

딥러닝을 이용한 차로이탈 경고 시스템⁺

(Lane Departure Warning System using Deep Learning)

최 승 완¹⁾, 이 건 태²⁾, 김 광 수³⁾, 곽 수 영⁴⁾*

(Seungwan Choi, Keontae Lee, Kwangsoo Kim, and Sooyeong Kwak)

요 약 최근 인공지능 기술이 급격히 발전하면서 첨단 운전자 지원 시스템 분야에 딥러닝 기술을 접목하여 기존의 기술보다 뛰어난 성능을 보여주기 위한 여러 연구들이 진행 되고 있다. 이러한 동향에 맞춰 본 논문 또한 첨단 운전자 지원 시스템의 핵심 요소 중 하나인 차로이탈 경고시스템에 딥러닝 기술을 접목한 방법을 제안한다. 제안하는 방법과 기존의 차선검출 기반의 경고시스템과의 비교 실험을 통해 그 성능을 평가 하였다. 고속도로 주행영상과 시내 주행영상을 이용한 두 가지의 서로 다른 환경에서 모두 제안하는 방법이 정확도 및 정밀도 부분에서 더 높은 수치를 보여주었다.

핵심주제어: 차선이탈 경고시스템, 첨단 운전자 지원 시스템, 딥러닝

Abstract As artificial intelligence technology has been developed rapidly, many researchers who are interested in next-generation vehicles have been studying on applying the artificial intelligence technology to advanced driver assistance systems (ADAS). In this paper, a method of applying deep learning algorithm to the lane departure warning system which is one of the main components of the ADAS was proposed. The performance of the proposed method was evaluated by taking a comparative experiments with the existing algorithm which is based on the line detection using image processing techniques. The experiments were carried out for two different driving situations with image databases for driving on a highway and on the urban streets. The experimental results showed that the proposed system has higher accuracy and precision than the existing method under both situations.

Key Words: Lane departure warning system, Advanced driver assistance system, Deep learning

1. 서 론

* Corresponding Author : sykwak@hanbat.ac.kr

Manuscript received January 31, 2019 / revised March 20, 2019 / accepted April 2, 2019

+ 이 논문은 2017년도 한밭대학교 교내학술연구비의 지원을 받아 진행된 연구임.

- 1) 한밭대학교 제어계측공학과, 제1저자
- 2) 한밭대학교 전자제어공학과, 제2저자
- 3) 한밭대학교 전자제어공학과, 제3저자
- 4) 한밭대학교 전자제어공학과, 교신저자

최근 다양한 분야에서 딥러닝(Deep learning) 기술을 적용하여 기존의 알고리즘 또는 시스템의 성능보다 뛰어난 결과를 보이는 가운데, 첨단 운전자 지원 시스템(Advanced driver assistance systems) 분야에서도 딥러닝 기술을 적용하여 기존 시스템의 성능을 향상시키고자 하는 다양한 연구가 활발히 진행되고 있다. 대표적인 예로써, 객체 검출 알고리즘을 이용하여 기존의 영상처리 기법보다 보행

자를 더 정확하게 인식하는 YOLO(You only look once)[1] 또는 Faster R-CNN[2]이 있고, 딥러닝 기술을 적용하여 역시 기존의 영상처리 기법보다 더 정확하게 차선을 검출하는 사례도 있다[5]. 본 논문에서 소개하는 차로이탈 경고 시스템에 딥러닝을 적용하여 성능을 개선시키고자 하는 연구도 이러한 최신 연구 동향에 부합한다고 할 수 있다.

