

# 딥러닝을 이용한 실시간 말벌 분류 시스템

## Real Time Hornet Classification System Based on Deep Learning

정 윤 주\*, 이 영 학\*, 이스라필 안사리\*\*, 이 철 희\*\*\*★

Yunju Jeong\*, Yeung-Hak Lee\*, Israfil Ansari\*\*, Cheol-Hee Lee\*\*\*★

### Abstract

The hornet species are so similar in shape that they are difficult for non-experts to classify, and because the size of the objects is small and move fast, it is more difficult to detect and classify the species in real time. In this paper, we developed a system that classifies hornets species in real time based on a deep learning algorithm using a boundary box. In order to minimize the background area included in the bounding box when labeling the training image, we propose a method of selecting only the head and body of the hornet. It also experimentally compares existing boundary box-based object recognition algorithms to find the best algorithms that can detect wasps in real time and classify their species. As a result of the experiment, when the mish function was applied as the activation function of the convolution layer and the hornet images were tested using the YOLOv4 model with the Spatial Attention Module (SAM) applied before the object detection block, the average precision was 97.89% and the average recall was 98.69%.

### 요 약

말벌 종은 모양이 매우 유사하기 때문에 비전문가가 분류하기 어렵고, 객체의 크기가 작고 빠르게 움직이기 때문에 실시간으로 탐지하여 종을 분류하는 것은 더욱 어렵다. 본 논문에서는 바운딩 박스를 이용한 딥러닝 알고리즘을 기반으로 말벌 종을 실시간으로 분류하는 시스템을 개발하였다. 훈련 영상의 레이블링 작업 시 바운딩 박스 안에 포함되는 배경 영역을 최소화하기 위하여 말벌의 머리와 몸통 부분만을 선택하는 방법을 제안한다. 또한 실시간으로 말벌을 탐지하고 그 종을 분류할 수 있는 최선의 알고리즘을 찾기 위하여 기존의 바운딩 박스 기반 객체 인식 알고리즘들을 실험을 통하여 비교한다. 실험 결과 컨볼루션 레이어의 활성화함수로 mish 함수를 적용하고, 객체 검출 블록 전에 공간집중모듈(Spatial Attention Module, SAM)을 적용한 YOLOv4 모델을 사용하여 말벌 영상을 테스트한 경우 평균 97.89%의 정밀도(Precision)와 98.69%의 재현율(Recall)을 나타내었다.

*Key words : Hornet classification, Deep learning, Object Detection, Object labeling, Mish function, Spatial attention module*

\* SW Convergence Education Center, Andong National University

\*\* Smart Vision Tech.

\*\*\* Dept. of Computer Engineering, Andong National University

★ Corresponding author

E-mail : chlee@andong.ac.kr, Tel : +82-54-820-6190

※ Acknowledgment

This work was supported by a Research Grant of Andong National University.

Manuscript received Dec. 2, 2020; revised Dec. 23, 2020; accepted Dec. 28, 2020.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

### I. 서론

말벌은 꽃가루를 옮겨주거나 생태계의 중간 포식자이지만 양봉업계는 최대의 해충으로 벌통의 특징상 가장 큰 종류인 장수말벌 20여 마리가 1시간 만에 꿀벌 10만 마리를 죽일 수 있다고 한다. 일반적인 말벌 퇴치 방법은 말벌 유인제를 개발하는 방법[1], 꿀벌통 일체형의 포획시스템을 개발하는 방법[2] 등이 있다. 또한 최근 이철희 등은 실시간 말벌 모니터링 시스템의 구축을 위하여 YOLOv2 모델에 AlexNet, VGG19, GoogLeNet, ResNet50 등의 특징추출신경망을 합성하여 말벌 인식의 성능을 평가하는 연구를 수행하였다[3].

