

특집논문 (Special Paper)

방송공학회논문지 제24권 제2호, 2019년 3월 (JBE Vol. 24, No. 2, March 2019)

<https://doi.org/10.5909/JBE.2019.24.2.243>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

드론 영상 종합정보처리 및 분석용 시스템 개발

임 송 원^{a)}, 조 성 만^{a)}, 박 구 만^{a)‡}

Integrated Video Analytics for Drone Captured Video

SongWon Lim^{a)}, SungMan Cho^{a)}, and GooMan Park^{a)‡}

요 약

본 논문에서는 다양한 재난치안안전 임무 상황에서 적용할 수 있는 드론 영상 종합정보 처리 및 분석용 시스템을 제안한다. 제안하는 시스템은 드론에서 획득한 영상을 서버에 저장하고, 다양한 시나리오에 따른 영상 처리 및 분석을 수행한다. 각 임무에 따라 필요한 기능은 딥러닝을 활용하여 드론으로부터 확보하는 영상에서 영상분석 시스템을 구성한다. 실험 영상을 통해 교통량 측정, 용의자 및 차량 추적, 조난자 식별 및 해상 초계 임무에 적용할 수 있음을 확인했다. 드론 운용자가 임무에 따른 필요 기능을 선택하고 신속하게 대처할 수 있는 시스템을 구현하였다.

Abstract

In this paper, we propose a system for processing and analyzing drone image information which can be applied variously in disasters-security situation. The proposed system stores the images acquired from the drones in the server, and performs image processing and analysis according to various scenarios. According to each mission, deep-learning method is used to construct an image analysis system in the images acquired by the drone. Experiments confirm that it can be applied to traffic volume measurement, suspect and vehicle tracking, survivor identification and maritime missions.

Keyword : Drone-Video Analytics, Deep-learning, License Plate Recognition, Object Detection, Object Tracking

a) 서울과학기술대학교(Seoul National University of Science And Technology)

‡ Corresponding Author : 박구만(Park GooMan)

E-mail: gmpark@seoultech.ac.kr

Tel: +82-2-970-6430

ORCID:<https://orcid.org/0000-0002-7055-5568>

※ 동 연구는 다부처 사업으로 수행중인 재난치안용 멀티콥터 무인기 특화임무 장비 기술 개발(과제번호 10080094) 연구결과 중 일부임.

※ This study is part of the research result of the multi-copter un-manned special mission equipment development project (No. 10080094)

※ 이 논문의 연구 결과중 일부는 “2018년도 한국방송·미디어공학회 추계 학술대회”에서 발표한 바 있음.

· Manuscript received January 15, 2019; Revised February 28, 2019; Accepted March 11, 2019.

1. 서론

드론은 여러 용도에 활용되고, 다양한 응용 분야의 연구로 발전하고 있다. 특히 사람의 접근이 제한되는 목적지 탐색 및 감시 임무에 도움을 줄 수 있으므로, 재난치안 상황에 적용할 수 있는 임무용 무인기(mission drone) 시스템 도입을 고려하고 있다^[1].

이에 본 논문에서는 드론 영상 종합정보 분석용 시스템을 제안한다. 임무용 드론을 통해 수행 가능한 임무 시나리오를 설정하고, 객체 검출 및 객체 추적 기술 등을 활용하여 각 임무 상황에 따른 영상 분석 기능을 구현하였다.

영상에서 객체를 검출하거나 인식하고자 할 때, 물체의 형태나 크기, 위치가 변해도 쉽게 식별한다면 좋은 분석 기능이라 할 수 있다. 드론 영상의 경우, 공중 촬영 형태의 시점이므로 물체와의 거리가 멀어지거나 각도가 다양해질 수 있기 때문에 일반 영상과는 달리 영상 분석 처리에 어려움이 따를 수 있다. 예를 들어, 일반적인 카메라 시점으로 차량의 번호판을 인식한다면, 영상 내 객체의 좋은 특징점(key point)을 활용하여 정확한 인식 기능을 이끌어 낼 수 있을 것이다. 하지만 드론 영상에서 확보하는 번호판의 경우, 왜곡되는 각도로 인해 번호판 문자 인식에 어려움이 따를 수 있다. 그러므로 기존의 영상처리 분석 방식보다 더욱 정확하고 빠르게 처리할 수 있는 딥러닝 기반의 알고리즘을 선택하여 객체 인식 신경망을 생성하였다.