기존의 차로이탈 경고 시스템은 주로 영상처리기법을 이용하는데, 주행영상에서 차선을 먼저 검출하고 검출된 차선의 좌, 우 차선 폭 정보로부터 이탈 여부를 판단하거나, 차선 사이에 삼각형의 빗변의 길이를 이용하여 차로이탈 여부를 판단한다[6]. 기존 시스템과 제안하는 방법의 가장 큰 차이점은 차선검출 단계를 거치지 않는다는 것이다. 대신 제안하는 시스템은 정상주행 데이터와 차로이탈 데이터들을 이용하여 콘볼루션 신경망 (Convolution neural network; CNN)을 학습시키고, 그 결과로 얻은 모델을 이용하여 현재 상황의 정상주행 여부를 직접적으로 판단한다. Fig. 1에 나타낸 기존의 차로이탈 경고시스템과 제안하는 차로이탈 경고 시스템의 대략적인 처리 과정에서 이러한 차이점을 확실하게 볼 수 있다. 기존의 방법과 제안하는 방법의 구체적인 알고리즘에 대한 설명은 각각 2절과 3절에 나와 있다.

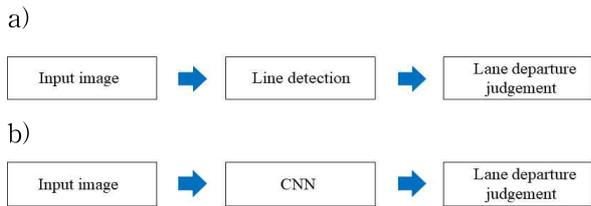


Fig. 1 The comparison of data processing flow for lane departure warning a) existing method, b) proposed method

제안하는 방법의 성능을 테스트하기 위해 참고 문헌 [6]에서 제시한 알고리즘과 처리 속도와 정확도면에서 비교 실험을 수행하였다. 이 때 입력 영상으로는 고속도로 주행과 시내 주行的 서로 다른 두 가지 환경에서 구축한 데이터베이스를 사용하였다. 자세한 실험 방법과 환경 그리고 실험 결과는 4장에 정리하였다. 실험 결과 본 논문에서 제안한 방법이 두 환경에서 모두 처리 속도와 정확도면에서 기존 방법보다 더 뛰어난 성능

을 보이는 것을 확인할 수 있었다. 5장에서는 본 연구의 내용을 요약하고 향후 성능 향상을 위한 과제에 대해 간단하게 논의한다.

2. 차선검출 기반 차로이탈경고 방법

2.1 차선검출

기존의 차로이탈 경고시스템은 영상에서 차선을 먼저 검출하고 이후 검출된 차선 데이터를 이용하여 차로이탈 여부를 판단한다. 따라서 다양한 환경에서 정확하게 차선을 검출하는 것이 차로이탈 여부를 판단하기 위한 필수조건이다. Fig. 2는 차선검출 방법의 전체적인 개요를 보여준다. 획득된 영상은 황색 성분 강조 및 역투영 사상 (Inverse perspective mapping; IPM)을 이용하여 탑뷰(Top-view)영상으로 변환해 주는 전처리 과정을 거치며 이후 RANSAC (Random sample consensus)

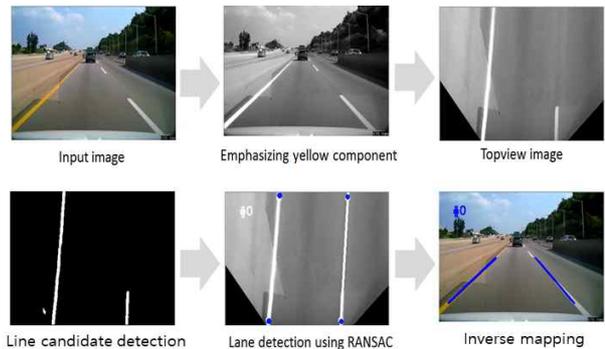


Fig. 2 Overview of the line detection algorithm[6]

을 이용하여 차선을 검출한다.

