

효율적인 객체 검출을 위해 Attention Process를 적용한 경량화 모델에 대한 연구

박찬수¹, 이상훈^{2*}, 한현호³

¹광운대학교 대학원 플라즈마바이오디스플레이 석사 과정, ²광운대학교 인제니움학부 교수, ³울산대학교 교양학부 교수

A Study on Lightweight Model with Attention Process for Efficient Object Detection

Chan-Soo Park¹, Sang-Hun Lee^{2*}, Hyun-Ho Han³

¹Master's Degree, Dept. of Plasma Bio Display, KwangWoon University

²Professor, Ingenium College of Liberal Arts, KwangWoon University

³Professor, College of General Education, University of Ulsan

요 약 본 논문에서는 기존 객체 검출 방법 대비 매개변수를 감소시킨 경량화 네트워크를 제안하였다. 현재 사용되는 검출 모델의 경우 정확도 향상을 위해 네트워크 복잡도를 크게 늘렸다. 따라서, 제안하는 네트워크는 EfficientNet을 특징 추출 네트워크로 사용하였으며, 후속 레이어는 저수준 세부 특징과 고수준의 의미론적 특징을 활용하기 위해 피라미드 구조로 형성하였다. 피라미드 구조 사이에 attention process를 적용하여 예측에 불필요한 노이즈를 억제하였다. 네트워크의 모든 연산 과정은 depth-wise 및 point-wise 컨볼루션으로 대체하여 연산량을 최소화하였다. 제안하는 네트워크는 PASCAL VOC 데이터셋으로 학습 및 평가하였다. 실험을 통해 융합된 특징은 정제 과정을 거쳐 다양한 객체에 대해 견고한 특성을 보였다. CNN 기반 검출 모델과 비교하였을 때 적은 연산량으로 검출 정확도가 향상되었다. 향후 연구로 객체의 크기에 맞게 앵커의 비율을 조절할 필요성이 사료된다.

주제어 : 딥러닝, 특징 피라미드, 경량화, 객체 검출, SSD

Abstract In this paper, a lightweight network with fewer parameters compared to the existing object detection method is proposed. In the case of the currently used detection model, the network complexity has been greatly increased to improve accuracy. Therefore, the proposed network uses EfficientNet as a feature extraction network, and the subsequent layers are formed in a pyramid structure to utilize low-level detailed features and high-level semantic features. An attention process was applied between pyramid structures to suppress unnecessary noise for prediction. All computational processes of the network are replaced by depth-wise and point-wise convolutions to minimize the amount of computation. The proposed network was trained and evaluated using the PASCAL VOC dataset. The features fused through the experiment showed robust properties for various objects through a refinement process. Compared with the CNN-based detection model, detection accuracy is improved with a small amount of computation. It is considered necessary to adjust the anchor ratio according to the size of the object as a future study.

Key Words : Deep Learning, Feature Pyramid, Lightweight, Object Detection, SSD

*Corresponding Author : Sang-Hun Lee(leesh58@kw.ac.kr)

Received April 21, 2021

Accepted May 20, 2021

Revised May 3, 2021

Published May 28, 2021

1. 서론

최근 컴퓨터 비전에서 딥러닝 기반의 객체 검출 연구가 활발히 진행 중이다. 검출 네트워크는 크게 모델 구성에 따라 two-stage[1] 와 one-stage detector[2]로 분류된다. Two-stage detector는 물체가 존재할 만한 영역(region proposal)을 탐색한 후에 classification을 수행하는 방법이다. 이 방법은 다양한 proposals를 찾는 과정에서 많은 탐색 시간을 소모하기 때문에 실시간 검출에 적합하지 않은 단점이 있다. 이러한 과정을 개선한 것이 one-stage detector이다. Two-stage detector와 다르게 한 번의 네트워크 전파로 객체에 대한 분류 및 회귀를 수행하는 방법이다. 대표적인 모델로 SSD(Single Shot multibox Detector)[3], YOLO(You Only Look Ones)[4]이 있으며 빠른 검출 속도가 장점이다. 이후, one-stage detector들의 검출 정확도를 향상시키기 위해 모델 구조를 깊게 확장한 방법들이 제안되었다. 그러나, 네트워크의 연산 요구량이 늘어남에 따라 학습 및 테스트 시간이 길어지는 문제가 있다. 네트워크 크기 또한 증가하기 때문에 실시간 서비스에 부적합해지는 단점이 있다.

