

# 도로 CCTV 데이터를 활용한 딥러닝 기반 차량 이상 감지

신동훈<sup>1</sup>, 백지원<sup>1</sup>, 박찬홍<sup>2</sup>, 정경용<sup>3\*</sup>

<sup>1</sup>경기대학교 컴퓨터과학과 학생, <sup>2</sup>상지대학교 정보통신소프트웨어공학과 교수, <sup>3</sup>경기대학교 컴퓨터공학부 교수

## Deep Learning-based Vehicle Anomaly Detection using Road CCTV Data

Dong-Hoon Shin<sup>1</sup>, Ji-Won Baek<sup>1</sup>, Roy C. Park<sup>2</sup>, Kyungyong Chung<sup>3\*</sup>

<sup>1</sup>Student, Data Mining Lab., Department of Computer Science, Kyonggi University,

<sup>2</sup>Professor, Department of Information and Communication Software Engineering, Sangji University,

<sup>3</sup>Professor, Division of Computer Science and Engineering, Kyonggi University

**요약** 현대사회에서는 차량을 소유하는 사람들이 증가하면서 교통문제가 발생하고 있다. 특히 고속도로 교통사고 문제는 발생률이 낮지만 치사율은 높다. 따라서 차량의 이상을 탐지하는 기술이 연구되고 있다. 이 중에는 딥러닝을 이용한 차량 이상탐지 기술이 있다. 이는 사고 및 엔진고장으로 인한 정차차량 등의 차량 이상을 탐지한다. 그러나 도로에서 이상이 발생할 경우 운전자의 위치를 파악할 수 있어야 빠른 대처가 가능하다. 따라서 본 연구에서는 도로 CCTV 데이터를 활용한 딥러닝 기반 차량 이상 감지 방법을 제안한다. 제안하는 방법은 먼저 도로 CCTV 데이터를 전처리한다. 전처리는 배경 추출 알고리즘인 MOG2를 이용하여 배경과 전경을 분리한다. 전경은 변위가 존재하는 차량을 의미하며 도로 위에서 이상이 존재하는 차는 변위가 없어 배경으로 판단된다. 배경이 추출된 이미지는 이상을 탐지하기 위해 YOLOv4를 이용하여 객체를 탐지한다. 해당 차량은 이상이 있으므로 판단한다.

**주제어** : 도로 교통, 딥러닝, 객체탐지, 이상탐지, 도로 CCTV 데이터, 배경 추출

**Abstract** In the modern society, traffic problems are occurring as vehicle ownership increases. In particular, the incidence of highway traffic accidents is low, but the fatality rate is high. Therefore, a technology for detecting an abnormality in a vehicle is being studied. Among them, there is a vehicle anomaly detection technology using deep learning. This detects vehicle abnormalities such as a stopped vehicle due to an accident or engine failure. However, if an abnormality occurs on the road, it is possible to quickly respond to the driver's location. In this study, we propose a deep learning-based vehicle anomaly detection using road CCTV data. The proposed method preprocesses the road CCTV data. The pre-processing uses the background extraction algorithm MOG2 to separate the background and the foreground. The foreground refers to a vehicle with displacement, and a vehicle with an abnormality on the road is judged as a background because there is no displacement. The image that the background is extracted detects an object using YOLOv4. It is determined that the vehicle is abnormal.

**Key Words** : Road Traffic, Deep Learning, Object Detection, Anomaly Detection, CCTV, Extraction

\*This work is supported by the Korea Agency for Infrastructure Technology Advancement (KAIA) grant funded by the Ministry of Land, Infrastructure and Transport (Grant 21CTAP-C157011-02).