객체를 검출하는 방법에는 특징 기반의 머신러닝을 이용하는 방법과 딥러닝을 이용하는 방법으로 크게 나눌 수 있다. 특징 기반 방법의 검출 순서는 다음과 같다. 먼저 대상 객체를 훈련하기 위해 객체로부터 다양한 특징 추출 알고리즘을 이용하여 특징을 추출한다. 주로 사용되는 특징 검출 알고리즘은 HOG (Histogram of oriented gradients)[4], LBP(Local binary pattern)[5], Haar-like[6] 등이 있다. 다음 과정은 추출된 특징을 이용하여 최적화된 분류 시스템을 만들어 내는 것이다. 분류 시스템으로 자주 사용되는 것은 SVM(Support Vector machine)[7], Adaboost[8], haar classifier(혹은 Cascade classifier) [9] 등이 있다. 마지막으로 생성된 분류 시스템에 테스트 영상을 입력하면 훈련된 객체가 검출되는 것이다.

의료장비, 자율주행자동차, 대형마트 등에서 널리 활용되는 딥러닝은 일반적으로 R-CNN, Fast R-CNN [10], Faster R-CNN[11], Mask R-CNN[12] 등의 2단계 탐지 알고리즘과 YOLO[13], SSD 등의 1단

계 탐지 알고리즘으로 구분된다. 2단계 탐지 알고리즘들은 먼저 클래스와 상관없이 객체를 포함할 가능성이 높은 영역을 제안(Region Proposal)한 후에 객체를 분류(Region Classification)하는 2단계 검출기로 객체 검출과 분류에 대한 정확도는 높지만 속도가 느려서 실시간 응용에 적합하지 않다. 반면 YOLO가 대표하는 1단계 검출 알고리즘은 위의 두 과정이 동시에 이루어지기 때문에 2단계 검출 알고리즘에 비하여 정확도는 다소 낮지만 실시간 처리에 적합할 정도로 속도가 빠르다는 장점이 있다.

본 논문에서는 영상기반으로 인공지능을 이용한 조기 말벌 방제 방법을 연구하였다. 실시간으로 말벌의 종을 분류하는 것을 목표로 하는 본 논문에서는 1단계 검출 알고리즘에 속하는 알고리즘들을 비교 분석하여 최적의 실시간 말벌 분류 시스템을 개발하였다.

본 논문의 구성은 2장에서 딥러닝 기반의 객체 검출 알고리즘들을 설명하였으며, 3장에서는 학습 영상의 레이블링 방법에 따른 실험 결과를 비교 분석하고, YOLOv4[14]를 포함한 기존의 여러 가지 검출 알고리즘들을 이용하여 말벌을 분류한 결과를 비교 분석하였다. 마지막으로 5장에는 결론을 기술하고 본 논문을 마무리하였다.

### II. 본론

2015년에 R-CNN 기반 알고리즘들의 느린 처리 속도를 보완하기 위하여 등장한 YOLO 모델은 예측하고자 하는 영상을  $N \times N$ 의 그리드 셀로 나누고 각각의 셀마다 한 개의 객체를 예측한다. 그리고 일정한 개수의 바운딩 박스를 통하여 객체의 위치




Fig. 1. The model architecture for hornet classification.

그림 1. 말벌 분류를 위한 모델 구조도

와 크기를 파악한다. 하지만 하나의 셀에 여러 개의 객체가 겹쳐 있을 경우 탐지하지 못하고 놓치게 되며 검출된 객체의 위치가 부정확하다는 단점이 있다. 특히 작은 객체의 인식에 적합하지 않다는 평가를 받는다.

YOLO의 한계를 극복하기 위하여 등장한 YOLOv2는 입력 영상의 해상도를 높이고 배치 정규화(Batch Normalization)를 적용하였다. 또한 완전연결층(Fully-connected layers)을 제거하고 완전 컨볼루션 네트워크(Fully Convolution Network, FCN)의 형태를 사용하여 객체 분류의 성능을 향상시켰다.

