

딥러닝 기반 이미지 처리를 이용한 통행 차량 높이검출 시스템

정재호¹, 김정주², 신동민^{1*}

¹한국과학기술원 안보융합연구원, ²(주)스타시큐리티

Vehicle Height Detection System using Deep Learning-based Image Processing

Jaeho Chung¹, Jeong Ju Kim², Dong Min Shin^{1*}

¹Institute for Security Convergence Research, Korea Advanced Institute of Science and Technology

²Star Security Co., Ltd.

요약 4차 산업 혁명의 시대가 열리면서, 인공지능을 활용한 연구에 관심이 증가하고 있다. 본 연구에서는 최근 들어 차량의 높이가 점차적으로 높아짐에 따라 발생하는 충돌 사고를 방지하고자 인공지능을 활용하여 차량의 높이를 사전에 정확히 측정하는 시스템을 개발하고자 한다. 본 연구에서는 Yolo V3, Mask RCNN 등을 사용한 딥러닝 방식으로 차량의 높이 측정 시스템을 개발하였다. Yolo V3를 사용하여 픽셀을 대상 영역을 추출하였다. 또한, 픽셀의 대상 영역과 빈 영역에 대한 학습은 Mask RCNN을 사용하여 수행하였다. 특히, 기존 차량의 높이 데이터(1300~2000 mm, 총 63679 개)와 보정계수를 사용하여 측정 시스템의 정확도가 98% 이상임을 확인하였다. 본 연구 결과는 차량의 높이를 미리 정확히 예측함으로써, 지하차도, 다리 등에서의 충돌 사고를 사전에 방지하는 시스템 또는 구조물을 설치할 수 있을 것으로 예상된다. 또한, 제조업체는 진입하는 차량의 높이를 사전에 예측하는 시스템 개발 시, 시행착오를 방지하고 개발 시간 및 비용을 절감할 수 있을 것으로 예상된다.

Abstract As the era of the 4th industrial revolution opens, interest in research using artificial intelligence is increasing. In this study, we developed a system that accurately measures the height of a vehicle using artificial intelligence in order to prevent collisions that occur as the heights of vehicles have gradually increased in recent years. In this study, a vehicle height-measurement system was developed using a deep learning method with Yolo V3, Mask RCNN, etc. The target area was extracted from a pixel by Yolo V3. In addition, learning for the target area and the empty area of a pixel was performed using Mask RCNN. It was confirmed that the accuracy of the measurement system was 98% or higher by using the height data of existing vehicles (1300-2000 mm, 63679 units in total) and a correction factor. The results of this study are expected to be used to install a system or structure that prevents collisions in underground roadways and bridges by accurately predicting the height of the vehicle. In addition, when developing a system that predicts the height of an entering vehicle, manufacturers are expected to avoid trial and error as well as reduce development time and cost.

Keywords : Deep Learning, Height Detection, Image Process, RCNN, Yolo V3

*Corresponding Author : Dong Min Shin(Korea Advanced Institute of Science and Technology)