\*Corresponding Author : Kyungyong Chung(draginchi@gmail.com)

Received September 11, 2020

Accepted February 20, 2021

Revised October 8, 2020

Published February 28, 2021

## 1. 서론

4차 산업혁명 시대에는 인공지능과 교통수단의 발달하고 있다. 이는 원활한 이동과 편리한 공간, 안전한 주행을 목적으로 하고 있다. 또한 자동차의 역할은 단순운송수단이 아닌 생활공간으로 바뀌고, 편의의 새로운 가치를 제공하는 인포테인먼트 형태로 변화하고 있다. 하지만 지속적인 노력에도 불구하고 교통사고는 지속적으로 증가한다. 이 중 고속도로 교통사고는 전체 발생량 중에 2%에 불과하지만 사망은 전체 6%에 부상도 3%에 달한다. 사고 건수는 적지만 사고발생시 심각한 사고로 이어진다. 또한 정지된 차는 도로 정체나 2차 사고의 원인이 된다. 이와 같이 교통사고는 빠른 인지와 대처 및 대응방안이 필요하다.

최근 딥러닝을 이용하여 교통부분에서 교통량, 자율주행 차량제어, 신호제어 등 많은 분야에서 사용한다[1,2]. 딥러닝을 통한 예측 및 탐지는 지도학습과 비지도학습을 통한 모델을 구성된다. 하지만 현실에서는 정상적인 도로 영상 데이터보다 이상을 나타내는 사고 데이터가 현저히 적다. 따라서 지도학습을 위한 데이터가 불충분하고 불균형의 문제가 있다. 이에 본 연구에서는 비지도학습 기반의 이상치 탐지 방법을 통해 데이터 불충분 문제와 균형적 문제점을 해결한다. 또한 기존의 딥러닝을 이용한 사고 위험성 연구는 통계적인 수를 기반으로 하여 직관적이지 않으며 결과는 설명하기 힘든 경우가 많다.

본 연구에서는 딥러닝 기반 객체 탐지 모델인 YOLOv4를 통해 도로위의 차량 이상 감지를 제안한다. 이는 차량 파손 및 교통사고 발생 시 차량이 정지해 있다는 전제를 둔다. 배경 추출 알고리즘인 MOG2를 이용하여 배경과 전경을 분리한다. 배경에는 변위가 없는 객체들만 남는다. 정지된 차량 또한 변위가 없기 때문에 배경에 남게 된다. 추출된 배경을 통해 객체 탐지를 진행하게 된다. 이를 기반으로 CCTV 영상을 통해 도출된 이상 감지를 운전자 및 사고 관리자에게 제공함으로써 2차사고 예방과 빠른 후속조치가 가능하게 된다.

## 2. 관련연구

### 2.1 도로 교통에서 이상탐지 연구 동향

이상탐지(Anomaly Detection)는 데이터에서 예상과 다른 패턴을 나타내는 개체 및 이상 값을 찾는 방법이다[3,4]. 이상탐지는 다양한 분야에서 활용되고 있기 때문

에 목적에 맞게 이상에 대한 정의가 필요하다.

차량 이상탐지에서의 이상은 램프 고장, 엔진고장 등의 차량 고장을 의미한다. 이는 심각한 교통사고의 원인이 되기 때문에 주행 전후 또는 주행 중 운전자와 동승자, 보행자의 안전을 위해 국내외에서 차량 이상탐지에 대한 연구를 활발하게 진행하고 있다. 예를 들어, 현대자동차는 엔진의 진동을 감지하여 차량의 이상을 진단하는 KSDS (Knock Sensor Detection System)을 개발하였다 [4]. 이는 차량에 내재된 진동감지 센서를 통해 주행 중 엔진에서 발생하는 진동신호를 실시간으로 모니터링하고, 이상 진동 신호를 감지한다. 이는 소리의 특성을 이용하여 탐지하는 방법이다. 소리는 각각의 특성을 가지고 있기 때문에 파장과 진폭의 차이가 있다. 따라서 엔진의 소리 데이터를 수집하여 유형별로 특성을 분석한다. 이에 따라 소리의 특정 벡터를 추출하며 고장 부위에서 나는 소리를 인공지능 모델이 반복학습을 진행하여 고장원인을 파악한다. 이에 따라 자동차 정비사는 시간을 절약하며 자동차를 수리할 수 있다. 또한 엔진경고 등을 통해 운전자에게 차량 고장에 대한 정보를 제공함으로써 안전하게 주행할 수 있도록 한다[5]. Fig. 1은 빅데이터에서 이상탐지 프로세스를 나타낸다.