YOLOv3[15]는 바운딩 박스 예측 단계에 기존 YOLO의 앵커 박스(Anchor box) 개념에 더하여 바운딩 박스마다 객체 점수(Objectness score)를 예측하고 앵커 박스와 정답 박스(Ground truth box) 사이의 IOU(Intersection Over Union)가 가장 높은 박스를 1로 매칭시키는 매칭 전략을 도입하였다. 즉, IOU가 가장 높은 박스에 대해서만 계산을 하고 나머지 박스는 무시하는 전략이다. 클래스 예측 단계에서는 각 Box에 다중 레이블 분류(multi-label classification)를 사용하여 바운딩 박스가 포함할 수 있는 클래스를 예측하였다. 또한 성능 향상을 위하여 기존의 softmax 대신 로지스틱 분류기(logistic classifier)를 사용하였다. 그림 2에서 YOLOv3의 객체 인식 및 분류의 아키텍처를 확인할 수 있다.




Fig. 2. Architecture of YOLOv3 [16].  
그림 2. YOLOv3의 구조도

YOLOv4[14]는 컴퓨팅 파워가 그리 높지 않은 환경에서 1-GPU를 이용하여 실시간으로 객체 검출을 목표로 연구되었다. 이를 위하여 연산량을 줄이기 위한 노력보다는 병렬적으로 최적화된 계산을 할 수 있도록 하였다. 또한 작은 객체의 검출에 취약한 기존 YOLO 알고리즘의 문제를 해결하기 위하여 입력 영상의 해상도를 512×512(기존 224×224, 256×256)로 증가시켰다.

YOLOv3에서 대부분의 아이디어를 도입한 YOLOv4는 성능 향상을 위하여 학습 단계에서 데이터 증

대, 손실함수, 정규화 등의 방법으로 훈련 비용을 증가시켜서 정확도를 높이기 위한 Bag of Freebies를 도입하였고, 수용필드 강화하여 검출 성능을 높이기 위한 피라미드형 풀링 모듈(Spatial Pyramid Pooling, SPP) 제안, 공간적 집중 매커니즘(Spatial Attention Module, SAM) 도입, 활성화 함수를 기존의 Leaky ReLU에서 Mish함수로 변경 등의 Bag of Specials 기법을 이용하여 검출 성능을 향상시켰다. 특히 그림 3과 식 (1)에 표시된 Mish 활성화 함수는 학습의 안정성, 평균 정확도 및 최고 정확도에서 성능을 전반적으로 개선시킨다고 평가를 받는다[17].

$$Mish f(x) = x \tanh(\text{softplus}(x)) = x \tanh(\ln(1 + e^x)) \quad (1)$$

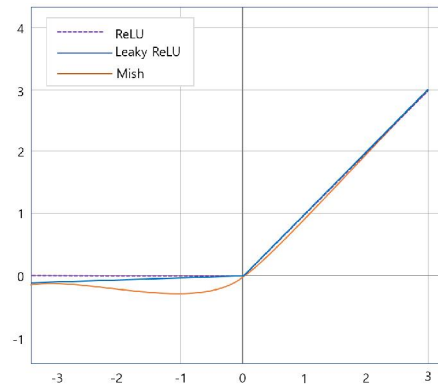


Fig. 3. ReLU, Leaky ReLU and Mish Activation Func.  
그림 3. ReLU, Leaky ReLU 및 Mish 활성화 함수

마지막으로 비 최대 억제(Non Maximum Suppression) 기법을 이용하여 예측된 바운딩 박스들 중에서 중복된 것을 하나로 통합한다. 그림 1에서 객체 검출을 위한 YOLOv4 아키텍처를 확인할 수 있다.

본 논문에서는 YOLOv3와 YOLOv4의 여러 기법들을 비교하여 실시간으로 말벌을 검출하고 분류하기 위한 최적의 모델을 찾는다. 또한 모델 선정 못지않게 학습 영상이 포함하고 있는 객체 레이블링의 중요성을 강조하고 이를 입증할 수 있는 연구를 수행하였다.

### III. 실험 및 결과

본 논문은 실시간으로 말벌을 감지하고 그 종을 분류하는 시스템에 대한 연구를 수행하였다. 연구에서 사용한 하드웨어 시스템은 Intel Core(TM) i9-7920

(2.90GHz), 메모리 64GB, Geforce TITAN-X이며, 주요 소프트웨어 시스템은 Visual Studio 및 python 3.7이다. 또한 본 연구에 사용한 말벌 영상은 2,986개의 등검은말벌, 말벌, 장수말벌 및 털보말벌 영상이며, 실험에 앞서 안동대학교 Bee Lab의 말벌 전문가로부터 각 말벌의 종별 분류에 대한 사전 검증을 받았다. 2,986개의 영상 중에서 2,590개의 영상을 랜덤하게 섞은 후 4:1의 비율로 학습(train)과 평가(validation)를 위하여 나누어 사용하고, 나머지 396개의 영상을 테스트에 사용하였다.