따라서, 정확도를 높이면서 실시간 검출이 가능하도록 모델 사이즈 및 연산량을 줄인 MobileNet[5]이 제안되었다. 일반적인 컨볼루션 모듈을 수정하여 적은 연산량으로 기존 방법과 유사한 성능을 보였다. 이러한 trade-off를 최소화한 알고리즘에서 착안하여 본 논문에서는 적은 연산량으로 효율적인 객체 검출을 위한 경량화 네트워크를 제안하였다. 특징맵 한 차원에 국한되지 않고 채널, 너비 그리고 깊이 차원을 복합적으로 확장한 EfficientNet[6]을 특징 추출 네트워크로 사용하였다. 이후 다양한 크기의 객체 검출이 가능하도록 특징 피라미드로 extra layers를 구성하였다. 제안하는 특징 피라미드 구조에서 연산량을 줄이기 위해 depth-wise 및 point-wise convolution으로 특징을 추출하였고, 추출된 특징맵에서 검출에 불필요한 영역을 억제하기 위해 attention process를 수행하였다.

2. 관련연구

2.1 Feature pyramid

특징 피라미드[7] 구조는 특징 스케일 불균형 문제 해결을 위해 제안되었다. 기존 one-stage detector의 경우 컨볼루션 과정을 거칠수록 특징맵 전반에 대한 문맥

정보로 압축되어 작은 객체에 대한 정보가 손실되는 문제가 있다. 이러한 문제를 해결하기 위해 컨볼루션 중간 과정의 특징맵을 활용하여 검출을 수행하는 방법이 특징 피라미드 구조이다. 그림 1은 one-stage detector의 대표 모델 SSD와 특징 피라미드 구조의 비교 이미지이다.




Fig. 1. Comparison between SSD and Feature Pyramid

2.2 SSD

대표적인 one-stage detector 모델 SSD는 한 번의 네트워크 전파로 추출된 특징맵을 개별적으로 활용하는 것이 특징이다. SSD는 빠른 검출 속도로 실시간 검출이 가능한 것이 장점이며, 백본 네트워크인 VGG-16을 확장된 구조로 구성되어 있다. 입력 이미지가 모델을 전파하여 다양한 크기의 특징맵을 생성하며, 생성된 특징맵으로 검출을 수행하는 모델이다. 큰 크기의 특징맵은 객체 정보가 상대적으로 압축이 덜 되어 작은 객체를 검출하는데 유리하다. 반면에, 작은 크기의 특징맵은 객체를 판별하는 문맥 정보로 압축되기 때문에 큰 객체를 검출하는데 이점이 있다. 검출 과정은 특징맵의 각 픽셀 중심점을 기준으로 고정된 비율의 앵커 박스로 후보 경계 상자를 생성한다. 이때, 앵커 박스는 특징맵의 크기가 다르기 때문에 중첩비를 기준으로 특징맵 크기에 맞춰 재조정된 후 경계 상자를 생성한다. 그리고 나서, 수 많은 후보 경계 상자들 중 객체에 대한 신뢰도가 높은 경계 상자 외 모두 제거하는 방법인 NMS(Non-Maximum Suppression)[8]를 적용한다. 입력 이미지는 300×300으로 조정 후 모델의 입력으로 사용하며, 백본 네트워크와 확장 레이어로 구성된다.




Fig. 2. Proposed Network Architecture

3. 제안하는 방법

본 논문에서는 적은 연산량으로 효율적인 객체 검출이 가능한 경량화 객체 검출 모델을 제안하였다. 실시간 검출을 위해 one-stage 구조를 채용하였으며, 백본 네트워크로 EfficientNet-B0를 적용하였다. 이후, 다양한 크기의 객체 검출이 가능하도록 후속 레이어를 특징 피라미드 구조로 형성하였다. 또한, 작은 객체와 같이 특징 정보가 상대적으로 부족한 특징을 보완하기 위해 CA-block으로 특징 추출 및 강조 과정을 수행하였다. 그림 2는 제안하는 네트워크의 구조이다.

