

지능형 자동차를 위한 비디오 기반의 교통 신호등 인식 시스템

추연호 · 이복주 · 최영규[†]

[†]한국기술교육대학교 컴퓨터공학부

A Video based Traffic Light Recognition System for Intelligent Vehicles

Yeon Ho Chu, Bok Joo Lee and Young Kyu Choi[†]

[†]Korea University of Technology and Education, School of Computer Science and Engineering

Abstract

Traffic lights are common in cities and are important cues for the path planning of intelligent vehicles. In this paper, we propose a robust and efficient algorithm for recognizing traffic lights from video sequences captured by a low cost off-the-shelf camera. Instead of using color information for recognizing traffic lights, a shape based approach is adopted. In learning and detection phase, Histogram of Oriented Gradients (HOG) feature is used and a cascade classifier based on Adaboost algorithm is adopted as the main classifier for locating traffic lights. To decide the color of the traffic light, a technique based on histogram analysis in HSV color space is utilized. Experimental results on several video sequences from typical urban environment prove the effectiveness of the proposed algorithm.

Key Words : traffic light recognition, intelligent vehicle, shape analysis, HOG (Histogram of Oriented Gradient), AdaBoost algorithm, cascade classifier

1. 서 론

최근 들어 안전을 위한 지능형 차량에 대한 관심이 점점 높아지고 있는데, 특히 신호등과 같은 중요한 교통 정보를 차량에 제공하여 활용하도록 하는 방법에 대한 연구가 활발하다 [1]. 과거에는 신호등 정보의 활용을 위해 교차로의 고정된 위치에 카메라 등의 센서를 설치하여 운영하는 정적인 방법을 사용하였으나, 최근에는 카메라를 차량에 직접 장착하여 차량 내에서 직접 신호등 정보를 검출 및 인식하는 동적인 방법에 대한 연구가 진행되고 있다[2-4]. 본 논문에서는 이러한 동적인 방법에 초점을 맞추는데, 차량 내 카메라에서 신호등을 자동으로 검출하고 인식하는 방법에 대해 기술한다.

신호등은 교통 표지판과 같은 정적인 정보와는 달리 시간에 따라 동적으로 변화하는 특징을 가지므로, 이를 실시간에 인식하여 차량에 제공하는 것이 필요하다. 또

한 신호등 인식은 잘못된 신호 정보를 차량이 이용할 경우 사고의 위험이 있기 때문에, 무엇보다 신호 정보의 높은 인식률을 요구하고 있다.

일반적으로 신호등 인식 방법은 색상 기반 방법과 형태 기반 방법으로 나눌 수 있는데, 색상에 기반한 방법은 선명한 화질의 영상을 안정적으로 얻을 수 있는 경우 좋은 결과를 나타내지만, 그렇지 않거나 배경이 복잡한 상황에서는 오검출이 많이 발생할 수 있다. 형태에 기반한 방법은 화질에 의한 문제를 극복할 수 있지만 다양한 형태로 나타나는 신호등을 안정적으로 인식하기 위해서 각각의 특징 규칙(characteristic rule)을 생성해서 처리해야 한다는 단점이 있다. 본 논문에서는 기존의 색상 기반 알고리즘들이 가지는 문제점들을 극복하고, 보다 안정적으로 신호등을 검출하는 방법으로, 형태 기반 알고리즘에 초점을 맞춘 새로운 신호등 인식 방법을 제안한다.

본 논문의 구성은 다음과 같다. 먼저 2장에서 기존의 방법들의 문제점과 제안된 방법의 특징을 설명하고, 3장에서는 제안된 신호등 인식 알고리즘을 자세히 기술

[†]E-mail : ykchoi@koreatech.ac.kr

한다. 4장에서 실제 도로 환경에서 실험한 결과를 보이고 분석하며, 마지막으로 5장에서 결론을 맺고 향후 개선사항을 소개한다.

2. 기존 연구 및 제안된 방법의 동기

지능형 교통 시스템에 기반한 신호등 검출방법들이 제안되었는데, 이들은 고정된 카메라를 사용하며, 따라서 지능형 차량을 위한 신호등 인식에는 적합하지 않다. Tu와 Li는 MCMC (Markov Chain Monte Carlo) 이론에 기반한 신호등 인식 방법을 제안했으나 실시간 성능이 좋지 않다[5].

