

# Advanced Bounding Box Prediction With Multiple Probability Map

Poo-Reum Lee \*, Yoon Kim \*\*

## Abstract

In this paper, we propose a bounding box prediction algorithm using multiple probability maps to improve object detection result of object detector. Although the performance of object detectors has been significantly improved, it is still not perfect due to technical problems and lack of learning data. Therefore, we use the result correction method to obtain more accurate object detection results. In the proposed algorithm, the preprocessed bounding box created as a result of object detection by the object detector is clustered in various form, and a conditional probability is given to each cluster to make multiple probability map. Finally, multiple probability map create new bounding box of object using morphological elements. Experiment results show that the newly predicted bounding box reduces the error in ground truth more than 45% on average compared to the previous bounding box.

▶ Keyword: Object Detection, GrabCut, Clustering, Object Segmentation, Background Cut

## 1. Introduction

인간은 매 순간 시각, 소리, 주변 관계 등 다양한 정보를 이용해서 강건하게 사물을 판단하고 그것으로부터 여러 가지 정보를 획득한다. 이러한 인간의 상호인지 작용을 컴퓨터로 구현하기 위해서 오래전부터 많은 노력이 이루어져 왔고, 그 중 하나는 영상에서의 객체 검출 분야이다. 객체 검출 기술은 번호판 자동 인식, 침입자 탐지, 안면 인식 등 주변에서 어렵지 않게 찾아볼 수 있다.

객체 검출은 한 장의 이미지 혹은 비디오 영상에서 관심 객체의 위치를 파악하는 것을 목표로 한다. 초기에는 비교적 형태가 일정한 객체의 특징을 이용해 특징점 매칭과 같은 방법으로 객체 위치를 검출하였다. 하지만 이러한 방법은 교통 표지판과 같이 형태가 일정하게 고정된 객체에 대해서만 사용이 가능했고, 인간의 얼굴이나 동물과 같이 고정되지 않은 형태의 객체에 대해서는 좋은 성능을 내지 못하였다. 이에 Viola와 Jones는 Haar-like feature와 Adaboost를 이용한 객체 검출 기술을 제안하였고, 이를 기반으로 객체의 평균적인 feature를 추출하는 것이 가능해졌다[1].

이후에도 객체의 특징을 더 뛰어나게 표현하는 feature를 찾기 위한 노력이 계속되었고, Pedro F. Felzenszwalb는 객체를 여러 부분으로 나눈 part model과 각 부분과의 거리를 이용한 LSVM(Latent Support Vector Machine)을 제안함으로써 객체 검출 기술의 성능을 증가시켰다[2].

딥러닝(deep learning)은 객체 검출 기술에 큰 변화를 가져왔다. 대량의 정제된 학습 데이터를 이용해 객체 분류기를 학습하였고, 그 결과 YOLO(You Only Look Once)와 같은 실시간 객체 검출기가 등장하였다[3]. 하지만 딥러닝(deep learning) 기술로 나오는 객체 검출 결과는 진리값과 비교했을 때 완벽하게 매칭되지 않는다. 객체 검출 결과로 나오는 bounding box는 실제 원하는 결과에 비해 더 작게 나오거나 또는 더 크게 생성될 수 있다. 이러한 결과는 충분한 양의 정제된 학습 데이터를 확보하기가 어려운 것이 하나의 원인이다.

객체 검출 결과와 진리값의 차이를 줄일 수 있다면 이를 이용한 응용 프로그램에서 뛰어난 성능을 기대할 수 있다. 두 값

• First Author: Poo-Reum Lee, Corresponding Author: Yoon Kim

\*Poo-Reum Lee (azure@kangwon.ac.kr), Dept. of Computer and Communications Engineering, Kangwon National University

\*\*Yoon Kim (yooni@kangwon.ac.kr), Dept. of Computer and Communications Engineering, Kangwon National University

• Received: 2017. 11. 22, Revised: 2017. 12. 04, Accepted: 2017. 12. 09.

• This work was supported by Institute for Information & communications Technology Promotion (IITP) grant funded by the Korea government (MSIP) (No: R-20160906-004163, Developing Bigdata Autotagging and Tag-based DaaS System).

• This study has been worked with the support of a research grant of Kangwon National University in 2017.

사이의 차이를 줄이기 위한 기술로 이미지 segmentation과 saliency detection을 예로 들 수 있다.

이미지 segmentation은 색상, 밝기, 재질 등과 같은 이미지 내의 여러 정보를 활용해 이미지의 영역을 분할하는 알고리즘이다. Adobe사의 대표적인 프로그램인 Photoshop에서 Magic Wand Tool 역시 이미지 segmentation 기술을 사용한 대표적인 예이다. 이외의 유명한 알고리즘으로는 GraphCut과 이를 확장시킨 GrabCut 등을 예로 들 수 있다. GrabCut은 GraphCut의 분할 알고리즘에 사용자의 상호작용과 반복적인 수행을 더하여 이전보다 더 뛰어난 객체 분리 결과를 도출하였다[4,12]. 그렇지만 GrabCut은 반복적인 알고리즘 동작과 많은 계산량으로 인해 매우 느린 편이다.