2.2 차선 이탈 판단

차선들 사이의 간격은 항상 일정하며 블랙박스의 카메라 위치가 차량의 중앙에 설치되어 차량의 중심과 영상의 가로 방향 중심선이 일치한다는 가정을 기반으로 두고 차량의 이탈여부를 판단한다. Fig 3과 같이 영상에서 차량의 중심과 차선사이에 거리를 표시한 빨간 삼각형과 같은 보조선이 있다고 가정 하였을 때 차

량의 중심과 검출된 왼쪽 차선과의 거리를 K_L 이라 하고, 차량의 중심과 검출된 오른쪽 차선과의 거리를 K_R 이라 하자. 그러면, $K_L \approx K_R$ 이면 정상주행(Fig. 3a), $K_L \ll K_R$ 이면 왼쪽 방향으로 차로를 이탈한 것으로(Fig. 3b), $K_L \gg K_R$ 이면 오른쪽 방향으로 차로를 이탈한 것으로(Fig. 3c) 판단한다.

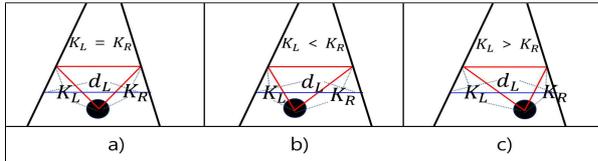


Fig. 3 Determination of vehicle's position between two lines a) center b) leaning to left c) leaning to right [6]

3. 딥러닝 기반 차로이탈 경고 방법

3.1 전체적인 흐름

본 논문에서 제안하는 방법의 전체적인 흐름은 Fig. 4와 같다. 먼저 실제 블랙박스 영상으로부터 수집된 주행 영상 데이터를 이용해 전처리 과정을 거친 학습 데이터를 구성하고, 구성된 학습 데이터를 바탕으로 제안하는 CNN 구조를 학습시킨다. 이후 학습 결과로 얻어진 모델을 이용하여 현재 상태가 정상주행인지, 차로이탈인지를 판단한다.

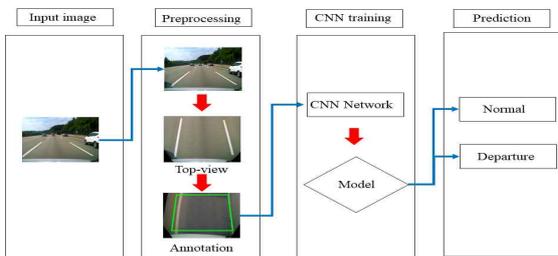


Fig. 4 The overall structure of the proposed method

3.2 학습데이터

우선 제안하는 방법에서 사용한 학습 데이터는 차선의 영역만을 관심 영역으로 갖는 128×128 의 컬러이미지를 사용한다. 또한 학습 데이터는 전처리 과정으로 영상을 탐부 변환한 후 사각형의 이미지 명명(Annotation) 작업을 해준 데이터다. 먼저 이미지 명명 작업은 정상주행 데이터와 차로이탈 데이터에 대한 애매한 기준을 보다 정확하게 구분 짓기 위해 사용한다. 정상주행 데이터의 경우에는 사각형의 이미지 명명 박스 안에 두 개의 차선이 모두 있거나 이미지 명명 박스와 두 개의 차선과의 거리가 어느 정도 가깝고, 차로이탈 데이터의 경우에는 사각형의 이미지 명명 박스 안에 한 개의 차선만 존재하거나 이미지 명명 박스와 차선과의 거리가 일정수준 이상 차이가 난다. Fig. 5a는 정상주행 데이터의 예를 Fig. 5b는 차로이탈 데이터의 예를 보여주고 있다.

