

SVM과 의사결정트리를 이용한 열악한 환경에서의 교통표지판 인식 알고리즘

Traffic Sign Recognition using SVM and Decision Tree for Poor Driving Environment

조 영 배*, 나 원 섭**, 엄 성 제**, 정 용 진***

Young-Bae Jo*, Won-Seob Na**, Sung-Je Eom**, Yong-Jin Jeong***

Abstract

Traffic Sign Recognition(TSR) is an important element in an Advanced Driver Assistance System(ADAS). However, many studies related to TSR approaches only in normal daytime environment because a sign's unique color doesn't appear in poor environment such as night time, snow, rain or fog. In this paper, we propose a new TSR algorithm based on machine learning for daytime as well as poor environment. In poor environment, traditional methods which use RGB color region doesn't show good performance. So we extracted sign characteristics using HoG extraction, and detected signs using a Support Vector Machine(SVM). The detected sign is recognized by a decision tree based on 25 reference points in a Normalized RGB system. The detection rate of the proposed system is 96.4% and the recognition rate is 94% when applied in poor environment. The testing was performed on an Intel i5 processor at 3.4 GHz using Full HD resolution images. As a result, the proposed algorithm shows that machine learning based detection and recognition methods can efficiently be used for TSR algorithm even in poor driving environment.

요 약

교통 표지판 인식(TSR)은 운전자 보조 시스템(ADAS)의 중요한 부분 중의 하나이다. 하지만 일반적인 주간 상황이 아닌 야간, 눈, 비, 안개 등의 열악한 상황에 대한 연구는 주간 상황과 달리 표지판 고유의 색이 정확히 나타나지 않기 때문에 많이 이루어지지 않고 있다. 본 논문에서는, 주간 상황뿐 아니라 열악한 환경에서도 적용 가능한 기계학습 기반의 교통 표지판 인식 알고리즘을 제안한다. 열악한 환경에서는 일반적인 RGB 색 체계 정보를 이용한 방법은 좋은 성능을 보이지 못하므로 표지판의 형태적 특징을 이용하는 HoG 특징점 추출기를 이용하여 표지판의 형태적 특징을 추출하고 SVM 알고리즘을 이용하여 표지판을 검출하였다. 검출한 표지판의 인식에는 Normalized RGB 색 체계의 25개의 참조점을 통한 의사결정트리를 이용하였다. Intel i5 3.4GHz 환경에서 Full HD 해상도의 이미지에 대해 실험한 결과 안개 및 야간 등의 열악한 환경에서의 검출률은 96.4%, 인식률은 94%로 본 논문에서 제안하는 학습기반의 알고리즘이 열악한 환경에서의 표지판 검출 및 인식에 효율적으로 적용이 가능함을 알 수 있다.

Key words : TSR, HoG, SVM, Decision Tree, Poor Environment

* Dept. of Electronics and Communications Engineering, Kwangwoon University, Tel : +82-10-5126-6950, E-mail : jjolba@naver.com

** Dept. of Electronics and Communications Engineering, Kwangwoon University

★ Corresponding author, Tel : +82-10-5571-5551, E-mail : yjjeong@kw.ac.kr

※ This work was supported by the industrial Core Technology development Program(10049192, Development of a smart automotive ADAS SW-Soc for a self-driving car) funded By the Ministry of Trade, industry & Energy and supported by the MSIP(Ministry of Science, ICT and Future Planning), Korea, under the Human Resource Development Project for SoC support program(NIPA-2014-H0601-14-1001) supervised by the NIPA(National IT Industry Promotion Agency).

Manuscript received Oct. 6, 2014; revised Nov. 13, 2014 ; accepted Nov. 18. 2014

I. 서론

교통 표지판 인식 시스템 (Traffic Sign Recognition : TSR)은 크게 분할 (Segmentation)과 검출 (Detection), 인식 (Recognition)의 세 단계로 나누어진다.

분할 단계에서는 표지판의 고유의 색을 통한 방법과 모양을 통하여 구별하는 방법이 있다. 색을 통한 방법은 표지판의 종류마다 테두리에 고유의 색을 갖는 특징을 이용하여 임계값을 통해 표지판 후보군을 추출한다. 그러나 이 방법은 표지판이 노후화되어 색이 바랬거나 날씨 또는 빛의 밝기에 영향을 받는 단점이 있다. 반면, 모양을 통한 방법은 표지판마다 갖는 고유의 형태를 이용하여 후보군을 정하는 방법으로, 색이 바랬거나 빛의 영향을 받지 않지만 표지판의 형태가 변형이 일어난 경우 후보군으로 정하기 어려운 단점이 있다.