email: ehdals9288@kaist.ac.kr

Received March 18, 2021

Revised April 9, 2021

Accepted July 2, 2021

Published July 31, 2021

1. 서론

도시화가 진행되면서, 구도심과 신도심이 병행하게 되고 차량의 높이가 시간이 지날수록 점점 높아지거나 불법적인 운행 위반을 하는 차량이 날로 증가하고 있다. 또한, 구도심의 지하차도나 장애물을 통과하기 위한 높이를 맞출 수 없는 차량이 증가하고 이에 따른 높이 제한으로 인한 충돌 사고가 Fig. 1과 같이 빈번히 발생하고 있다. 도로법 제 59조 및 동법 시행령 제 55조에 따르면, 4.2 m를 초과한 차량은 운행에 제한이 되며, 이를 위반할 시에는 도로법 제 59조 1항에 따라 과태료가 부과되고 있으나, 현실적으로 이를 실시간으로 단속하기는 힘든 실정이다. 기존의 차량 높이 제한 시스템의 경우, 승용차, 승합차, 화물차, 버스 등으로 나누어, 일률적으로 차량의 운전자에게 대략적인 높이 정보를 제공해 주고는 있으나, 화물칸의 높이 등을 제공해 주고 있지는 않아 문제가 되었고, 기존 높이 제한 구조물의 경우, 오히려 구조물로 인한 충돌 사고가 종종 일어났다. 복수의 라이더 센서를 이용하여 2층 버스와 같이 전고가 높은 차량을 위한 통과 높이 경고 시스템에 대한 연구 [1]가 있으나 설치 비용이 증가하는 문제점이 있다. 이러한 이유로, 인공지능 기법의 하나인 딥러닝 기법을 사용한 차량 높이 감지 시스템을 개발하게 되었다. 본 연구에서는 YOLO (You Only Look Once) V3 모델 [2-5]을 사용하여, 차량의 실시간 이미지를 그리드 셀 (grid cell)로 분할하였고, 각 셀마다 하나의 객체 예측을 하여, 테두리 상자 (bounding box)를 통해 차량의 정확한 크기를 파악하는 방법을 사용하였다. 기존의 차량사고 예방에 대한 YOLO V2 모델을 활용한 연구 [6]에 비해 개량된 V3 모델을 통해 Detecting의 정확도를 향상하였다. 또한, 실시간 동영상에서 차량 형상 픽셀을 추출하는 데에는 Mask RCNN기법 [7-10]을 사용하였으며, 촬영 위치에



Fig. 1. Examples of height limit collision accidents

따른 차량 높이 측정의 정확도 향상을 위해 기존 차량 데이터의 각도별 데이터를 활용하였다. 그리고 최종적으로 신경망 기반 객체 탐지 알고리즘 [11]을 통해 보정계수를 삽입함으로써, 각 운행하는 차량의 정확한 높이를 측정하는 시스템을 개발하고자 한다.

2. 딥러닝 기반 높이 인식 시스템

2.1 학습 과정 및 추론 과정 전체 설계도

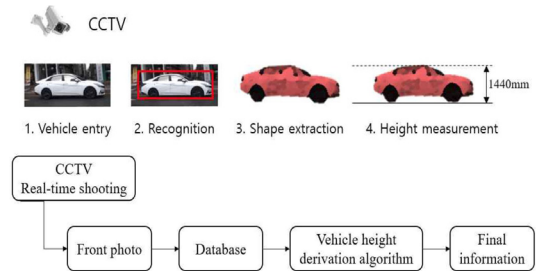


Fig. 2. System schematic diagram

Fig. 2는 본 연구에서의 전체적인 시스템 프로세스를 보여주고 있다. CCTV를 이용한 실시간 촬영을 통해 차량 진입 시, 차량의 전방사진을 촬영하고, 촬영된 사진을 바탕으로 축소 사진을 생성하여 데이터베이스에 저장한다. 이후 저장된 사진을 통해, 차량의 공간을 인식하고, 차량의 형상을 추출하게 되며, 이에 차량 높이 도출 알고리즘을 적용하여 차량 높이를 측정한다. 인식된 차량의 높이와 차량 번호판을 최종 정보로 저장하게 됨으로써, 사용자의 필요에 따라 저장된 정보를 사용할 수 있는 시스템이다.

2.2 딥러닝 검증 방법

본 연구에 사용된 딥러닝 알고리즘 검증 방법은 Fig. 3과 같다. 우선, Fig. 3의 (1)과 같이, 데이터를 훈련 세트와 테스트 세트로 분리하고, (2)와 같이 학습 알고리즘의 파라미터 또는 메타 파라미터인 하이퍼 파라미터 (hyper parameter)를 지정한다. 이후 (3)과 같이 테스트 세트를 통한 데이터의 편향성을 분석하고, (4)와 같이 예측된 클래스와 실제 레이블을 비교함으로써 본 연구에 사용된 딥러닝 알고리즘을 검증하였다. Fig. 3의 (1)에서와 같이, 훈련 세트와 테스트 세트를 분리한 이유는 다음과 같다. 만약 이를 분리하지 않을 시, 모델 검증을 위해 테스트

세트를 사용하여야 하며, 이는 고정 세트이므로 고정된 테스트 세트를 가지고 모델의 성능을 확인하고 파라미터를 수행하는 과정을 반복하면 결국 모델은 테스트 세트에서만 정확도가 높은 모델이 될 수 있기 때문이다.