객체를 추적하는 경우, KCF(Kernelized Correlation Filters) 알고리즘을 활용하여 성능을 높이고 사용자에게 편리한 기능을 추가하여 구현했다.

본 논문의 다음 장에서는 드론영상을 전송하고 저장하는 모듈에 대한 방법론을 제시하고, 각각의 장에서는 상황별 임무 시나리오를 설정하였고, 각각의 시나리오마다 필요 기능에 대한 구현 방법과 실험 결과를 설명한다. 그리고 5장에서 결론을 맺는다.

II. 영상분석 모듈 구성

임무용 드론을 운용하기 위해서는 단계별 시스템 모듈 구성이 필요하다. 그림 1과 같이 드론으로부터 영상을 수신

받는 모듈, 수신된 영상을 비디오 포맷으로 저장하는 모듈, 그리고 저장한 영상을 분석 시스템과 연동하는 분석 모듈로 구성한다.

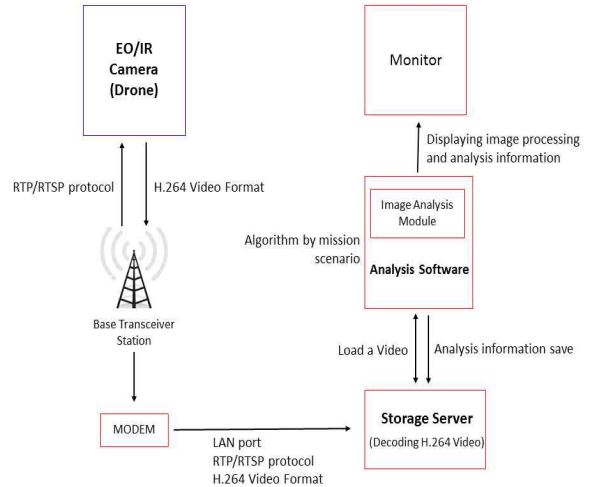


그림 1. 영상분석 모듈 구성도
Fig. 1. Video Analysis module configuration

영상 수신 모듈에서는 드론에 장착된 EO/IR 카메라를 통해 획득한 영상 정보를 수신한다. RTP/RTSP 프로토콜을 통해 영상을 수신하고, H.264 포맷으로 저장모듈에 저장한다. 본 논문에서 제안하는 분석 시스템은 영상분석 모듈에 포함되는 것으로 저장 모듈에 저장된 영상을 분석 처리하고, 동시에 결과를 저장 모듈에 다시 보냄으로써 저장한다.

III. 영상 처리/분석 알고리즘 기능

영상분석 기능을 통해 임무용 드론으로 활용할 수 있는 임무 시나리오를 설정하였다. 임무 시나리오는 교통량 측정 임무, 도주 차량 및 용의자 추적 임무, 조난자 식별 임무와 해상 조난자 식별 및 불법 선박 감시에 대한 해상 초계 임무 등이다. 각각의 임무마다 객체 인식(object detection) 및 객체 추적(object tracking) 알고리즘을 활용하였다.

물체를 검출하고 인식하는 문제는 물체의 지역적인 엣지(edge) 방향과 분포(histogram)를 추출하여 객체의 특징으로 사용하는 HOG(Histogram of Oriented Gradient) 방식의 기반이었다. 최근의 딥러닝 방식은 학습을 통해 영상 내 이

미지에서 객체의 특징을 피쳐 맵(feature map)으로 나타낼 수 있는 CNN(Convolutional Neural Network) 기반의 네트워크로 발전하고 있다.

