

논문 2017-12-13

합성곱 신경망 기반 야간 차량 검출 방법

(Night-time Vehicle Detection Method Using Convolutional Neural Network)

박 응 규, 최 연 규, 김 현 구, 최 규 상, 정 호 열*

(Woong-Kyu Park, Yeongyu Choi, Hyun-Koo KIM, Gyu-Sang Choi, Ho-Youl Jung)

Abstract : In this paper, we present a night-time vehicle detection method using CNN (Convolutional Neural Network) classification. The camera based night-time vehicle detection plays an important role on various advanced driver assistance systems (ADAS) such as automatic head-lamp control system. The method consists mainly of thresholding, labeling and classification steps. The classification step is implemented by existing CIFAR-10 model CNN. Through the simulations tested on real road video, we show that CNN classification is a good alternative for night-time vehicle detection.

Keywords : Night-time vehicle detection, Convolutional neural network, Head-lamp detection, Rear-lamp detection

1. 서 론

야간 주행 환경에서 운전자의 가시거리는 안전 운전과 직결되는 중요한 요소이다. 가시거리를 증가시키기 위해서는 상황등을 사용하는 것이 가장 좋은 방법이지만, 대향 차량이나 선행 차량의 운전자에게 눈부심을 유발해 상대 차량의 안전을 위협할 수 있다. 상대 차량의 존재 및 위치를 인지하여 상황등을 제어하는 시스템이 이미 상용화 되고 있다 [1, 2]. 최근에는 LED 등과 같은 차량용 조명 기술의 발달로 전조등의 미세 제어가 가능해 지면서, 차량 존재 지역의 빔 (Beam)만 차단하고, 차량이 존재하지 않는 지역의 모든 빔은 조사거리를 최대화

하여 운전자의 야간 주행 환경에서 시인성을 개선할 수 있는 ADB (Adaptive Driving Beam) [3], AFLS (Adaptive Front Lighting System) [4] 등의 개발이 활발히 진행되고 있다. 이러한 시스템의 개발 성공 여부는 카메라 등과 같은 센서를 사용하여 전방의 차량을 검출하고 그 위치를 예측하는 기법의 성능에 따라 좌우된다.

현재까지 개발된 대다수의 야간차량 검출 기법은 이진화 방법등으로 차량의 전조등 및 후미등 후보 영역을 먼저 찾고, 후보 영역의 기하학적 및 통계적인 특징 (feature)을 추출하여 이들 특징을 중심으로 차량인지 아닌지를 판별하는 방법론을 사용하였다 [5, 6]. 이러한 특징을 이용하여 차량인지 아닌지의 판별하는 방법으로는 Ada-boost 또는 SVM (Support Vector Machine)이 자주 사용되어 왔다. 본 연구 팀에서도 최근 SVM을 이용한 분류 방법을 제안하였는데, 기존 두 개의 범주 (class)를 분류하는 이진 분류기를 사용하는 경우보다 다중-클래스 (multi-class) SVM을 사용하는 경우가 보다 더 우수한 검출 성능을 보임을 보였다. 이러한 다중-클래스 분류를 위해서는 이진-클래스 SVM을 여러 개 활용하여 One-against-all SVM, One-against-one SVM, Top-down tree structure SVM, Bottom-up tree structure SVM 등의 구조를 만들어야 하며, 이들 중 Top-down

*Corresponding Author (hoyoul@yu.ac.kr)

Received: Mar. 2 2017, Revised: Mar. 22 2017, Accepted: Mar. 28 2017.

W. Park, Y. Choi, H. Kim, G. Choi, H. Jung: Yeungnam University

※ 본 연구는 미래창조과학부 및 정보통신기술진흥센터의 대학ICT연구센터 육성지원사업의 결과로 수행되었음 (IITP-2016-R2718-16-0035)

※ 이 논문은 2014년 교육부와 한국연구재단의 지역혁신창의인력양성사업의 지원을 받아 수행된 연구임 (NRF-2014H1C1A1073141)

tree 구조 기반 SVM이 가장 우수한 결과를 보였다 [7].