검출 단계에서는 주로 허프 변환을 이용한다. 허프 변환은 원 또는 선 허프 변환이 있으며 이를 통하여 원, 삼각, 사각형 등의 표지판 형태를 검출할 수 있다. 정확성이 높아 많이 이용되나 처리속도가 오래 걸리는 단점이 있다. 인식 단계에서는 표지판 후보군과 데이터 셋을 비교하여 상판도를 이용하는 템플릿 매칭 (Template Matching) 방식과 특징을 통한 기계학습 알고리즘인 SVM (Support Vector Machine), 신경망 (Neural Network), 의사결정트리 (Decision Tree)등의 방식이 이용된다.[1]

대다수의 TSR에서는 표지판 고유의 색을 통하여 픽셀의 일정 임계치 이상인 영역을 분할한 후 허프 변환을 통하여 표지판을 검출하는 방법을 이용하며, 검출된 표지판 영역을 템플릿 매칭을 이용하여 표지판을 분류하는 방법이 이용된다.[2] 이러한 방법은 주간 상황에는 원하는 만큼의 성능을 이끌어낼 수 있다. 하지만 실제 주행 시 기상 상황은 언제나 맑은 주간일 수는 없고 안개, 비, 눈, 야간 등의 열악한 환경을 자주 접하게 된다. 일반적으로 사용되는 TSR 알고리즘으로는 열악한 상황에서의 검출 및 인식이 어렵지만 이를 해결하기 위한 연구는 아직까지 활발히 이루어지지 않았다. 이를 해결하기 위하여, 본 논문에서는 열악한 환경에서 표지판의 형태적 특징을 추출한 후 미리 학습된 데이터와 비교하여 분류하는 SVM을 통한 표지판 검출방법을 이용하고 검출된 표지판들을 의사결정트리를 이용하여 표지판을 인식한

다.

본 논문의 구성으로는 2장에서 TSR 시스템의 분할 및 검출 단계에서 열악한 환경에 적용하기 위하여 사용한 색 체계와 특징점을 검출하는 법 및 SVM을 통한 검출 방법을 보여준다. 3장에서는 인식 단계에서의 영상의 전처리와 의사결정트리를 통한 인식 방법을 설명한다. 4장에서는 제안한 알고리즘의 성능 및 유용성을 실험 및 분석을 통하여 보인다. 마지막 5장에서 본 논문의 결론과 향후 과제에 대하여 언급한다.

II. 분할 및 검출

A. 분할 및 검출 흐름도

그림 1은 본 논문에서 구현한 분할 및 검출 흐름도이다. 입력 영상은 차량용 블랙박스를 통하여 열악한 환경에서 촬영된 1920x1080 해상도의 영상을 이용한다. 분할 단계에서는 RGB 컬러 체계에서 HSI 컬러 체계로 변환하여 특정 임계값 이상의 픽셀들을 추출한 후 클러스터링 기법을 통하여 잡음을 제거한다. 검출 단계에서는 분할된 픽셀 영역들에 HoG (Histogram of Oriented Gradient) 특징점 추출기를 이용하여 표지판의 형태적 특징을 추출하며 SVM 분류기를 통하여 검출한다.

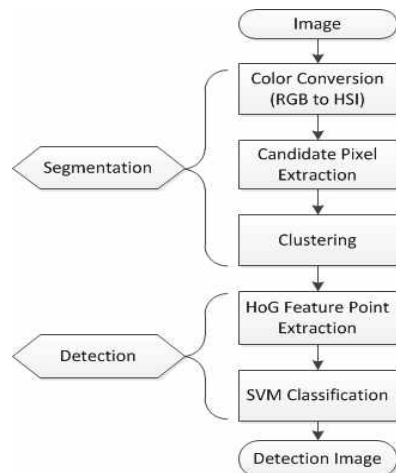


Fig 1. Segmentation & Detection Flow

그림 1. 분할 및 검출 흐름도

B. 색상 체계 변환

열악한 환경에서는 색의 간섭이 심하여 표지판 고

유의 색이 변형이 이루어지거나 제대로 표현되지 않아 표지판의 형태를 정확히 추출하기에 색 기반 검출 방법은 효과적이지 않다. 그러나 표지판 형태를 정확히 추출하지 않고 표지판이 존재할 수 있는 영역을 미리 추출한 후 표지판을 검출하면 속도적 이득을 취할 수 있다. 이는 조도 변화에 민감한 RGB 컬러 체계보다 HSI 컬러 체계로 변환하여 추출 시 더 좋은 성능을 보일 수 있다.[3]

H (Hue)는 색상을 의미하며 0~360도의 각도에 의하여 색이 구분된다. S(Saturation)는 채도를 의미하며, 색의 선명도를 나타낸다. 8비트의 경우 0~255의 값을 가지며, 0에 가까울수록 색이 흐려지며 255에 가까울수록 원 색에 가깝게 나타난다. V (Value) 또는 I (Intensity)는 밝기를 나타내며 0~255의 값을 갖는다. 0에 가까울수록 어두워지고 255에 가까울수록 밝아진다.

$$H = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}} \right\} \quad (1)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (2)$$

$$I = \frac{1}{3}(R+G+B) \quad (3)$$

주간 상황에서 표지판 고유의 색인 붉은색 영역의 Hue는 320~30도에 위치하고 있지만, 열악한 환경에서 색의 변형이 나타나기 때문에 Hue값이 280~60도에 위치한 픽셀들을 추출하였다. 또한, 열악한 환경에서 촬영된 영상에서 표지판이 영상의 외곽에 위치한 경우에는 빛이 적어 표지판이 보이지 않거나 흐려짐(blur) 현상이 심하여 형태를 알 수 없기 때문에 픽셀을 추출하는 관심영역은 중앙부분으로 한다. 그림 2의 a, b는 관심영역에서 HSI 컬러 체계를 통하여 추출된 그림이다.