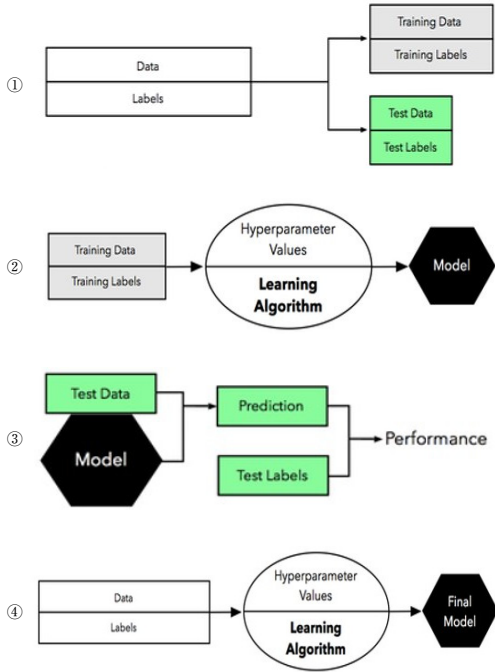


Fig. 3. Deep learning verification method

2.3 딥러닝 기반 차량 인식 (Yolo V3)

본 연구에서는 Yolo V3 딥러닝 모델을 사용하여 차량을 인식하였다. Yolo는 이미지를 한 번 보는 것으로 Object의 종류와 위치를 추측하는 딥러닝 기술 [1]로 단일 네트워크를 통해 여러 개의 테두리 상자에 대한 객체 확률을 계산한다. 본 연구에서는 Yolo 모델의 이미지를 $S \times S$ 개의 그리드 셀로 분할하여, 각 셀마다 하나의 객체 예측을 하게 하였으며, 테두리 상자를 통해 객체의 위치 및 크기를 파악하였다. 본 연구에서 사용된 훈련 프로세스는 Eq. (1)과 같다.

Eq. (1)에서 I_{ij}^{obj} 는 Object가 존재하는 그리드셀 i 의 Predictor 테두리 상자 j 를 의미하며, I_{ij}^{noobj} 는 Object가 존재하지 않는 그리드셀 i 의 테두리 상자 j 를 의미한다. 또한 I_i^{obj} 는 Object가 존재하는 그리드셀의 i 를 의미한다.

$$\begin{aligned} & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ & + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} (C_i - \hat{C}_i)^2 \\ & + \sum_{i=0}^{S^2} I_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2 \end{aligned} \quad (1)$$

또한, Eq. (1)에서 첫 번째 항은 Object가 존재하는 그리드셀 i 의 Predictor 테두리 상자 j 에 대해 가로 길이 x 와 세로 길이 y 의 loss를 계산한 것이며, 두 번째 항은 Object가 존재하는 그리드셀 i 의 Predictor 테두리 상자 j 에 대해 폭 w 와 높이 h 의 loss를 계산한 것이다. 그리고 세 번째 항은 Object가 존재하는 그리드셀 i 의 Predictor 테두리 상자 j 에 대해 Confidence score의 loss를 계산 ($C_i = 1$)한 것이며, 네 번째 항은 Object가 존재하지 않는 그리드셀의 i 의 테두리 상자 j 에 대해 Confidence score의 loss 값을 계산 ($C_i = 0$)한 것이다. 마지막으로 다섯 번째 항은 Object가 존재하는 그리드셀 i 에 대해 Conditional class probability의 loss를 계산한 것이다.

2.4 차량 형상 픽셀 추출

본 연구에서는 차량 형상 픽셀 추출 기법으로 Mask RCNN기법을 사용하였다. Mask RCNN기법은 실시간 영상으로부터 다수의 관심 영역 (ROI: Region of Interest) 후보가 제안되고 제안된 관심 영역은 곧 경계 박스로 특징맵을 RoIAlign방식으로 추출한다. 추출된 특징맵으로부터 Object의 클래스를 분류함과 동시에 Object의 마스크를 획득하고, 관심 영역 안에 존재하는 Object의 마스크 예측 시, 클래스 별로 독립적으로 예측하였으며, 실제 클래스에 해당하는 마스크 채널의 loss만 사용하여 학습하였다. Fig. 4 [8]는 Mask RCNN의 개략도를 보여주고 있다. 본 연구에서는 Mask RCNN에 사용될 이미지를 맞추기 위하여, Bilinear interpolation을 사용하여 resize를 수행하였다. 하나의 이미지를 2×2 의 이미지로 만든 후, 이를 다시 4×4 로 Up-sampling을 하여 2×2 에 있던 픽셀 값이 각각 대응하게 되고, 이때,

총 16개 중 4개의 픽셀만 값이 대응하므로 나머지 12개의 픽셀은 Bilinear interpolation을 이용하여 값을 채우는 방법을 사용하였다.