최근 심층신경망 (Deep Neural Network) 기술이 급속히 발전됨에 따라 신경망을 이용하는 연구 결과도 발표되고 있다. Wang, H. [8]는 야간차량 검출을 위해 심층신경망을 적용하였다. 이 방법에서는 적외선 카메라를 기본적으로 이용함으로써 자동 전조등 제어 시스템에 활용하기에는 차량 검출 거리가 다소 짧은다는 단점이 있다.

또한, Szarvas, M. [9]은 LIDAR 센서 정보를 심층신경망을 활용하여 보행자를 검출하는 방법을 제안 하였다. 야간 주행 환경에서 차량 또는 보행자를 검출하는 방법론으로 심층신경망을 활용하는 연구가 최근 활발히 진행 되고 있다.

신경망 (Neural Network)은 McCulloch에 의해 1943년 처음 제안 되었으며 [10], 문자 인식, 화상 처리, 자연 언어 처리, 음성 인식 등의 분야에서 활용되고 있다. LeCun, Yann [11]은 1998년 합성곱 신경망 (Convolutional Neural Network)을 통해 필기체 문자 인식에 대한 학습 시간을 크게 줄이면서도 높은 인식률을 보였다.

최근 이미지 데이터베이스 자원인 ImageNet은 매년 ILSVRC (ImageNet Large Scale Visual Recognition Challenge) 비주얼 인식 대회를 개최 하는데 Krizhevsky, Alex [12]이 합성곱 신경망을 활용하면서 2012년 이미지 분류 분야에서 다른 기계 학습 알고리즘에 비해 정확도를 크게 높인 후 합성곱 신경망 학습이 영상 처리 분야에서 활발히 연구 되고 있다.

본 논문에서는 카메라 센서를 이용하여 대향차량의 전조등과 선형차량의 후미등을 검출하기 위해 합성곱 신경망을 활용하는 야간 차량 검출 방법을 제안한다. 제안된 방법의 실효성을 입증하기 위해 야간 환경에서 획득한 주행 영상을 이용하여 시물레이션을 수행하고, 그 결과를 기존의 다중-클래스 기반 SVM 방법과 성능을 비교 분석 한다.

II. 야간 차량 검출 시스템

본 논문에서 제안하는 야간 차량 검출 시스템은 그림 1과 같이 각 화소의 밝기값을 기준으로 하는 이진화 (thresholding)과정 및 라벨링 (Labelling) 과정을 거쳐 차량의 전조등 및 후미등 후보 영역을




그림 1. 제안된 야간차량 검출 방법의 순서도
Fig. 1 Block diagram of the proposed night-time vehicle detection method

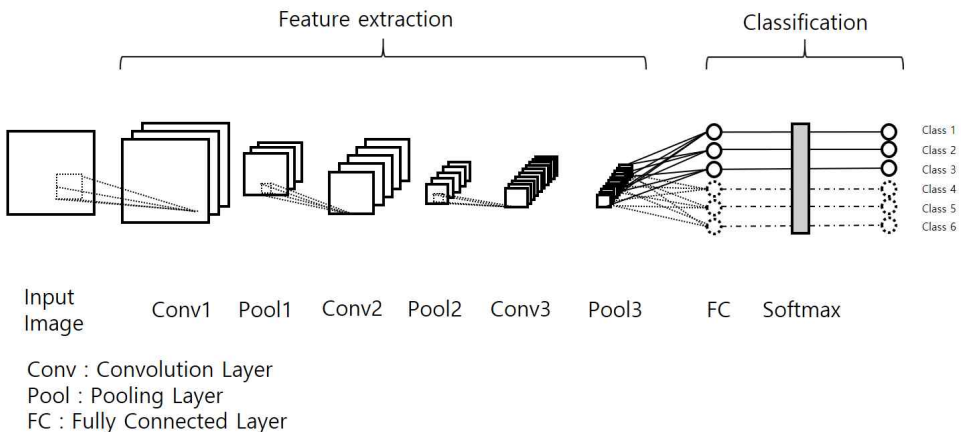


그림 2. CIFAR-10 모델 기반 야간차량 검출 분류기 구조
Fig. 2 Architecture of CIFAR-10 model based night-time vehicle classification