Fig. 1. Dawei Yang's Segmentation Algorithm

한편 Dawei Yang 등은 더 정확한 segmentation을 위해서 saliency detection의 결과와 함께 Superpixel을 사용하였다 [6,7]. Dawei Yang은 segmentation 과정을 Coarse Stage와 Fine Stage로 나눈 뒤, 순차적으로 Superpixel 데이터와 함께 배경 정보를 이용해 Fig. 1과 같이 segmentation을 진행하였다. Dawei Yang과 같이 배경 정보를 이용하면 더 나은 segmentation을 유도할 수 있지만 사용 범위가 비디오로 제한된다. 본 논문에서는 한 장의 이미지만 이용하는 것을 목표로 하였다.

Saliency detection 또한 객체 검출 결과 보정에 사용될 수 있다. Saliency detection은 영상 내에서 두드러지는 영역을 찾는 알고리즘으로써 주로 배경 모델을 생성한 뒤 이를 기반으로 객체의 위치를 파악하는 형태의 알고리즘이다. Xiaodi Hou와 Liqing Zhang은 입력 영상으로부터 주파수를 계산한 뒤 배경의 평균 주파수로부터 벗어나는 영역을 검출하는 방법을 이용해 객체의 위치를 파악하였고[8], Hiba Ramadan과 Hamid Tairi는 비디오 영상에서 패턴 마이닝(mining) 기법을 이용해 시공간적 saliency map을 구성하였다[9]. 하지만 saliency detection은 결과로 나오는 영역이 충분히 명확하기가 힘들기 때문에 구체적인 객체 위치를 파악하는데는 많은 노력이 필요하다.

본 논문에서는 위와 같은 문제를 해결하기 위해 clustering 알고리즘을 이용한 배경-객체 분할 기술을 제안하고, 이를 이용해 객체 검출 결과로 나온 bounding box를 보정한다. Clustering을 위해 사용하는 K-means 알고리즘은 주어진 데이터를 K개의 cluster로 묶는 알고리즘으로, 본 논문에서는 주어지는 이미지에 대해 K를 변화시켜 가면서 각각의 K에 대한 확률 맵을 생성한다. K에 따라 생성된 확률 맵을 종합하여 결과 확률 맵을 만들고 이를 기반으로

배경-객체를 분할한다. 제안하는 알고리즘은 객체 검출의 결과로 주어지는 사각형 영역의 근처만을 이용하므로 수행시간이 매우 빠르다. 또한 앞서 언급한 특징으로 인해 전체 배경의 영향을 적게 받아 결과적으로 단순한 배경뿐만이 아니라 복잡한 배경에서도 좋은 성능을 보인다[5].

논문의 구성은 다음과 같다. 2절에서는 Background Cut 위주로 기존의 배경-객체 분할 방법에 대해 기술한다. 3절에서는 K-means 알고리즘을 이용한 새로운 배경-객체 분할 모델을 제안한다. 4절에서는 객체 검출 결과로 나온 사각형을 제안된 방법을 이용해 배경-객체를 분할한 결과와 GrabCut을 이용해 분할한 결과를 비교하고, 제안하는 알고리즘이 객체 검출 결과 보정에 유효함을 밝힌다. 5절에서는 결론 및 향후 과제에 대해서 논의한다.

## II. Background Cut

배경-객체 분할 알고리즘은 전경 영역과 배경 영역을 GMM(Gaussian Mixture Model)과 같은 통계적인 모델로 설계하고 영상을 두 영역으로 각각 분할했을 때, 분할 결과는 코스트 함수의 값을 최소화하는 방향으로 이루어진다.

Xiaoou Tang과 Heung-Yeung Shum이 제안한 Background Cut의 경우 Color 모델과 Contrast 모델을 이용한다[10]. Background Cut은 비디오 환경에서 수행하는 알고리즘으로, 배경 데이터를 이용해 배경 데이터와 현재 영상간의 차이를 이용해서 Color 모델과 Contrast 모델의 에너지를 구성한다. 관련 식은 다음과 같다.

$$E(X) = \sum_{r \in \nu} E_1(x_r) + \lambda \sum_{(r,s) \in \epsilon} E_2(x_r, x_s). \quad (1)$$

$E_1$ 과  $E_2$ 는 각각 Color 모델과 Contrast 모델을 의미한다.  $x_r$ 는 픽셀  $r$ 에 대한 레이블 값이며  $\epsilon$ 은 픽셀  $r$ 의 주변 픽셀  $s$ 들로 이루어진 집합이다.

