

우천 상황에 강인한 CLAHE를 적용한 Adaboost 기반 차량 검출 방법

강석준^{*}, 한동석[°]

Robust vehicle Detection in Rainy Situation with Adaboost Using CLAHE

Seokjun Kang^{*}, Dong Seog Han[°]

요약

본 논문에서는 영상의 대비효과를 부각시키는 CLAHE(Contrast-Limit Adaptive Histogram Equalization)를 적용한 Adaboost 기반 방법을 통해 우천 상황에서 강인한 차량 검출 방법을 제안한다. 본 논문에서는 차량 검출의 효과적인 실시간 동작을 위해 2가지를 제안하였다. 먼저 영상의 RGB값을 통해 우천 상황 여부를 판단하여 검출 방법을 선택할 수 있도록 하여 연산량을 줄이는 것과 CLAHE를 이용한 영상 처리를 통해 영상 내에 차량의 후미등을 검출하여 관심영역을 지정해주는 방법을 제안했다. 또한 본 논문에서는 기존에 차량 검출 방법으로 제시되었던 가우시안 혼합 모델(Gaussian Mixture Model), 옵티컬 플로우(Optical Flow)와 Adaboost(Adaptive boosting)의 우천 상황에서의 차량 검출율을 비교하여 최종적으로 Adaboost를 선택한 이유를 설명했다. 본 논문 실험 결과는 CLAHE 미적용 시 정확율과 재현율은 각각 0.83, 0.77 이었고, CLAHE 적용 시 0.85, 0.87로 적용했을 때 정확율과 재현율에서 약 2%, 13% 향상되었다.

Key Words : CLAHE, ROI Extraction, Vehicle Detection, Image Processing, Adaboost

ABSTRACT

This paper proposes a robust vehicle detecting method by using Adaboost and CLAHE(Contrast-Limit Adaptive Histogram Equalization). We propose two method to detect vehicle effectively. First, we are able to judge rainy and night by converting RGB value to brightness. Second, we can detect a taillight, designate a ROI(Region Of Interest) by using CLAHE. And then, we choose an Adaboost algorithm by comparing traditional vehicle detecting method such as GMM(Gaussian Mixture Model), Optical flow and Adaboost. In this paper, we use proposed method and get better performance of detecting vehicle. The precision and recall score of proposed method are 0.85 and 0.87. That scores are better than GMM and optical flow.

I. 서 론

1.1 연구의 목적

자동차 산업의 발전에 따라 운전자의 안전과 편의

를 가져다주는 센서와 시스템이 개발되고 있다. 그중에서도 차량에 탑재되는 비전 센서는 도로 위 물체를 탐지하여 인간이 놓치거나 보지 못한 부분을 포착하여 운전자에게 제공한다. 카메라를 통한 물체 인식은

* 본 연구는 미래창조과학부 및 정보통신기술진흥센터의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음 (IITP-2016-H8601-1-6-1002)

◆ First Author : Kyungpook National University Department of Electronics Engineering, wilcokang@knu.ac.kr, 학생회원

° Corresponding Author : Kyungpook National University Department of Electronics Engineering, dshan@knu.ac.kr, 종신회원
논문번호 : KICS2016-10-317, Received October 17, 2016; Revised November 28, 2016; Accepted November 28, 2016

크게 보행자^[1], 차선^[2], 차량 등이 있다. 이들 정보는 현재 도로 상황을 판단하는데 있어 필수적인 요소다. 그 중에서도 차량 검출은 ADAS(Adaptive Driver Assistance System)과 같은 운전자 편의 보조 시스템에 있어 필수적 사항이 되었다. 차량을 검출하기 위해서는 크게 레이더를 통한 차량 검출과 카메라로부터 들어오는 영상을 처리하여 검출하는 방법이 있다. 레이더는 차량을 검출하는 반경과 탐지율에 있어 비전 센서에 비해 검출 성능이 좋아 ADAS에 주로 쓰이지만 검출되는 물체를 분류하는 것이 쉽지 않아 그 부분을 비전 센서를 통해 이뤄지고 있다. 비전 센서의 경우 인간의 눈처럼 도로에 있는 물체를 영상으로 받아들여 이를 처리하므로 검출되는 물체가 무엇인지 쉽게 분류할 수 있다. 하지만 비전 센서는 날씨가 흐린 우천 상황이나 빛이 거의 없는 밤인 경우 해당 센서의 활용성이 급격하게 저하된다. 보다 안전한 운전자 보조 시스템을 개발하기 위해 이러한 비전의 문제를 해결하기 위한 방안이 활발히 연구되고 있다.

