

# Measurement of Construction Material Quantity through Analyzing Images Acquired by Drone And Data Augmentation

Ji-Hwan Moon<sup>†</sup> · Nu-Lee Song<sup>†</sup> · Jae-Gab Choi<sup>†</sup> · Jin-Ho Park<sup>††</sup> · Gye-Young Kim<sup>††</sup>

## ABSTRACT

This paper proposes a technique for counting construction materials by analyzing an image acquired by a Drone. The proposed technique use drone log which includes drone and camera information, RCNN for predicting construction material type, dummy area and Photogrammetry for counting the number of construction material. The existing research has large error ranges for predicting construction material detection and material dummy area, because of a lack of training data. To reduce the error ranges and improve prediction stability, this paper increases the training data with a method of data augmentation, but only uses rotated training data for data augmentation to prevent overfitting of the training model. For the quantity calculation, we use a drone log containing drones and camera information such as Yaw and FOV, RCNN model to find the pile of building materials in the image and to predict the type. And we synthesize all the information and apply it to the formula suggested in the paper to calculate the actual quantity of material pile. The superiority of the proposed method is demonstrated through experiments.

Keywords : Drone, UAV, RCNN, Deep Learning, Counting Number, Construction Material

## 드론 영상 분석과 자료 증가 방법을 통한 건설 자재 수량 측정

문 지 환<sup>†</sup> · 송 누 리<sup>†</sup> · 최 재 갑<sup>†</sup> · 박 진 호<sup>††</sup> · 김 계 영<sup>††</sup>

## 요 약

본 논문에서는 드론에 의하여 획득된 영상을 분석하여 건축자재의 수량을 측정하는 기술을 제안한다. 제안하는 기술은 드론 및 카메라 정보가 담겨있는 드론 로그와 영상 내 건축자재터미 종류와 영역을 예측하는 RCNN, 실제적인 수량 계산을 위한 사진측량법을 사용한다. 기존 연구에선 학습 데이터의 부족으로, 자재 종류 및 건축자재터미 영역 예측 정확도의 오류 범위가 컸다. 논문에서는 이러한 오류 범위를 줄이고 예측 안정성을 높이기 위해 자료 증가 방법으로 학습 데이터를 증가시킨다. 자료 증가는 학습 모델의 과적합을 막기 위해 회전에 의한 증가 방법만 사용한다. 수량 계산 방법으로는 Yaw, FOV 등의 드론 및 카메라 정보가 담겨있는 드론 로그와 영상 내 건축자재터미 영역을 찾고, 종류를 예측해 줄 RCNN 모델을 사용하고, 이 모든 정보를 종합해 논문에서 제안하는 수식에 적용하여 자재터미의 실제적인 수량을 계산한다. 제안하는 방법의 우수성은 실험을 통하여 확인한다.

키워드 : 드론, 무인항공기, RCNN, 딥러닝, 수량 측정, 건축 자재

## 1. 서 론

촬영된 영상 내 객체들을 구분하고 구분된 객체들의 수량

을 측정하는 것은 컴퓨터 비전의 주된 연구 목표 중 하나이다. 최근 연구에선, Counting CNN, Hydra CNN을 사용하거나 CNN의 손실 함수를 수정하여 영상 분할에 밀도 맵을 추가하여 객체를 인식 및 수량 측정 하는 방법[1]이 있다. 또한 기존의 고정된 카메라가 아닌 드론 같은 무인 항공기를 통해 인식 및 수량 측정을 진행하기도 한다[2]. 하지만 기존 연구에선 단일 객체에 관한 인식과 수량을 계산하고, 건축 자재 같이 일정 수의 객체가 숨겨져 있는 것에는 연구가 진행되지 않고 있다. 그래서 본 연구에선 이러한 객체를 중심으로 영상 분할을 진행하고 수량을 측정하고자 한다.