Shen은 저가의 고성능 카메라를 이용해 취득된 영상을 기반으로 신호등 인식을 수행했다[6]. 이 알고리즘은 가우시안 분포에 따른 색상과 채도 모델을 사용하고, 수집된 샘플의 학습을 통해 통계적인 모델 파라미터를 획득한다. 학습된 모델로부터 실험 이미지상의 신호등 후보영역을 추출하였으며, 형태 정보를 고려한 전처리 방법을 후보 영역에 적용하였다. Lu는 검출과 분류를 사용해 신호등 인식을 수행했다[7]. 검출 단계에서는 HSI색상 공간에서 신호등의 특정 색상으로 영역을 추출한 후, 모폴로지(morphology) 연산과 영역 라벨링을 통해 신호등의 후보 영역을 검출하였다. 분류 단계에서는 외곽선을 검출하고 신호등 후보 영역의 색상을 매치하여, 신호등과 일치하는 영역을 추출하였다. Raoul은 스포트라이트 검출과 적응형 신호등 템플릿에 기반한 실시간 신호등 인식을 제안했다[8]. 이와 같은 기존의 색상 기반 알고리즘은 신호등의 색상이 잘 보존되어 있는 경우에 적합하다. Fig. 1과 같이 저가의 고성능 카메라를 이용해 실제 도로 환경에서의 촬영한 영상에서는 색상의 구분이 어려운데, 태양광이나 네온사인 등 주변광의 요인으로 색상 정보가 손실되어 신호등의 과란 색상의 검출이 매우 어려움을 알 수 있다.

다양한 차선에 위치한 차량에서 일정 거리 이상의 신호등을 인식하기 위해서는, 넓은 화각이 요구되며, 신호등의 크기는 작아진다. 색상 기반 알고리즘은 태양광에 의한 색상 손실을 보상하기 힘들며, 다양한 조명 환경에 대응하기 위해, 신호등의 색상 범위를 넓게 설정할 경우, 넓은 화각을 가지는 다양한 배경의 입력영상에서 검출된 오검출 영역을 필터링 하기 힘들다. 따라서, 카메라의 성능과 조명 환경에 종속되지 않는 알고리즘으로는 색상기반 알고리즘 보다는 형태에 기반한 방법이 더 적합하다. 따라서 본 논문은 형태에 기반한 신호등 인식 알고리즘으로 기계 학습(machine learning)을 이용한 방법을 제안한다.



Fig. 1. Example of color segmentation algorithm.




Fig. 2. Conceptual diagram of our system.

Fig. 2는 제안된 신호등 인식 시스템의 개념도를 보여주고 있는데, 차량 내부에 CCD 카메라, 임베디드 신호처리 보드, 경로안내 시스템을 장착하여 사용자에게 신호 정보를 전달하도록 구성하였다. CCD 카메라는 차량의 전방 영상을 촬영하여 신호처리 보드로 전송하고, 이 보드에서 제안된 신호등 인식 알고리즘을 수행하게 된다. 인식 결과는 경로안내시스템으로 전달되어 사용자에게 영상과 음성으로 정보를 제공한다.

3. 제안된 신호등 인식 알고리즘

Fig. 3은 제안된 방법의 구성을 보여주고 있다. 전체 과정은 3단계로 이루어지는데, 먼저 정규화된 신호등 샘플로부터 분류기를 생성하는 학습 단계와, 생성된 분류기를 이용해 입력 영상에서 신호등을 찾는 검출 단계, 마지막으로 검출된 신호등 영역으로부터 신호정보를 인식하는 인식 단계이다.

학습 단계에서는 정규화된 신호등 샘플을 이용해 HOG (Histogram of Oriented Gradient) 특징량(feature)과 Cascade 기반의 AdaBoost 알고리즘을 사용하여 분류기를 생성 하였다. 검출 단계에서는 다양한 크기의 신호등을 검출하기 위해서 가변 크기의 윈도우를 사용하였으며, 학습된 분류기를 이용해 윈도우 영역내의 신호등 유무를 판별하도록 하였다. 마지막으로 인식 단계에서는 히스토그램 분석을 통해, 신호등으로 분류된 영역내에서 신호정보를 인식하도록 하였다.