C. 클러스터링


클러스터링 기법은 데이터들을 연결성이 있는 부분들을 각각 묶어서 여러 그룹으로 라벨링하는 기법이다. 표지판 영역에 해당하는 픽셀들은 서로 연결성이 있으며 일정 픽셀 이상이 모여 있기 때문에 일정 이하의 픽셀로 이루어진 그룹들은 잡음으로 간주하여 제거한다. 그림 2의 c는 클러스터링 기법을 통하여 잡음을 제거한 영상이다.



a. 실제 영상



b. 관심영역 추출



c. 클러스터링을 통한 잡음 제거


Fig 2. Extracted pixels of ROI and noise reduction
그림 2. 추출된 표지판 영역 및 잡음 제거

D. HoG 특징점 추출 및 SVM 분류기

HoG (Histogram of Oriented Gradient) 특징점 추출기는 영상을 블록과 셀 단위로 구분지어 엣지 성분의 기울기 변화량을 히스토그램화 하여 특징을 추출하는 방법이다.



a. 실제 영상



b. HoG 특징 추출 영상

Fig 3. HoG feature of traffic sign

그림 3. 표지판의 HoG 특징

영상을 셀로 분할하여, 각 셀 단위로 엣지들의 방향에 대한 히스토그램을 구한 후 블록 단위로 히스토

그림 정규화하여 벡터 특징값을 이용한다.[4][5] HoG는 엣지의 방향정보를 이용하기 때문에 빛에 강건한 특징을 가지고 있어 열악한 환경에서 표지판의 윤곽선 특징을 추출하기에 적합한 추출기이다. 그림 3은 표지판의 HoG 특징 추출에 관한 그림이다.

SVM 분류기는 어떤 한 대상과 또 다른 대상을 구분 짓는 초평면을 구하여 두 대상을 분류하는 방법이다. 두 대상을 구분 짓는 초평면들은 여러 가지 존재하며, 이들 중 각 대상들의 특징값과의 마진이 최대가 되는 초평면이 최적의 초평면이 된다. 이 때, 최적의 초평면과 가장 인접한 특징값들을 서포트 벡터(Support Vector)라 부른다.[4][5]

SVM에서 학습의 의미는 이 초평면을 구하는 것을 의미하며 분류하고자 하는 대상들의 샘플을 수백 개 학습시켜 구해낸다. 표지판 검출기로서 SVM을 이용하기 때문에 열악한 환경에서 촬영된 표지판 영상 120장과 표지판이 아닌 영상 120장을 학습 샘플로 구성하였다.

해상도가 1920x1080인 원 영상에서 하나의 마스크 영역에 대하여 HoG 특징 추출 및 SVM 분류를 할 경우 약 1.3초가 소요된다. 이렇게 전체 관심영역에 대하여 수행할 경우 소요시간이 오래 걸리고 오검출이 되는 영역들이 많이 나타나게 되었다. 이러한 문제점을 해결하기 위하여 해상도를 줄이고 추출되는 HoG 특징수를 줄였다. 640x360과 320x180 해상도에서는 마스크 및 HoG 크기와 특징점 추출 개수를 줄여 수행시간이 크게 줄었지만, 320x180 해상도에서는 표지판뿐만 아니라 표지판이 아닌 신호등과 같은 표지판과 유사한 형태들도 표지판으로 오검출된다. 이는 해상도가 줄어들면서 검출하고자 하는 대상 마스크 크기와 특징수도 줄어 표지판의 특징값과 표지판이 아닌 원형 형태 잡음 영역의 특징값의 차이가 모호해지기 때문이다. 640x360 해상도에서는 이 차이가 명확하여 오검출이 일어나지 않는다.

즉, 알고리즘의 처리 속도를 높이기 위하여, 320x180 해상도에서 SVM을 이용하여 표지판 후보군을 검출한 후, 검출된 후보군들을 640x360 해상도에서 재분류하여 최종 표지판을 검출하는 방법을 이용하였다.

III. 인식

A. 인식 흐름도

그림 4는 인식과정에 대한 흐름도이다. 검출된 표

지판 영역을 이용하여 영상의 가독성을 높이기 위해 히스토그램 평활화를 실시하고 특징점 추출을 위하여 25개의 점 중 두 점을 선택해 해당 점 주위 네 개의 픽셀을 Normalized RGB체계에서 처리를 한 후 의사결정트리를 이용하여 최종적으로 인식을 실시한다.