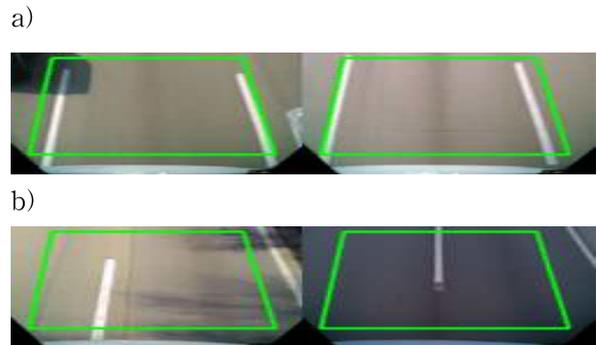


Fig. 5 Examples of Training Data. a) Normal driving data, b) Lane departure data

또한 Fig. 6a와 같이 3차원 일반 영상으로 직선 차로에서의 정상주행 데이터에 맞춰 이미지 명명 작업을 하게 되면 곡선차로에서는 정상주행중인데도 불구하고 Fig. 6b와 같이 차선이탈 데이터로 구분되는 데이터를 얻게 되는 문제를 고려하여, 3차원 영상을 탐부 영상으로 전처리하여 사용하였다. 이와 같이 탐부 영상으로 변환한 후 이미지 명명 작업을 수행하면 Fig. 7에서와 같이 곡선 차로에서의 문제가 해결된 것을 확인할 수 있다. 결과적으로 학습 데이터는 탐

뷰 변환과 이미지 명명 작업 등의 전처리된 데이터를 사용 하였으며, 총 9,727장의 정상주행 데이터와 8,165장의 차로이탈 데이터로 구성되어 있다.



Fig. 6 Annotation of driving data without top-view transformation a) on a straight lane and b) on a curved lane

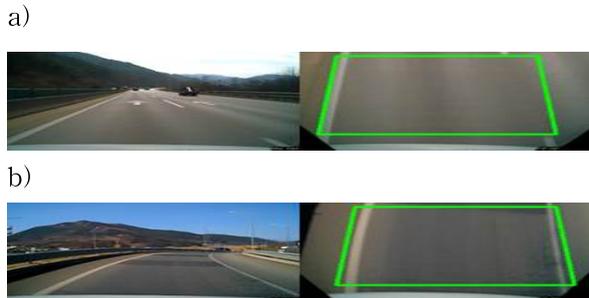


Fig. 7 Annotation of driving data with top-view transformation a) on a straight lane and b) on a curved lane

3.3 CNN 구조

본 논문에서 채택한 CNN 구조는 Fig. 8과 같으며 파이썬(Python)의 케라스(Keras) 라이브러리를 이용하여 구현하였다. 제안하는 CNN의 입력은 128×128 크기의 컬러 이미지를 입력으로 받으며 총 6개의 층으로 이루어져 있고, 5개의 컨볼루션 층 (Convolution layer)과 1개의 완전 연결 층 (Fully connection layer)으로 이루어져 있다. 5개의 컨볼루션 층은 각각 3×3 크기의 32, 64, 128, 256, 512개의 특징 맵 (Feature map)을 갖고 있으며 각 컨볼루션 층 이후에는 3×3 크기에 간격이 2인 최대 풀링 (Max pooling)을 사용하였다. 마지막 층은 1개의 완전 연결 층으로 이루어져 있으며 출력은 Softmax를 이용하여 정상주행과 차로이탈 각각의 경우를

확률로 나타낼 수 있도록 하였다. 또한 각 층의 활성화 함수 (Activation function)로는 ReLU를 사용하였으며, 과적합(Over-fitting)을 방지하기 위해 드롭아웃 (Dropout)기법을 도입하였다. 이후 학습을 진행하는데 최적화 방법으로는 ADAM (Adaptive moment estimation)을 이용하였다.

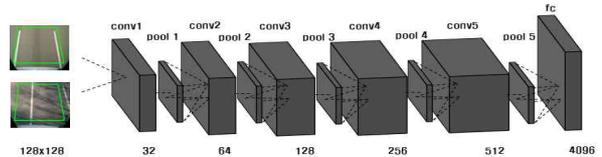


Fig. 8 The proposed CNN architecture.