제안된 시스템은 횡형식 신호등 인식을 목표로 하고 있으며, 신호등 샘플로 정규화된 횡형식 삼색등 이미지를 사용하였다. 제안된 알고리즘은 기계학습을 통해 신

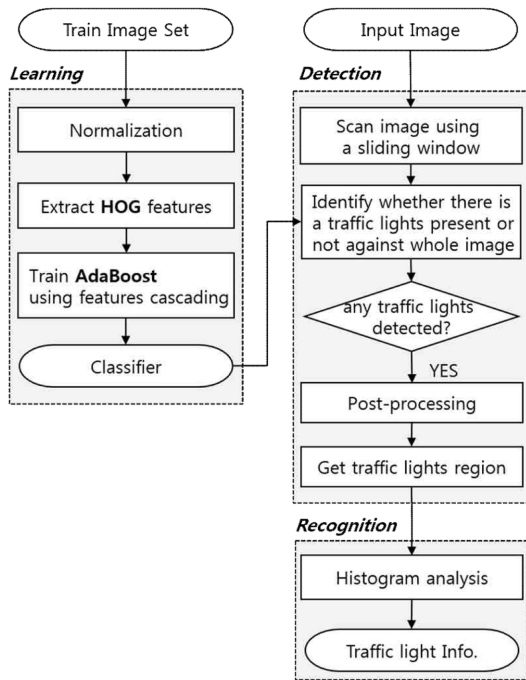


Fig. 3. Block diagram of proposed method.

호등을 검출하며, HOG 특징량을 이용한 Cascade 기반의 AdaBoost 알고리즘을 사용하여 분류기를 생성하였다. 분류기를 통해, 신호등으로 검출된 영역은 오검출 영역의 필터링 단계와 신호등 병합의 검출 후처리 과정을 거친 후, 최종적으로 신호정보를 인식한다.

3.1. 특징량 (Feature)

최근 객체 검출에 많이 사용되는 특징량(feature)으로 Haar [9], LBP (Local Binary Pattern) [10], HOG [11] 등이 있다. Haar 는 Viola-Jones 분류기에서 사용되었는데 영상에서 영역들 간의 밝기 차이를 이용하는 방법이다. 다양한 형태의 기본 특징량을 정의하고, 이들을 조합하여 물체의 특징을 추출한다. LBP는 조명 변화에 강인한 특성을 가지는데, 하나의 중앙 화소에 대해 이웃 화소들과의 관계를 규정하는 일종의 연산자이다. 이웃 화소의 밝기를 중앙 화소의 밝기 값으로 이진화 하고, 그 결과를 정해진 방향으로 정렬하여 코드로 나타낸다. 이들 특징량은 객체 내부에 다양성이 존재할 경우 식별이 어려운 특성을 가진다.

제한된 방법에서는 적색, 황색, 녹색등을 포함하는 신호기 전체 영역이 검출 대상이며, 신호기 내부의 신호 상태가 변화하므로, Haar 나 LBP 와 같이 영역간의

밝기 차를 이용한 특징량은 적합하지 않음을 실험을 통해 관찰하였으며, 신호기 내부의 동적인 신호 변화에 강인한 HOG 를 특징량으로 사용하였다.

Dalal과 Triggs에 의해 제안된 HOG는 어떤 물체 영상이 갖는 지역적인 기울기 분포 특성을 추출하여 물체를 추출하는 방법이다. 즉, 국소영역에 대한 밝기의 분포 방향을 히스토그램화하여 이를 특징벡터로 나타내는 것으로써, 국소영역의 기하학적인 변화에 강건한 특성을 가진다. HOG 특징량 추출을 위해서는, 우선 기울기 값을 계산하여 셀을 벡터화 하고, 셀들을 블록으로 구성된 후 정규화를 수행한다.