차량을 검출하는 방법은 많은 방법이 존재하지만 그 중에서도 가우시안 혼합 모델(GMM, Gaussian Mixture Model)^[3], 옵티컬 플로우(Optical Flow)^[4]와 Adaboost(Adaptive boosting)^[5]과 같은 방법을 적용하여 차량을 검출한다. 본 논문에서는 각각의 방법들을 우천 주행 영상에 적용하여 가장 적절한 차량 검출 모델이 어떤 것인지 찾고자 한다.



그림 1. 우천 상황에서의 고속도로 환경
Fig. 1. Highway in rainy situation

1.2 GMM(Gaussian Mixture Model)

가우시안 혼합 모델(GMM)은 주어진 표본 데이터 집합의 분포 밀도를 하나의 확률밀도 함수로 모델링하는 방법을 개선한 밀도추정방법으로 복수의 가우시안 확률밀도함수로 데이터의 분포를 모델링 하는 방법이다. 가우시안 혼합 모델을 이용하여 차량의 유팽선을 추출하여 각각의 객체로 분리한 후 최종적으로 차량을 검출하고 추적하는데 사용된다. 하지만 가우시안 혼합 모델을 기반으로 한 차량 추적방법의 혼란 문제점은 나란히 달리는 차량을 각각의 객체로 인식하는 점과 차량이 아닌 영역을 객체로 검출하는 것이 있




그림 2. (a)원본 영상, (b)GMM을 이용한 차량 검출 결과
Fig. 2. (a)original image, (b)result of vehicle detection using GMM

다. 또한 주행 차량에서 가우시안 혼합 모델의 경우 배경이 정지한 상태에서 더욱 유용하다. 그림 2는 가우시안 혼합 모델을 이용하여 우천 상황에서 주행 차량에 촬영된 영상에서 차량을 검출한 결과이다. 그림 2에서 볼 수 있듯이 주행 차량에서 차량 검출을 하는데 가우시안 혼합 모델이 적합한 방법이 아닌 것을 확인할 수 있다.

1.3 옵티컬 플로우(Optical Flow)

옵티컬 플로우는 영상 픽셀의 움직임을 모션 벡터로 표현하여 차량을 검출하는 방법^[6]이다. 옵티컬 플로우는 영상 전체 영역에 대해 각 픽셀의 모션을 감지하고자 대조하기 때문에 연산량이 크다는 단점이 있다. 이러한 단점을 극복하기 위해 W. Kruger^[7], Z. Hu^[8] 등이 단위 픽셀을 사용하거나 인접한 프레임으로부터 활력(vitality)과 신뢰성(reliability) 값을 정의하여 객체를 부여하여 해결하고자 했다. 하지만 옵티컬 플로우를 적용한 차량 검출 방법은 배경이 움직이거나 영상의 노이즈에 민감하게 반응하고 여전히 처리해야하는 연산량이 많은 점에서 실시간 검출을 해야 하는 주행 차량의 차량 검출에는 적합하지 못하다. 그림 3은 옵티컬 플로우를 적용하여 차량 검출한 결과이다. 결과를 보면 알 수 있듯이 옵티컬 플로우는 주행 차량에서 차량 검출 방법으로 적절치 못한 것을



그림 3. (a)원본 영상, (b)옵티컬 플로우 방법을 이용한 차량 검출 결과
Fig. 3. (a)original image, (b)result of vehicle detection using Optical Flow

알 수 있다.

앞에서 다룬 차량 검출 알고리즘은 현재까지도 사용되는 강력한 알고리즘이지만 우천 상황과 같은 악 조건에서는 검출성능이 저하된 것을 확인할 수 있다. 따라서 본 논문에서는 다음과 같은 방법을 통해 차량 검출을 하고자 한다. 영상에서 물체를 검출하는 과정은 크게 3가지의 단계로 구성될 수 있다. 먼저 입력 영상에서 물체가 있을만한 영역, 즉 관심영역(ROI, Region Of Interest)을 선정한 후 그 부분에서 차량에 해당되는 특징을 추출한 다음 이를 이용하여 분류하여 차량인지 아닌지 검출하는 것이 일반적이다. 해당 논문에서 우천 상황에 효과적으로 차량 검출을 위해 다음과 같이 제안한다. 먼저 영상의 RGB값을 추출하여 영상의 날씨 환경을 추측한 뒤 우천 상황인 경우 후미등을 이용하여 관심영역을 추출하고 미리 학습된 Adaboost를 사용하여 차량 검출을 실시한다. 다음 장에서는 보다 자세한 세부 알고리즘 설명을 하고자 한다.

