

특징 융합과 공간 강조를 적용한 딥러닝 기반의 개선된 YOLOv4S

황범연¹, 이상훈^{2*}, 이승현²

¹광운대학교 플라즈마바이오디스플레이학부 석사과정, ²광운대학교 인제니움학부 교수

Modified YOLOv4S based on Deep learning with Feature Fusion and Spatial Attention

Beom-Yeon Hwang¹, Sang-Hun Lee^{2*}, Seung-Hyun Lee²

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

²Professor, Ingenium College of Liberal Arts, KwangWoon University, Korea

요약 본 논문은 특징 융합과 공간 강조를 적용하여 작고 폐색된 객체 검출을 위한 개선된 YOLOv4S를 제안하였다. 기존 YOLOv4S은 경량 네트워크로 깊은 네트워크 대비 특징 추출 능력 부족하다. 제안하는 방법은 먼저 feature fusion으로 서로 다른 크기의 특징맵을 결합하여 의미론적 정보 및 저수준 정보를 개선하였다. 또한, dilated convolution으로 수용 영역을 확장하여 작고 폐색된 객체에 대한 검출 정확도를 향상시켰다. 두 번째로 spatial attention으로 기존 공간 정보 개선하여 객체간 구분되어 폐색된 객체의 검출 정확도를 향상시켰다. 제안하는 방법의 정량적 평가를 위해 PASCAL VOC 및 COCO 데이터셋을 사용하였다. 실험을 통해 제안하는 방법은 기존 YOLOv4S 대비 PASCAL VOC 데이터셋에서 mAP 2.7% 및 COCO 데이터셋에서 mAP 1.8% 향상되었다.

주제어 : 객체 검출, 공간 강조, 딥러닝, 특징 융합, 특징 피라미드, 옴로

Abstract In this paper proposed a feature fusion and spatial attention-based modified YOLOv4S for small and occluded detection. Conventional YOLOv4S is a lightweight network and lacks feature extraction capability compared to the method of the deep network. The proposed method first combines feature maps of different scales with feature fusion to enhance semantic and low-level information. In addition expanding the receptive field with dilated convolution, the detection accuracy for small and occluded objects was improved. Second by improving the conventional spatial information with spatial attention, the detection accuracy of objects classified and occluded between objects was improved. PASCAL VOC and COCO datasets were used for quantitative evaluation of the proposed method. The proposed method improved mAP by 2.7% in the PASCAL VOC dataset and 1.8% in the COCO dataset compared to the Conventional YOLOv4S.

Key Words : Object Detection, Spatial attention, Deep learning, Feature fusion, PAN, YOLO

*This article is extended from the conference paper presented at ICCT2021.

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

Received September 6, 2021

Accepted December 20, 2021

Revised September 23, 2021

Published December 28, 2021

1. 서론

컴퓨터 비전은 객체 검출, 추적, 그리고 초해상도 기법 등 다양한 분야에서 활발히 연구되었다[1,2]. 그 중 객체 검출은 객체의 위치를 파악하고 객체를 분류하는 과정이다. 최근 딥러닝 기반의 객체 검출 방법은 크게 one-stage와 two-stage 방법으로 구분된다. Two-stage 방법은 객체 검출 시 객체가 있을만한 영역을 찾는 region proposal 알고리즘을 사용한다. 선택된 영역을 기반으로 localization과 classification을 동시에 수행하는 방법이다. 대표적인 방법으로 Region based Convolutional Neural Networks(R-CNN)[3]가 있다. 반면 one-stage 방법은 localization과 classification을 동시에 처리하는 기법으로 two-stage 기법 대비 빠른 속도를 가진다. Single shot multibox detector(SSD)[4] 방법과 You only look once(YOLO)[5]방법 등이 있다. 하지만 기존 two-stage 방법 대비 낮은 정확도를 보여 초기 모델들은 깊이를 깊게 확장하는 방법으로 정확도를 개선하였다. 그러나 해당 방법은 연산량이 증가하여 요구되는 하드웨어 성능이 높아졌다. 최근 객체 검출은 연산량을 감소시켜 하드웨어 자원을 효율적 활용하며 검출 정확도를 향상 시키는 연구가 진행되고 있다. 대표적으로 Efficientdet[6] 및 Scaled YOLOv4[7] 모델이다. 본 논문은 YOLOv4[8]의 반복 횟수를 줄인 YOLOv4S를 기반으로 작고 폐색된 객체의 정확도를 향상시켰다. 먼저 Path aggregation network(PAN) [9]구조에 Spatial Attention[10]을 적용하여 공간 정보를 강조하였다. 그 결과 폐색된 객체의 검출 성능을 개선하였다. 두 번째로 Feature Fusion을 적용하여 서로 다른 scale의 특징 융합을 통해 저수준 및 고수준 각각의 정보 개선을 통해 검출 정확도를 개선하였다. 제안하는 방법의 평가를 위해 PASCAL VOC 및 COCO 데이터셋을 사용하여 학습 및 평가를 진행하였다. 이때 Spatial Attention의 최적의 검출 성능을 위하여 rate에 대한 절제 연구를 진행하였다. 본 논문은 제안된 환경에서 객체 검출 시 성능 향상에 기여할 것으로 기대된다.