추출하고, 추출된 후보 영역을 합성곱 신경망기반 분류기 (classification)에 입력하여 해당 후보영역이 전조등 (또는 후미등)인지 차량 인지를 판별하는 과정으로 구성된다. 일반적으로 합성곱 신경망을 이용한 물체 인식에서는 입력영상으로 부터 검출/인식 하고자하는 대상 물체의 후보 영역을 추출하기 위한 방법으로 Selective Search나 Edge box와 같은 전처리 방법을 활용하거나 [13] RPN (Region Proposal Network) 와 같이 신경망 내에서 물체의 후보영역을 추론하는 방법이 사용되고 있다 [14]. 제안 방법에서는 후보영역 추출을 위해 이진화와 라벨링을 사용하는데 이는 야간 환경에서 빠르고 효과적으로 차량 후보 영역의 추출이 가능하기 때문이다. 전조등이나 후미등이 아닌 후보 영역이 생성되지만 합성곱 신경망의 성능에 따라 효과적으로 분류 가능하다. 카메라로부터 입력된 R, G, B 형식의 컬러 영상으로부터 Y, Cb, Cr 형식으로 변환 후 Y 영상의 밝기값을 기준으로 미리 정해진 문턱값 (threshold value)를 이용하여 이진화 하며 이진 영상으로부터 8-방향 탐색 기반 라벨링 기법을 사용하여 후보영역을 검출한다. 위 방법을 통해 전조등의 경우 약 800m, 후미등의 경우 브레이크등이 켜져 있을 때 약 400m, 켜져 있지 않은 경우 약 250m 전방의 후미등을 후보영역으로 추출할 수 있다. 이를 초과할 경우 전조등 및 후미등의 문턱값을 초과하지 못하여 후보 영역으로 구분되지 않는다.

Ada-boost와 SVM 등을 분류기로 사용하는 경우 후보영역으로부터 기하학적 또는 통계적인 특징을 추출하여 분류기의 입력으로 사용하게 되지만, 합성곱 신경망을 사용하는 경우에는 별도의 특징추출 (feature extraction) 과정이 필요하지 않다. 제안된 방법에서도 이러한 특징추출 단을 별도로 사용하지 않고 후보영역의 영상데이터 자체가 합성곱 신경망에 입력되어 분류된다.

합성곱 신경망 분류를 위해서는 기존의 CIFAR-10 [15] 모델을 사용한다. 이 모델은 Krizhevsky, Alex가 2010년 제안한 모델로 이미지를 총 10개의 클래스로 분류하는 모델이다. 이 모델의 구조는 그림 2에서 보는 바와 같이 총 3개의 합성곱 신경망 층, 3개의 ReLU (Rectifier Linear Unit) 활성화함수 층, 3개의 풀링 (Pooling) 층, 2개의 정규화 (Local Response Normalization) 층, 하나의 내적 (Inner Product) 층, 그리고 하나의 소프트맥스 (Softmax) 층의 구조로 이루어진다. 본문에서는 야간 차량 검출에 적합하도록 후보 영역



그림 3. 첫 번째 합성곱 층 가중치 필터
Fig. 3 Weight filters of the first convolution layer




그림 4. 첫 번째 합성곱 층 결과 영상의 예
Fig. 4 Examples of result in the first convolution layer