이에 본 논문에서는 각각의 임무 시나리오마다 CNN 기반의 객체 검출 신경망을 구성하였다. 신경망은 선별적인 후보 영역을 제안(region proposal)하고 이에 대한 객체를 판단하는 R-CNN(Region Convolutional Neural Network) 방식의 ‘YOLO’ 알고리즘을 이용하여 구성했다.

1. 교통량 측정 임무

드론을 통해 특정 구간의 도로에서 교통량을 측정하는 임무를 수행한다. 현재의 교통량을 측정하는 기준은 교통량 정보제공 시스템이며, 측정 방식은 차종을 구분하고, 구분한 차종 하에서 차량의 수를 측정한다. 따라서 교통량 정보제공 시스템과 동일하게 차종을 구분하고 구분한 차종에 따라 차량의 수를 나타내는 기능으로 구현하였다. 우선 차종을 구분하는 기준은 일반 차량, 버스, 트럭으로 세 가지로 나누었으며, 딥러닝 방식을 이용하여 차종을 구분할 수 있는 신경망을 생성하였다.

사용한 네트워크는 객체 검출 분야에서 널리 사용되는 R-CNN 방식인 YOLO 알고리즘의 ‘Darknet-19’ 네트워크를 통해 구현하였다. R-CNN 방식의 네트워크는 다양한 후보 영역으로 물체를 경계 상자(bounding box)형태로 제안하는 기능과 물체가 무엇인지 판단하는 분류(classification) 기능이 분리되어 있어, 높은 정확도를 지닌다.

YOLO 알고리즘은 R-CNN 방식과 같은 분리된 방식의




그림 2. YOLO 네트워크 아키텍처
 Fig. 2. YOLO Network Architecture

기능을 하나의 네트워크로 구성함으로써 빠른 처리 속도를 자랑한다. 또한 아래 그림 3과 같이 영상에 등장하는 많은 차량을 일괄적으로 검출 할 수 있어야 하는데, YOLO 네트워크는 이미지를 격자(grid)로 분할하여 그리드 셀 내에서 후보 영역의 경계 상자로 구분하기 때문에 단일 이미지 패치(patch)에서 다양한 물체에 대한 분류가 가능하다. 이에 드론을 통해 실시간으로 객체를 검출하고 차종을 구분하는데 적합하다고 판단했다²⁾.

우선, 차종을 구분하는 신경망 생성을 위해 학습데이터를 수집하였다. 학습데이터(training set)는 10개의 일반도로 영상에서 약 18,000대의 차량 학습 데이터를 확보하였다.

차종을 구분하기 위해 ‘car’, ‘bus’, ‘truck’ 이름으로 세 가지 종류에 대한 클래스(class)를 설정하고, 영상 내에서 세 가지 클래스에 해당하는 객체에 대한 경계 상자(bounding-box)형태의 마킹(marking)을 통해서 정답을 알려주는 주석(annotation)과정을 수행하였다.

학습은 클래스(class=3), 배치-사이즈(batch=64), 미니




그림 3. 차종 구분 기능
 Fig. 3. Vehicle classification function




그림 4. (좌부터) 엣지 영상 이미지와 레이블링 형태 저장
Fig. 4. Edge image and Save the labeling type

(subdivision=16), 학습율(learning rate=0.001)과 같은 하이퍼-파라미터로 진행하였다. 특히, 학습 과정에서 신경을 썼던 부분은 ‘car’, ‘bus’, ‘truck’ 세 가지 클래스의 학습 데이터의 양을 균등하게 배분하는 것이었다. 학습과정에 있어서, 특정 클래스에 치우치게 학습하는 것을 방지하기 위함이다. 이에 차종 별로 각각 약 6000대의 차량을 학습하도록 했다. 차종을 구분한 후에는 구분한 차량의 숫자를 세어주는 기능을 추가하여 교통량 측정 기능을 구현하였다.