Fig. 4. Mask R-CNN Framework for instance segmentation [8]

2.5 차량 높이 도출 알고리즘

$$Coefficient = \frac{Truth Value}{Learning Value}$$




Fig. 5. Correction coefficient calculation method

본 연구에서는 정확도 향상을 위해서 AI 허브[12]에서 제공하는 기존 차량 데이터의 각도 및 높이와 시간대별 실내외 촬영 사진을 활용하였다. 그리고 활성화수로는 경사 함수인 Rectified Linear Unit (ReLU)를 사용하였다. 또한, 영상을 통해 차량의 높이를 산출하기 위해서는 차량에 대한 라벨링을 하여야 하며, 초기 영상만으로는 라벨링 작업이 불가능하기에, 본 연구에서는 제조사에서 제공하는 높이와 영상을 통해 식별된 차량과의 보정계수를 산출하여 이를 적용하였다. 예를 들어, Fig. 5와 같이, 아반떼, 소나타, 포터의 경우 제조사에서 제공하는 높이는 각각 1,420 mm, 1,445 mm, 1,970 mm이고 보정 전 차량의 값을 1,000 mm로 설정하여 보정계수를 산출하여 적용하였다. Eq. (2)는 보정계수를 산출할 시 사용된 식이다.

$$Coefficient = \frac{T}{L} \tag{2}$$

Eq. (2)에서 T는 실제 True value를 뜻하고, L은 학습된 Learning value를 뜻한다.

3. 연구 결과




Fig. 6. Car model length/height distribution (●: Hyundai, ▼: Kia, ◆: Chevrolet, ▲: Renault-Samsung, ■: Ssangyong) [10]

Model	Real Height (mm)	Calculated Height (mm)	Absolute accuracy (%)
Avante	1420	1398.7	98.5
Sonata	1445	1458	99.1
K3	1440	1412.6	98.1
SM6	1460	1474.6	99
Malibu	1465	1488.4	98.4

Table 1. Example of vehicle height calculation accuracy

본 연구에서는 국내 도로의 CCTV 동영상 자료를 대상으로 검증하였다. 시스템의 차량 인식 시간은 0.3 sec 이내로 측정되었다. AI 허브 [12]에서 제공하는 데이터는 차량 제조사별로 현대: 24916 대, 기아: 22442 대, 쉐보레: 6293 대, 르노삼성: 6087 대, 쌍용: 3941 대이다. 예시를 위해 Fig. 6에 차량 제조사에 따른 차량의 길이와 높이를 표시하였고 Table 1에서는 제조사별 대표적인 차량의 실제 높이와 도출된 높이의 비교를 나타내었다. 정확도는 차량 제조사의 스펙과 비교 시, 대략적으로 98% 이상의 정확도를 보여주었다. Fig. 7은 차량 높이의 인식 결과를 보여주고 있다. Fig. 7에서 볼 수 있듯이, 우선, 차량의 종류에 따라 색상별로 확인 (승용차, 트럭, 버스 등)이 가능하며, 보정계수를 적용하여, 차량의 높이를 산출하였다. 또한, 본 연구에서는 픽셀 단위에 대한 학습 기반으로 비정상적인 진입 차량, 주행 속도, 도로의 평탄성 및 차량의 흔들림에 따라 발생하는 차량의 고저차와 상관없이 차량의 높이 측정이 가능하게 개발되었다. 그리

고, 기본 차량 외 추가적인 적재물을 포함한 높이를 측정함으로써, 실제 차량의 높이를 정확하게 측정할 수 있었다. 본 연구에서 개발한 시스템의 경우, 최종 결과물은 사진 단위로 저장이 되도록 설정을 하였으며, 번호판 인식이 가능할 경우, 차량 번호판을 가변문자표시기 (VMS: Variable Message Sign)으로 전송 가능한 포맷으로 결과물을 생성할 수 있도록 개발하였다.