기울기 값은 밝기 영상 $I(x, y)$ 로 부터 x 축과 y 축의 변화에 대한 분포의 크기 m 과 $I(x, y)$ 변화에 대한 방향성을 나타내는 θ 를 다음의 식 (1-3) 을 이용하여 계산하였다.

$$m(x,y) = \sqrt{f_x(x,y)^2 + f_y(x,y)^2} \tag{1}$$

$$\theta(x,y) = \tan^{-1} \frac{f_y(x,y)}{f_x(x,y)} \tag{2}$$

$$\begin{aligned} f_x(x, y) &= I(x + 1, y) - I(x - 1, y) \\ f_y(x, y) &= I(x, y + 1) - I(x, y - 1) \end{aligned} \tag{3}$$

계산된 변화에 대한 밝기영상 분포의 크기 m 과 방향성 θ 를 이용하여 8×8 픽셀 크기를 하나의 셀로 하였으며, 이 셀 내부의 밝기의 변화에 대해 히스토그램을 작성하였다.

마지막으로, 각 셀에서 구해진 작성된 밝기에 대한 방향성 히스토그램을 3×3 셀을 하나의 블록으로 하는 정규화를 실시한다. i 행 j 열의 셀 (i, j)의 특징량(9차원)을 $F_{ij} = [f_1, f_2, \dots, f_9]$ 로 나타낸다. k 번째 블록의 특징량(81차원)은 다음과 같이 표현 할 수 있다.

$$B_k = [F_{ij}, F_{i+1j}, F_{i+2j}, F_{ij+1}, F_{i+1j+1}, F_{i+2j+1}, F_{ij+2}, F_{i+1j+2}, F_{i+2j+2}] \tag{4}$$

이러한 특징량은 다음과 같은 정규화 과정을 거쳐 특징 벡터를 v 를 만든다.

$$v = \frac{f}{\sqrt{|B_k|^2 + \epsilon^2}} (\epsilon=1) \tag{5}$$

3.2. 분류기 (Classifier)

기계 학습에서 특징 벡터를 분류하기 위해 Bayesian 분류기[12], 신경망(Neural Network)[13], SVM (Support

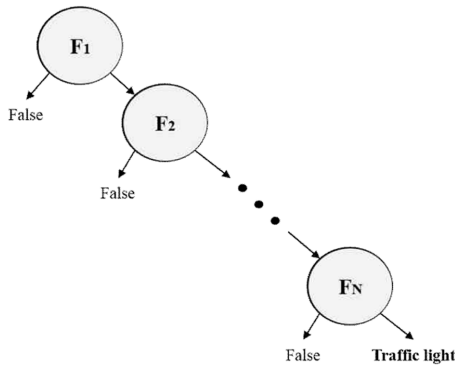


Fig. 4. Cascade classifier based on AdaBoost.

Vector Machine)[14], AdaBoost[15] 등 다양한 방법들이 제안되었다. 본 연구에서는 AdaBoost 기법을 사용하였는데, 이 방법은 학습에 비교적 많은 시간이 소요되지만 검출 성능이 우수하고 구현이 용이한 것으로 알려져 있다. AdaBoost는 Freund와 Schapire에 의해 2-class 문제를 해결하기 위해 설계된 알고리즘으로서, Viola와 Jones는 Haar-like 특징량과 AdaBoost에 기반한 객체검출 기술을 통해 얼굴 검출을 수행 함으로써, 높은 정확도와 빠른 처리속도를 보여주었다. 또한, 보행자 검출, 차량 검출, 번호판 검출 등 주로 이진 분류 문제를 해결하기 위해 많은 연구들에서 응용 되고 있다.

AdaBoost 알고리즘을 기반으로 Cascade 구조의 분류기를 생성하여 검출시 연산량을 감소시켜 실시간성을 높이도록 하였다. Fig. 4는 AdaBoost 기반의 거절 Cascade 개념도를 보여주고 있다.

각 노드는 높은 검출율(false negative가 적음)과 낮은 거절율(false positive가 많음)을 갖도록 설계되었다. 각 노드에서 Cascade의 결과가 거짓인 경우 연산을 정지시키고 알고리즘은 해당 위치에 신호등이 존재하지 않는다고 판단하며, 전체 Cascade를 모두 통과 하였을 경우에만 신호등으로 판단된다. 따라서 영상에서 신호등이 드문 경우, 거절 Cascade를 사용하여 연산 속도를 크게 줄이게 된다.