1. 데이터 레이블링

머신러닝 학습 방법 중에서 지도학습은 데이터에 대한 명시적인 정답인 레이블을 알려주면서 학습시키는 방법이다. 지도학습의 정확도를 높이기 위하여 그동안 많은 연구원들이 최고의 모델을 설계하기 위하여 끊임없이 노력해왔다. 하지만 모델을 설계하는 작업 못지않게 좋은 데이터를 획득하고 정확하게 레이블을 설정하는 작업 또한 중요하다. 인공지능이 아무리 발전하여도 데이터 레이블링 작업을 기계가 대신할 수 없으며, 또한 아무리 우수한 모델이라도 훈련 영상 내의 객체에 대하여 잘못된 위치 정보와 카테고리를 설정하여 학습에 적용한다면 좋은 결과를 얻을 수 없을 것이다. 따라서 데이터 레이블링 작업은 AI 성능에 결정적인 영향을 미치는 작업이다.

본 논문에서는 영상에서 말벌 객체를 레이블링할 때 설정하는 영역에 따라서 탐지 및 분류 정확도의 차이가 있는지를 알아보기 위하여 두 가지 방법으로 객체 레이블링을 수행하였다. 첫 번째는 그림 4의 (a)와 같이 말벌의 머리, 몸, 날개 및 다리 영역 전체를 선택하여 레이블링을 하였다. 두 번째는 그림 4의 (b)와 같이 말벌의 머리와 몸 영역만을 선택하였다.




Fig. 4. Data labeling - Object area setting, (a) Head-body-wing-legs, (b) Head & body. 그림 4. 데이터 레이블링 - 객체 영역 설정 (a) 머리-몸-날개-다리, (b) 머리와 다리

Alexey B. 등이 제공하는 COCO 사전 학습 파일인 YOLOv4.weights[21]를 이용하여 전이 학습을 수행한 결과를 그림 5에서 확인할 수 있다.




Fig. 5. Comparison of average loss function and mAP according to labeling method, (a) Head-body-wing-legs, (b) Head & body. 그림 5. 레이블링 방법에 따른 평균 손실함수와 mAP의 비교 (a) 머리-몸-날개-다리, (b) 머리와 다리

말벌의 레이블링 영역을 머리, 몸, 날개 및 다리 전체 영역으로 설정할 때의 손실함수는 2.0338이며 mAP는 40.5%에 불과하였다. 하지만 레이블링 영역을 머리와 몸으로 제한하였을 때 손실함수는 2.0383으로 유의미한 차이는 없었지만 mAP는 96.2%로 크게 증가하였다. 이는 말벌의 종 사이의 주요 특징은 날개와 다리보다는 머리와 몸에서 뚜렷하게 확인할 수 있을 뿐만 아니라, 날개와 다리 사이의 배경 영역이 학습에 방해 요소로 작용하기 때문이라고 판단된다.

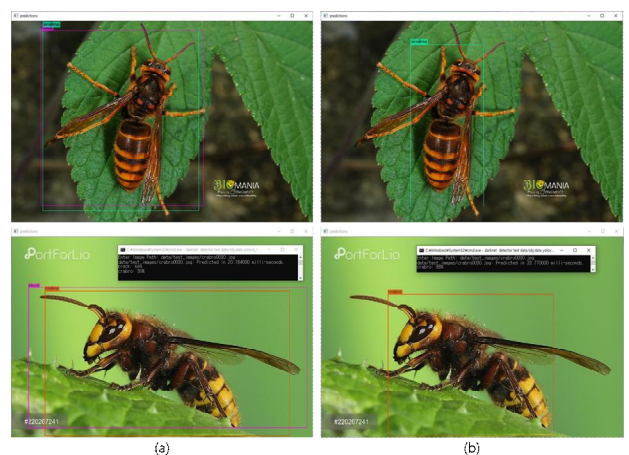


Fig. 6. Test results according to labeling method, (a) Head-body-wing-legs, (b) Head & body. 그림 6. 레이블링 방법에 따른 테스트 결과 (a) 머리-몸-날개-다리, (b) 머리와 다리