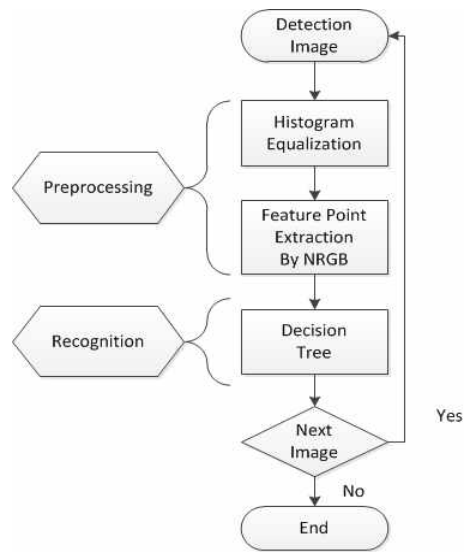


Fig 4. Recognition Flow
그림 4. 인식 흐름도

B. 히스토그램 평활화

검출된 표지판 영역은 영상에서 빛이 들어온 각도나 시간, 혹은 기상상황에 따라 픽셀 별로 밝기 값이 다르게 나타날 수 있는데 이러한 영상은 가독성이 떨어져 인식이 떨어지는 결과를 나타낼 수 있다. 그러한 점을 보완하기 위하여 본 논문에서는 히스토그램 평활화를 사용하여 문제점을 보완하였다. 히스토그램 평활화는 영상의 밝기 값의 분포를 나타내어 주는 지표인 히스토그램을 전 픽셀에 걸쳐서 균일한 빈도를 보일 수 있도록 변환을 하는 것을 말한다. 즉, 밝기 값이 비선형적으로 분포되어 있거나 일정 밝기에 몰려있는 히스토그램을 모든 밝기 값에 대하여 히스토그램의 누적 값이 선형적으로 증가하도록 바꿔주는 것이다.[6]

영상의 히스토그램은 밝기 값의 빈도로 나타내므로 밝기 값을 연속변수로 하는 확률밀도함수로 해석할 수 있다. 히스토그램 평활화를 하는 변환은 원래 영상의 히스토그램 값의 누적 함으로 주어진다. 실제 영상의 히스토그램은 이산적이기 때문에 모든 밝기 값에서 균일하게 나타나지 않지만, 구간변환은 거의

일정하게 나타난다. 다음 그림 5의 a, b는 히스토그램 평활화를 실행하기 전과 후의 영상을 보여준다.



Fig 5. Histogram Equalization
그림 5. 히스토그램 평활화

본 논문에서는 히스토그램 평활화를 HSI 색 체계에서 색 정보를 나타내는 H 값은 평활화를 실시하지 않고 채도 값인 S와 밝기 값인 I를 평활화를 하여 H 값을 평활화하였을 때 그림 5의 c와 같이 나타날 수 있는 색의 번짐을 막을 수 있었다.

그림 5의 a와 b를 비교하면 히스토그램 평활화 실행 후의 영상이 그 전의 영상보다 더 가독성이 좋은 영상으로 바뀐 것을 확인할 수 있다. 이렇게 가독성이 더 좋아진 영상을 이용하여 표지판 인식을 실행한다.

히스토그램 평활화를 하지 않고 표지판 인식을 실행하게 되면 오인식이나 미인식하는 경우가 종종 발생하였으나 히스토그램 평활화를 한 후 인식을 실행하면 오인식 및 미인식의 숫자를 줄여 표지판 인식률을 약 15% 향상시키는 결과를 얻었다.

C. Normalized RGB

일반적인 RGB 색 체계를 기반으로 한 특징점들은 약간의 조도 변화에도 불안정하며, 색 정보와 밝기 정보를 독립적으로 표현하지 못하는 단점이 있다.[3]

위와 같은 단점을 극복하기 위하여 본 논문에서는 Normalize RGB (NRGB) 색 체계를 통하여 색 정보를 정규화 하였다. NRGB값의 정의는 다음과 같다. 여기서 R, G, B는 RGB 색 체계의 각각의 값이다.

$$r = \frac{R}{R+G+B}, g = \frac{G}{R+G+B}, b = \frac{B}{R+G+B} \quad (4)$$

결괏값의 추출에는 총 25개의 참조점을 사용하였으며 하나의 특징점이 아닌 한 점 주변 4개의 점의 NRGB값을 합하여 다른 점의 값과의 차를 이용하여 밝기 값에 둔감한 변수를 구할 수 있었다. 두 개의 점의 차를 통해 만들어진 변수의 수는 ${}_{25}C_2$ 로 총 300개이다. 그림 6은 하나의 표지판에서 참조점을 고르고 그 점을 기준으로한 주변의 4픽셀을 선택하는 것을 보여준다.




Fig 6. Reference Point Extraction for Recognition
그림 6. 인식을 위한 참조점 추출

그림 6의 b에서 왼쪽 위에 있는 검은 부분이 기준점이며 그것을 기준으로 4픽셀을 결정한 것을 나타낸다. 본 논문에서는 참조점 하나만이 아닌 주변 4픽셀을 이용하고 두 지점간의 값의 차를 통해 특징한 수치를 만들어낸다. 그 이유는 하나의 참조점만을 이용해 학습이나 분류를 위한 변수로 삼는 것보다 주변 4픽셀을 이용하면 더 정확한 값을 얻을 수 있고 한 지점을 이용하는 것 보다 두 개의 지점의 차이를 이용하면 NRGB가 밝기 성분에 대한 보정을 해주는 것과 같이 영상 전체적으로 퍼져있는 빛의 영향을 조금 더 줄일 수 있기 때문이다.