2. 관련연구

2.1 YOLOv4

YOLOv4는 YOLOv3의 검출 속도 및 검출 정확도

향상을 위하여 Cross stage partial(CSP)구조[12]와 PAN구조를 적용하였다. 기존 YOLOv3의 Darknet53의 경우 dense block을 연속으로 쌓아 특징을 추출한다. 그러나 이 방법은 가중치의 중복 연산을 초래하여 추론 효율성이 떨어진다. 따라서, 이러한 문제점을 개선하기 위해 YOLOv4는 dense block을 대신하여 중복 연산을 최소화한 CSP block을 사용하였다. 또한, 기존 YOLO의 부족한 특징 활용 능력 개선을 위하여 Spatial pyramid pooling(SPP) 및 PAN 구조를 결합하였다. 그 결과 기존의 부족한 공간 정보 개선 및 서로 다른 scale을 활용하여 검출 정확도가 향상되었다. YOLOv4는 YOLOv3 대비 작은 객체에 대해 검출 정확도 향상 및 검출 속도를 개선하였다. 또한, YOLOv4는 경량화를 위하여 CSPblock 내부 Densblock의 반복 횟수를 1회로 고정 및 입력 채널을 낮춘 경량화 모델인 YOLOv4S가 존재한다. 다음 Fig. 1은 YOLOv4의 구조이다.




Fig. 1. YOLOv4 structure

2.2 Cross Stage Partial Network




Fig. 2. Dense block and CSP block

CSPNet은 네트워크의 최적화 과정 중 발생하는 가중치 중복 문제를 해결을 위해 제안된 네트워크이다. 기존의 base layer를 두 개의 부분으로 나누어 cross stage 계층에서 나누어진 가중치 정보를 결합하였다. 결과 기존의 발생하는 기울기 중복 연산 문제를 해결하였다. 기존 구조 대비 중복된 기울기 연산을 감소시켜

정확도 향상 및 추론 효율성을 개선하였다. Fig. 2의 (a)는 기존의 dense block 구조이며 (b)는 CSPblock의 구조이다.

3. 제안하는 방법

본 논문에서는 특징 융합과 공간 강조를 적용한 개선된 YOLOv4S를 제안하였다. 제안하는 방법은 서로 다른 scale의 특징 맵의 저수준 정보와 의미론적 정보를 결합하여 PAN구조에서 손실된 작은 객체에 대한 정보를 개선하였다. 또한, PAN 구조에 Spatial Attention을 적용하여 공간 정보 강조하였다. 그 결과 제안하는 방법은 폐색된 객체 검출 정확도 및 검출 속도 모두 개선하였다. Fig. 3은 제안하는 방법의 구조이다.




Fig. 3. Proposed method

3.1 특징 융합 모듈

제안하는 Feature Fusion 모듈은 두 가지 방법을 적용하여 작은 객체에 대해 검출 정확도 향상 및 공간 정보를 개선하였다. 첫 번째로 고수준의 의미론적 정보와 저수준의 정보 융합하여 작은 객체 검출을 위한 특징 정보를 개선하였다. 두 번째로 공간 정보 개선을 위해 dilated convolution을 적용하였다. 그 결과 기존 대비 수용 영역을 확장하여 제안하는 방법은 공간 정보를 개선하고 작은 객체에 대해 적은 연산량으로 검출 정확도 및 검출 속도를 향상시켰다. Fig. 4와 식(1)는 제안하는 Feature fusion module(FFM)이다.

$$M_{FF} = Dilated(Upsample(Conv_{i+1}); Conv_i) \quad (1)$$

$$i \in \{3,4\}$$

식(1)의 M_{FF} 은 제안하는 방법의 특징 융합 모듈이다. Rate3의 dilated convolution을 적용하여 5×5 컨볼루션 크기의 수용 영역으로 넓혀 기존 컨볼루션 대비 적은 연산량으로 공간 정보를 개선하였다.