3.1 Convolution-Attention block

제안하는 CA-block을 통해 적은 연산량으로 특징을 추출하면서 객체에 대한 정보를 강조하였다. CA-block은 특징 추출과 공간 강조 과정으로 구성되어 있다. 그림 3는 CA-block의 특징 추출 과정을 나타낸다.




Fig. 3. Feature extraction process

먼저, 입력 특징의 채널 정보를 풍부하게 가지도록 비선형적으로 확장하였다. 이후 depth-wise 컨볼루션[9]으로 공간 축의 위치 정보를 압축 후 GAP(Global Average Pooling)[10]를 통해 벡터 형태로 나열하였다. Dense layer를 통해 특징 벡터의 상관 관계를 연산한 후 sigmoid 활성화 함수로 정규화 과정을 수행하였다. 이렇게 계산된 값은 객체의 의미론적 정보만을 포함하며 곱 연산을 통해 attention 과정을 수행하였다. 마지막으로, 강조된 특징의 채널을 선형적으로 줄여 입력 채널에 맞게 조정하였다. 제안하는 특징 추출 및 attention process는 적은 채널 수에서 풍부한 특징을 추출하며 비객체 특징 정보를 억제할 수 있다. 또한, 특징 압축 과정을 거치면서 발생하는 공간 정보의 손실을 최소화하기 위해 그림 4와 같이 공간 강조 과정을 수행하였다.




Fig. 4. Spatial Attention Process

특징 추출 과정을 거친 특징에서 dilation rate가 다른 depth-wise 컨볼루션으로 작거나 큰 객체의 공간 정보를 추출하였다. 추출된 특징들은 채널 축으로 압축하여 공간 맵으로 형성 후 concatenate 연산을 수행하였다. 합쳐진 공간 맵들은 3×3 컨볼루션으로 한 채널의 공간 맵을 구성하여 요소 곱 연산을 통해 공간 강조를 수행하였다.

3.2 Lightweight feature attention process

백본 네트워크에서 추출된 특징 맵은 다양한 크기의 객체에 대해 견고한 특성을 가지도록 특징 피라미드 구조를 구성하였다. 객체의 문맥 정보를 압축하여 고수준의 의미론적 정보를 가지는 특징을 객체의 세부 정보를 가지는 저수준 특징맵과 융합하였다. 그림 5는 고수준 및 저수준 특징의 융합을 나타낸다.

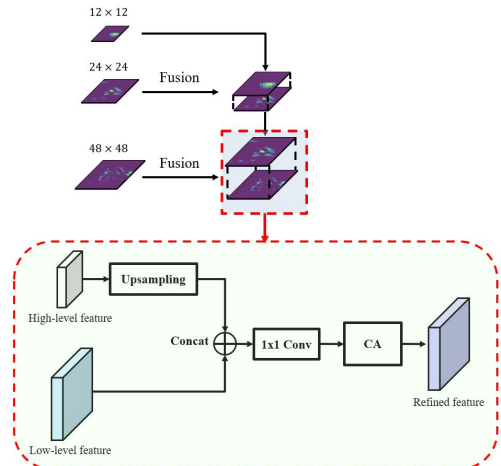


Fig. 5. Up-sampling fusion block

고수준 특징은 입력 이미지 전체의 문맥 정보를 압축하기 때문에 큰 객체를 검출하는데 사용된다. 그리고 저수준 특징은 객체의 경계 및 위치 정보를 포함하기 때문에 작은 객체를 검출하는데 사용된다. 하지만, 저수준 특징의 경우 의미론적 정보가 부족한 문제 때문에 분류 성능이 상대적으로 떨어진다.