그림 5. 첫 번째 풀링 단의 결과 영상 예
Fig. 5 Examples of the result image in the first pooling layer

영상의 크기를 32x32로 고정하여 사용하였으며, 출력단의 클래스의 개수를 3개 또는 6개로 변경하여




그림 6. 첫 번째 풀링 단의 정규화된 결과 영상 예

Fig. 6 Examples of the normalized result image in the first pooling layer

구성하였다. 합성곱 신경망 층에서 사용되는 가중치 (Weight) 필터는 5x5 크기로 첫 번째 및 두 번째 층은 각각 32개로 구성되어 있으며, 세 번째 층은 64개로 구성되어 있다. 각 필터의 가중치 초기값은 가우시안 분포에 따라 무작위로 생성한다. 필터의 가중치는 역전파 (Back Propagation) 알고리즘에 의해 학습된다. 그림 3은 이렇게 학습된 첫 번째 합성곱 신경망 층의 32개 필터의 가중치를 영상으로 도식화하여 나타내었으며, 그림 4는 임의의 입력 후보 영역 영상에 대하여 합성곱 연산 결과를 보인 것이다.

합성곱 연산과정에서 입력 영상의 각 테두리 부분의 합성곱 결과는 Zero Padding 함으로써 결과 영상의 크기가 입력영상의 크기와 동일하도록 한다. 합성곱 연산 결과 값 x 에 대해 ReLU 활성화함수를 아래 식 (1)과 같이 적용하였다.

$$f(x) = \max(0, x) \tag{1}$$

풀링 단계에서는 3x3 크기의 커널을 이용하여 커널내의 값들 중 가장 큰 값을 선택하는 맥스 풀링 (Max Pooling)방법과 커널내의 값들의 평균값으로 정하는 평균 풀링 (Average Pooling) 방법을 이용한다. 첫 번째 풀링 층에서는 맥스 풀링 방법을 이후두번째 및 세 번째 풀링 단계에서는 평균 풀링을 적용한다. 오버래핑 풀링 (Overlapping Pooling) 방법을 사용하며 두 픽셀만큼 이동하여 적용한다. 그림 5는 첫 번째 풀링단의 결과 영상을 보인 것으로 16x16 크기의 총 32개 영상이 생성된다. 풀링단의 결과 영상은 결과 값의 범위가 너무 커지지 않도록




그림 7. 학습에 사용된 여섯 가지 클래스별 영상의 예

Fig. 7 Example image of six different classes for Training

정규화 한다. 그림 5와 6은 첫 번째 풀링 단의 결과 영상을 나타낸 것으로, 그림 5는 정규화 이전이며 그림 6은 정규화된 결과 영상이다.

이와 같은 합성곱 연산과 풀링은 세 번 반복하여 적용되며 그 결과는 완전-연결 층 (fully-connected layer)에 연결되어 실질적인 분류작업이 수행된다. 분류하고자하는 클래스 개수만큼의 뉴런 (neuron)이 출력 단을 구성하고 하나의 뉴런이 하나의 클래스에 대한 확률로 나타낼 수 있도록 소프트맥스 함수를 적용한다. 출력 단의 뉴런은 해당 클래스의 분류 결과를 0~1 사이의 확률로 나타내며 가장 높은 확률을 갖는 클래스로 분류된다.

III. 실험 및 결과

본 논문에서는 그림 7과 같이 전조등, 후미등, 반사체, 가로등, 신호등, 기타 총 6개의 클래스로 구분한 데이터 베이스를 이용하여 학습하는 경우와 반사체, 가로등, 신호등, 기타를 모두 기타 클래스로 분류하여 전조등, 후미등, 기타 3개의 클래스로 구분한 데이터 베이스를 이용하는 경우로 나누어 제안된 알고리즘을 적용한다. 전조등을 제외 한 각 클래스는 총 1만개의 데이터를 사용했으며, 전조등의 경우 총 4400개의 데이터를 바탕으로 학습에 사용된 데이터와 검증에 사용한 데이터는 1:1 비율로 무작위 선택하였다. 데이터 베이스로 부터 100개의 데이터를 무작위로 선택하여 구성된 집단 (Batch)을 학습 및 검증에 적용하며 이 과정을 검증 데이터 베이스를 모두 적용 될 때 까지 반복하여 학습한다. 이때 이러한 반복 학습하는 과정을 세대 (Epoch)라고 하며, 최적의 분류 성능을 갖는 모델을 찾을 때까지 세대를 증가 시키면서 반복 학습한다.