레이블링 방법에 따른 두 가지 학습의 테스트 결과를 그림 6에서 확인할 수 있다. 그림 6은 위에서부터 아래로 털보말벌(V. Simillima)과 말벌(V. Crabro)이 포함된 영상이다. (a)열의 위쪽 이미지는 등검은말벌 46%, 털보말벌 54%로 예측되어 높은 컨피던스 점수를 선택하면 털보말벌로 제대로 분류하였다고 할 수 있으나 아래쪽 이미지는 등검은말벌 69%, 말벌 30%로 예측되어 잘못 분류되었다고 볼 수 있다. 하지만 (b)열은 위에서부터 아래로 털보말벌과 말벌이 포함된 영상으로 각각 97%와 99%의 높은 컨피던스 점수로 제대로 예측되었다. 별도로 보관해두었던 396개의 영상을 테스트한 결과를 표 1에서 확인할 수 있다.

Table 1. Test results according to labeling method.

표 1. 레이블링 방법에 따른 테스트 결과

	Labeling Method (a)			Labeling Method (b)		
	TP	FP	FN	TP	FP	FN
V. Velutina	114	8	3	115	5	2
V. Crabro	143	9	6	149	6	2
V. Mandarinina	85	2	2	86	3	2
V. Simillima	95	6	2	101	2	2

영상에서 객체를 인식하고 분류를 할 때 주로 사용하는 지표로 확률통계 분야의 정밀도(precision)와 재현율(recall)이 있다.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

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

등검은말벌을 기준으로 식 (2)의 정밀도와 식 (3)의 재현율을 설명하면 다음과 같다. 정밀도는 등검은말벌로 분류된 모든 객체의 수에 대하여 등검은말벌이 등검은말벌로 정답 분류된 비율이고, 재현율은 모든 등검은말벌 객체수에 대하여 등검은말벌이 등검은말벌로 정답 분류된 비율을 의미한다. 두 가지 레이블링 방법으로 네 가지 종의 말벌에 대하여 테스트한 결과 정밀도와 재현율의 평균은 표 2와 같다.

결과적으로 말벌을 레이블링할 때 머리, 몸, 날개 및 다리 전체 영역을 선택하는 것보다 머리와 몸 영역만을 선택할 때 더 높은 컨피던스 점수로 더

Table 2. Comparison of precision and recall according to labeling method.

표 2. 레이블링 방법에 따른 정밀도와 재현율의 비교

	Labeling Method (a)		Labeling Method (b)	
	Precision	Recall	Precision	Recall
V. Velutina	0.9344	0.9743	0.9583	0.9829
V. Crabro	0.9408	0.9597	0.9613	0.9868
V. Mandarinina	0.9770	0.9770	0.9663	0.9773
V. Simillima	0.9406	0.9726	0.9806	0.9806

정확하게 종을 분류한다고 할 수 있다.

## 2. 말벌 분류를 위한 사전 학습 모델의 성능 비교

본 연구에서는 실시간 말벌의 검출과 종의 분류에 가장 적합한 모델을 찾기 위하여 YOLOv3 모델, YOLOv4 모델 및 SAM을 적용한 YOLOv4 모델의 성능을 비교하였으며 그 결과를 표 3과 표 4에서 확인할 수 있다.