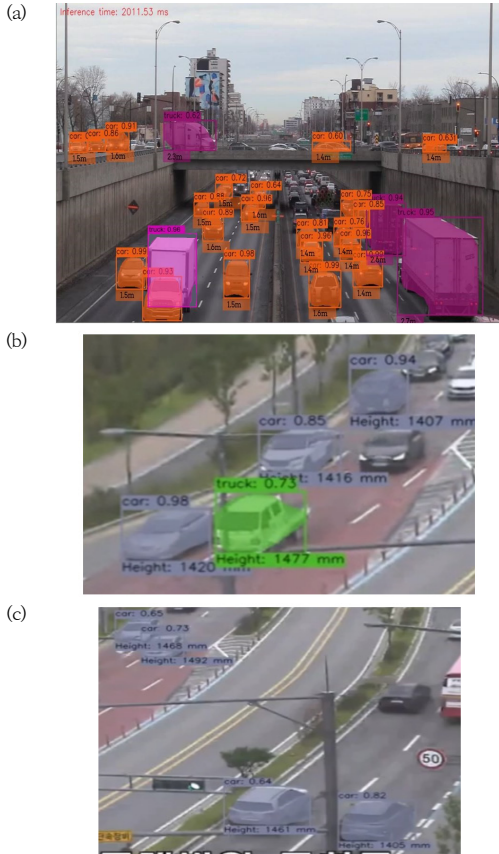


Fig. 7. (a) Example of recognition results #1, (b) Examples of recognition results #2 (c) Examples of recognition results #3.

4. 결론

본 연구에서는 YOLO, RCNN, Learning data set 등을 이용하여 인공지능 기반 차량 높이 측정 시스템을 개발하였다. 따라서, 본 연구를 통해 다음과 같이 정리할 수 있다.

(1) YOLO를 이용하여 픽셀의 Object 영역을 추출하

였고, Mask RCNN을 사용하여 픽셀의 Object 영역과 Empty 영역의 구분에 대한 학습을 수행하였다.

(2) AI 허브에서 제공하는 기존 차량 높이 데이터를 활용하고 오차에 대한 보정계수를 이용하여 시스템의 높이 정의 및 정확도를 향상하였고, Annotation 기법을 이용하여 데이터의 초기 라벨링 작업을 수행하여 학습을 위한 데이터를 생성하였다.

(3) 1300~2000 mm 사이의 높이를 가지는 차량의 제조사별로 현대: 24916 대, 기아: 22442 대, 쉐보레: 6293 대, 르노삼성: 6087 대, 쌍용: 3941 대의 데이터를 이용해, Learning data와 Test data를 통한 시스템의 전체 정확도는 98~99 %임을 확인하였다.

(4) YOLO의 One-Look 방식을 적용하여 Real-Time적인 차량 높이 분석이 가능하다는 것을 확인할 수 있었다.

본 연구 결과는 인공지능을 통한 도로의 상황을 파악하는 연구 분야에 도움이 될 것으로 본다. 그리고 지자체 또는 행정부 측에서는 본 연구 결과를 통해, 차량의 높이를 미리 정확히 예측함으로써, 지하차도, 다리 등에서의 충돌 사고를 사전에 방지하는 시스템 또는 구조물을 설치할 수 있을 것으로 예상된다. 또한, 관련 업체 및 제조사 측에서는 본 논문의 결과를 통해, 진입하는 차량의 높이를 사전에 예측하는 시스템을 구현하는 데 따른 시행착오를 방지하고 개발 시간 및 비용을 절감할 수 있을 것으로 예상된다.

References

- [1] T. Kim, S. Ok, G. Heo, I. Lee, "An Overheight Warning System for High Height Vehicles", The Korea Institute of Information and Communication Engineering, vol. 24, pp. 849-856, 2020. DOI: <https://doi.org/10.6109/ikiice.2020.24.7.849>
- [2] H. J. Jeong, K. S. Park, Y. G. Ha, "Image preprocessing for efficient training of YOLO deep learning networks," Proceeding of 2018 IEEE International Conference on Big Data and Smart Computing (BigComp), IEEE, pp. 635-637, Jan 2018.
- [3] P. Hurtik, V. Molek, J. Hula, M. Vajel, P. Vlasanek, T. Nejezchleba, "Poly-YOLO: higher speed, more precies detection and instance segmentation for YOLO V3," arXivpreprint arXiv:2005.13243, 2020.