2. 도주 용의자 및 차량 추적 임무

도주하는 용의자를 추적하는 경우, 용의자의 인상착의 및 사전 정보 등을 활용하여 추적을 하기 때문에 사용자의 선택성과 특수성이 시스템에 고려되어야 한다. 이에 트래킹(tracking) 알고리즘인 KCF(Kernelized Correlation Filters)를 활용하여^[3], 도주하는 용의자를 추적을 하지만, 드론으로 획득한 영상에서 사용자가 추적하고 싶은 객체를 드래그 인(dragging)을 통해 사용자가 추적하고자 하는 대상을 선택할 수 있게 하였다.

차량을 추적하는 경우, 차량의 번호판을 인식하는 기능을 추가하였다. 번호판 인식 기능은 번호판 영역을 검출하고, 검출한 영역 내에서 개별 문자 인식이 가능해야 한다. 그러나 기존의 엣지 및 외곽선 검출로 문자를 인식하는 것은 조감도(bird's-eye view) 영상에서 카메라 시점을 기준으로 왜곡되는 각도로 인해 정확도가 매우 낮다.

이에 따라 국내 차량 번호판을 인식할 수 있는 학습데이터를 마련하고, 번호판을 인식하는 네트워크를 생성하고자

했다. 우선 다수의 번호판 샘플을 획득하기 위해 그림 4와 같이 엣지 이미지 영상에서 SVM(Support Vector Machine) 방식을 통해 번호판 영역을 검출한 후, 이를 라벨링(labeling) 형태로 저장하도록 하여, 학습데이터의 Augmentation 과정을 수행했다. 이렇게 저장된 라벨링 형태의 번호판은 YOLO 네트워크의 학습을 통해 차량 번호판 검출부를 생성했다. 번호판 검출 신경망은 class=1, batch=64, subdivision=8, learning rate=0.001의 하이퍼-파라미터로 학습을 진행하였다.




그림 5. 번호판 영역 내에서 annotation 과정
Fig. 5. Annotation Process within License Plate area

검출한 번호판 영역 내에서 개별 문자 및 숫자를 인식하기 위해서, 문자와 숫자를 합친 총 43개의 클래스로 설정했다. 그림 5와 같이 개별 문자에 대한 학습을 위해 43개 클래스에 대한 번호판 문자 영역을 Annotation 과정을 진행했다. 번호판 개별 문자에 대한 데이터 셋이 준비되면 YOLO 네트워크 ‘Darknet-53’을 통해 class=43, batch=64, subdivision=64, learning rate=0.001의 하이퍼-파라미터로 학습을 진행하여 번호판 문자 인식 모델을 생성하였다.



그림 6. 얼굴 학습 데이터 (좌부터, 'faces 94' 'facial-original-image' 'SCUT-HEAD' database)
 Fig. 6. Learn in 43 Class within License Plate area

3. 조난자 식별 임무

조난자 식별 임무에서는 빠르게 구조자를 검출하는 것이 임무 시나리오에 필요한 기능이다. 특히, 바다에 빠진 사람을 식별하는 상황이라면 기존의 객체 추적 알고리즘을 사용하여 바다에 빠져있는 조난자를 지속적으로 추적할 수도 있다. 하지만 추적 알고리즘의 경우 바다에 빠진 조난자가 파도에 가려져, 추적중인 객체를 놓쳐버릴 수 있다.

이에 다른 제약에 의해서 객체가 가려지더라도 다시 사람이 다시 노출되었을 때, 재빨리 물체를 잡아내는 회수율 (recall)이 중요하다. YOLO 네트워크는 대상에 대한 검출 능력을 더욱 끌어올리기 위해, 객체에 대한 후보 영역을 제한하는 예측 상자(prediction box)를 사이즈 비율 별로 구분한 5개의 형태로 디자인 하였다. 이렇게 디자인된 5개의 'Anchor-box'는 식별하고자 하는 대상의 후보 영역들을 빠르게 살펴보면서, 물체에 대한 검출을 빠르게 잡아낸다. 이에 익사상황에 빠진 조난자를 식별하는데 적합하다고 판단했다.