따라서, 고수준 특징을 선형 보간 방법으로 확장 후 융합하였다. 그 후, 확장된 특징을 1×1 컨볼루션으로 정제 후 특징 추출 및 attention process를 수행하였다. 이 과정을 통해 적은 매개변수로 효율적인 특징 추출이 가능하다. 식 (1)은 Up-sampling fusion block의 특징 융합 과정을 의미한다.

$$F_{fused} = CA(Conv_{1 \times 1}[F_L \oplus Upsample(F_H)]) \quad (1)$$

융합된 특징 F_{fused} 는 저수준 특징 F_L 과 고수준 특징 F_H 를 융합 후 1×1 컨볼루션으로 입력 채널과 동일하게 조정하였다. 그리고 나서, CA-block을 통해 특징 추출 과정을 수행하였다. 그러나, down-sampling 과정에서는 low-level 특징을 압축하여 high-level 특징과 융합하기 때문에, 식 (2)와 같은 방법으로 융합 과정을 수행하였다.

$$F'_{fused} = Conv_{1 \times 1}[CA(F_L) \oplus F_H] \quad (2)$$

high-level 특징을 CA-block의 첫 번째 depth-wise 컨볼루션의 stride를 2로 적용하여 특징맵의 크기를 $\frac{1}{2}$ 로 감소시켰다. Down-sampling 특징 융합 과정을 통해 공간 정보 손실을 최소화하면서 특징 압축 과정을 수행하였다.

3.3 Loss function

제안하는 네트워크는 total loss L 을 최소화하는 방향으로 adam optimizer를 통해 각 레이어의 가중치를 학습하였다. Total loss는 각 클래스의 분류 손실과 localization 손실의 합이며 아래 식 (3)와 같이 정의하였다.

$$L(x, c, l, g) = \frac{1}{N}(L_{conf}(x, c) + L_{loc}(x, l, g)) \quad (3)$$

Total loss L 은 식 (4)와 (5)의 합이다.

$$L_{conf}(x, c) = -\sum_{i \in pos} x_{ij}^p \log(\widehat{C}_i^p) - \sum_{i \in neg} \log(\widehat{C}_i^0) \\ \text{where } \widehat{C}_i^p = \frac{\exp(C_i^p)}{\sum_p \exp(c_i^p)} \quad (4)$$

$$L_{loc}(x, l, g) = \sum_{i \in Pos} \sum_{m \in (cx, cy, w, h)} x_{ij}^k \text{Huber}(l_i^m - g_i^m) \quad (5)$$

식 (3)과 같이 분류 손실 L_{conf} 와 회귀 손실 L_{loc} 를 나타낸다. L_{loc} 는 predicted box l 과 groundtruth box g 사이의 Huber 손실로 정의하였다. Predict box는 중심 좌표 x, y 와 bounding box의 너비 및 높이 값으로 회귀한다. 그리고 L_{conf} 는 객체와 배경 클래스의 softmax loss의 합이다.

4. 실험 및 결과

제안하는 네트워크의 실험은 ILSVRC CLS-LOC 데이터셋으로 사전 학습된 EfficientNet-B0 네트워크를 백본 네트워크로 사용하였다. 제안하는 방법은 Tensorflow 2.3 및 NVIDIA Geforce GTX TITAN Xp GPU를 통해 실험을 수행하였다. Adam optimizer로 네트워크 레이어의 가중치를 미세 조정하며, 0.001 learning rate, 0.9 momentum, 0.0005 weight decay 그리고 batch size를 32로 적용하였다. 모델 학습을 위해 PASCAL VOC2007+2012 train dataset(16,551 images)으로 학습을 진행하였고, 평가는 PASCAL VOC2007 test dataset(4,952 images)을 사용하였다. 기존 검출 네트워크와 정량적 평가를 위해 아래 식 (6)과 같이 AP(Average Precision)로 성능을 평가하며 식 (7)과 같이 전체 클래스의 평균값으로 정의하였다.

$$AP = \frac{1}{11} \sum_{r \in (0.0, \dots, 1.0)} P_{interp}(r) \quad (6)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (7)$$

4.1 PASCAL VOC 2007


제안하는 모델의 평가를 위해 PASCAL VOC 2007 test dataset을 사용하였다. PASCAL VOC dataset은 총 20개의 객체 클래스를 가지며, 대표적으로 Vehicle(aeroplane, bicycle, boat, bus, car, motorbike, train), Animal(bird, cat, cow, dog, horse, sheep), Indoor(bottle, chair, dining table, potted plant, sofa, tv/monitor) 그리고 Person 네 가지의 분류로 나뉜다.