Fig. 4. Feature fusion module

3.2 공간 강조 모듈

폐색된 객체의 검출 정확도 향상을 위해서는 배경과 객체 간 구분이 필요하다. 따라서 공간 정보를 강조하여 폐색된 객체 검출 정확도를 향상시켰다. 제안하는 방법은 기존 PAN구조 내부 CSP block 구조를 Spatial attention module(SAM)과 결합시켰다. 기존의 객체 정보와 강조된 공간 정보의 결합을 통하여 공간 정보를 강조하였다. 그 결과 폐색된 객체의 검출 정확도가 개선되었다. Fig. 5와 식(2) 제안하는 SAM이다.

$$M_{SA}(F) = \sigma(f^{5 \times 5}(F_{AVG}; F_{MAX})) \quad (2)$$

식(2)의 M_{SA} 는 제안하는 방법의 공간 강조 모듈이다. 공간 정보 추출을 위해 특징 맵에 max-pooling 및 avg-pooling 연산을 통하여 적은 연산량으로 공간 정보를 추출하였다. 추출된 공간 정보를 시그모이드 활성화 함수를 통하여 정규화를 진행하였다.

정규화된 정보는 강조된 공간 정보와 기존 정보를 결합하여 공간 정보를 개선하였다.

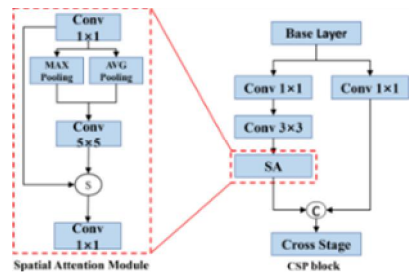


Fig. 5. Spatial attention module

3.3 손실 함수

제안하는 방법은 L_{Total} 를 최적화하는 방향으로 Stochastic gradient descent(SGD) optimizer을 통하여 각 계층의 가중치를 학습하였다. L_{Total} 는 각 클래스의 localization 손실 함수 및 분류 함수의 합이며 아래의 식(3)과 같이 정의하였다.

$$L_{Total} = L_{CloU} + L_{Conf} + L_{Class} \quad (3)$$

L는 식 (4-6)의 합이다.

$$L_{CloU} = 1 - IoU + \frac{P^2(b, b^{gt})}{c^2} + \alpha v \quad (4)$$

$$L_{Conf} = - \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{obj} [\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j)] - \lambda \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{noobj} [\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j)] \quad (5)$$

$$L_{Class} = \sum_{i=0}^{S^2} I_{i,j}^{obj} \sum_{c \in classes} [\hat{P}_i^j \log(P_i^j) + (1 - \hat{P}_i^j) \log(1 - P_i^j)] \quad (6)$$

식(4)는 L_{CloU} [13]은 기존 localization 손실 함수로 사용되던 L_1 , L_2norm 는 스케일 해석 및 비 직관성이 존재한다. 따라서 이를 개선하기 위해 Intersection over Union(IoU)을 고려한 손실 함수이다. 기존 손실 함수 대비 빠른 수렴 속도와 중첩비를 고려하여 객체 검출 정확도를 향상시켰다. 식(5)의 \hat{C} 은 신뢰도 점수이며 (6)의 \hat{P} 의 경우 예측 박스 점수이다. 식(5)와 (6)은 각각 객체의 신뢰도 점수 및 클래스 점수이다.