D. 의사결정트리

의사결정트리 (Decision Tree)는 분류 또는 예측의 과정이 나무구조에 의한 추론규칙에 의해서 표현되기 때문에 다른 방법 (신경망, 회귀분석 등)에 비하여 연구자가 그 과정을 쉽게 이해하고 설명할 수 있다는 장점을 가지고 있다. 의사결정트리는 트리모형의 형성을 위해 그 목적과 데이터의 종류에 따라 알맞은 분리기준 (split criterion)과 정지규칙 (stopping rule)을 지정한다. 의사결정트리의 알고리즘에는 ID3, CART, C4.5 등이 있으며, 본 논문에서는 J. Ross Quinlan에 의해 제안된 C4.5 알고리즘을 이용해 의사결정트리를 생성한다. C4.5 알고리즘은 ID3의 한계점으로 지적되던 다음과 같은 문제들을 보완한 알고리즘으로 알려져 있다.[7]

1. 연속 및 이산 변수 모두 처리
2. 속성 값 누락된 학습 데이터를 처리
3. 서로 다른 값어치로 변수를 처리
4. 트리 생성이후 가지치기 가능

C4.5 알고리즘은 자료의 불순도를 나타내는 엔트로피(Entropy)라는 지표와 엔트로피를 이용하여 자료의 불순도가 얼마만큼 감소하는지를 알아보는 지표인 정보이득(Information Gain)이라는 지표가 사용된다. 엔트로피와 정보이득의 정의는 다음과 같다.[7]

$$Entropy(X) = \sum_{i=1}^c -p_i \log p_i \quad (5)$$

$$Gain(X, T) = Entropy(X) - \sum_{v \in T} \frac{|X_v|}{|X|} Entropy(X_v) \quad (6)$$

식 (5)에서 p_i 는 p 가 가질 수 있는 부분집합의 확률을 말하며 일반적인 이진트리에서는 p_+ 나 p_- 등과 같이 두 가지로 표현이 되며 이진트리에서는 나누어지는 항목의 수가 같으면 엔트로피는 1, 한쪽으로 모두 나누어 졌을 시는 엔트로피는 0을 가지게 된다. 식 (6)에서 v 는 T 의 부분집합이고 $|X|$ 와 $|X_v|$ 는 각각의 집합의 개수를 의미한다. 여기서 T 는 X 의 하위노드를 의미 한다. 즉 정보이득은 상위노드와 하위노드간의 엔트로피의 차이를 이용하여 얼마만큼 불순도가 감소하였는지를 파악하는 지표이다. 그러므로 정보이득 값이 더 클수록 하위분류를 더 잘했다고 볼 수 있다.

이렇게 정보이득을 이용하여 트리를 구성하다보면 과적합 (Overfitting) 현상이 생길 수 있다.[7] 과적합이란 너무 학습을 많이 하여 불필요한 것까지 학습된 현상을 말한다. 즉, 너무나 분류를 많이 해서 굳이 분류를 하지 않아도 될 것들도 분류를 하여 트리의 크기가 커지는 현상이다. 이러한 과적합을 없애기 위해서 학습을 적당한 시점에서 멈출 수 있도록 정지조건을 잘 설정해야 한다. 정지조건을 설정하는 방법은 트리의 최대 깊이 (Depth)를 설정하거나 정보이득 값의 하한선을 두는 방법 등이 있다. 여기서 트리의 깊이란 트리가 구성되었을 때 시작 노드부터 마지막 잎노드까지 몇 단계를 거쳐서 도착하는 가를 나타내는 것으로 일반적으로 깊이가 클수록 인식률이 높아지지만 일정 깊이 이후로는 인식률이 크게 증가하지 않는다.[7]

또한 완성된 트리는 가지치기 (Pruning)를 이용하여 최적화를 시킬 수도 있다. 가지치기란 트리의 크기가 너무 커지게 되면 정확성보다 오류가 더 늘어나게 되는 것을 막기 위하여 트리의 크기를 줄이는 것을 의미한다. C4.5 알고리즘에서 사용하는 사후 가지치기 (Post-Pruning)은 완성된 트리에서 실시하는 가지치기 방법이다. 사후 가지치기 방법은 이전 알고리즘들에 비해 C4.5 알고리즘에서 개선된 내용 중 하나이다.[7] 사후 가지치기의 정의는 다음과 같다.

$$P(T,v) = E(T) - E(v) \quad (7)$$

식 7에서 T 는 완성된 트리를 v 는 작은 서브 트리를 말하며 $P(T,v)$ 는 가지치기로 얻어지는 이득 값을 말하고 $E(T), E(v)$ 는 T 와 v 에서의 오인식 수를 말한다.

가지치기는 가장 마지막의 잎 노드부터 시작하여 가장 큰 이득 값이 얻어질 때 까지 식 (7)을 반복적으로 실시하며 v 의 오류가 T 의 오류보다 작은 경우에만 실시한다.[7]

E. 참조점을 이용한 의사결정트리

본 논문에서는 25개의 참조점 중 두 개를 선택하여 각 점의 주변 4픽셀의 NRGB 값을 합하여 두 점의 차이로 하나의 특징을 나타내는 수치로 사용한다. 그림 7은 본 논문에서 사용한 노드 결정 방법과 정지조건을 이용한 의사결정트리를 형성하는 과정을 나타낸 흐름도이다.