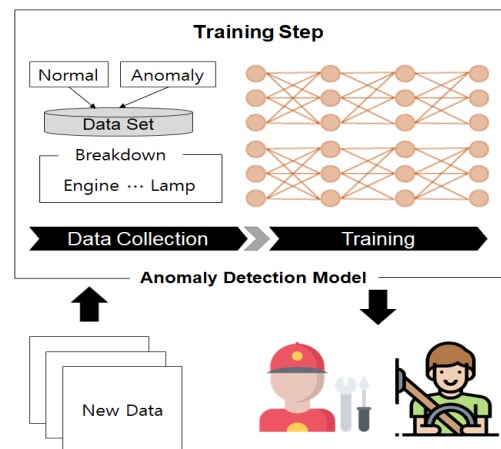


Fig. 1. Anomaly Detection Process in Bigdata

### 2.2 딥러닝 기반 객체탐지

딥러닝이 발전하면서 영상, 이미지 등을 이용한 시각 데이터에서 객체인식 및 탐지 기술에 대한 연구가 활발히 진행되고 있다. 이를 위해 CNN을 기반으로 이미지 분류, 객체탐지, 이미지 생성 등이 가능하다. CNN은 Convolution 연산을 적용하여 모델의 복잡도를 감소시

키고 유의미한 특징을 추출한다[6]. 또한 객체탐지(Object Detection)는 특정 대상을 인식하기 위해 탐지 대상에 대한 후보 영역을 발견하고, 객체의 종류 및 위치를 예측한다. CNN 기반의 객체 탐지를 위한 알고리즘은 R-CNN, Fast-R-CNN, Faster-R-CNN, YOLO 등이 있다.

R-CNN은 3단계로 구분되어 객체를 탐지한다. 첫 번째 단계는 Region proposal 단계이다. 이는 대상의 클래스를 구분하지 않고 이미지에서 region을 추출하는 과정이다. 두 번째 단계는 특징벡터를 추출하는 단계이다. 이는 region proposal 영역을 원본 이미지에서 제거하고 동일한 크기로 생성 후 CNN을 이용하여 특징을 추출한다. 마지막 단계에서는 특징에 대해 분류를 수행한다. R-CNN은 이미지 데이터 1개당 region proposal 영역의 개수만큼 CNN 연산을 수행하기 때문에 속도가 매우 느리고 복잡도가 높은 단점이 있다[7]. Fast R-CNN은 R-CNN의 속도 문제를 개선한 방법이다. 이는 Rol Pooling 방법을 사용한다. Rol Pooling은 모든 region proposal 영역마다 컨볼루션 연산을 진행하는 대신 입력 이미지에 한번만 컨볼루션을 적용하고 Rol Pooling으로 객체를 판별하기 위해 특징을 추출한다. 따라서 Fast-R-CNN은 입력 이미지에 한번만 연산된 특징과 Rol Pooling을 적용시켜 특징을 찾는 방법이다[8]. Faster R-CNN은 컨볼루션 내부에 Region Proposal을 생성할 수 있는 네트워크를 설계하여 소요시간을 개선하고, 정확한 region proposal을 직접 생성할 수 있다.

Faster-R-CNN은 Fast-R-CNN에 Region Proposal을 network에 추가한 알고리즘이다[9]. YOLO는 이미지 데이터의 바운딩 박스와 분류 확률을 단일 회귀 문제로 하여 이미지 데이터를 한번 보는 것으로 객체의 종류와 위치를 예측하는 알고리즘이다. 이는 간단한 처리과정으로 속도가 빠르기 때문에 실시간 시각 데이터를 분석하기에 적합한 알고리즘이다. 또한 데이터를 한번만 학습하여 이미지에 존재하는 객체가 무엇이며, 어디에 위치에 있는지 파악하기 쉽다. YOLO는 객체의 일반적인 특징을 학습하기 때문에 새로운 데이터가 입력되어도 예측이 가능하다[10].