\* 이 논문은 숭실대학교 IITP 과제(4년)에 의하여 연구되었음.  
\* 이 논문은 2019년도 한국정보처리학회 춘계학술발표대회에서 '딥러닝과 드론을 이용한 동일 모양 건축 자재 수량 측정에 관한 실증적 연구'의 제목으로 발표된 논문을 확장한 것임.  
† 준 회 원 : 숭실대학교 융합소프트웨어학과 석사과정  
†† 종신회원 : 숭실대학교 소프트웨어학과 교수  
Manuscript Received : July 9, 2019  
First Revision : October 10, 2019  
Accepted : November 27, 2019  
\* Corresponding Author : Gye-Young Kim(gkim11@ssu.ac.kr)

본 연구에선 크게 두 가지 사항을 고려한다. 첫 번째는 드론을 사용해 촬영한 영상 내 자재의 종류를 인식하는 것과, 인식한 건축자재더미가 영상에서 차지하는 크기를 계산하는 것이다. 두 번째는 인식한 자재의 체적 정보와 자재더미 영역, 드론 정보를 사용해서 촬영한 자재더미의 수량을 측정하는 것이다.

건축자재를 인식하는 방법, 더 넓게는 물체를 인식하는 방법에는 물체가 가지는 고유한 특징을 구분해 내는 방법을 사용하였다. 여기서 고유한 특징은 물체의 색상, 질감, 회전과 크기에 관계없이 검출되는 특별한 모양 등이 있다. 기존의 특징 구분은 높은 정확도를 보이지 못 했다. 이러한 정확도는 하드웨어의 발전으로 딥러닝을 사용한 학습과 결합되어 물체의 고유한 특징을 학습을 통해 좀 더 세밀하게 분리 혹은 군집화하여 향상되었다. 하지만 세밀한 분류를 위해 학습을 할 때 학습할 데이터 집합이 충분하지 않으면 과적합 혹은 잘못된 결과를 산출하는 경우가 많다. 학습 자료의 부족 문제를 해결하기 위해 자료를 추가적으로 수집하는 방법이 있지만, 추가 자료 수집이 어려운 경우 GAN[3]이나 데이터의 회전, 이동 같은 자료 증가 방법을 사용해 데이터를 늘려 과적합을 막고 임의성을 증가시킨다.

단일 물체의 수량 측정 같은 경우는 한 영상 내 인식되는 수량을 측정하면 된다. 좀 더 자세한 측정을 시도하는 경우엔 물체의 특징을 추출하여 특징 간 거리 혹은 차이를 이용하는 방법이 있다. 하지만 여러 물체가 겹쳐져 있어 서로의 특징을 가리거나 단일 물체의 특징이 구분이 안 되는 경우가 있다. 기존 연구[4]에서는 드론을 사용하여 물체를 촬영하였고, 촬영시의 드론의 고도, 회전각 등을 사진측량법에 적용시킴으로서 계산을 하였다.

본 연구에서는 건설자재더미 수량 측정을 위해 기존 연구와 동일한 방법을 사용하며, 학습과 인식 부분의 고도화를 위해 자료 증가 방법을 사용한다. 자료 증가 방법으로는 한 건설자재에 대한 과적합을 막기 위해 회전에 의한 증가 방법만을 사용하도록 한다.

## 2. 관련 연구

물체를 탐지하기 위해선 고유한 특징을 추출한다. 물체의 모양을 추출하는 경우엔 추출한 특징 집합을 서로 비교하여 유사도 점수를 매긴다[5]. 이 연구는 영상 내부의 모든 영역을 탐지 하는데, 모든 영역의 특징을 추출하기엔 너무 시간이 오래 걸리기 때문에 완전 탐색과 영상 분할의 장점을 결합한 선택적 탐색을 이용해 물체의 위치를 생성하여 특징을 추출하기도 한다[6]. 또한, 비교 정확도를 높이기 위해 물체를 분할해서 표현하기도 하는데, 분할된 표현을 연결시키면 하나의 물체를 더 자세하게 표현할 수 있어 비교 정확도가 높아진다[7]. 특징과 학습을 결합해서 사용할 때 비지도 학습한 분류기를 이용하여 두 영상 도메인의 공통 특징 공간을 학습하도록 하여 군집화 하는 방법[8]과 단순히 CNN과 max