3.3. 학습 과정

학습 과정은 신호등 검출에 필요한 분류기를 생성하는 과정으로, 수집된 학습 샘플로부터 HOG 특징량을 추출하고 AdaBoost 기반의 Cascade 분류기를 구축한다. 학습을 통해 복잡도에 따라 다수의 약 분류기(weak classifier)를 생성한 후, 이를 하나의 강 분류기(strong classifier)로 연결하였으며, 총 14단계로 Cascade를 구성하였다. 각 단계의 오검출율은 0.5로 설정 하였

으며, 이는 입력 후보들 중 50% 이상을 걸러 낼 수 있는 약분류기를 찾겠다는 의미이다. 최종 검출기의 오검출율은 $0.5^{14} = 0.0000610$ 정도이며, 이는 입력 영상의 모든 가능한 윈도우 영역에 대한 오검출율을 의미한다.

3.4. 검출 과정 및 검출 후처리

신호등 검출 과정은 카메라의 입력 영상 위를 가변 크기의 윈도우를 사용해 반복적으로 슬라이딩하는 방식을 사용하였다. 즉, 윈도우 크기는 검출하고자 하는 거리 범위 내의 신호등 크기를 카메라 파라미터를 이용해 사전에 계산한 후, 최소영역과 최대 영역, 그리고 윈도우 배율 값을 설정하여 다양한 크기의 신호등을 검출할 수 있도록 구성하였다. 윈도우 내의 이미지는 학습 과정에서 생성된 분류기의 입력이 되며, 모든 단계를 통과한 윈도우는 신호등 영역으로 판단된다.

검출 후처리 과정은 오검출 영역의 필터링 단계와 신호등 병합의 두 단계로 구성된다. 오검출 영역의 필터링은 분류기로 검출된 영역을 검증하는 단계로서, 검출 영역을 HSV 색상 모델로 변환 후, 신호등의 적색, 황색, 녹색의 H, S, V 범위안에 있는 화소들의 개수를 찾는다. H, S, V 값의 범위는 수집된 샘플을 통해 획득된 통계 값을 사용하였다.

Fig. 5는 검출 영역을 검증한 예로서, 신호등의 색상 범위에 있을 경우, 해당 픽셀을 그대로 도시하고, 그렇지 않을 경우, 해당 픽셀을 검은색으로 도시한 예이다. 최종적으로 신호등 색으로 판단된 화소의 수가 설정된 임계치(Threshold) 이상이면, 검출된 영역에 신호등이 존재하는 것으로 간주하였다.

본 논문에서는 횡형식 3색 신호등을 검출 대상으로 하였는데, 4색 신호등의 경우 3색 신호등의 검출 결과를 병합하여 추출할 수 있다. Fig. 6은 분류기를 통해 검출된 3색 신호등의 검출 결과를 병합하여, 4색 신호등 영역을 추출 한 예를 보여주고 있다.

3.5. 신호정보 인식 과정

최종적으로 신호등으로 검출된 영역은 신호정보를 인식하기 위해 히스토그램 분석을 수행하였다. 히스토



Fig. 5. Example of verification for detection region.



Fig. 6. Example of merging detection regions.



Fig. 7. Example of traffic status recognition.

그림 분석을 위해서는 적절한 bin(bin)의 수를 선정하는 것이 중요하다. 신호등의 경우 물리적으로 각 등이 정사각형의 동일한 크기를 가지고 있으므로, 신호등 영역의 중첩비를 계산하여, 3색 신호등과 4색 신호등으로 구분 하였으며, 3색 신호등의 경우 bin의 수를 3으로, 4색 신호등의 경우 bin의 수를 4로 설정하여 신호정보를 검출토록 하였다. 각 bin 내에 신호 정보의 존재 유무는 3.4절의 오검출 영역 필터링 단계에 사용한 신호등의 HSV 색상 값을 이용하여 판단하였다. Fig. 7은 3색과 4색 신호등의 신호정보 추출 예를 보여준다.