- [4] R. Huang, J. Pedoeem, C. Chen, "YOLO-LITE: a real-time object detection algorithm optimized for non-GPU computers," Proceeding of 2018 IEEE International Conference on Big Data and Smart Computing (BigComp), IEEE, pp. 2503-2510, Jan 2018.
- [5] Y. Tien, G. Yang, Z. Wang, H. Wang, E. Li, Z. Liang, "Apple detection during defferent growth stage in orchards using the improved YOLO-V3 model," Computers and Electronis in Agriculture, vol. 153, pp. 417-426, 2019.
DOI: <https://doi.org/10.1016/j.compag.2019.01.012>
- [6] S. H. Han, S. Chae, S. A. Hassan, T. Rahim, S. Y. Shin, "Video-Based Traffic Accident Prevention Safety System Using Deep Learning", The Journal of Korean Institute of Communications and Information Sciences, vol. 45(8), pp. 1399-1406, 2020.
DOI: <https://doi.org/10.7840/kics.2020.45.8.1399>
- [7] J. Y. Chiao, K. Y. Chen, K. Y. K. Liao, P. H. Hsieh, G. Zhang, T. C. Huang, "Detection and classification the breast tumors using mask R-CNN on sonograms," Medicien, vol. 98, no. 19, 2019.
DOI: <https://doi.org/10.1097/MD.0000000000015200>
- [8] N. Dryden, T. Maruyama, T. Benson, M. Snir, V. Essen, "Channel and filter parallelism for large-scale CNN training," Proceeding of the International Conference for High Performance Computing, Networking, Storage and Analysis, pp. 1-20, Nov 2019.
- [9] T. Geng, T. Wang, A. Sanaullah, C. Yang, R. Patel, M. Herbordt, "A framework for acceleration of CNN training on deeply-pipelined FPGA clusters with work and weight load balancing," Proceeding of 28th International Conference on Field Programmable Logic and Applications (FPL), IEEE, pp. 394-404, Aug 2018.
- [10] X. Wu, S. Wen, Y. A. Xie, "Improvement of Mask-RCNN object segmentation algorithm," Proceeding of International Conference on Intellignet Robotics and Applications, Springer, pp. 582-591, Aug 2019.
- [11] B. Benjdira, T. Khursheed, A. Koubaa, A. Ammar, K. Ouni, "Car detection using unmanned aerial vehicles: Comparison between faster r-cnnand yolov3," Proceeding of 1st International Conference on Unmanned Vehicle Systems-Oman (UVS), IEEE, pp. 1-6, Feb 2019.
- [12] AI Hub, URL: <https://aihub.or.kr/aidata/13596/download> 2019.

정 재 호(Jaeho Chung)

[정회원]



- 2011년 8월 : KAIST 해양시스템 공학과 (공학석사)
- 2018년 2월 : KAIST 기계공학과 (공학박사)
- 2018년 4월 ~ 2019년 2월 : 한국 기계연구원 박사후연구원
- 2019년 9월 ~ 현재 : KAIST 안보 융합연구원 연구조교수

<관심분야>

딥러닝, 유체역학실험, CFD, Shock M&S

김 정 주(Jeong Ju Kim)

[정회원]



- 2013년 3월 ~ 2019년 9월 : (주)스타시큐리티 대표이사
- 2019년 10월 ~ 현재 : (주)스타시큐리티 이사

<관심분야>

딥러닝, 높이제한 시스템, 스마트 화재 감지 시스템

신 동 민(Dong Min Shin)

[정회원]



- 2015년 2월 : KAIST 해양시스템 공학과 (공학석사)
- 2019년 8월 : KAIST 기계공학과 (공학박사)
- 2019년 8월 ~ 2020년 5월 : 군산대학교 조선해양기자재역량강화센터 연구교수
- 2020년 6월 ~ 현재 : KAIST 안보융합연구원 연구조교수

<관심분야>

딥러닝, 유체역학, 해양파, 선박 복원성