II. 제안된 차량 검출 방법의 세부 알고리즘

2.1 제안된 차량 검출기 모델

본 논문에서 제안하는 주행 차량의 차량 검출 모델은 그림 4와 같다. 먼저 카메라로부터 입력받은 영상을 RGB 색 공간에서 YCbCr 색 공간으로 변환하여 밝기를 측정한다. YCbCr 색 공간의 3가지 값은 Y는 휘도, Cb와 Cr은 색차 성분을 의미하고

$$\begin{pmatrix} Y \\ Cb \\ Cr \end{pmatrix} = \begin{pmatrix} 0.257 & 0.504 & 0.098 \\ -0.148 & -0.291 & 0.439 \\ 0.439 & -0.368 & -0.071 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} + \begin{pmatrix} 16 \\ 128 \\ 128 \end{pmatrix} \quad (1)$$

이들 중 밝기의 지표로 사용할 수 있는 것은 Y 값이다. 아래의 식 1은 RGB 색 공간을 YCbCr 색 공간으로 변환하는 수식으로, 영상을 RGB 색 공간으로 입력 받을 때 RGB 데이터타입이 uint8형이었고 이를 YCbCr 색 공간으로 변환해도 uint8형으로 유지할 수

있다. 이때 Y 값의 범위는 16에서 235정도였는데 대체적으로 70이하일 때 영상이 어둡거나 우천 상황이라 차량이 검출이 잘 되지 않는다고 정한다. 본 논문에서는 연산량을 줄이고자 영상 상단 절반 부분의 임의의 픽셀 10개의 RGB 평균을 사용하여 식 1에 대입한다. 해당 부분은 조도 센서를 이용하면 더 정확한 결과를 얻을 수 있다.

Y 값이 70이하인 영상은 비전 센서가 정확하게 차량을 구분 짓기 힘들다고 가정한다. 따라서 해당 영상은 차량이 어디쯤 있는지 관심영역(ROI, Region Of Interest)을 선별하기 위해 영상 내에 적색을 추출한다. 추출된 적색이 두 군데 이상이여야만 차량의 후미등으로 간주했다. 일단 빨간불이 있는 것을 차량이 있는지의 유무를 판단하는 지표로 선택한 이유는 다음과 같다. 자동차 전용도로 혹은 고속도로에서는 신호등이 없으므로 입력 영상으로부터 계산된 밝기 값이 70이 하라면 그때 적색을 2개 이상 내는 것은 자동차일 것이라는 가정을 했다. 또한 Y 값이 70이하라는 건 주행 환경이 어두워서 전방을 정확하게 인지 못하는 경우라고 가정하였고 해당 상황일 경우 운전자들은 전조등을 켜고 주행할거라 가정했다. 후미등은 전조등을 켜면 동시에 켜지는 불이므로 영상에서 적색을 찾는다는 것이 차량의 위치를 기준할 수 있는 방법으로 가정했다.

위와 같은 과정을 거친 영상은 명암대비를 향상하기 위해 기존에는 적용되지 않았던 대비제한 히스토그램 평활화(CLAHE, Contrast-Limit Adaptive Histogram Equalization)^[9]를 적용하였고 최종적으로 학습기반으로 방법 중 자체적인 학습 샘플을 가지고 객체를 인식하는 방법인 Adaboost 알고리즘을 이용해 차량검출을 하였다.