조난자를 식별하는 기준은, 바다 속에 빠진 조난자가 처한 상황을 고려하여 사람의 얼굴을 검출하는 신경망으로 구성했다. 특히 드론 영상에 따른 다양한 자세(pose)와 먼 거리에 있는 얼굴을 검출하도록 했다. 학습 데이터는 위 그림 6과 같은 기존의 얼굴 데이터 셋인 'faces 94', 'faces 96' 등을 활용 하였고, 먼 거리의 얼굴을 인식하기 위해 작은 사이즈의 얼굴 학습 데이터 'SCUT_HEAD' 데이터 셋을 400장 이미지를 포함하여 학습했다.

4. 해상 초계 시나리오

해상 초계 시나리오는 불법 어로 및 조난 선박을 식별하고 식별한 선박에 한해서 선박 번호를 인식한다. 하지만 국내의 실제 선번 데이터를 구성하기는 쉽지 않았다. 이에 단일의 선번 번호판에서 다양한 각도와 노이즈를 주어 데이터의 양을 증가시켜 학습을 진행했다. 학습 데이터는 선박이 등장하는 영상 10개에서 약 200대의 선박 training set을 확보하고, class=1, batch=64, subdivision=8, learning rate=0.001와 같은 파라미터로 학습을 진행하였다.

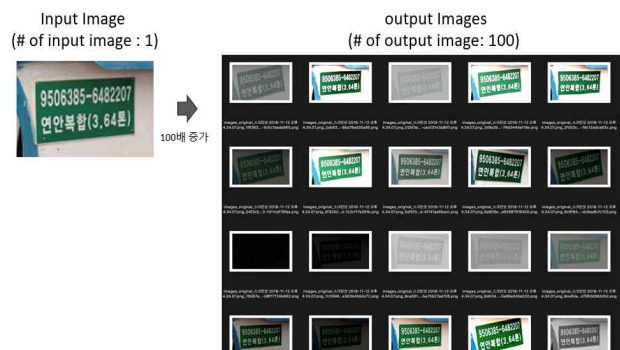


그림 7. 선박 번호판 augmentation 과정
 Fig. 7. Ship License Plate Augmentation Process

IV. 실험

영상분석 모듈에 포함되는 구현한 알고리즘의 정확성을

표 1. 차종 구분 정확도

Table 1. Classification Accuracy

Figure / Order	1	2	3	4	5
Number of data	2,000	6,000	10,000	15,000	18,000
Number of training	9,000	9,000	9,000	9,000	9,000
Accuracy(%)	59%	63%	68%	72%	85%

알기 위해 실험을 진행하였다. 우선 교통량 측정 임무에서 구현한 차종 인식 기능이다. 실험 영상은 공중촬영 형태의 일반도로 영상을 준비하였다. 표 1과 같이 준비한 실험 영상에서 총 18,000장의 데이터 수를 학습시키는 과정에서 정확도를 기록하였다. 결과는 학습하는 숫자에 비례하여 데이터의 수가 18,000장 일 때, 85%를 기록했다. 특히, 학습 과정에서 신경을 썼던 부분은 ‘car’, ‘bus’, ‘truck’ 세 가지 클래스 각각의 학습 데이터 숫자를 균등하게 배분하는 것이었다. 학습과정에 있어, 특정 클래스에 치우치게 학습하는 것을 방지하기 위함이었다. 이에 차종 별로 각각 약 6000대의 차량을 학습하도록 했다.




그림 8. 객체 추적 알고리즘 구성

Fig. 8. Ship License Plate Augmentation Process

도주하는 용의자 및 차량에 대한 추적 성능을 측정하기 위해, 공중 촬영 형태의 실험 동영상을 준비하였다. 그림 8과 같이 실험 영상에서 도주하는 용의자의를 드래그 인을 통해 선택하고, 경계 상자 형태로 객체를 잘 추적하는지를 육안으로 확인하였다.