pooling을 사용하여 물체의 특징을 학습하는 방법이 있다[9]. 여러 학습 모델을 결합하여 사용하는 경우도 있는데 RNN에 강화 학습을 추가해 영상 내 특정 부분에 집중하도록 학습하여 여러 개의 물체를 인식하거나[10], CNN의 전방전파와 RNN의 연성된 정보 활용 방법을 결합하는 경우도 있다. 이 경우에는 각 CNN 계층이 하나의 RNN 타임 스텝스가 되어 학습하는 것으로 사람의 시각 체계와 비슷하게 동작한다[11]. 학습데이터 부족으로 인해 생기는 문제를 방지하기 위해 DAGAN을 사용하여 데이터를 직접 생성하거나[12] 데이터 간의 관계를 좀 더 자세히 분류하여 자료 증가 방법을 적용시키거나[13] 선택적으로 자료 확장 방법을 적용하기 위한 알고리즘을 설계하기도 한다[14].

물체의 수량을 측정하는 방법은 물체가 무엇인지 구분해내기 때문에 인식에 종속되는 경우가 많다. 색으로 인식 하고 수량을 측정하거나[15] 가우시안 혼합 모델과 3D 모델을 사용해 물체를 인식 및 측정하는 경우[16]같이 인식에 사용된 특징을 사용해 수량을 측정할 경우 잘못된 인식 결과가 나왔을 때 이를 판단하는 알고리즘과 해결 방법이 필요하다. 하지만 인식 결과를 판단하는 알고리즘은 결국 인식 정확도를 높이는 문제가 되기 때문에 학습을 통해 정확도를 높여 수량을 측정하는 방법이 많이 사용된다[17, 18]. 각 물체의 특징이 매우 비슷하거나 특징을 가리고 있는 경우, 정확도는 매우 낮아지는데 이를 해결하기 위해 watershed를 적용하거나[19] 영상 내부 특성을 통계적으로 표현하고 학습하여[20] 사용하기도 하지만 정확도가 매우 낮으며 범용성이 떨어진다.

## 3. 딥러닝을 통한 건축자재 수량 측정

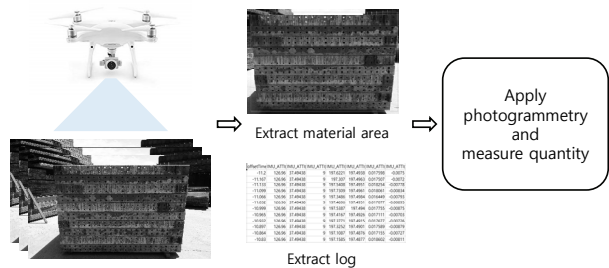


Fig. 1. Construction Material Dummy Counting Outline. First, We Capture a Construction Material Dummy. Second, Recognize the Material Dummy and Extract the Dummy Area. Last, use Photogrammetry for Counting

이 논문은 드론의 촬영 환경을 설정 및 추출하는 것과 자료 증가 방법을 사용한 딥러닝 모델 학습, 사진측량법을 사용한 건축 자재 더미 수량 계산하는 부분으로 나뉜다.

제안하는 방법에 사용될 딥러닝 모델은 R-CNN의 한 종류인 YOLO[19]를 사용하며, 학습 데이터 집합은 환경변수 설정이 끝난 드론으로 직접 촬영한 건설 자재더미를 사용한다. YOLO 모델은 학습 과정 중 내부적으로 영상의 크기를 축소

시켜 학습 속도를 높이고 메모리 소모량을 감소시킨다. 하지만 건설자재더미 중 벽돌같이 작은 자재는 영상을 축소시키게 되면 학습이 불가능할 정도로 크기가 작아진다. 그래서 우리는 단일 자재가 아닌 전체 자재 즉, 영상 내부의 건설 자재 더미 영역을 관심영역으로 지정한 후에 관심영역을 찾고 영역 내 물체가 무엇인지 판단하도록 학습한다. 학습 시 영상의 크기는 448x448의 크기로 축소 되도록 하며 사용할 건축 자재는 벽돌, 시멘트, 팔레트, 타이박스로 한다. 그리고 학습은 평균 오류율이 1.0이하가 될 때 중단한다.