Table 3. Test results according to YOLO models

표 3. YOLO 모델에 따른 테스트 결과

	YOLOv3			YOLOv4			YOLOv4 (SAM-Mish)		
	TP	FP	FN	TP	FP	FN	TP	FP	FN
V. Velutina	107	4	15	115	5	2	118	3	3
V. Crabro	130	12	22	149	6	2	150	3	1
V. Mandarinina	80	5	6	86	3	2	88	2	1
V. Simillima	82	5	7	101	2	2	102	3	1

Alexey B. 등이 주장하는 것처럼 YOLOv4는 객체 검출의 정밀도와 재현율에서 모두 YOLOv3에 비하여 월등히 우수하다. 특히 컨볼루션 레이어의 전 과정에서 Mish 활성화 함수를 사용하고, 객체

Table 4. Comparison of precision and recall according to YOLO models.

표 4. YOLO 모델에 따른 정밀도와 재현율의 비교

	YOLOv3		YOLOv4		YOLOv4 (SAM-Mish)	
	Prec.	Reca.	Prec.	Reca.	Prec.	Reca.
V. Velutina	0.964	0.877	0.958	<b>0.982</b>	<b>0.975</b>	0.975
V. Crabro	0.915	0.855	0.961	0.986	<b>0.980</b>	<b>0.993</b>
V. Mandarinina	0.941	0.930	0.966	0.977	<b>0.978</b>	<b>0.989</b>
V. Simillima	0.943	0.921	<b>0.981</b>	0.980	0.971	<b>0.990</b>

검출 전 단계에서 공간적 집중 매키니즘(SAM)을 적용한 YOLOv4 모델의 말벌 검출과 분류 정확도가 더욱 우수하다.

그림 7에서 YOLOv3와 YOLOv4 모델을 이용한 말벌 검출 및 종 분류 결과의 차이를 확인할 수 있다.



Fig. 7. Comparison of object detection results of YOLOv3 and YOLOv4, (a) YOLOv3, (b) YOLOv4

그림 7. YOLOv3와 YOLOv4의 객체 검출 결과 비교

#### IV. 결론

본 논문에서는 말벌의 공격에 의한 꿀벌의 피해를 조기에 방제하기 위하여 영상 기반으로 딥러닝을 이용하여 실시간 말벌 모니터링 및 분류 방법을 연구하였다. 말벌류의 학습 영상 준비 단계에서 데이터 레이블링의 중요성을 강조하기 위하여 말벌 객체 영역을 머리, 몸, 날개 및 다리 전체를 포함하는 방법과 머리와 몸 부분만을 포함하는 방법으로 구분하여 그 결과를 비교하였다. 실험 결과 머리와 몸 부분만을 레이블링 영역으로 포함시키는 경우가 검출율, 분류 정확도, 컨피던스 점수 등 모든 영역에서 성능이 좋다.

또한 실시간 말벌 검출과 분류에 더 적합한 모델을 찾기 위하여 YOLOv3 모델과 YOLOv4, YOLOv4 (SAM-Mish) 모델의 성능을 비교하였다. 비교 결과 YOLOv4(SAM-Mish) 모델의 정밀도와 재현율이 가장 높은 것으로 확인되었다. 본 연구의 향후 수행 과제는 말벌 모니터링 트랩을 제작하고 여러 종류의 말벌을 실시간으로 감시하면서 획득한 영상으로 대규모의 말벌 데이터베이스를 구축하고자 한다.