4. 실험 결과 및 고찰

제안하는 방법은 Pytorch 1.8.0 및 NVIDIA Geforce RTX 2070과 GTX TITANXp 통하여 실험을 진행하였다. 최적화는 SGD optimizer을 통해 각 계층의 가중치를 조절하였다. Learning rate 0.001 momentum 0.0937, weight decay 0.005 batch size 12 및 22 그리고 Epoch 300으로 사전 학습 없이 학습을 진행하였다. 모델 학습을 위해 PASCAL VOC 2007+12 (8,218장) [14] 훈련 데이터세트 및 COCO (118,287장) [15] 훈련 데이터세트를 사용하여 학습을 진행하였다. 평가는 각각 PASCAL VOC 2007 (4,952장) 테스트 데이터세트 및 COCO 2017 (4,952장) 테스트 데이터세트로 정량적 평가를 진행하였다. 식(7)과 같이 Average precision(AP)으로 성능을 평가하며 식(8)과

같이 전체 클래스의 평균값을 사용해 다른 모델과의 비교를 진행하였다.

$$AP = \sum (r_{n+1} - r_n) P_{interp}(r_{n+1}) \quad (7)$$

$$P_{interp}(r_{n+1}) = \max_{\tilde{r} \geq r_{n+1}} P(\tilde{r})$$

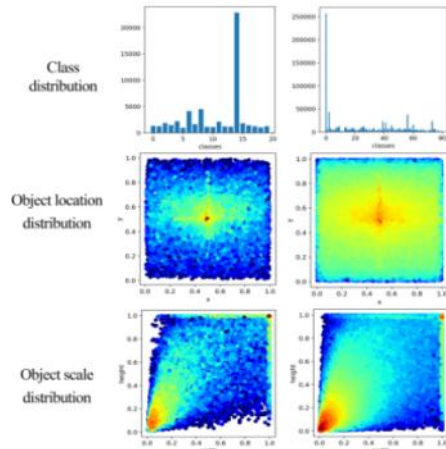
$$mAP = \frac{1}{N} \sum_{i=1}^n AP_i \quad (8)$$

4.1 PASCAL VOC

제안하는 모델 평가를 위해 PASCAL VOC 2007 테스트 데이터 세트를 사용하였다. PASCAL VOC 데이터 세트는 총 20개의 클래스를 가지며 Superclass라는 4개의 범주로 Person, Animal(Bird, Cat, Cow, Dog, Horse, Sheep), Vehicle(Aeroplane, Bicycle, Boat, Bus, Car, Motorbike, Train), Indoor(Bottle, Chair, Dining table, Potted plant, Sofa, TV) 구성된다.

4.1.1 Anchor scale

기존 YOLOv4S은 COCO 데이터세트를 기준으로 앵커 비율을 설정하였다. Fig. 6처럼 VOC 데이터세트의 경우 COCO 데이터세트 대비 객체의 위치 및 객체의 비율이 높다. 따라서 K-means clustering 알고리즘을 사용하여 재설정된 앵커는 다음 Table 1과 같다. Table 1을 보면 기존 앵커 비율대비 PASCAL VOC 기반 앵커가 큰 것을 알 수 있다.



(a) PASCAL VOC (b) COCO

Fig. 6. Dataset object distribution

Table 1. Anchor scale

Method	Small	Middle	Large
YOLOv4S	[12, 16] [19, 36] [40, 28]	[36, 75] [76, 55] [72, 146]	[142, 110] [192, 243] [459, 401]
Proposed	[23, 32] [49, 57] [54, 132]	[121, 103] [107, 225] [183, 215]	[359, 170] [240, 338] [420, 315]

4.1.2 Compared to other models

Table 2. Compared to model in PASCAL VOC

Method	Input Size	FPS	mAP
Faster R-CNN	1000 × 600	7	73.2
SSD512	512 × 512	22	76.8
YOLOv4S	512 × 512	85.3	73.6
Proposed	512 × 512	91.7	76.3

Table 2는 PASCAL VOC 2007+12 훈련 데이터 세트로 학습한 딥러닝 기반 객체 검출 모델의 성능 비교한 표이다. 제안하는 방법은 FFM과 SAM을 적용하여 작고 폐색된 객체 검출 정확도를 향상시켰다. 기존 모델과 비교하여 mean Average precision(mAP)가 약 2.7% 및 FPS 약 6.4 향상되었다. 다른 검출 모델인 SSD512와 비교하여 제안하는 방법은 작고 폐색된 객체에 한정되어 검출 정확도 향상을 위해 큰 객체에 대해 AP가 감소하였다. 그 결과 SSD512 대비 mAP가 약 0.5 정도 낮다. 하지만, SAM을 CSP 구조 내부에 적용하여 적은 연산량 증가 대비 추론시간을 개선하여 약 5배 빠른 검출 속도로 실시간 검출 성능을 가진다.