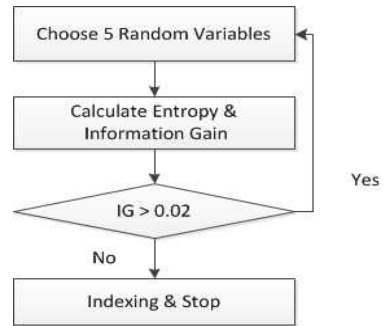


Fig 7. Decision Tree Generation

그림 7. 의사결정트리 형성

input : training set X
output : decision tree R

```

Algorithm
1. choose 5 random variables
2. get entropy for each 5 variables
3. choose best entropy //best when 1
4. Create root node R;
5. T=R;
6. X_t = choose 5 random variables
7. split_node(T,X_t) //call recursive function

8. split_node(T,X_t) {
9. get entropy for each 5 variables
10. estimate information gain for all variables
11. choose one variable which maximize information gain
12. if(T satisfy the stopping condition) {
13. Assign noes to T
14. return }
15. else {
16. divide X_t into X_t_left and X_t_right
17. create new nodes X_left and X_right
18. split_node(T,X_left)
19. split_node(T,X_right) } }
    
```

Fig 8. Pseudo Code of Decision Tree

그림 8. 의사결정트리 의사코드

최초 300개의 변수 중 임의로 5개를 선택하여 엔트로피를 계산한 후 가장 엔트로피 값이 가장 큰 변수를 선택한다. 그 변수를 기준으로 변수 값보다 큰 쪽과 작은 쪽으로 이분화 하여 좌측, 우측 자식 노드를 생성하고 좌, 우측 노드의 변수를 이용하여 정보 이득을 계산한다. 정보이득을 계산할 때도 5개의 임의의 변수를 선택하여 계산하며 가장 정보이득 값이 큰 변수를 선택한다. 계산한 정보이득 값이 0.02보다 큰 경우 다시 처음 과정으로 돌아가고 0.02보다 작은 경우는 분류된 변수에 색인을 달고 트리 형성을 중지한다. 그 후 형성된 트리를 이용하여 인식하고자 하는 표지판에 적용한다. 그림 8은 표지판 인식을 위한 의사결정트리를 생성하는 의사코드를 보여준다.

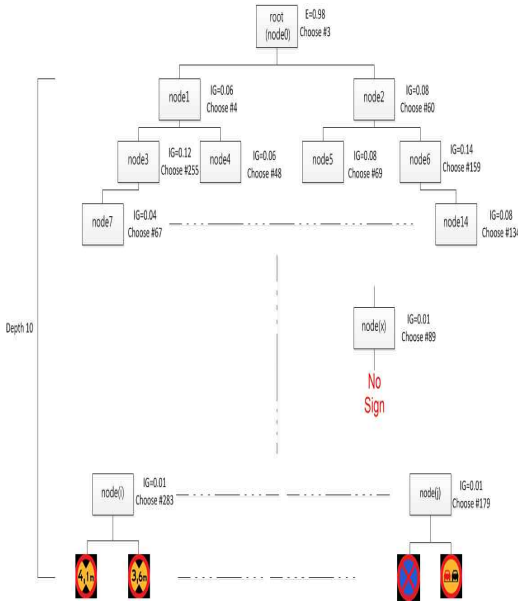


Fig 9. Decision Tree in Daytime
그림 9. 주간상황의 의사결정트리

이렇게 생성된 트리는 주간 상황 시 노드의 수는 1017개, 깊이는 10이고 열악한 상황 시 노드의 수는 58개, 깊이는 5이다. 주간 상황은 100개의 표지판 이미지와 표지판이 아닌 이미지 50개를 이용하여 학습하였으나 열악한 환경은 표지판 이미지 20개와 표지판이 아닌 이미지 10개를 이용하여 학습을 실시하여 데이터의 양이 충분치 못하기 때문에 열악한 상황에서의 트리는 노드의 수나 깊이가 크기 못하였다. 하지만 학습 데이터를 추가로 더 확보한다면 트리의 크기를 크게 할 수 있고 그 인식률 또한 향상시킬 수

있다. 그림 9는 주간 상황에서 사용한 트리이고 그림 10은 열악한 환경에서 사용한 트리이다.

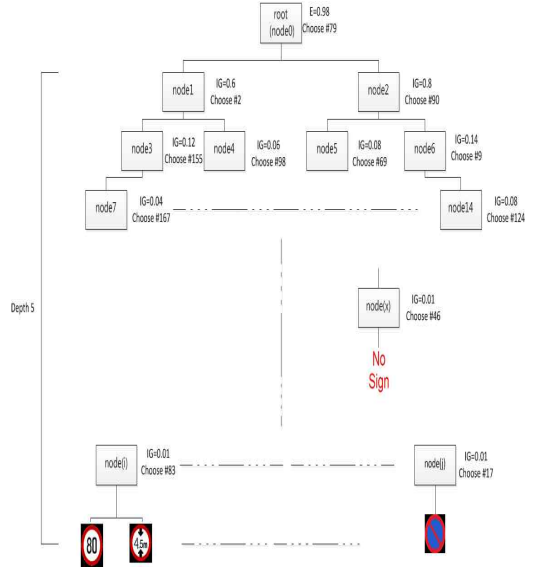


Fig 10. Decision Tree in Poor Driving Environment
그림 10. 열악한 환경의 의사결정트리

참조점이나 특징점을 많이 사용하지 않고 한두 개만을 이용하여 의사결정트리를 생성하여 표지판 인식을 실시할 수도 있다. 하지만 그렇게 생성된 트리는 날씨가 맑은 주간 상황에서는 괜찮은 성능을 나타내는 분류기가 될 수 있지만 다양한 변수가 존재하는 열악한 환경에서는 분류기로서 좋은 성능을 나타내지 못하는 것을 확인할 수 있었다.