### 3. 도로 CCTV 데이터를 활용한 딥러닝 기반 차량 이상 감지

#### 3.1 데이터 수집 및 전처리

본 연구에서는 도로 교통에서 차량의 이상을 감지하기 위해 Nvidia에서 주최하는 AI CITY CHALLENGE의 데이터를 수집한다[11]. 데이터 셋은 30프레임의 800 X 410 해상도의 약 15분 길이의 영상을 제공한다. 각각 100개의 학습 및 테스트 데이터를 제공하며, 학습 데이터에는 차량 이상의 지점을 영상 내 시간을 통해 주석으로 제공한다. Table 1은 차량 이상 지점 주석을 나타낸다.

Table 1. Vehicle Abnormal Point Annotation

Video ID	Start Timestamp	End Timestamp
2	587	894
9	0	287
11	0	888
14	475	600
33	165	884
35	106	185
49	422	894
...	...	...

Table 1에서 Video\_ID는 비디오 식별 번호이다. Start\_Timestamp는 이상 지점을 나타내는 시작 시간(s)이다. End\_Timestamp는 이상 지점의 종료를 나타내는 시간(s)이다. 예를 들어 식별 번호 2번의 영상의 이상 시작 지점은 9분 47초 지점이며 종료 시간은 14분 54초를 나타낸다. 학습 데이터 100개의 영상 중 이상 지점이 포함된 영상은 21개이다.

#### 3.2 MOG2를 이용한 배경 추출

차량의 이상 감지를 위해 영상의 전경과 배경을 분리한다. 영상에서 전경은 객체가 변위되는 부분이며 배경은 영상에서 변위되지 않는 정적인 부분을 의미한다. 배경 추출을 위해서는 먼저 정적인 배경을 모델링 한다. 배경 모델링은 두 가지 주요 단계로 이루어진다. 첫 번째 단계는 초기 값을 통해 계산을 진행하여 배경을 모델링한다. 두 번째 단계에서는 장면의 변화에 적응하기 위해 모델을 업데이트한다. 배경 추출은 모델링된 배경과 현재 프레임의 영상을 빼서 변위되는 부분인 전경 마스크를 생성한다. 전경 마스크는 영상에서 변위되는 객체에 속하는 픽셀을 포함하는 이진 이미지이다. 생성된 마스크를 통해 현재 프레임의 영상에서 빼주게 되면 배경 추출이 된다. 본 연구에서 배경 추출은 MOG2를 사용한다[12,13]. Fig. 2는 MOG2를 이용한 정지영상에서 추출된 배경을 나타낸다.

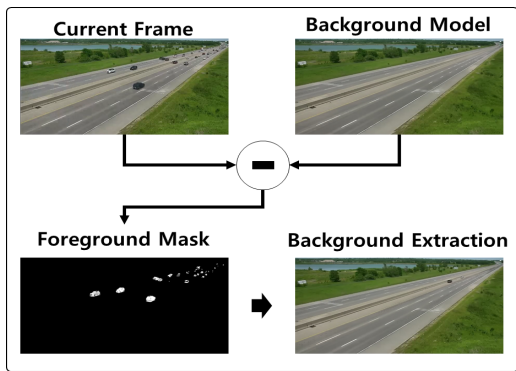


Fig. 2. Background Result Extracted using MOG2

Fig. 2에서 모델링된 배경과 현재 프레임의 이미지를 통해 프레임 별 전경 마스크를 생성한다. 생성된 전경 마스크를 통해 배경을 추출하게 된다. 사고 및 차량 고장의 경우 도로에서 차가 정지된다. 따라서 정지된 차는 배경 추출 시 전경에 해당하지 않으므로 배경으로 유지된다.