Table 1. Compared to network in PASCAL VOC

Method	VOC 07+12 (AP : 0.5)	Input size
SSD300[3]	77.5	300×300
DSSD321[11]	78.6	321×321
HSD320[12]	81.7	320×320
RefineDet512[13]	81.8	512×512
Proposed	81.3	384×384

표 1은 PASCAL VOC 07+12 train 데이터셋으로 학습한 CNN 계열 객체 검출 네트워크의 성능 비교 표이다. Faster R-CNN[2]의 연산 복잡도를 개선하기 위해 SSD, YOLO와 같이 end-to-end 기반의 검출 모델들이 제안되었다. HSD(Hierarchical Shot Detector)[10]과 RefineDet[11]는 기존 SSD 알고리즘을 기반의 개선된 네트워크이다. 정확도 향상을 위해 네트워크의 depth를 늘려 모델의 특징 분류 성능이 향상되었으나, 연산에 요구되는 매개변수도 증가하는 단점이 있다. 이러한 모델 확장 시 발생하는 trade-off를 최소화하기 위해 본 논문에서는 경량화 네트워크를 제안하였다. 연산 복잡도를 줄인 CA-block으로 특징 피라미드 구조를 형성하여 기존 SSD 대비 향상된 검출 정확도와 빠른 속도를 달성하였다.

그림 6은 PASCAL VOC 07 test 데이터셋의 검출 결과 비교이다. 각 이미지의 좌측 결과는 SSD 네트워크의 검출 결과이며, 우측의 결과는 제안하는 방법을 통한 검출 결과이다. 기존 SSD의 경우 네트워크에서 각 컨볼루션을 거친 특징을 개별적으로 예측에 사용하는 구조이다. 특징맵 각 그리드의 중심점에서 후보 경계 상자를 생성하기 때문에 SSD는 다양한 크기의 객체 검출이 가능하다. 하지만 특징을 재활용하지 않고 예측에 바로 적용되기 때문에 불충분한 특징 정보로 객체 예측을 수행한



(a) SSD (b) Proposed method

Fig. 6. PASCAL VOC 07 test detection result

다. 이러한 문제를 해결하기 위해 제안하는 방법은 특징 피라미드 구조로 네트워크를 구성하였다. 작은 객체를 예측하는 스케일인 저수준 특징맵은 의미론적 정보를 내포하는 고수준 특징맵과 융합함으로써 특징 정보를 보충하였다. 그리고, 고수준의 특징맵은 객체의 위치 정보를 보충하여 큰 객체와 작은 객체 모두 견고하게 검출이 가능하였다. 객체의 폐색이 존재하는 경우 attention process를 수행함으로써 객체 정보 외 노이즈 혹은 불필요한 특징을 억제하여 검출 성능이 향상되었다.

4.2 Network Inference Time

본 논문에서는 효율적인 객체 검출을 위해 경량화 네트워크를 제안하였다. 제안하는 방법의 trade-off를 측정하기 위해 기존 검출 네트워크와 비교하여 실험을 진행하였다.

Table 2. Inference time from PASCAL VOC 2007

Method	Backbone Network	FPS
SSD300[3]	VGG-16	46
DSSD[11]	Residual-101	15
HSD320[12]	VGG-16	40
RefineDet512[13]	VGG-16	25
Faster R-CNN[14]	VGG-16	7
YOLOv2[15]	Darknet-19	81
YOLOv3[16]	Darknet-53	45
Proposed	EfficientNet-B0	83

표 2는 PASCAL VOC 2007 test 데이터셋에서 제안하는 네트워크의 추론 시간 비교 표이다. 제안하는 네트워크는 기존 네트워크 대비 적은 FLOPS(Floating point Operations Per Second)와 매개변수로 빠른 검출 속도를 보였다. CNN 계열의 검출 알고리즘은 GPU에서 행렬 연산을 수행하며 많은 연산 복잡도를 요구하기에 네트워크 구성에 따라 실시간 성능에 영향을 미친다. 제안하는 방법에서는 기존 convolution module 대비 trade-off를 최소화한 구조를 이용하여 빠른 검출 성능을 달성하였다.