표 2에서는 차량을 추적하는 임무에서 필요한 번호판을 인식 정확도를 나타냈다. 번호판 인식 정확도는 번호판 영

표 2. 번호판 검출 정확도 결과

Table 2. License Plate detection Accuracy

Figure / Order	1	2	3	4	5
Number of data	1000	1600	2000	3000	4000
Number of training	10,000	10,000	10,000	10,000	10,000
Accuracy(%)	34%	58%	66%	81%	70%

역 내에서 개별 문자 정확도로 판단하였다. 영상에서 검출한 약 3,000개의 차량 번호판을 학습했을 때, 가장 높은 정확도를 기록하였다. 오히려 4,000개의 번호판을 검출한 데이터에서는 오히려 좋지 못한 정확성을 기록하였는데, 확보한 번호판 학습 데이터 셋에서 현재의 번호판과 구 번호판과의 문자 배치, 색깔, 폰트 등이 달라지기 때문이었다. 이러한 번호판의 특성들이 달라지는 것은 결국, 번호판 학습데이터의 불균형 문제를 일으키게 되었다.

그러므로 향후 연구에는 번호판 문자의 배치 및 폰트, 색깔 등에 강인할 수 있는 학습데이터 생성 연구가 필요하다. 정확도 결과에서는 현재의 번호판에서는 준수한 정확도를 나타내었으며, 드론 영상처리 분석 시스템에서 번호판을 인식할 수 있는 기능을 제시했다는 점이다.




그림 9. 사람 얼굴 검출 신경망 구성

Fig. 9. Human face detection Neural Network Composition

조난자 식별의 경우, 공중촬영 형태의 실험 영상에서 얼굴을 제대로 검출 하는지를 육안으로 살펴보았다. 총 50프레임 길이의 영상에서 얼굴을 검출하는 것은 실시간 정확도로 평균 86%로 사람의 얼굴 유무를 판단하였다. 그림 9와 같이 바다 속에 빠진 사람들이 파도로 인해 얼굴이 보이지 않다가 다시 노출되었을 때, 곧바로 경계 상자 형태로 대상을 잡아내는 회수율이 아주 좋았으며 먼 거리에서 떨어진 작은 크기의 얼굴에서도 제대로 식별한다는 것을 확

인할 수 있었다.

아래 표 3에서는 해상 초계 시나리오의 경우 선박을 검출하는 정확도를 기록하였다. 선박이 등장하는 영상에서 200대의 선박을 Annotation 과정을 거쳐서 학습 횟수에 따라 정확도를 구분해보았다. 실험은 선박이 등장하는 공중촬영 형태의 영상에서 실험을 해보았으며 학습 횟수가 15,000번이었을 때, 94%로 가장 높은 정확도를 기록하였다. 학습 횟수가 30,000 이상이 되었을 때는 학습했던 선박 형태가 아닌 선박이 등장하면 검출 능력이 떨어졌다.

이는 모델을 학습하는 과정에서 학습 데이터를 지나치게 학습하여, 학습 데이터에 대해서는 오차가 감소하지만, 실제 데이터에서는 오차가 증가하는 과적합(over-fitting) 문제가 발생한 것이다.

표 3. 선박 검출 정확도 결과 (흰색 번호판)
 Table 3. Ship detection Accuracy

Figure / Order	1	2	3	4	5
Number of data	200	200	200	200	200
Number of training	3,000	6,000	9,000	15,000	30,000
Accuracy(%)	75%	88%	91%	94%	82%