### 3.3 딥러닝 기반 차량 이상 감지

MOG2를 통해 추출된 배경에는 사고 및 고장으로 인해 정지된 차량이 포함되어 있다. 본 연구에서는 정지된 차는 사고나 차량 고장이라는 전제를 두기 때문에 추출된 배경에 남아있는 차량을 탐지하면 된다. 따라서 이를 탐지하기 위해 딥러닝 기반의 객체 탐지 모델인 YOLOv4를 사용한다[14]. YOLOv4는 기존의 딥러닝 기반 객체 탐지 모델보다 높은 FPS와 작은 mini-batch-size를 통해 적은 GPU를 통해 사용이 가능하다. 이는 높은 FPS를 통해 실시간 탐지를 가능하게 하며 적은 컴퓨팅 파워 사용으로 비용적인 부분을 감소가 가능하다. 본 연구에서는 COCO 데이터 셋[5]을 통해 사전 학습된 가중치를 사용한다. COCO 데이터 셋은 80개의 객체로 구성된 데이터이며 차량과 관련된 5(오토바이, 승용차, 자전거, 버스, 트럭)개의 객체가 포함되어 있다. 따라서 도로 위의 차량과 관련된 객체를 탐지 가능하다. Fig. 3은 사고나 차량 고장으로 인해 정지된 이상을 탐지한 결과를 나타낸다. 첫 번째 그림은 배경 추출을 통해 사고나 차량 고장으로 인해 정지된 차량을 나타낸다. 두 번째 그림은 정지된 차량을 YOLOv4를 통해 이상을 탐지한 결과를 나타낸다. 파란색 테두리는 올바르게 탐지된 결과를 나타내지만 빨간색 테두리는 도로 밖의 차량이 주차되어 있는 경우로 오탐된 결과를 나타낸다.




Fig. 3. Result of Detecting Stopped Anomaly

## 4. 결과 및 성능 평가

제안하는 도로 CCTV 데이터를 활용한 딥러닝 기반 차량 이상 감지는 두 가지 성능평가를 진행한다. 정확도 평가는 차량 이상 지점 주석을 이용한다. 이상 감지는 이진 분류를 통해 진행된다. 객체 탐지 모델을 통해 차량이 감지되면 이상, 감지되지 않으면 정상으로 판단한다. 초단위로 정상, 이상을 탐지 할 때 초단위로 주석과 비교하여 성능을 평가하기 위해 사용되는 지표인 혼동 행렬을 생성한다. 첫 번째 성능평가는 Accuracy를 통한 이상 탐지의 정확도를 평가한다. 식(1)은 Accuracy의 수식을 나타낸다.

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

식(1)에서 TP는 True Positive, TN은 True Negative, FP는 False Positive, FN은 False Negative를 의미한다. Fig. 4는 이상 탐지 정확도 결과를 나타낸다.




Fig. 4. Anomaly Detection Accuracy Result

Fig. 4에서 INDEX는 데이터의 식별 번호를 나타낸다. 정확도의 평균은 82.4%로 높은 수치를 나타낸다. 하지만 Accuracy는 데이터가 불균형하여 각 클래스별 입력이 다른 경우 데이터 편중 문제로 인해 성능에 문제가 생길 수 있는 한계점이 있다. 이를 해결할 수 있는 F1-score를 함께 사용한다. 두 번 번째 성능 평가는 F1-score를 통한 제안한 방법의 이상 탐지의 정확도를 평가한다. 식(2)는 F1-score를 구하는 수식을 나타낸다.

$$F1 - score = 2 * \frac{precision * recall}{precision + recall} \quad (2)$$

$$Precision = \frac{TP}{TP + FP}, Recall = \frac{TP}{TP + FN} \quad (3)$$

식(2)의 F1-score는 정밀도와 재현율의 Trade-off를 적절하게 반영하여 정확성을 나타내는 지표로 사용한다. 또한 식(2)에서 정밀도와 재현율은 식(3)으로 표현 가능하다. 정밀도와 정확도의 차이는 정확도는 참값에 근접한 정도를 나타내는 지표이지만 정밀도는 측정값들의 분포의 정도를 나타낸다[15]. Table 2는 F1-score를 통한 탐지 결과를 나타낸다.