#### References

- [1] Young-Soo Kim, "Development of Natural Luring Liquid Against the Wasps inflicting Honeybees," *Journal of Apiculture*, Vol.21, No.1, pp.37-42, 2006.
- [2] Jin Sil Lee, "Development of trapping system for *Vespa velutina* and commercialization," *Korean Society Of Applied Entomology*, 2018.
- [3] Cheolhee Lee, Yunju Jeong, "Performance Evaluation of YOLO according to Based Feature Extraction Network in *Vespa* Detection," *Journal of Apiculture*, Vol.35, No.3, pp.149-159, 2020. DOI: 10.17519/apiculture.2020.09.35.3.149
- [4] Y. Lee, "Histogram of Oriented Gradients and Normalized Correlation Coefficient based Two-wheeler Detection System using Adaboost," *Advanced Science and Technology Letters*, Vol.129, pp.59-64, 2016. DOI: 10.14257/astl.2016.129.12
- [5] T. Ojala, M. Pietikäinen and D. Harwood, "A Comparative Study of Texture Measures with Classification Based on Feature Distributions," *Pattern Recognition*, Vol.29 No.1, pp.51-59, 1996. DOI: 10.1016/0031-3203(95)00067-4
- [6] P. Viola and M. J. Jones, "Rapid Object Detection using a Boosted Cascade of Simple Features," *CVPR 2001*, 2001.
- [7] X. Huang, S. Lei and J. Suykens, "Ramp loss linear programming support vector machine," *Journal of Machine Learning Research*, pp. 2185-2211, 2014. DOI: 10.5555/2627435.2670321
- [8] SCHAPIRE, Robert E. "Explaining adaboost," *Empirical inference. Springer, Berlin, Heidelberg*, pp.37-52, 2013. DOI: 10.1007/978-3-642-41136-6\_5
- [9] WILSON, Phillip Ian, "FERNANDEZ, John. Facial feature detection using Haar classifiers," *Journal of Computing Sciences in Colleges*, Vol.21, No.4, pp.127-133, 2006. DOI: 10.5555/1127389.1127416
- [10] Girshick, Ross. "Fast r-cnn," *Proceedings of the IEEE international conference on computer vision*. 2015.

- [11] Ren, Shaoqing, et al. "Faster r-cnn: Towards real-time object detection with region proposal networks," *Advances in neural information processing systems*. 2015.
- [12] He, Kaiming, et al. "Mask r-cnn," *Proceedings of the IEEE international conference on computer vision*. 2017.
- [13] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection," *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- [14] Bochkovskiy, Alexey, Chien-Yao Wang, and Hong-Yuan Mark Liao. "YOLOv4: Optimal Speed and Accuracy of Object Detection." *arXiv preprint arXiv:2004.10934*, 2020.
- [15] Redmon, Joseph, and Ali Farhadi. "Yolov3: An incremental improvement." *arXiv preprint arXiv:1804.02767*, 2018.
- [16] Chethan Kumar B, "YOLOv3 and YOLOv4: Multiple Object Detection for Surveillance Applications," *Proceedings of the Third International Conference on Smart Systems and Inventive Technology (ICSSIT 2020)*, pp.20-22, 2020.  
DOI: 10.21203/rs.3.rs-86158/v1
- [17] Misra, Diganta. "Mish: A self regularized non-monotonic neural activation function." *arXiv preprint arXiv:1908.08681*, 2019.
- [18] Alexey B., "YOLOv4 model zoo," <https://github.com/AlexeyAB/darknet/wiki/YOLOv4-model-zoo>.

---

## BIOGRAPHY

---

### Yunju Jeong (Member)



1991 : BS in Computer Science & Statistics, Andong National Univ.  
2000 : MS in Computer Engineering, Andong National Univ.  
2019 : PhD in Computer Engineering, Kyungpook National Univ.

2019~ : Teaching assistant professor in SW Convergence Education Center, Andong National Univ.

### Yeung-Hak Lee (Member)



1988 : BS degree in Electronic Engineering, Yeungnam Univ.  
1991 : MS degree in Electronic Engineering, Yeungnam Univ.  
2003 : PhD degree in Electronic Engineering, Yeungnam Univ  
1991~1995 : Research Engineer, LG Precision.

2005~2006 : Postdoc, Cardiff Univ.

2010~2016 : Professor, Kyungwoon Univ.

2017~ : Research Engineer, Andong National Univ.

2019~ : Teaching assistant professor in SW Convergence Education Center, Andong National Univ.

### Israfil Ansari (Member)



2019 : PhD in Computer Engineering, Andong National Univ.

2019 ~ : Research manager at Smart Vision Tech Inc.

### Cheol-Hee Lee (Member)



1995 : BS degree in School of Electronic and Electrical Engineering, Kyungpook National Univ.

1997 : MS degree in Electronic Engineering, Kyungpook National Univ.

2000 : PhD degree in Electronic Engineering, Kyungpook National Univ.

2000~2003 : Full-time lecturer, in Dept. of Computer Engineering, Kyungwoon Univ.

2003~current : Professor, Dept. of Computer Engineering, Andong National Univ.