제안 방법에 사용할 영상들은 드론을 사용해서 자재더미의 윗면과 측면을 각각 수직, 정면에서 촬영한 영상들을 사용한다. 하지만 이러한 특수성을 지닌 영상들은 많은 자료를 찾기가 힘들기 때문에 자체적으로 자료를 늘리는 방법이 필요하다. 그래서 우리는 회전에 의한 자료 증가 방법을 사용하여 자료를 증가시켰으며, 방법은 다음과 같다: 먼저 YOLO는 영상의 범위를 0과 1사이의 값으로 정규화시켜 표현한다. 그래서 관심영역 또한 정규화 되어 표현되는데, 총 5개의 변수가 한 영상의 관심 영역과 인식 라벨을 구성한다.  $C, X, Y, W, H$ 는 각각 인식 라벨, 관심 영역 중심 가로, 세로 좌표, 관심 영역의 가로, 세로 높이를 나타내는데, 이를 포함한 영상의 회전은 다음과 같이 표현된다. 그리고 회전의 결과를 적용한 사진은 Fig. 2와 같다.

$$\begin{aligned} < C, X, Y, W, H > \\ < C, Y, 1-X, H, W > \\ < C, 1-X, 1-Y, W, H > \\ < C, 1-Y, X, H, W > \end{aligned} \quad (1)$$



Fig. 2. Material Dummy Image Obtained using Data Augmentation Method

위의 수식과 영상을 적용해 4배의 데이터 집합을 만들어 내며, YOLO의 회전에 강건하지 않은 면을 보완하여 학습한다.

다음은 건설자재더미의 수량을 계산하는 방법이다. 먼저, 상기 사항을 바탕으로 학습한 모델을 사용하여 더미 영역과 자재 종류를 인식한다. 그리고 윗면과 측면 각각의 Yaw값을 비교하여 자재 더미의 가로, 세로 길이 값 중 두 영상에서 공통으로 찍힌 값을 찾는다. 영상의 Yaw값이 약 90°, 270° 정도의 차이가 난다면 촬영된 더미의 체적을 구성하는 직선 중 세로가 공통으로 촬영된 것이며, 0°, 180° 정도 차이가 난다면 가로가 공통으로 촬영된 것이다. 다음으로 더미와 드

론 간의 거리차이 때문에 발생하는 옆면과 측면 영상의 화소 값의 차이를 없애주기 위해 공통 선분을 사용한 정규화를 한다. 정규화는 윗면, 측면 각기 다른 영상의 공통 선분을 체적의 화소 값들에 곱해주는 방식으로 진행된다. 다음으로 수량 계산의 간편화를 위해 체적의 높이 화소 값으로 체적 성분을 나눠 주면 자재 더미는 높이가 1인 체적을 가지게 된다. 이를 수식으로 표현하면 다음과 같다.

$$\begin{aligned} W: H_u, D: H_s &\Rightarrow WH_s : H_u H_s, DH_u : H_s H_u \quad (2) \\ &\Rightarrow WH_s : H_u H_s : DH_u \\ &\Rightarrow \frac{WH_s}{DH_u} : \frac{H_u H_s}{DH_u} : 1 \end{aligned}$$

여기서 체적의 가로, 세로, 높이를 각각  $W, H, D$ 라 하고,  $H_u, H_s$ 를 두 영상에서 공통으로 촬영된 가로 성분이라 가정한다. 식(2)의 마지막을 보면 높이가 1인 체적 성분을 가진 자재 더미가 되는데 높이 값을 기준으로 하나의 단일 자재 층이 존재함을 가정하면 인식된 단일 자재의 높이 값을 알 수 있으므로 나머지 성분의 값도 알게 된다. 이 가정된 상황에서 가로, 세로성분을 이용해 더미 윗면의 촬영돼야 할 실제 대각선 길이를 다음의 수식을 통해 구할 수 있다.

$$diagonal = 2 \times (h_d - h_a) \times \tan\left(\frac{FOV}{2}\right) \quad (3)$$

식(3)의  $h_a$ 는 가정된 상황의 높이를 나타내며  $h_d$ 는 드론의 실제 높이를 나타내고  $FOV$ 는 드론의 화각을 나타낸다. 이제 식(2)의 자재더미 층수를 변경시켜가며 식(2),(3)의 대각선 길이의 차를 비교하고 제일 차가 작은 높이를 자재더미의 높이로 설정한다. 그리고 자재더미의 체적 비율을 계산해 수량을 산출하며, 앞의 설명의 전체 개요도는 Fig. 1과 같다.

