의미한다.

$$m_h(n) = (\sigma_s + \sigma_l) / TP(n) \quad (2)$$

where

$n$ : model number

$\sigma_s$ : std of gradients of segments between the features extracted from an input image and the features in the database


$\sigma_l$ : std of length of segments between the features extracted from an input image and the features in the database

$TP(n)$ : true positive; number of correctly recognized vehicle model  $n$

그림 8(a)와 같이 완전히 같은 영상에서  $\sigma_s$ 와  $\sigma_l$ 을 구한다면, 모든 선분들의 기울기와 길이가 같으므로 그 값은 0이다. 따라서  $\sigma_s$ 와  $\sigma_l$ 가 작을수록 정인식된 차종의 인식 효율성이 높다. 그림 8(b)는 서로 다른 차량의 헤드라이트 사이에서 특징점 매칭을 하였을 때의 결과를 보여준다. 그림 8(a)와 달리 특징점들이

연결된 선분들의 길이와 기울기 값이 많이 다르고 연결된 선분의 수도 5개에 불과하다.

표 2는 실험에서 사용된 차량의 차종 인식결과를 구체적으로 보여준다. 표 2의 숫자는 실험에 사용된 차량의 번호이고 가로축의 O는 차량 데이터베이스에 포함된 다른 차량으로 인식하였을 경우를 나타낸다. 예를 들어 1번(그랜저XG) 차량의 경우 17개의 정인식과 3개의 오인식이 있는데 오인식된 경우를 보면 12번(쏘렌토)와 16번(제네시스)로 오인식하였다. 12번으로 오인식 한 경우를 살펴보면 12번의 헤드라이트가 다른 차량들의 헤드라이트에 비해 1번의 헤드라이트와 닮은 형태를 가졌기 때문에 보이고, 16번의 경우에는 16번의 헤드라이트 형태가 다른 차량들에 비해 복잡하고 뚜렷하여 많은 특징점이 추출되어, 비교적 뚜렷하지 않은 형태의 헤드라이트를 가진 차량들이 가장 많이 오인식 하는 결과를 보였다. 16번은 정인식의 경우에도 모든 차량을 정확하게 인식하였다. 모든 차량을 정확하게 정인식한 차량들은 총 6종으로 복잡하고 뚜렷한 형태의 헤드라이트를 가진 차량들이거나 다른 차량들과 확연히 다른 특징을 가진 헤드라이트를 장착한 차량이었다. 특징점의 분포에서 살펴보면, 한 곳에 특징점들이 뭉쳐있는 것보다 특징점들 사이의 거리가 다양할수록 정인식한 빈도가 높았다. 본 논문에서 제안한 차량 헤드라이트 특징을 이용한 차종 인식의 실험은 CPU 3.0Ghz, RAM 2G, Windows 7 환경에서 이루어졌고 400회의 실험에 672초의 시간이 소요되었다. 신규 차량 영상이 입력되고 차종인 인식되는데까지는 약 1.68초가 필요하였다. 이[8]가 제안하는 방법이 93.7%의 인식률과 한 차량의 차종을 인식하는데 2.4초가 필요한 것과 비교할 때 인식률에서는 약간 나쁘고, 계산속도 부분에서는 조금 빠르다.



(a)



(b)

그림 8. 입력 영상과 데이터베이스 영상 간의 특징점 매칭 (a) 동일한 영상 간의 매칭, (b) 이종 차량 영상 간의 매칭

표 2. 세부 차종 인식 결과

(O: others)

		최종 인식된 차종																				
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	O
승용차	1	17											1				2					
	2		20																			
	3			20																		
	4				20																	
	5					19											1					
	6						20															
	7		1					16				1			2							
	8						1		14										1			4
	9									18	2											
	10										19					1						
	11											19					1					
	12												13				2					5
	13	1										1		16								2
	14														19		1					
	15										1					19						
	16																20					
	17																	16	4			
	18																	2	17	1		
	19																			20		
	20				2																	18