그림 8은 총 200 세대 (Epoch)까지 증가시키면서 반복 학습한 모델의 분류 성능을 나타낸 것이다.


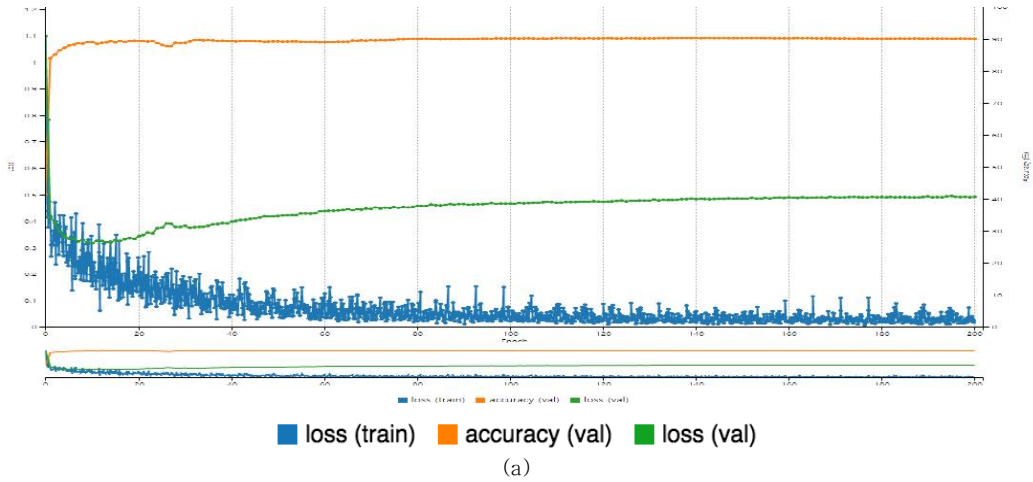


그림 8. (a) 6 개 클래스로 분류하는 경우, (b) 3 개 클래스로 분류하는 경우, 세대 증가에 따른 분류 성능 (분류 정확도, 검증 손실, 학습 손실)

Fig. 8 For the case of (a) six classes, classification performances(accuracy, validation loss, training loss) according to the number of epochs

그림에서 가장 위의 주황색 그래프는 분류 정확도 (Accuracy), 가운데의 녹색 그래프가 검증 손실 (Loss) 그리고 아래의 파란색 그래프는 학습 손실을 나타낸다. 손실은 모델의 에러에 대한 지표 값으로 작을수록 정확하게 분류된다는 것을 뜻한다. 학습 손실은 세대 반복 학습에 따라 계속 줄어들지만, 검증 손실은 일정 회수 세대만큼의 반복 학습 이후 오히려 증가한다. 이는 과적합 (Overfitting)이 발생한 것으로 본 실험에서는 6개 클래스로 분류 학습한 경우 8번째 세대, 3개의 클래스로 분류 경우 10 번째 세대의 모델을 분류 모델로 사용 하였다. 학습에 사용된 학습율 (learning rate)은 0.001, 지수감

소 (exponentially decay)는 0.95로 설정 하였다.