Fig. 7. PASCAL VOC detection result

Fig. 7은 기존의 YOLOv4S과 제안하는 방법의 검출 결과이다. 기존 방법은 공간 정보가 부족하여 폐색된

객체인 Indoor 클래스의 검출이 어렵고, 특징 활용 능력이 부족해 작은 객체 검출이 어렵다. 하지만 제안하는 방법은 FFM과 SAM를 적용하여 특징 활용 능력 향상 및 공간 정보 개선하였다. 그 결과 기존에 검출이 어려운 작고 폐색된 객체 검출 성능이 향상되었다.

4.1.3 Ablation study

Table 3. Ablation study on SAM rate

Rate	mAP
3	0.758
5	0.760
7	0.756

다음은 제안하는 방법의 SAM의 rate 변화에 따른 검출 정확도에 관한 절제 연구를 진행하였다. 기존 모듈은 max pooling 및 avg pooling 이후 컨벌루션 rate 7를 사용하여 공간 정보를 압축하였다. 하지만 절제 연구 결과 Table 3과 같이 rate 5 이상을 사용하면 오히려 성능이 감소하였다. 이는 rate가 일정량 이상 커지면 공간 정보 추출 이후 공간 정보 정제를 방해하는 것으로 보여 준다. 반대로 낮은 경우에도 비슷한 결과를 보여주었다. Table 3은 SAM의 rate 변화에 따른 mAP이다.

4.2 COCO

제안하는 모델 평가를 위해 COCO 테스트 데이터 세트를 사용하였다. 총 80개의 클래스를 가지며 12개의 Superclass인 Person, Vehicle, Outdoor, Animal, Accessory, Sports, Kitchen, Food, Furniture, Electronic, Appliance, Indoor로 구성되어있다. COCO 데이터세트는 $AP_{50} \sim AP_{95}$ 의 평균을 사용하여 평가를 진행하였다.

Table 4. Compared to model in COCO

Method	FPS	Param (M)	mAP	Small (AP)
SSD512	22	38M	22.8	10.9
YOLOv3	35	65M	31.0	15.2
YOLOv4S	86	7.9M	33.4	16.1
Proposed	89	8.4M	35.2	17.1

Table 4는 COCO 훈련 데이터세트로 학습한 딥러닝 기반 객체 검출 모델의 성능 비교 표이다. COCO

데이터세트는 PASCAL VOC 대비 작은 객체와 폐색된 객체의 비율이 높은 데이터세트이다. 이미지 별 평균 객체가 7개 이상 존재하며 최대 63개의 객체가 존재한다. 또한, Table 4의 Small의 경우 객체 크기가 32^2 보다 작은 객체를 기준으로 선정되었다. 제안하는 방법은 YOLOv3와 비교하여 mAP가 약 1.8% 및 작은 객체의 검출 정확도가 약 1.9% 향상되었다. 이는 기존 방법 대비 FFM 모듈을 통해 PAN 진행 중 손실된 작은 객체의 정보를 개선하여 성능이 향상되었다. 또한, SAM을 PAN 내부 CSP 구조를 개선하여 작고 폐색된 객체에 대해 검출 정확도 및 추론 시간을 개선하였다.

Fig. 8은 기존 모델과 제안하는 방법의 COCO 데이터 세트 검출 결과 비교이다. 기존의 모델은 공간 정보가 부족하여 person 객체와 frisbee 객체 검출하지 못하였다. 하지만 제안하는 방법은 SAM을 적용하여 공간 정보 개선을 통해 객체 간의 정보를 구분 가능하다. 또한, FFM을 적용하여 작은 객체에 대해 저수준 정보와 고수준의 의미론적 정보를 결합하였다. 그 결과 작고 폐색된 객체 검출 성능이 향상되어 기존의 검출하지 못한 person 객체 검출이 가능하였다.