3.3 학습 및 모델 적용

3.2 절에서 설명한 CNN 구조에 전처리 과정을 통해 가공된 128×128 크기의 데이터 셋을 이용하여 학습을 진행하였다. 획득된 9,727장의 정상주행 데이터와 8,165장의 차로이탈 데이터 중에서 각각 1,000장씩 총 2,000장의 데이터를 검증용 데이터 (Validation data)로 사용하고, 나머지 15,892장의 데이터를 학습용 데이터로 사용하였다. 학습 횟수 (Epoch)는 총 40회로 설정하고 미니배치 (Mini-batch) 크기는 100으로 설정하여 학습을 진행 하였으며 학습이 40회 반복 되는 동안 이전의 검증 정확도 (Validation accuracy)보다 높은 결과가 나오면 업데이트 해주는 방법을 이용하여 최고의 검증 정확도를 도출할 수 있도록 하였다. Fig. 9는 학습 결과를 보여주고 있으며, 학습 결과 98.7%의 검증정확도를 보여주었다.

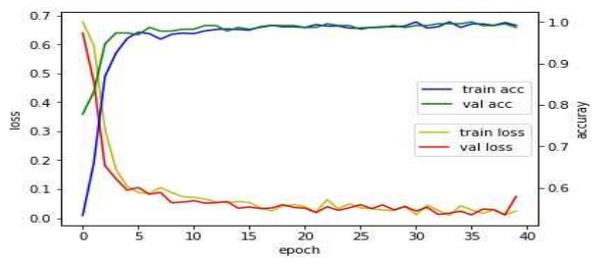


Fig. 9 The validation accuracy in relation to the different number of epochs

이후 블랙박스로부터 얻어진 주행영상에 CNN의 입력데이터와 동일한 전처리 과정을 해준 후, 학습 결과로 나온 모델을 이용하여 현재 상황이 정상주행인지 차로이탈인지를 판단하고 차로이탈의 확률을 나타낸다. Fig. 10은 제안하는 방법을 이용하여 차로이탈 여부를 판단한 결과영상이며 영상 윗부분에 현재 주행 상태에 대한 판단 결과와 그에 대한 확률을 표시해 주며 판단 결과가 정상 주행이면 초록색으로 표시되고, 차로 이탈로 판단된 경우는 빨간색 글씨로 표시된다.



Fig. 10 Sample images of experimental results

4. 실험 및 평가

앞의 3절에서 언급한 것과 같이 획득된 총 15,892장의 학습용 데이터를 이용해 학습된 모델을 이용하여 기존의 차선검출기반의 방법과 제안하는 방법을 비교 실험하였다. 이후 실제 차량에 부착된 블랙박스를 통하여 고속도로와 대구 도심지역을 촬영하여 추가적으로 실험을 위한 데이터를 수집 하였고, 촬영된 실험 데이터는 720x480크기의 동영상 이며, 비교적 잡음이 적은 고속도로 환경과 가로수, 주변차량, 지하도로 등 여러 가지 잡음이 있는 시내주행 환경으로 구성되어 있다. 최종적으로 실험에서 사용한 학습용 데이터와 실험에 사용된 테스트 데이터는 Table 1과 같다.

Table 1 The number of frames in the dataset for training CNN and validation

	Training data (Frames)	Test data (Frames)
Driving on a highway	8,727	39,259
Driving in urban	7,165	18,214
Total	15,892	57,473

각각의 성능은 식 (1) ~ (3)과 같이 계산되는 정확도(accuracy)와 정밀도(precision), 재현율(recall)을 기반으로 각각 구하여 성능을 평가 하였다.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \times 100 \quad (1)$$

$$Precision = \frac{TP}{(TP + FP)} \times 100 \quad (2)$$

$$Recall = \frac{TP}{(TP + FN)} \times 100 \quad (3)$$

여기서 TP는 실제 정상주행 상황을 정상주행으로 판단한 경우이며 TN은 차로이탈 상황을 차로이탈로 판단한 경우, FP는 차로이탈 상황을 정상주행으로 판단한 경우, FN은 정상주행 상황을 차로이탈로 판단한 경우를 나타낸다.