V. 결 론

본 논문에서는 재난치안 임무 상황에서의 드론 영상 종합정보 분석/처리 시스템을 제안한다. 임무 지역에서 발생할 수 있는 재난, 치안 상황의 시나리오로 설정하였으며, 그에 따른 필요 기능을 제안한다. 드론으로부터 얻어지는 bird's-eye view 영상에서 임무 상황에 따라 필요한 기능을 적용할 수 있는 R-CNN 기반의 딥러닝 네트워크를 생성하였다. 임무 상황에 따른 실제 데이터를 구성하는 것에 어려움이 있었으며, 부족한 학습 데이터를 생성할 수 있는 연구 방향이 필요하다. 특히 번호판 인식 문제의 경우 번호판의

각도, 문자 영역내의 배치, 상황에 따라 발생할 수 있는 노이즈, 번호판 배경에 따른 색깔 정보 등 다양한 요소들을 포함할 수 있는 학습 데이터를 생성할 수 있는 기능이 필요하다.

그럼에도 드론 영상 종합정보 분석 시스템은 각각의 임무 시나리오에 따른 드론 영상 종합분석 시스템 기능을 마련했다는 점에서 영상 정보 분석 모듈에 대한 고가의 장비 및 센서 등의 하드웨어를 대체할 수 있고, 특수성이 높은 엔진으로의 구성이 가능하다는 결론을 얻을 수 있었다.

참 고 문 헌 (References)

- [1] Keun-Taek. Kim, S. Min-Soon. Park and Sang-Hyun. Park, "The Concept of Operations of the Multicopter UAVs for Disaster and Public Safety - Based on Mission Scenarios," Current Industrial and Technological Trends in Aerospace Volume 15, No. 2, pp.84-96, 2017, December.
- [2] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi "You Only Look Once: Unified, Real," Computer Vision and Pattern Recognition 2016, pp. 779-788, June 2016, arXiv:1506.02640 .
- [3] João F. Henriques, Rui Caseiro, Pedro Martins, Jorge Batista "High-Speed Tracking with Kernelized Correlation Filters" Computer Vision and Pattern Recognition 2016, pp. 779-788, June 2016, arXiv:1506.02640 .
- [4] Peiyun Hu, Deva Ramanan, "Finding Tiny Faces" Computer vision and Pattern Recognition 2017, Apr 2017.
- [5] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton Neural Information Processing Systems 2012
- [6] Ross Girshick, "Fast R-CNN" The IEEE International Conference on Computer Vision 2015, pp.1440-1448, 2015.
- [7] Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks", Computer Vision and Pattern Recognition, pp.71-287, June 2015, arXiv:1506.01497.
- [8] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vicent Vanhoucke, Andrew Rabinovich, Computer vision and Pattern Recognition 2014, Sep 2014 arXiv:1409.4842


저 자 소 개

임 송 원



- 2018년 : 청운대학교 방송영상학과 학사
- 2018년 ~ 현재 : 서울과학기술대학교 일반대학원 미디어IT공학과 석사과정
- ORCID : <https://orcid.org/0000-0002-0944-4527>
- 주관심분야 : 컴퓨터비전, 영상분석

조 성 만



- 2018년 : 서울과학기술대학교 전자IT미디어공학과 학사과정
- 2018년 ~ 현재 : 서울과학기술대학교 일반대학원 미디어IT공학과 석사과정
- ORCID : <https://orcid.org/0000-0002-7922-9638>
- 주관심분야 : 컴퓨터비전, 영상분석

박 구 만



- 1984년 : 한국항공대학교 전자공학과 공학사
- 1986년 : 연세대학교 전자공학과 석사
- 1991년 : 연세대학교 전자공학과 박사
- 1991년 ~ 1996년 : 삼성전자 신호처리연구소 선임연구원
- 1999년 ~ 현재 : 서울과학기술대학교 전자IT미디어공학과 교수
- 2006년 ~ 2007년 : Georgia Institute of Technology Dept.of Electrical and Computer Engineering. Visiting Scholar
- 2016년 ~ 2017년 : 서울과학기술대학교 나노IT디자인융합대학원 원장
- ORCID : <https://orcid.org/0000-0002-7055-5568>
- 주관심분야 : 컴퓨터비전, 실감미디어