4. 실험 결과 및 분석

제안된 시스템은 차량 내부에 장착 가능한 VGA급 해상도를 지원하는 카메라를 사용하여, 25 m 거리 이내의 신호등을 인식하는 것을 목표로 하였다. 영상에서 신호등의 크기가 클수록 검출에 용이하나, 차량이 다양한 차선에 위치하는 것을 고려해야 함으로, 9 mm의 초점거리를 가지는 렌즈를 선택하였다. 알고리즘의 개발은 Windows 환경에서 C와 C++, OpenCV를 사용하여 진행하였고, 구현된 알고리즘을 리눅스 환경의 신호처리 보드에 포팅하였다. Fig. 8은 개발된 시스템을 실제 차량에 장착하여 시험한 영상을 보여준다.

학습 샘플을 구축하기 위해, 차량에 장착된 카메라를 이용하여 도로 환경을 촬영하였다. 샘플은 다양한 날씨에 따른 조명 환경이 반영되어야 함으로 수 일에 걸쳐 촬영 되었으며, 시간대별로 다양한 도로환경에서 3색과 4색 신호등을 포함한 영상과 일반 도로 영상을 수집하였다. 수집된 영상을 이용해, 60 × 28 pixel 크기로 정규화된 3색 신호등 영역을 Positive 샘플로 추출 하였으며, 신호등을 포함하고 있지 않은 도로 영상을 Negative 샘플로 추출하여 학습 샘플을 구축하였다. Fig. 9는 학습에 사용된 3색 신호등의 이미지를 보여주고 있으며, 다양한 신호상태를 반영하기 위해, 4색 신호등 영역을 분할하여 샘플에 포함하였다. 샘플은 신호등의 식별이 보다 용이하도록, 신호등 상단의 풀대 영



Fig. 8. Example of traffic light recognition.



Fig. 9. Example of positive samples.

역을 추가하였으며, 정지신호 1,500개, 대기신호 1,154개, 좌회전신호 1016개, 직좌신호 1043개, 그 외 동시 신호를 포함하여 총 7,616개의 Positive 샘플이 사용되었다.

제안된 시스템은 신호등 검출을 위한 Cascade 분류기 생성을 위해 OpenCV에서 제공하는 Cascade Classifier 모듈을 사용하였다. 학습 파라미터로는 각 Cascade 학습 단계에 사용되는 전경 및 배경 샘플 수, 학습 할 Cascade 단계 수, 기본 분류기들에게 요구되는 오검출율의 상한, 그리고 최종 검출기에 대해 예상되는 오검출율 등이 있다. 검출 파라미터에는 슬라이딩 윈도우 크기와 배율이 있는데, 최소 영역과 최대 영역 사이에서 scale factor에서 설정된 값을 비율로 하여 영역을 확대하며 검출을 수행하게 된다. 또한 신호등으로 분류된 영역 주위로는 다수의 검출 영역이 존재하게 되는데, 최소 중복 영역 수를 설정할 수 있도록 하여 이 이상의 영역이 존재 할 경우, 해당 영역을 병합하여 최종 신호등 영역으로 판단한다.

제안된 시스템의 성능을 측정하기 위해 30 개의 장소에서 주간, 야간, 흐린 날의 영상을 각 각 촬영 하였으며, 신호등과 카메라의 거리는 20 ~ 25 m 정도를 유지하였다. 각 동영상은 평균 100프레임 정도의 연속된 이미지로서, 신호가 변경되는 순간을 포함 하였다. Table 1은 촬영된 동영상을 입력으로 하여 인식율과 처

Table 1. Performance of our system

	Recognition Rate [%]	Processing Speed [Hz]
Day	96.69	23.65
Night	80.00	33.52
Cloudy	86.67	23.57

리 속도를 측정된 결과를 보여주고 있다. 연속한 100 프레임의 이미지 중 하나의 프레임이라도 실패하면 실패로 간주하였다. 실험 결과 주간에는 매우 안정적인 결과를 보이지만, 야간과 흐린날에 인식율이 떨어지는 것을 알 수 있었는데, 야간에는 신호기의 형태가 보이지 않거나 신호등 조명이 번지는 영향을 많이 받는 것으로 분석되었다. 흐린날에는 신호기 자체를 검출하는 것은 안정적이었으나, 신호기 내부의 신호정보 인식에 실패하는 경우가 다수 발생했다. 이와 같이 실험을 통해 제안된 방법이 주간에는 충분히 활용할 수 있으며, 야간 및 흐린날에도 성능의 개선 여지는 있지만 충분히 활용할 수 있음을 확인할 수 있었다.