2.2 관심영역 추출

영상 내에서 차량이 존재하는지, 존재한다면 어디에 존재하는지 관심영역을 추출하는 것은 전체 알고




그림 4. 차량 검출 시스템 블록 다이어그램

Fig. 4. The block diagram of an overall system of vehicle detection

리즘의 연산량 감소와 검출율 향상의 장점을 제공한다. 관심영역을 추출하는 방법은 다음과 같다. 영상 내에서 적색이 같은 수평선상에 2군데 이상 검출되는 것을 차량의 후미등이라 가정하고 후미등 간격의 2배 만큼의 길이에 해당되는 영역을 관심영역으로 지정했다. 이 과정에서 차량의 후미등을 강조하기 위해 CLAHE를 적용하였다. CLAHE는 대비제한 적응 히스토그램 평활화로써, K. Zuierveld가 처음 제안한 방법으로 명암대비 향상에 쓰이는 영상 전처리 방법이다. CLAHE의 파라미터들은 블록 크기와 클립 한계 (clip-limit) 총 2개가 있다. 먼저 블록 크기는 히스토그램 평활화를 진행할 때 어느 정도의 크기로 나눠 진행할지 결정하는 매개변수로 크기를 작게 할수록 영상에서 나뉘지는 블록의 개수가 증가한다. 블록의 크기를 줄여 개수가 증가하면 작은 영역에서 CLAHE가 진행되어 영상의 지역적 특징이 부각된다. 클립 한계는 블록마다 CLAHE를 진행할 때 해당 블록이 지니는 히스토그램 분포의 최댓값을 제한하여 이를 재분배하는 매개변수이다. 클립 한계가 낮아질수록 최댓값에서 재분배하는 히스토그램의 값이 증가하여 대비가 뚜렷해진다. 그림 5는 입력 영상의 그레이스케일 (grayscale)영상과 CLAHE 영상의 히스토그램 분포이다. 그림 5를 보면 차량이 있는 부분이 강조되도록 히스토그램이 재분포되는 것을 확인할 수 있다. 이렇게 함으로써 후미등을 좀 더 강조할 뿐만 아니라 차량 자체를 강조할 수 있어 이후에 진행되는 Adaboost를 적용한 검출기를 통해 특징 추출을 좀 더 원활하게 진행 할 수 있다.

2.3 특징 추출 및 차량 검출

차량을 분류하기 위해서 여러개의 분류기를 조합한 Adaboost를 사용했다. Adaboost는 현재 SVM(Support Vector Machine)^[10]과 같이 사진에 학




그림 5. 그레이스케일 영상과 CLAHE 영상의 히스토그램
Fig. 5. Histogram of grayscale and CLAHE

습된 물체를 분류하는 대표적인 방법이다. Adaboost는 자체적인 학습 샘플을 가지고 객체를 인식하기 때문에 특히 이진 분류 문제에 대해 좋은 성능을 보인다. 하지만 자체적인 학습 샘플을 이용하여 객체를 인식하므로 데이터에 의존적이라는 단점과 테스트 영상에 노이즈가 많아 물체 분간에 어려운 경우 그 성능이 낮게 나온다는 단점 등이 있다. 본 논문에서는 차량 검출을 위해 Haar-like 특징, 적분영상, 계층 구조를 적용하여 약한 분류기(weak classifier)를 통해 반복적인 학습을 순차적으로 선택하고 조합하여 강한 분류기(strong classifier)를 만들었다. 그림 6는 본 논문에 적용된 Adaboost 알고리즘의 블록 다이어그램이다. 3개의 약한 분류기를 조합하여 차량을 판별하는 강한 분류기를 만들었다.

Adaboost를 우천 상황에서 효과적으로 특징 추출과 차량을 검출을 하기 위해 2가지 형태의 학습 데이터셋을 구성했다. 먼저 차량 자체를 인식하기 위해 차량의 부분 이미지, 즉 좌측, 우측, 중앙과 원거리 차량 영상을 각각 2,500장씩 총 10,000장을 준비했다. 또한




그림 6. Adaboost 블록 다이어그램
Fig. 6. The block diagram of Adaboost algorithm

우천 상황에서 차량의 특징 추출을 효과적으로 하기 위해 국내 고속도로 주행 영상을 위의 방법과 동일하게 각각 1,000장씩 4000장 준비했다. 총 14,000장의 학습 데이터를 Haar-like 필터를 통해 특징을 추출했다. Haar-like 특징은 물체의 경계선(Edge)과 형태 특징을 검출하기 위해 그림 7과 같은 필터를 적용하여 차량의 특징을 추출하였다. 총 13개의 Haar-like 필터를 사용하여 특징 추출을 하였다. 그림 7에 보이는 12개의 필터 외에 대각선을 추출하기 위한 필터도 사용하여 차량 특징을 검출했다. 다양한 Haar-like 필터를 통해 얻은 차량 특징을 Adaboost를 통해 학습했다.