5. 결론

본 논문에서는 효율적인 객체 검출을 위한 경량화 네트워크를 제안하였다. 제안된 방법은 기존 컨볼루션 대비 적은 연산량을 요구하는 CA-block으로 구성하였다. Multi-scale 특징을 활용하기 위해 특징 피라미드 구조로 형성하였다. CA-block은 특징 추출 후 채널 정보와 공간 정보를 강조함으로써 다양한 크기의 객체에 대해 견고한 특성을 보였다. 제안하는 네트워크의 성능과 속도를 측정하고자 PASCAL VOC 데이터셋으로 학습 및 평가하였다. 실험을 통해 제안하는 네트워크가 기존 CNN 계열의 검출 네트워크 대비 빠르고 정확한 검출 성능을 달성하였다. 향후 연구로 객체의 크기에 맞게 앵커의 비율을 조절하는 연구의 필요성이 사료된다.

REFERENCES

- [1] Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 580-587).
- [2] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- [3] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016, October). Ssd: Single shot multibox detector. In *European conference on computer vision* (pp. 21-37). Springer, Cham.
- [4] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- [5] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [6] Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning* (pp. 6105-6114). PMLR.
- [7] Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).
- [8] Neubeck, A., & Van Gool, L. (2006, August). Efficient non-maximum suppression. In *18th International Conference on Pattern Recognition (ICPR'06)* (Vol. 3, pp. 850-855). IEEE.
- [9] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- [10] Lin, M., Chen, Q., & Yan, S. (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- [11] Fu, C. Y., Liu, W., Ranga, A., Tyagi, A., & Berg, A. C. (2017). Dssd: Deconvolutional single shot detector. *arXiv preprint arXiv:1701.06659*.
- [12] Cao, J., Pang, Y., Han, J., & Li, X. (2019). Hierarchical shot detector. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 9705-9714).
- [13] Zhang, S., Wen, L., Bian, X., Lei, Z., & Li, S. Z. (2018). Single-shot refinement neural network for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4203-4212).
- [14] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *arXiv preprint arXiv:1506.01497*.

- [15] Redmon, J., & Farhadi, A. (2017). YOLO9000: better, faster, stronger. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7263–7271).
- [16] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767.

박 찬 수(Chan-Soo Park) [중산학원]



- 2020년 2월 : 광운대학교 컴퓨터공학과(공학사)
- 2020년 3월 ~ 광운대학교 대학원 플라즈마바이오 디스플레이학과(석사 과정)
- 관심분야 : 객체 검출, 딥러닝, 영상처리

·E-Mail : chansoopark@kw.ac.kr

이 상 훈(Sang-Hun Lee) [중산학원]



- 1983년 2월 : 광운대학교 응용전자공학과(공학사)
- 1987년 2월 : 광운대학교 전자공학과(공학석사)
- 1992년 2월 : 광운대학교 전자공학과(공학박사)
- 1990년 ~ 현재 : 광운대학교 정교수
- 2012년 2월 ~ 2013년 2월 : 광운대학교 정보통신처장
- 2013년 2월 ~ 2015년 2월 : 광운대학교 학생복지처장
- 2015년 2월 ~ 2017년 12월 : 한국융합학회 편집위원장
- 2018년 1월 ~ 2020년 1월 : 한국융합학회 회장
- 관심분야 : 영상인식, 3D 영상처리, 기계 학습, 영상 처리와 생체 인식, IOT 영상처리, 딥러닝
- E-Mail : leesh58@kw.ac.kr

한 현 호(Hyun Ho Han) [중산학원]



- 2009년 2월 : 광운대학교 컴퓨터공학과(공학사)
- 2011년 2월 : 광운대학교 정보콘텐츠대학원 유비쿼터스컴퓨팅학과(공학석사)
- 2019년 8월 : 광운대학교 정보디스플레이학과(박사)
- 2020년 3월 ~ 현재 : 울산대학교 교양대학 교수
- 관심분야 : 무선 네트워크, 영상인식, 3D 영상처리, 기계 학습, 딥러닝
- E-Mail : hhhan@ulsan.ac.kr