Table 2. Result of Detection using F1-score

Index	Precision	Recall	F1 Score
1	80.2	78.6	79.4
2	72.5	72.1	72.3
...	...	...	...
100	73.8	76.4	75.1
Mean	81.4	79.6	80.5

Table 2에서 Index는 영상의 ID 번호이며 영상 별로 각각의 F1-score를 구하고 평균을 구하여 성능을 나타낸다. 전체 평균을 결과는 Precision은 81.4이며 Recall은 79.6으로 F1-score는 80.5로 신뢰 가능한 결과를 나타낸다. 하지만 도로 위가 아닌 도로 밖이나 갓길에 주차된 차량을 탐지한 경우가 있어 성능에 영향을 미친다.

### 5. 결론

본 연구에서는 도로 CCTV 데이터를 활용한 딥러닝 기반 차량 이상 감지를 제안하였다. 도로 위의 차량의 이상을 감지하기 위해서는 차량 파손이나 사고로 인한 정

지된 차량이라는 전제가 필요하다. 배경 추출 알고리즘인 MOG2를 이용하여 변위가 진행되는 차량을 제외하고 정지된 차량을 배경에 남게 한다. 딥러닝 기반의 객체탐지 기술인 YOLOv4를 통해 차량을 감지하고 이상이라고 판단한다. 제안하는 방법에 대한 성능평가를 진행한 결과 Accuracy는 82.5%이며 F1-score는 80.5로 신뢰가 가능한 성능을 보였다. 따라서 도로에서 정지된 차량으로 인한 2차 사고나 빠른 사고 조치를 위해 사용이 가능하다. 향후 연구에는 도로 세그멘테이션을 통해 갓길이나 도로 밖에 주차된 차량을 제거하여 잘못 탐지될 경우를 방지하여 성능 향상을 도모할 계획이다.

### REFERENCES

- [1] D. H. Shin, R. C. Park & K. Chung. (2020). Prediction of Traffic Congestion Based on LSTM Through Correction of Missing Temporal and Spatial Data, *IEEE Access*, 8, 150784-150796. DOI : 10.1109/access.2020.3016469
- [2] C. M. Kim, E. J. Hong, K. Chung & R. C. Park. (2020). Driver Facial Expression Analysis Using LFA-CRNN-Based Feature Extraction for Health-Risk Decisions, *Applied Sciences*, 10(8), 2956. DOI : 10.3390/app10082956
- [3] D. H. Shin, R. C. Park & K. Chung (2020) Decision Boundary-Based Anomaly Detection Model Using Improved AnoGAN From ECG Data, *IEEE Access*, 8, 108664-108674. DOI : 10.1109/access.2020.3000638
- [4] HYUNDAI Tech, <https://tech.hyundaimotorgroup.com/>
- [5] T. Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona & D. Ramanan. (2014). Microsoft coco: Common objects in context, *In European conference on computer vision*, 740-755. DOI : 10.1007/978-3-319-10602-1\_48
- [6] S. S. Park, J. W. Baek, S. M. Jo & K. Chung. (2019). Motion Monitoring using Mask R-CNN for Articulation Disease Management, *Journal of the Korea Convergence Society*, 10(3), 1-6. DOI : 10.15207/JKCS.2019.10.3.001
- [7] C. Ma, L. Chen & J. Yong. (2019). AU R-CNN: Encoding expert prior knowledge into R-CNN for action unit detection, *Neurocomputing*, 355, 35-47. DOI : 10.1016/j.neucom.2019.03.082
- [8] J. Li, X. Liang, S. Shen, T. Xu, J. Feng & S. Yan. (2017). Scale-aware fast R-CNN for pedestrian detection, *IEEE transactions on Multimedia*, 20(4), 985-996. DOI : 10.1109/tmm.2017.2759508

[9] X. Lei & Z. Sui. (2019). Intelligent fault detection of high voltage line based on the Faster R-CNN, *Measurement*, 138, 379-385.  
DOI : 10.1016/j.measurement.2019.01.072

[10] Y. Jamtsho, P. Riyamongkol & R. Waranusast (2020) Real-time Bhutanese license plate localization using YOLO, *ICT Express*, 6(2), 121-124.  
DOI : 10.1016/j.icte.2019.11.001