그림 7. Haar-like 특징
Fig. 7. Haar-like features

III. 실험 결과

3.1 차량 검출기 성능 비교

실험을 진행하기에 앞서 성능 테스트를 위해 블랙 박스로 활용된 고속도로 주행 영상 500장을 사용했다. 영상은 날씨가 좋은 상황 250장과 우천 상황과 같은 날씨가 좋지 않는 상황 250장씩 준비했다. 본 논문에서 제안하는 Adaboost 알고리즘과 기우시안 혼합 모델, 옵티컬 플로우 방법의 검출 결과는 표 1과 같다. 검출 결과를 분석하기 위해 정확률(Precision)과 재현율(recall)을 구했다. 정확률과 재현율을 구한 식은 식 2를 이용했다.

$$\frac{TP}{TP+FP} = \text{Precision} \quad (2)$$

$$\frac{TP}{TP+TN} = \text{Recall}$$

표 1. 차량 검출 결과
Table 1. Result of vehicle detection

	Precision	recall
GMM	0.52	0.41
Optical Flow	0.48	0.37
Adaboost	0.83	0.77

표 1의 결과를 보면 Adaboost 알고리즘과 그 외의 검출기의 미검출율 차이가 많이 나는 것을 확인할 수 있다. 차량이 주행하면서 다른 차량을 검출하는데 미검출율이 높다는 것은 해당 검출 방법이 운전자의 도로 상황에는 적합하지 않다고 판단할 수 있다. 따라서 GMM, 옵티컬 플로우와 Adaboost 중에서는 Adaboost 알고리즘이 주행 차량의 차량 검출 방법으로 적합함을 알 수 있었다.

3.2 CLAHE 적용 전과 적용 후의 Adaboost 검출기의 성능 비교

차량이 있는 관심영역을 보다 효과적으로 검출하기 위해 제안되었던 CLAHE를 적용하기 전과 후의 Adaboost 차량 검출 정확율과 재현율 비교 결과를 표 2에 표기했다. 정확률은 CLAHE를 적용하기 전과 후의 차이가 약 2.4% 향상되는 결과를 얻었다. 재현율의 경우 CLAHE를 적용한 경우가 그렇지 않은 경우보다 약 13% 향상되는 것을 확인할 수 있었다.

표 2. CLAHE를 적용한 Adaboost 차량 검출 결과
Table 2. Result of vehicle detection with Adaboost using CLAHE

	Precision	recall
Adaboost with CLAHE	0.85	0.87
Adaboost without CLAHE	0.83	0.77

3.3 제안하는 시스템과 기우시안 혼합 모델과 옵티컬 플로우 방법의 성능 비교

본 논문에서 제안하는 CLAHE 기반 Adaboost 검출 알고리즘과 기우시안 혼합 모델과 옵티컬 플로우 방법의 차량 검출 결과는 표 3과 같다. 표 3의 결과를 통해 알 수 있는 것은 주행 차량의 차량 검출은 기우시안 혼합 모델과 옵티컬 플로우 방법보다 학습기반 모델인 Adaboost 검출 알고리즘의 검출 성능이 더 좋은 점과 CLAHE를 적용한 Adaboost는 우천 상황과 같은 차량 검출이 힘든 환경에서도 다른 알고리즘에 비해 성능이 우수함을 보여준다.

표 3. CLAHE를 적용한 Adaboost 차량 검출 결과
Table 3. Result of vehicle detection with Adaboost using CLAHE

	Precision	recall
GMM	0.47	0.43
Optical Flow	0.47	0.39
Adaboost with CLAHE	0.85	0.87

표 3의 내용에서 CLAHE를 적용한 경우에 Adaboost를 제외한 다른 방법에서 정확률이 약간 저하되었고 재현율이 향상되었다. CLAHE 과정에서 영상에 변형이 생겨 차량이 아닌 것까지 검출한 것이 정확률 저하에 영향을 준 것으로 사료된다. 하지만 재현율은 전체적으로 향상되었다. 이를 통해 알 수 있는 점은 CLAHE를 통해 실제 차량을 차량으로 인식하는 성능이 향상될 수 있다는 것을 알게 되었다. 기존에 영상 전처리 과정을 하지 않고 Adaboost를 통해 차량 분류를 하는 것보다 CLAHE와 같은 영상 전처리를 한 뒤 차량 분류 작업을 한 것이 재현율 향상에 도움이 되는 것을 확인할 수 있었다.