5. 결론 및 향후 과제

차량 내부에 장착된 카메라를 이용하여 복잡한 도로 환경에서 신호등을 인식하는 새로운 방법을 제안하였다. 제안된 방법은 HOG 특징량과 Cascade 기반의 AdaBoost 를 이용하는 형태기반 알고리즘으로 고화질의 카메라를 사용하지 않아도 다양한 조명 환경의 실제 도로 환경에서 안정적으로 신호기를 검출하고 인식하는 것을 확인할 수 있었다.

현재 시스템이 황형식 신호등에 초점을 맞추었는데, 다양한 유형의 신호등에 대한 처리 기능을 추가하는 것과, 차선 등을 인식해서 도로정보를 구하고 이를 신호등의 검출 영역을 제한에 사용하는 것, 그리고 흐린 날과 야간의 인식률을 높이는 것이 향후 과제로 남아 있다.

참고문헌

1. J. Gong, Y. Jiang, G. Xiong, C. Guan, G. Tao and H. Chen, "The Recognition and Tracking of Traffic Lights Based on Color Segmentation and CAM-SHIFT for Intelligent Vehicles," *Intelligent Vehicles Symposium, IEEE*, pp. 413-435, 2010.
2. N. H. Yung and A. H. Andrew, "An Effective Video Analysis Method for Detecting Red Light Runners," *IEEE Transactions on Vehicular Technology*, vol. 50, no. 4, pp. 1074-1084, 2001.
3. Y. C. Chung, J. M. Wang and S. W. Chen, "A Vision-based Traffic Light System at Intersections," *Journal of Taiwan Normal University: Mathematics, Science & Technology*, vol. 47, no. 1, pp. 67-86, 2002.
4. G. K. Pang and H. H. Liu, "LED Location Beacon System Based on Processing of Digital Images," *IEEE Transactions on Intelligence Transportation Systems*, vol. 2, no.3, pp. 135-150, 2001.
5. Z. Tu and R. Li, "Automatic Recognition of Civil Infrastructure Objects in Mobile Mapping Imagery Using Markov Random Field," *International Archives of ISPRS*, vol. 33, no. 2, 2000.
6. Y. Shen, U. Ozguner and K. Redmill, "A Robust Video based Traffic Light Detection Algorithm for Intelligent Vehicles," *IEEE Intelligent Vehicles Symposium, Piscataway NJ USA*, pp. 521-526, 2009.
7. K. H. Lu, C. M. Wang and S. Y. Chen, "Traffic Light Recognition," *Journal of the Chinese Institute of Engineers*, vol. 31, no. 6, pp. 1069-1075, 2008.
8. R. Charette and F. Nashashibi, "Real Time visual Traffic Lights Recognition Based on Spot Light Detection and Adaptive Traffic Lights Templates," *IEEE Intelligent Vehicles Symposium, Piscataway NJ USA*, pp. 358-363, 2009.
9. P. Viola and M. J. Jones, "Robust real-time face detection," *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137-154, 2004.
10. T. Ojala, M. Pietikainen and D. Harwood, "A Comparative Study of Texture Measures with Classification Based on Feature Distributions," *Pattern Recognition*, vol. 29, no. 1, pp. 51-59, 1996.
11. N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," *Computer Vision and Pattern Recognition*, vol.1, pp. 886-893, 2005.
12. K. Fukunaga, "Introduction to Statistical Pattern Recognition," *second ed., New York: Academic Press*, 1990.
13. H. Rowley, S. Baluja and T. Kanade, "Neural network-based face detection," *IEEE Trans. on PAMI*, vol. 20, no. 1, pp. 23-38, 1998.
14. E. Osuna, R. Freund and F. Girosit, "Training support vector machines: an application to face detection," *In IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '97)*, pp. 130-136, San Juan, Puerto Rico, 1997.
15. Y. Freund and R. E. Schapire, "Experiments With a New Boosting Algorithm. In Machine Learning," *In Proceedings of the Thirteen International Conference In Machine Learning, Bari*, pp. 148-156, 1996.

접수일: 2015년 5월 27일, 심사일: 2015년 6월 4일,
게재확정일: 2015년 6월 22일