#### 4. 실험 및 결과 확인

건축 자재 더미를 촬영하는데 사용한 드론은 DJI Phantom4 Pro Plus이며, 화각은 84° 값을, Yaw는 북쪽을 기준으로 0°~360° 사이의 값을 가지게 한다. 드론의 높이는 드론이 움직이기 시작한 위치를 기준으로 수직 위치로 움직인 길이로 정하고, 촬영 시에는 건축 자재더미의 윗면과 측면을 촬영하며, 영상의 크기는 5472x3078로 한다. 학습에는 Intel Core i5와 RTX 2080을 사용하였으며, 자료 증가 방법을 제외한 실험 영상 자료는 직접 공장 및 야적장을 촬영하였다.

실험 결과는 학습 모델을 이용한 자재더미의 종류 인식하는 것과 영상 내 더미가 차지하는 실제 영역과 학습 모델을 사용하여 예측한 더미 영역의 차이를 확인하는 부분, 상기 사항을 바탕으로 드론 정보와 영상 내부 정보를 결합하여 수량을 측정하는 부분으로 나뉜다.

Table 1. Construction Materials Dummy Recognition , Segmentation Accuracy Compare with Prior Study. Recognition Accuracy is Calculated by MAE of Test Image and Image Segmentation Accuracy is Calculated by RMSE, Which Compares Ground Truth with Predicted Dummy Area

Approach	Recognition [MAE]	Image segmentation [MSE]
No data augmentation[2]	0.22	0.28
data Augmentation	0.19	0.29

먼저, 자료 증가 방법을 통한 정확도 향상을 확인하기 위해 학습된 YOLO 모델을 사용하여 테스트 집합을 검증하였다. 인식 정확도는 모든 절대 오차의 평균을 나타내는 MAE (Mean Absolute Error)를 사용하였으며, MAE의 식은 다음과 같다:  $n$ 은 테스트 집합 크기,  $y_i, \hat{y}_i$ 는 각각  $i$ 번째 영상의 인식 결과와 예측결과 일 때,  $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$ . 자료 증가 방법을 사용했을 때의 평균 절대오차는 19%로, 기존 연구보다 3% 감소한 결과가 산출되었으며, 인식 결과는 Fig. 3에서 확인할 수 있다.

건축 자재 더미영역은 검증 영상의 Ground Truth와 모델이 예측한 영역의 차이를 통해 계산하며, 정확도 수치는 크기 의존적 오류(Scale-dependent Errors)의 한 종류인 MSE(Mean Squared Errors)를 사용한다. MSE의 수식은 다음과 같다:  $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ . Table 1의 결과를 보면 기존 결과와 비슷한 것을 볼 수 있다. 이는 YOLO의 특성과 관련이 있는데, YOLO는 Ground Truth를 사각형으로 설정해 Fig. 3의 (a)처럼 비어있는 공간도 자재 더미 영역으로 계산하기 때문이다.




Fig. 3. Validation Images After Learning (a) Bricks (b) Cements

학습 모델이 잘못 인식을 하는 경우도 있다. 이는 건축 자재가 동일 원료를 사용하여 색상과 질감이 비슷한 문제가 있기 때문이다. 예를 들어, 벽돌과 연석같이 서로 비슷한 색상과 질감, 모양을 가지는 자재를 모델을 통해 인식해보면 하나의 자재로 인식되는 경우가 있다. 또한, 플라스틱 벽돌과 시멘트 벽돌같이 육안으로도 구분이 불가능한 자재는 잘못 인식 되는 경우가 있는데, 상기 문제들은 학습에 방해되어 오류를 증가시킨다. 잘못 인식된 결과는 Fig. 4와 같다.