먼저 고속도로 주행영상을 이용하여 각각의 방법에 적용시켜 실험한 결과를 Table 2에 정리하였다. 기존 방법은 차선을 검출한 이후 차선의 데이터를 이용하여 현재 주행 중인 차량이 차로를 이탈하였는지 여부를 판단하는데, 비교적 잡음이 적은 고속도로 환경에서는 차선검출이 수월하여 차로이탈 여부를 판단하는 것 또한 비교적 수월하다. 또한 제안하는 방법도 잡음이 적으면 차로이탈 여부를 판단하기 수월하기 때문에 고속도로 환경에서의 차로이탈 여부를 판단한 결과는 두 방법이 성능 면에서 크게 차이나지 않는 것을 확인 할 수 있다. 제안하는 방법이 근소하게 정확도 및 정밀도에서 약간 높은 성능을 보이고 있으며 재현율에서는 기존의 방법이 근소하게 높음을 확인 할 수 있다.

Table 2 The result of a comparative experiment with a dataset consisting of highway driving images

	Existing method (Frames)	Proposed method (Frames)
TP (True Positive)	32,148	34,374
TN (True Negative)	6,040	4,114
FP (False Positive)	642	217
FN (False Negative)	429	554
Accuracy	97.20	98.03
Precision	98.04	99.37
Recall	98.68	98.41

다음으로 시내 주행영상에서의 실험 결과를 Table 3에 정리 하였다. 시내주행 영상의 특성상 여러 가지 잡음들이 존재하기 때문에 고속도로로 주행환경보다 차선검출이 더 어렵고 차로 이탈 여부를 판단하는 것 또한 어려움이 있어 고속도로주행영상에 비해 정확도가 많이 떨어진다. 반면 제안하는 방법은 기존의 방법에 비해 시내주행에서도 비교적 차선 이탈여부를 더 잘 판단 한다. 따라서 Table 3 시내 주행 영상을 이용한 실험에서는 제안하는 방법이 정확도, 정밀도, 재현율 면에서 모두 기존의 방법보다 높은 성능을 보임을 확인 할 수 있다.

Table 3 The result of a comparative experiment with a dataset consisting of street driving images

	Existing method (Frames)	Proposed method (Frames)
TP (True Positive)	7,421	9,274
TN (True Negative)	5,066	6,509
FP (False Positive)	1,271	1,129
FN (False Negative)	4,456	1,302
Accuracy	68.55	86.65
Precision	85.37	89.14
Recall	62.48	87.68

최종적으로 고속도로로 주행영상, 시내주행영상 두 가지 영상을 이용한 실험을 종합 한 결과는 아래 Table 4와 같으며 제안하는 방법의 성능이 기존의 방법 보다 높음을 확인 할 수 있다.

Table 4 The total result of experiments

	Existing method (Frames)	Proposed method (Frames)
TP (True Positive)	39,569	43,648
TN (True Negative)	11,106	10,623
FP (False Positive)	1,913	1,346
FN (False Negative)	4,885	1,856
Accuracy	88.17	94.42
Precision	95.38	97.01
Recall	89.01	95.92

추가적으로 기존의 방법과 제안하는 방법 두 가지

방법의 한 프레임 당 처리시간에 대한 결과를 Table 5에 정리하였고 제안하는 방법의 처리속도가 10배 이상 빠른 것을 확인 할 수 있다.

Table 5 Average processing time per frame

	Existing method	Proposed method
Average processing speed (sec/frame)	0.324	0.0089

제안하는 방법의 처리속도가 기존의 방법보다 빠른 것은 기존의 방법은 차선을 검출한 이후 차로의 이탈여부를 판단하는 반면 제안하는 방법은 차선을 검출하는 단계 없이 바로 차로 이탈 여부를 판단하기 때문이다.