검출 성능 측정을 위한 척도로는 아래의 식 (2), (3), (4)와 같이 accuracy, precision 과 recall을 사용한다.

$$accuracy = \frac{TP+TN}{TP+TN+FN+FP} \times 100 \quad (2)$$

$$precision = \frac{TP}{TP+FP} \times 100 \quad (3)$$

$$recall = \frac{TP}{TP+FN} \times 100 \quad (4)$$

표 1. 다중-클래스 SVM 및 제안 방법 (6 클래스 및 3 클래스)의 검출 성능 평가

Table 1. Detection performance evaluation of multi-class SVM and the proposed methods with 6 classes and 3 classes

(%)				
Method	Object	Accuracy	Precision	Recall
multi-SVM	Head	89.61	47.23	90.78
	Tail	93.97	73.89	97.98
CNN C6	Head	96.33	84.20	72.32
	Tail	94.07	74.83	99.18
CNN C3	Head	94.58	64.78	85.89
	Tail	94.11	75.12	98.81

제안 방법의 성능을 비교 평가하기 위해 전조등, 후미등, 도로 반사체, 가로등, 신호등, 기타 잡음의 6개의 클래스로 학습하는 다중-클래스 기반 SVM 방법 [7]을 구현하였다.

표 1은 야간 환경에서 획득한 주행 영상의 Ground Truth 데이터를 바탕으로 검출 성능을 측정 한 결과이다. Ground Truth는 20 프레임당 하나의 프레임에 대한 전조등 및 후미등의 위치와 후보 영역의 결과를 비교하여 성능을 평가한다. Ground Truth 데이터는 다중-클래스 기반 SVM, 제안된 6개 클래스 분류 합성곱 신경망 (CNN C6), 3개 클래스 분류 합성곱 신경망 (CNN C3)의 전조등 및 후미등의 검출 성능을 비교 하였다.

제안된 합성곱 신경망 분류기의 성능이 다중-클래스 기반 SVM 방법에 비해 accuracy 측면에서는 다소 우수한 결과를 나타내었다. 특히 후미등의 경우 precision과 recall 측면에서 모두 우수한 성능을 보였다. 그러나 전조등의 경우 recall 측면에서는 다소 부족함을 보였다.

IV. 결론

본 논문에서는 지능형 전조등 제어시스템에 적용할 수 있는 합성곱 신경망기반 야간 차량 전조등 및 후미등 검출 방법을 제안 하였다. 야간 도로 주행 영상에 적용한 실험을 통해 제안된 합성곱 신경망 기반 방법이 기존의 다중-클래스 기반 SVM 방법과 유사한 검출 성능을 보임으로써 합성곱 신경망 학습 방법이 야간 차량 검출에 적용 가능함을 확인 하였다. 향후 우수한 성능의 심층 신경망을 적용하고 객체 추적 및 전조등 및 후미등의 페어링 과정을 추가하여 보다 강인한 야간 환경 차량 검출

시스템의 개발이 기대된다.

Reference

- [1] J. Rebut, B. Bradai, J. Moizard, A. Charpentierhi, "A Monocular Vision Based Advanced Lighting Automation System for Driving Assistance," Proceedings of IEEE International Symposium on Industrial Electronics, pp. 311-316, 2009.
- [2] Mobileye, Adaptive Headlight Control, Available: <http://www.mobileye-vision.com>, <http://www.mobileye.com/technology/applications/head-lamp-control>.
- [3] G. Elger, B. Spinger, N. Bienen, N. Benter, "LED Matrix Light Source for Adaptive Driving Beam Applications," Proceedings of IEEE Electronic Components and Technology Conference, pp. 535-540, 2013.
- [4] M. Dassanayake, R. Miller, S. Abdelnour, M. S. Wrobel Jr, J. Shannon, "Adaptive Front Lighting System for a Vehicle," U.S. Patent No. 7,540,638, 2009.
- [5] P.F. Alcantarilla, L.M. Bergasa, P.Jimenez, M.A. Sotelo, I. Parra, D. Fernandez, "Night Time Vehicle Detection for Driving Assistance Light Beam Controller," Proceedings of IEEE Intelligent Vehicles Symposium, pp. 291-296, 2008.
- [6] V.B. Sutar1, L.S. Admuthé, "Night Time Vehicle Detection and Classification Using Support Vector Machine," IOSR Journal of VLSI and Signal Processing, Vol. 1, No. 4, pp. 1-9, 2012.
- [7] H. Lim, H. Lee, J.H. Park, H. Jung, "Night-time Vehicle Detection Based on Multi-class SVM," IEMEK J. Embed. Sys. Appl., Vol. 10, No. 5, 2015 (in Korean).
- [8] H. Wang, Y. Cai, X. Chen, L. Chen, "Night-Time Vehicle Sensing in far Infrared Image With Deep Learning," Journal of Sensors, 2016.
- [9] M. Szarvas, U. Sakai, J. Ogata, "Real-time Pedestrian Detection Using LIDAR and Convolutional Neural Networks," Proceedings