[11] Z. Tang, M. Naphade, M-Y Liu, X. Yang, S. Birchfield, S. Wang, R. Kumar & D. Anastasiu, J. N. Hwang (2019) Cityflow: A city-scale benchmark for multi-target multi-camera vehicle tracking and re-identification, *CVPR*, 8797-8806.  
DOI : 10.1109/cvpr.2019.00900

[12] Z. Zivkovic. (2004). Improved adaptive Gaussian mixture model for background subtraction, In Proc of the 17th International Conference on Pattern Recognition, *ICPR*, 2, 28-31.  
DOI : 10.1109/icpr.2004.1333992

[13] Z. Zivkovic & F. van der Heijden. (2006) Efficient adaptive density estimation per image pixel for the task of background subtraction, *Pattern Recognition Letters*, 27(7), 773-780.  
DOI : 10.1016/j.patrec.2005.11.005

[14] A. Bochkovskiy, C. Y. Wang & H. Y. M. Liao. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection, *arXiv preprint arXiv:2004.10934*.

[15] H. Yoo & K. Chung. (2020). Deep Learning-based Evolutionary Recommendation Model for Heterogeneous Big Data Integration, *KSII Transactions on Internet and Information Systems*, 14(9), 3730-3744.  
DOI : 10.3837/tiis.2020.09.009

**신 동 훈(Dong-Hoon Shin)** [학생회원]



- 2019년 2월 : 동서대학교 컴퓨터공학부 (공학사)
- 2019년 9월 ~ 현재 : 경기대학교 컴퓨터과학과 석사과정
- 2019년 3월 ~ 현재 : 경기대학교 컴퓨터과학과 데이터마이닝 연구실 연구원
- 관심분야 : 데이터 마이닝, 헬스케어, 딥러닝, AR/VR, 추천 시스템, 인공지능

· E-Mail : dhshin8227@kyonggi.ac.kr

**백 지 원(Ji-Won Baek)** [학생회원]



- 2017년 2월 : 상지대학교 컴퓨터정보공학부 (공학사)
- 2018년 9월 ~ 2020년 8월 : 경기대학교 컴퓨터과학과 (석사)
- 2020년 8월 ~ 현재 : 경기대학교 컴퓨터과학과 (박사과정)
- 2017년 2월 ~ 2018년 2월 : 인퍼닉

연구원

- 2018년 9월 ~ 현재 : 경기대학교 컴퓨터과학과 데이터마이닝 연구실 연구원
- 관심분야 : 인공지능, 데이터 마이닝, 헬스케어, 딥러닝, 빅데이터 분석
- E-Mail : jwbaek@kyonggi.ac.kr

**박 찬 흥(Roy C. Park)** [정회원]



- 2008년 8월 : 상지대학교 산업공학과 (공학사)
- 2010년 8월 : 상지대학교 컴퓨터정보공학과 (공학석사)
- 2015년 2월 : 상지대학교 컴퓨터정보공학과 (공학박사)
- 2015년 3월 ~ 2019년 2월 : 동서대학교 컴퓨터공학부 교수

- 2019년 3월 ~ 현재 : 상지대학교 정보통신공학과 교수
- 관심분야 : 클라우드, 빅데이터, 헬스케어, 인공지능, HCI, 정보검색, 추천 시스템
- E-Mail : roypark@sangji.ac.kr

**정 경 용(Kyungyong Chung)** [종신회원]



- 2000년 2월 : 인하대학교 전자계산공학과 (공학사)
- 2002년 2월 : 인하대학교 전자계산공학과 (공학석사)
- 2005년 8월 : 인하대학교 컴퓨터정보공학부 (공학박사)
- 2006년 3월 ~ 2017년 2월 : 상지대학교 컴퓨터정보공학부 교수

- 2017년 3월 ~ 현재 : 경기대학교 컴퓨터공학부 교수
- 관심분야 : 데이터 마이닝, 헬스케어, 빅데이터, 지능시스템, 인공지능, HCI, 인공지능, 추천 시스템
- E-Mail : draginchi@gmail.com