IV. 결 론

본 실험을 통해, 차량 검출에 있어 관심 영역 지정 할 때 CLAHE를 적용하여 후미등 검출 성능이 향상되는 것과 이를 통해 Adaboost를 이용한 분류 작업에서 차량 검출의 재현율이 향상되는 것을 확인할 수 있다. 해당 논문을 통해 말하고자 하는 것은 주행 차량에 적용되는 차량 검출 알고리즘은 운전자의 안전에 대한 신뢰성을 보장하기 위해 운전 환경이 우천 상황과 같이 어떠한 환경이라도 강인한 검출율을 보여줘야 된다는 점이다. 주행 차량에 장착되는 비전 센서 기반 차량 검출은 레이더 센서와의 주종관계를 따진다면 주인이 되기 어려운 보조적인 역할로 사용되고 현재까지도 그렇게 되고 있다. 이는 아직까지 비전 센서가 인간의 눈보다 물체를 검출하는데 부족함이 있기 때문이다. 하지만 자율주행차량의 몇몇 사례들을 보면 레이더 기반 차량 검출 방법은 아직까지 해결해야 할 문제가 많다. 따라서 차량용 비전 센서의 물체 인식 능력이 향상되어 운전자의 편의와 안전을 보장하는 ADAS가 개발되어야 한다.

References

- [1] P. Dollar, C. Wojek, B. Schiele and P. Perona, "Pedestrian detection: An evaluation of the state of the art," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 34, pp. 743-761, Apr. 2012.
- [2] M. Y. Jeong and G. H. Kim, "Lane detection on non-flat road using piecewise linear model," *J. KICS*, vol. 39, no. 6, pp. 322-332, Jun. 2014.
- [3] O. M. Lee, I. S. Won, S. M. Lee, and J. W. Kwon, "On-road car detection system using VD-GMM 2.0," *J. KICS*, vol. 40, no. 11, pp. 2291-2297, Nov. 2015.
- [4] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," in *Proc. IEEE Comput. Soc. Conf. CVPR 2001.*, vol. 1, pp. 511-518, 2001.
- [5] Berthold K. P. Horn and Brian G. Schunck, "Determining optical flow," *Artificial Intell.*, vol. 17, pp. 185-203, Aug. 1981.
- [6] C. Song and J. Lee, "Detection of illegal U-turn vehicle by optical flow analysis," *J. KICS*, vol. 39C, no. 10, pp. 948-956, Nov. 2014.
- [7] W. Kruger, W. Enkelmann, and S. Rössle, "Realtime estimation and tracking of optical flow vectors for obstacle detection," in *Proc. Intell. Veh. '95 Symp.*, pp. 304-309, Sept. 1995.
- [8] Z. Hu and K. Uchimura, "Tracking cycle: A new concept for simultaneously tracking of multiple moving objects in a typical traffic scene," in *Proc. IEEE 2000 Intell. Veh. Symp.*, pp. 233-239, Oct. 2000.
- [9] K. Zuiderveld, *Contrast Limited Adaptive Histogram Equalization*, Academic Press Inc., 1994.
- [10] C. W. Hsu and C. J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE Trans. Neural Networks*, vol. 13, no. 2, pp. 415-425, Mar. 2002.

강 석 준 (Seokjun Kang)



2016년 2월 : 경북대학교 전자
공학과 공학사
2016년 3월~현재 : 경북대학교
모바일통신공학과 석사과정
<관심분야> 전자공학, 영상처리,
신호처리

한 동 석 (Dong Seog Han)



1987년 : 경북대학교 전자공학
과 공학사
1989년 : KAIST 전기 및 전자
공학과 공학석사
1993년 : KAIST 전기 및 전자
공학과 공학박사
1987년 10월~1996년 8월 : 삼
성전자 기술총괄신호처리 연구소 선임연구원
1996년 8월~현재 : 경북대학교 전자공학부 교수
2006년 7월~2008년 7월 : 정보통신연구진흥원 디지
털 TV/방송사업단 단장
2011년~현재 : 경북대학교 ICT·자동차융합연구센터장
ORCID : 0000-0002-7769-0236
<관심분야> 통신신호처리, 지능형 교통시스템