5. 결론 및 향후 연구방향

비교실험의 결과 비교적 잡음이 적은 고속도로 상황에서는 기존의 방법과 제안하는 방법의 정확도 및 정밀도 차이는 크게 차이 나지 않지만, 다양한 잡음이 존재하는 시내주행 영상의 경우에는 제안하는 방법의 정확도 및 정밀도가 기존의 방법보다 높음을 확인 하였다.

좀 더 다양한 환경에서의 데이터를 이용한 학습 및 비교실험을 수행할 예정이며, 현재 정상주행 및 차선이탈 두 가지 경우로 판단하는 것을 기존의 이미지 명명 작업 보다 조금 더 정밀하게 이미지 명명 작업을 진행 하여 정상주행, 왼쪽차로이탈, 오른쪽차로이탈과 같이 세부적인 판별을 할 수 있도록 확장하고자 한다.

References

- [1] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. "You only look once: unified, real-time object detection" The IEEE Conference on Computer Vision and Pattern Recognition, pp. 779-788, 2016

[2] S. Lee and N. Cho. "Pedestrian detection using YOLO and Tracking" Korea Broadcasting and Media Engineering Society 2018 Summer Conference, pp. 79-81, 2018

[3] R. Shaoqing, H. Kaiming, R. Girshick, and J. Sun. "Faster R-CNN: towards real-time object detection with region proposal networks" Computer Vision and Pattern Recognition, pp. 1-9, 2015

[4] Y. Byeon and K. Kwak, "Comparative analysis of performance using faster RCNN and ACF in people detection" Journal of Journal of Korean Institute of Information Technology, Vol.15, No. 6, pp. 11-21, 2017

[5] Y. Ye, X. Hao, and H. Chen "Lane detection method based on lane structural analysis and CNNs" Intelligent Transport Systems, Vol. 12, No. 6, pp. 513-520, 2018

[6] K. Kim, S. Choi, and S. Kwak "A lane detection and departure warning system robust to illumination change and road surface symbols" Journal of the Korea industrial information Systems Research, Vol. 19, No. 1, pp. 1-3, 2013

[7] H. Jung, J. Min, and J. Kim "An efficient lane detection algorithm for lane departure detection", 2013 IEEE Intelligent Vehicles Symposium, pp. 976-981, 2013



최 승 완 (Seungwan Choi)

- 학생회원
- 2011년 3월-2018 2월 : 한밭대학교 전자제어공학과 학사
- 2018년 3월-현재 : 한밭대학교 제어계측공학과 석사과정
- 관심분야 : 영상처리, 컴퓨터 비전, 지능형자동차



이 건 태 (Keontae Lee)

- 학생회원
- 2012년 3월-2018 6월 : 한밭대학교 전자제어공학과 학사
- 관심분야 : 영상처리, 컴퓨터 비전, 지능형자동차



김 광 수 (Kwangsoo Kim)

- 정회원
- 2004년 2월 : 서울대학교 전기컴퓨터공학부 공학박사
- 2004년 1월-2007년 3월 : 삼성전자 통신연구소 책임연구원
- 2007년 4월-2008년 2월 : 현대자동차 차량정보기획팀 과장
- 2008년 3월-현재 : 한밭대학교 전자제어공학과 부교수
- 관심분야 : 모바일로봇, 통계신호처리, 제어공학



곽 수 영 (Sooyeong Kwak)

- 정회원
- 2010년 2월 : 연세대학교 컴퓨터과학과 공학박사
- 2010년 3월-2011년 1월 : 삼성전자 영상디스플레이사업부 책임연구원
- 2011년 2월-현재 : 한밭대학교 전자제어공학과 부교수
- 관심분야 : 영상처리, 컴퓨터비전, 지능형시스템