Fig. 4. Mispredicted Curb and Unrecognized Brick

Table 2. Construction Material Counting Accuracy. The Our\_recog Means the Result of Measuring the Quantity using Correctly Recognized Images. The Our\_total Means the Result of Calculations, Including Incorrect Predictions

	Our_recog	Our_total	[19]	[20]
RMSE	34.64	49.96	34	36.79

수량 계산 정확도는 실제 자재 더미 수량과 사진측량법을 사용해 계산한 결과를 비교하였다. 다른 연구와 비교할 수 있게 RMSE(Root Mean Squared Errors)를 사용하였으며 수식은 다음과 같다:  $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ , RMSE는 수치가 낮을수록 좋다. RMSE를 사용한 수량 계산 정확도는 Table 2에서 확인할 수 있다. Table 2에서 Our\_recog는 올바르게 인식된 결과들을 사용하여 수량측정법을 사용한 것이고, Our\_total은 오인식된 결과들도 포함한 계산 결과이다. 제안된 방법은 다른 연구에 비해 건축 자재 같이 밀집도가 매우 높은 객체의 수량을 측정할 수 있다. 또한, 올바르게 인식된 결과를 사용할 경우, 34.64의 오류로 다른 연구에 뒤처지지 않는 정확도를 보인다. 하지만 잘못 인식된 결과가 포함되면 49.96의 높은 오류를 보인다.

## 5. 결 론

본 연구는 건축자재가 쌓여있는 더미영상을 드론을 통해 획득했을 때, 해당 더미의 체적과 더미를 이루는 건축자재의 종류를 예측하였다. 관계자가 아닌 타인의 사진 촬영을 엄격히 금지하는 건축 자재의 특성상 학습 및 결과 확인을 위한 자료가 부족한 점을 보완하기 위해 자료 증가 방법을 통해 학습 데이터 집합 부족으로 인한 정확도를 올리고 과적합을 방지하였다. 상기 방법을 통해 다른 최신 연구들에 밀리지 않는 수량 측정 결과를 보이기도 한다. 하지만 결과에서 나타났듯이 수량 측정에서, 빛과 색 같은 주변 환경의 영향을 많이 받으며, 비어있는 자재 더미 영역에 대한 예외 처리가 부족하다.

이러한 문제점을 개선하기 위해 향후에는 자재 더미 영역의 공백에 대한 예외처리를 해야 할 것이다. 또한 주변 환경에 강건한 인식 방법을 위해 딥러닝 모델의 변형 혹은 교체를 통해 자재 더미 영역 및 인식 정확도를 올려 수량 계산 오차를 줄여야 한다.