IV. 실험 및 분석

본 논문에서 제안하는 알고리즘의 성능 검증을 위하여 야간 혹은 안개 낀 상황 등의 열악한 환경 이미지 50장을 사용하여 실험을 진행하였다. 실험에 사용된 이미지는 실제 블랙박스 촬영 영상을 이용하여 실험을 진행하였다. 실험 프로세서는 Intel i5 3.4 GHz, 8G RAM, 운영체제는 Windows 7 64bit, 컴파일러는 Visual Studio 2010, OpenCV 2.4, libsvm 3.17, OpenMP를 이용하였다. 표 1은 일반적으로 검출에 사용하는 허프 변환을 이용한 검출법과 본 논문에서 제안한 검출법과의 비교표이다. 검출률을 계산하는 방법은 다음과 같다.

$$Detection\ rate = \frac{\#\ of\ detected\ signs}{\# \ of\ all\ signs} \quad (8)$$

표 1. 기존 방법과 제안한 방법의 열악한 환경에서의 검출률 비교

Table 1. Comparison of conventional method and proposed method

Method	Conventional method	Proposed method
# of traffic signs	57	57
# of detected signs	2	55
Detection rate	3.5 %	96.4 %

기존의 허프 변환을 이용한 검출법[2]을 열악한 환경에 적용했을 때 검출률은 약 3.5%로 거의 인식하지 못하는 것을 확인할 수 있다. 그 이유는 표지판의 고유의 색으로 영역을 분할한 후 원형 혹은 삼각형 표지판을 검출하는데 열악한 환경에서는 표지판 고유의 색이 정확히 분할되지 않아 표지판을 검출하지 못한다.



Fig 11. Detected traffic sign in poor environment
그림 11. 열악한 환경에서 검출된 표지판 영역

그러나 본 논문에서 제안한 방법은 픽셀의 가장자리 성분을 이용한 특징점을 이용한 기계학습법을 사용하여 검출하기 때문에 열악한 환경에서도 표지판 검출이 가능하다. 검출률 또한 96.4%로 상당히 높은 수준의 검출률임을 확인할 수 있다. 또한 분할 및 검출 부분을 수행하는데 소요되는 시간은 25ms로 매 프레임마다 검출을 할 필요가 없는 실제 주행 상황에서 실시간 처리를 하기에 충분함을 알 수 있다. 그림 11은 열악한 환경에서 최종 검출된 표지판 영역을 나타낸다.

또한 본 논문에서 제안하는 의사결정트리를 이용한 TSR 시스템의 인식률의 향상을 살펴보기 위해 Japanese Puzzle을 이용한 방법[8]과 신경망회로를 이용한 방법[9]과의 비교를 하였으며 비교한 실험값은 표 2와 같다.

표 2. 주간 상황에서 의사결정트리를 이용한 것과 Japanese Puzzle 및 신경망회로를 이용한 것과의 비교

Table 2. Comparison of Japanese puzzle, Neural network and Decision tree in day-time environment

	[8]	[9]	proposed
인식률 (%)	91.4	95.8	99.8

Japanese Puzzle을 이용한 방법은 규제표지를 인식했을 때 최소 84.29%의 인식률을 보이고 지시표지를 인식했을 때 최대 95.22%까지 인식률을 보였으며 평균 91.4%의 인식률을 나타내었다. 신경망회로를 이용한 방법에서는 지시표지를 인식했을 때 최소 93.3%의 인식률을 보이고 주의표지를 인식했을 때 최대 97.5%까지 인식률을 보였으며 평균 95.8%의 인식률을 나타내었다. 본 논문에서 제안하는 의사결정트리를 이용한 방법은 지시, 규제, 주의표지판에 대해서 99.8%의 인식률을 보였다. Japanese Puzzle이나 신경망회로와 달리 다른 종류의 표지판에 대해 각각 훈련을 하지 않고 하나의 트리를 이용하여 훈련과 인식을 실시하여 위와 같은 결과를 얻을 수 있었다.



Fig 12. Final recognition result in poor environment
그림 12. 열악한 환경에서의 최종 인식 결과

주간 상황에서 표지판 인식을 실험한 영상은 일반적으로 교통표지판 인식에 많이 사용하는 벤치마크 영상인 스웨덴 교통표지판 이미지 100장으로 진행하였다. 그리고 열악한 환경에서는 검출과 같이 블랙박

스 촬영 영상 50장을 사용하였다. 그림 12는 열악한 환경에서 실시한 최종 인식 결과를 보여주는 창이다.

또한 주간 상황뿐 아니라 열악한 환경에서의 인식도 가능하게 되었는데 주간 상황과 열악한 환경에서의 인식률은 표 3과 같다.