- of IEEE Intelligent Vehicles Symposium. 2006.
- [10] W. S. McCulloch, W. Pitts, "A Logical Calculus of the Ideas Immanent in Nervous Activity," The bulletin of mathematical biophysics Vol. 5, No. 4, pp. 115-133, 1943.
- [11] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based Learning Applied to Document Recognition," Proceedings of the IEEE Vol. 86, No. 11, pp. 2278-2324, 1998.
- [12] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks," Advances in neural information processing systems, pp. 1097-1105, 2012.
- [13] R. Girshick, J. Donahue, T. Darrell, J. Malik, "Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation," Proceedings of IEEE conference on computer vision and pattern recognition pp. 580-587.
- [14] S. Ren, K. He, R. Girshick, J. Sun, "Faster r-cnn: Towards Real-time Object Detection With Region Proposal Networks," In Advances in neural information processing systems, pp. 91-99, 2015.
- [15] A. Krizhevsky, G. Hinton. "Convolutional Deep Belief Networks on cifar-10," Unpublished manuscript 40, 2010.


Woong-Kyu Park (박 옹 규)



He received M.S. degree in department of information and communication engineering from Yeungnam University, Korea, in 2014. He is a researcher in Wi-Media Regional Innovation Center, Yeungnam university. His research interests Data structure, Non-volatile Memory, intelligent vehicle and Image processing.

Email: pwkyu@ynu.ac.kr

Yeongyu Choi (최연규)



He is received B.E. degree in department of electronic engineering from Kumoh national institute of technology, Republic of Korea, in 2015. He is currently a master candidate in department of information and communication engineering, Yeungnam University. His interests include intelligent vehicle and image processing.

Email: ygchoi1111@gmail.com

Hyun-Koo KIM (김현구)



He is Ph.D. Candidate in department of information and communication engineering from Yeungnam University, Korea, in 2013.

Currently, He is a senior researcher in Gyeongbuk Institute of IT Convergence Industry Technology. His research interests seonsor fusion based advanced driving asistant system, deep learning, self driving car systems and signal processing.

Email: hkkim@gitc.or.kr

Gyu Sang Choi (최 규 상)

He received Ph.D. degree in department of computer engineering from Pennsylvania State University, in 2005.

Currently, he is a professor in the department of information and communication engineering from Yeungnam University, Korea. His research interests Non-volatile memory, Operating system, Storage system, intelligent vehicles, and nonlinear systems.

Email: castchoi@ynu.ac.kr

Ho-Youl Jung (정 호 열)

He is received the Ph.D. degree in Electronics Engineering from the Institut National des Sciences Appliquées de Lyon (INSA de Lyon), France,

in 1988. He is currently a Professor in the Department of Information and Communications Engineering, Yeungnam University, Korea. Both teaching and research interests include digital signal/image processing, intelligent vehicles, and nonlinear systems.

Email: hoyoul@yu.ac.kr