## References

- [1] H. Cholakkal, G. Sun, F. S. Khan, and L. Shao, "Object counting and instance segmentation with image-level supervision," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 12397-12405)*, 2019.
- [2] M.-R. Hsieh, Y.-L. Lin, and W. H. Hsu, "Drone-based object counting by spatially regularized regional proposal networks," In *The IEEE International Conference on Computer Vision (ICCV)*, 2017.
- [3] J. H. Moon, N. I. Song, J. G. Choi, J. H. Park, and G. Y. Kim, "Empirical study for counting same shaped building material quantity using UAV and deep learning," *Spring Conferece of KIPS*, Vol.26 No.1 pp.649-652, 2019.
- [4] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. C. Courville, and Y. Bengio, "Generative adversarial nets," In *Proceedings of NIPS*, pp.2672-2680, 2014.
- [5] S. Belongie, J. Malik, and J. Puzicha, "Shape Matching and Object Recognition Using Shape Contexts," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol.24, pp.509-522, Apr. 2002.
- [6] J. R. Uijlings, K. E. Sande, T. Gevers, and A. W. Smeulders, "Selective Search for Object Recognition," *International Journal of Computer Vision*, Vol.104, No.2, pp.154-171, Sep. 2013. doi: 10.1007/s11263-013-0620-5
- [7] P. F. Felzenszwalb and D. P. Huttenlocher, "Pictorial Structures for Object Recognition," *International Journal of Computer Vision*, Vol.61, Issue 1, pp.55-79, Jan. 2005. doi: 10.1023/B:VISI.0000042934.15159.49
- [8] R. Gopalan, R. Li, and R. Chellappa, "Domain adaptation for object recognition: An unsupervised approach," In *Proc. of ICCV*, pp.999-1006, 2011.
- [9] Dominik Scherer, Adreas Muller, and Sven Behnke, "Evaluation of pooling operations in convolutional architectures for object recognition," In *International Conference on Artificial Neural Networks*, 2010.
- [10] J. Ba, V. Mnih, and K. Kavukcuoglu, "Multiple object recognition with visual attention," ICLR, 2015.
- [11] M. Liang and X. Hu, "Recurrent Convolutional Neural Network for Object Recognition," *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp.3367-3375.
- [12] A. Antoniou, A. Storkey, and H. Edwards. Data augmentation generative adversarial networks. *arXiv preprint arXiv:1711.04340*, 2017.
- [13] Y. Xu, R. Jia, L. Mou, G. Li, Y. Chen, Y. Lu, and Z. Jin, "Improved relation classification by deep recurrent neural networks with data augmentation," CoRR, abs/1601.03651, 2016.
- [14] E. D. Cubuk, B. Zoph, D. Mane, V. Vasudevan, and Q. V. Le, "AutoAugment: Learning Augmentation Policies from Data," 11 Apr. 2019, CVPR2019.
- [15] Y. B. Brahme, and P. S. Kulkarni, "An Implementation of Moving Object Detection, Tracking and Counting Objects for Traffic Surveillance System," *2011 International Conference on Computational Intelligence and Communication Networks*, Gwalior, pp.143-148, 2011. doi: 10.1109/CICN.2011.28
- [16] D. Beymer, "Person Counting Using Stereo," *Proc. Workshop Human Motion*, pp.127-133, 2000.
- [17] D. Oñoro-Rubio and R. J. López-Sastre, "Towards perspective-free object counting with deep learning," In: Leibe B., Matas J., Sebe N., Welling M. (eds) *Computer Vision - ECCV 2016*. ECCV 2016. Lecture Notes in Computer Science, vol. 9911. Springer, Cham.
- [18] M. S. Rahman and M. R. Islam, "Counting objects in an image by marker controlled watershed segmentation and thresholding," *2013 3rd IEEE International Advance Computing Conference (IACC)*, Ghaziabad, 2013, pp. 1251-1256. doi: 10.1109/IAdCC.2013.6514407
- [19] T. Kobayashi, T. Hosaka, S. Mimura, T. Hayashi, and N. Otsu, "HLAC approach to automatic object counting," *ECSIS Symposium on Bio-inspired Learning and Intelligent Systems for Security*, pp.40-45, 2008.
- [20] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.779-788, 2016.



## 문지환

<https://orcid.org/0000-0002-3504-6645>

e-mail : noel@soongsil.ac.kr

2019년 숭실대학교 컴퓨터학부(학사)

2019년 ~ 현 재 숭실대학교

융합소프트웨어학과 석사과정

관심분야 : Computer Vision & Deep Learning



## 송누리

<https://orcid.org/0000-0002-5322-6682>

e-mail : nuri@soongsil.ac.kr

2018년 숭실대학교 컴퓨터학부(학사)

2018년 ~ 현 재 숭실대학교

융합소프트웨어학과 석사과정

관심분야 : Computer Vision & Deep Learning



**최 재 갑**

<https://orcid.org/0000-0002-1167-9384>  
e-mail : kor03@soongsil.ac.kr  
2018년 군산대학교 컴퓨터학부(학사)  
2018년 ~ 현 재 송실대학교  
융합소프트웨어학과 석사과정  
관심분야 : Computer Vision & Deep Learning



**박 진 호**

<https://orcid.org/0000-0003-1961-6983>  
e-mail : j.park@ssu.ac.kr  
1994년 송실대학교 소프트웨어공학(학사)  
2001년 송실대학교 컴퓨터학과(석사)  
2011년 송실대학교 컴퓨터학과(박사)  
2016년 ~ 현 재 송실대학교 소프트웨어학과  
교수

관심분야 : Computer Vision & Deep Learning



**김 계 영**

<https://orcid.org/0000-0001-6908-6920>  
e-mail : gkim11@ssu.ac.kr  
1990년 송실대학교 전자계산학과(학사)  
1992년 송실대학교 컴퓨터학과(석사)  
1996년 송실대학교 컴퓨터학과(박사)  
1997년 한국전자통신연구원(Ph.D)  
2001년 한국전력공사 선임연구원  
2001년 ~ 현 재 송실대학교 소프트웨어학과 교수  
관심분야 : Computer Vision, Pattern Recognition, Augment Reality