5. 결 론

차종 인식은 차량 범주 관련 연구에서 기반이 되는 기술로서 번호판 인식과 더불어 필수적인 연구 분야이다. 차종 인식에 대한 관심이 높아지면서 많은 연구가 진행되고 있지만, 현대 사회에는 매우 다양한 차종이 존재하기 때문에 구체적인 차종의 모델을 인식하는 데는 많은 어려움이 있다. 본 논문에서는 국내에 존재하는 대부분의 차량 모델들이 서로 다른 헤드라이트를 장착하고 있는 점에 착안하여 차량 헤드라이트를 특징으로 하는 차종인식을 제안하였다. 본 논문에서는 차량 번호판의 위치로부터 차량 헤드라이트 관심 영역을 추출하고 헤드라이트 영상에 SIFT 알고리즘을 적용하여 차량 헤드라이트 특징 정보를 추출한 다음 이를 바탕으로 차종 인식을 시도한다. 제안한 방법의 성능을 평가하기 위해 54종의 차량들에 대한 영상을 확보하고 이 중 400장의 영상을 선정하여 실험하였다. 실험결과의 정확성을 도모하기 위해 평균 동질성이라는 용어를 정의하고 이를 통해 차종 인식의 정확도와 효율성을 확인하였다. 본 논문에서 제안한 차종 인식 방법은 전체 90%의 인식

률과 16.45의 평균 동질성을 보이고 한 차량의 차종을 인식하는데 약 1.68초가 필요하였다.

향후 연구에서는 비교적 단순한 형태의 헤드라이트를 장착한 차량에서의 보다 정밀한 특징 정보를 추출하고, 차량 형태 정보를 추가로 이용하여 보다 정확한 차종 인식 시스템을 구현한다면 인식을 향상에 도움이 될 것으로 생각된다.

참 고 문 헌

[1] 김민호, 최두현, “차량 헤드라이트의 특징 정보를 이용한 차종 인식,” 2011년 정보 및 제어 심포지움(ICS '11) 논문집, pp. 211-212, 2011.

[2] 나인섭, 김수형, “지능형 교통정보시스템(ITS)에 관한 국내외 기술개발 현황,” 한국멀티미디어학회지 제14권 제1호, pp. 16-30, 2010. 3.

[3] X. Limin, “Vehicle Shape Recovery and Recognition using Generic Models,” Proceedings of the 4th World Congress on Intelligent Control and Automation, pp. 1055-1059, 2002.

[4] W. Wu, Z. QiSen and W. Mingjun, “A Method



of Vehicle Classification using Models and Neural Networks,” Proceedings of the IEEE conf. on Vehicular Technology Conf., Vol.4, pp. 3022-3026. 2001.

[5] Kyoung-Mi Lee and W. N. 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.

[6] W. Hwang and H. Ko, “Real-time vehicle recognition using local feature extraction,” *Electronics Letters*, Vol.37, No.7, pp. 424-425, 2001.

[7] M. Kagesawa, S. Ueno, K. Ikeuchi and H. Kashiwagi, “Local-Feature Based Vehicle Recognition in Infra-Red Images using Parallel Vision Board,” Proceedings of the IEEE Conf. on Intelligent Robots and systems, pp. 1828-1833, 1999.

[8] 이효종, “신경망을 이용한 운행차량의 차종 인식 연구,” 전자공학회 논문지, 제42권, 제4호, pp. 69-78, 2005.

[9] 김종화, 최두현, “탐색영역축소 및 코너템플릿을 이용한 차량번호판 추출,” 2010년도 한국멀티미디어학회 춘계학술발표대회 논문집 제13권, 제1호, pp. 31-32, 2005.

[10] 김민호, 최두현, “SIFT 기반 영상 타일링,” 제 22회 신호처리합동학술대회, pp. 319-320, 2009.

[11] David G. Lowe, “Distinctive Image Features from Scale-Invariant Keypoints,” *Int. J. of Computer Vision*, Vol.60, No.2 pp. 91-110, 2004.



**김민호**

2001년 3월~2006년 8월 경북대학교 전자전기컴퓨터학부 학사  
 2006년 8월~2008년 8월 경북대학교 대학원 전자전기컴퓨터학부 석사

2009년 3월~2011년 2월 경북대학교 대학원 전자전기컴퓨터학부 박사수료  
 관심분야: 신호처리, 영상처리, 무인자동차, 비파괴검사



**최두현**

1986년 3월~1991년 2월 경북대학교 전자공학과 학사  
 1991년 3월~1993년 2월 포항공과대학교 전자전기공학과 석사  
 1993년 3월~1996년 8월 포항공과대학교 전자전기공학과 박사

1996년 8월~2000년 2월 경북대학교 전자전기공학부 계약조교수  
 2003년 3월~현재 경북대학교 전자공학부 조교수, 부교수  
 관심분야: 신호처리, 영상해석, 비파괴검사, 지능 알고리즘, 무인자동차