Fig. 8. COCO detection result

5. 결론

본 논문에서는 Feature Fusion과 Spatial Attention을 적용하여 객체 검출 성능을 개선한 YOLOv4S를 제안하였다. 제안한 방법은 기존 모델 대비 작은 객체에 대한 검출 정확도를 향상시켰다. 또한, 기존 YOLOv4S는 경량화로 특징 활용 능력이 부족하여 검출 정확도가 낮은 문제가 있다. 제안하는 방법은 Feature Fusion으로 특징맵 개선 및 dilated convolution으로 수용 영역을 확장하여 공간 정보를 개선하였다. 또한, Spatial Attention을 적용하여 공간 정보를 강조하여 폐색된 객체의

검출 정확도를 향상시켰다. 제안하는 방법은 PASCAL VOC와 COCO 데이터세트로 학습 및 평가를 진행하였다. 실험을 통해 제안하는 방법은 기존 대비 작고 폐색된 객체 검출 정확도 및 검출 속도를 개선하였다. 향후 연구로 PAN 구조를 개선하여 특징 추출과정에서 연산량을 줄이면서 검출 성능 향상을 위한 연구의 필요성이 사료된다.

REFERENCES

- [1] S. Shin, S. Lee & H. Han. (2021). A Study on Residual U-Net for Semantic Segmentation based on Deep Learning. *Journal of Digital Convergence*, 19(6), 251-258.
- [2] C. S. Park, S. H. Lee & H. H. Han. (2021). A Study on Lightweight Model with Attention Process for Efficient Object Detection. *Journal of Digital Convergence*, 19(5), 307-313.
- [3] K. He, G. Gkioxari, P. Dollar & R. Girshick. (2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 386-397.
- [4] J. Qu, C. Su, Z. Zhang & A. Razi. (2020). Dilated convolution and feature fusion SSD network for small object detection in remote sensing images. *IEEE Access*, 8, 82832-82843.
- [5] S. Shin, H. Han & S. H. Lee. (2021). Improved YOLOv3 with duplex FPN for object detection based on deep learning. *The International Journal of Electrical Engineering & Education*.
- [6] M. Tan, R. Pang & Q. V. Le. (2020). EfficientDet: Scalable and Efficient Object Detection. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 10778-10787.
- [7] C. Y. Wang, A. Bochkovskiy & H. Y. M. Liao. (2020). Scaled-YOLOv4: Scaling Cross Stage Partial Network. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 13029-13038).
- [8] A. Bochkovskiy, C. Y. Wang & H. Y. M. Liao. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv preprint arXiv:2004.10934*.
- [9] S. Liu, L. Qi, H. Qin, J. Shi & J. Jia. (2018). Path Aggregation Network for Instance Segmentation. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 8759-8768.
- [10] Woo, S., Park, J., Lee, J. Y., & Kweon, I. S. (2018). CBAM: Convolutional block attention module. In

Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 11211 LNCS (pp. 3-19).

- [11] J. Redmon & A. Farhadi. (2018). YOLOv3: An Incremental Improvement. ArXiv.
- [12] C. Wang, H. M. Liao, I. H. Yeh, Y. Wu, P. Chen & J. W. Hsieh. (2019). CSPNet: A New Backbone that can Enhance Learning Capability of CNN. *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops* (pp. 390-391).
- [13] Z. Zheng, P. Wang, W. Liu, J. Li, R. Ye & D. Ren. (2020). Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(7), 12993-13000.
- [14] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn & A. Zisserman. (2010). The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2), 303-338.
- [15] T. Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár & C. L. Zitnick. (2014). Microsoft COCO: Common Objects in Context. *In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 8693 LNCS* (Issue PART 5, pp. 740-755).

황 범 연(Beom-Yeon Hwang) [학생회원]



- 2021년 2월 : 광운대학교 컴퓨터 공학과(학사)
- 2018년 8월 ~ 현재 : 광운대학교 대학원 플라즈마바이오 디스플레이학과(석사과정)

· 관심분야 : 객체 검출, 딥러닝, 영상처리
 · E-Mail : clown1320@kw.ac.kr

이 상 훈(SangHun Lee) [종신회원]



- 1983년 2월 : 광운대학교 응용전자 공학과(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, 영상처리와 생체 인식, IOT 영상처리, 딥러닝
 · E-Mail : leesh58@kw.ac.kr

이 승 현(Seung-Hyun Lee) [정회원]



- 1984년 2월 : 광운대학교 응용전자 공학과(공학사)
- 1986년 2월 : 광운대학교 전자공학과 (공학석사)
- 1993년 2월 : 광운대학교 전자공학과 (공학박사)

· 관심분야 : 홀로그래피, 실감콘텐츠
 · E-Mail : shlee@kw.ac.kr