표 3. 주간 상황과 열악한 환경의 인식률

Table 3. Recognition rate at daytime and poor environment

	인식률(%)
주간	99.8
열악	94

주간 상황과 열악한 환경 모두 전체 데이터 중 80%는 학습에 사용하고 20%를 인식에 사용하였다. 표 3에서 열악한 환경에서는 주간 상황보다 인식률이 저하되는 것을 확인할 수 있는데 그 이유는 학습을 위한 데이터가 충분치 않고 차량이 빠르게 이동하면서 촬영이 정확히 되지 않은 영상들이 다수 섞여 있었기 때문이다.

의사결정트리를 이용한 인식에 걸리는 시간은 주간 및 열악한 상황 모두 최대 1ms로 충분히 실시간 처리가 가능함을 확인할 수 있었다.

V. 결론

본 논문에서는 일반적인 주간 상황 뿐 아니라 열악한 환경에서도 사용가능한 TSR 알고리즘을 구현하였다. 기존에 구현되어 있는 TSR 알고리즘과 달리 주간 상황뿐 아니라 열악한 상황에서도 표지판을 검출 및 인식이 가능하며 적외선 카메라와 같이 다른 장치를 이용하지 않고 기계학습 방법을 이용하여 해결이 가능하다는 점에서 실제 적용 시 비용 절감에 유리하다는 장점이 있다. 제한한 검출 알고리즘의 소요시간은 25ms로 시속 70km로 주행하는 차량의 경우 25ms당 0.5m를 이동하고 또한 교통 표지판을 인식하기 위하여 매 프레임마다 표지판의 검출 및 인식을 하여야 할 필요가 없으므로 실제 주행 상황에 적용하기에 타당하다. 하지만 영상의 해상도가 증가하거나 다른 기능을 복합적으로 처리해야 하는 경우에는 하드웨어 설계를 하여 처리속도를 높여야할 필요도 있다. 인식 알고리즘의 경우는 처리속도는 1ms로 충분히 실시간 처리가 가능하다. 그러나 열악한 환경에서의 인식률의 향상을 위하여 충분한 학습데이터를 확보하여야 하겠다.

References

- [1] Carrasco Pascual and Juan Pablo, "Advanced Driver Assistance System based on Computer Vision using Detection, Recognition and Tracking of Road Signs", Universidad Carlos III de Madrid. Departamento de Ingeniería de Sistemas y Automática, 2009
- [2] Mogelmoose, Andreas, Mohan M. Trivedi, and Thomas B. Moeslund. "Vision-based traffic sign detection and analysis for intelligent driver assistance systems: Perspectives and survey." *Intelligent Transportation Systems, IEEE Transactions on* 13.4 (2012): 1484-1497.
- [3] Jong-Beom Park, "A Study on the Revised Method using Normalized RGB Features in the Moving Object Detection by Background Subtraction," *The Journal of The Korea Institute of Intelligent Transport Systems Vol. 12, No. 6*, pp.108~115, Korea Intelligent Transport System, 2013
- [4] Zaklouta, Fatin, and Bogdan Stanculescu. "Real-time traffic-sign recognition using tree classifiers." *Intelligent Transportation Systems, IEEE Transactions on* 13.4 (2012): 1507-1514.
- [5] Dalal, Navneet, and Bill Triggs. "Histograms of oriented gradients for human detection." *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. Vol. 1. IEEE, 2005.
- [6] Mi-Jin Jun, Joon Jae Lee, "Image Histogram Equalization Based on Gaussian Mixture Model", *Journal of Korea Multimedia Society Vol. 15 No. 6*, pp.748-760, Korea Multimedia Society, 2012
- [7] J. R. Quinlan., "*C4.5: programs for machine learning*," San Mateo: Morgan Kaufmann Publishers, Burlington, Massachusetts, 1993
- [8] Young-Sun Sohn, "A Recognition of Traffic Safty Signs Using Japanese Puzzle", *J. Korean Inst. Intell. Syst. Vol. 18, No. 3*, pp. 416~421, Korean Institute of Intelligent Systems, 2008
- [9] Min-Chul Shin, Sang-Il Na, Jung-Ho Lee, Jun-Ho Jeong, Dong-Seok Jeong, "Traffic Sign Recognition Using Color Information and Neural Networks", *32nd Fall Conference Vol. 32, No. 2*, Korea Institute of Information Scientists and Engineers, 2005

BIOGRAPHY

Jo Young-Bae (Student Member)

2012 : BS degree in Informations and Communications, Beakseok University.
 2012 : Course of MS in Electronics and Communications Engineering, Kwangwoon University.

Jeong Yong-Jin (Member)

1983 : BS degree in Control and Instrumentation Engineering, Seoul National University.
 1995 : MS, PhD degree in Electronics and Computer Engineering, University of Massachusetts, Amherst
 1983~1989 : Research Engineer, ETRI
 1995~1999 : Chief Researcher, Samsung Electronics
 1999~current : Professor, Dept. of Electronics and Communications Engineering, Kwangwoon Univ.

Na Won-Seob (Student Member)

2014 : BS degree in Electronics and Communications Engineering, Kwangwoon University.
 2014 : Course of MS in Electronics and Communications Engineering, Kwangwoon University.

Eom Sung-Je (Student Member)

2013 : BS degree in Electronics Engineering, Daejin University.
 2013 : Course of MS in Electronics and Communications Engineering, Kwangwoon University.