Color 모델을 의미하는  $E_1$ 은 한 이미지의 모든 픽셀의 정보를 이용하여 만든 가우시안 혼합 모델과 픽셀 하나에 대한 가우시안 혼합 모델로 이루어져 있다. 이미지의 모든 픽셀에 대한 가우시안 혼합 모델을 이용함으로써 전체적인 이미지에서 급격한 픽셀값의 변화에 대해 대처할 수 있다. 또한 한 픽셀에 대한 가우시안 혼합 모델을 같이 사용함으로써 시간의 흐름에 따른 조명의 변화나 배경의 변화에 강인한 대처가 가능하다.

$$p(I_r|x=0) = \sum_{k=1}^{K_b} w_k^b N(I_r|\mu_k^b, \Sigma_k^b). \quad (2)$$

식 (2)는 배경의 Color 모델을 나타낸다.  $N(I_r|\mu_k^b, \Sigma_k^b)$ 은 가우시안 정규분포이고,  $k$ 는 전체 픽셀에 대한 혼합 분포의 인덱스이다.  $x=1$ 인 경우 전경에 대한 모델을 나타내고  $p(I_r|x=0)$ 인 경우 배경에 대한 모델을 의미한다.

$$p_B(I_r) = N(I_r|\mu_r^B, \Sigma_r^B). \quad (3)$$

식 (3)은 가우시안 분포로 구성된 각 픽셀에 대한 Color 모델을 나타낸다. 배경 픽셀에 대한 평균과 분산을 각각  $\mu_r^B$ ,  $\Sigma_r^B$ 로 표기하였다.

$$p_{mix}(I_r) = \alpha \cdot p(I_r|x=0) + (1-\alpha) \cdot p_B(x_r). \quad (4)$$

식(4)는 식 (2)와 식 (3)에서 언급한 두 식을 혼합한 식이다. 여기서  $\alpha$ 는 두 모델을 혼합하기 위한 가중치이다. 전경에 대한 Color 모델은 식 (4)에서 나오는 확률과 임계값을 비교해 판단한다. 식 (5)에서  $B$ 는 배경,  $F$ 는 전경,  $U$ 는 불확실한 영역으로 레이블링 되고, 불확실한 영역  $U$ 를 배경 또는 전경으로 판단하기 위해 Color 모델에 대한 에너지 식을 만든다.

$$E_1(x_r) = \begin{cases} -\log p_{mix}(I_r) & x_r = 0 \\ -\log p(I_r|x_r = 1) & x_r = 1 \end{cases} \quad (5)$$

식 (5)에서  $x_r$ 이 0이면 배경을 의미하고,  $x_r$ 이 1이면 전경이다.

Contrast 모델에 대한 에너지 식을 만드는 과정은 식 (6)과 같다. Contrast 모델은 인접한 두 픽셀의 색 차이를 이용한다.

$$E_2(x_r, x_s) = |x_r - x_s| \cdot \exp(-\beta d_{rs}). \quad (6)$$

앞서 나온 두 에너지 식  $E_1$ 과  $E_2$ 를 합한  $E(x)$ 가 최소가 되도록 객체를 분리함으로써 Background Cut이 동작하게 된다. 최소화하는 방법으로는 Min Cut 알고리즘을 사용한다.

### III. The Proposed Scheme

제안하는 알고리즘은 영상에 clustering 알고리즘을 이용해서 나온 결과의 형태를 분석해 확률을 부여하는 방법을 사용한다[11]. 제안하는 알고리즘은 전처리 단계와 clustering 알고리즘을 이용한 확률 맵 구성 단계, 확률 맵을 이용한 최종 위치 추정 단계로 나눌 수 있다.

#### 1. Preprocessing

입력으로 영상과 함께 객체 검출 결과로 나온 bounding box의 좌표가 주어진다. Clustering에 앞서 Fig. 2와 같이 bounding box 영역 확대를 하고 블러(blur) 처리를 한다.



Fig. 2. Bounding box area expansion (before: left, after: right)

입력으로 주어지는 bounding box의 확대 작업에는 두 가지

이유가 있다. 첫 번째는 주어지는 사각형이 객체를 충분히 포함하지 못할 가능성이 있기 때문이다. 이 작업은 제한하는 알고리즘뿐만 아니라 GrabCut과 같은 segmentation 작업의 결과를 위해서도 필요한 단계이다. 두 번째는 bounding box 내에 배경을 많이 포함시키는 효과를 주기 위해서이다. 의도적으로 bounding box 안의 배경을 증가시킴으로써 배경을 객체로 오판하는 결과를 줄이게 된다.

#### 2. Probability map making with clustering

전처리 단계가 끝나면 해당 영역에 대해 K-means를 수행한다. Fig. 3은 K=11부터 14까지의 결과이다. 실제 구현에서는 K=3부터 시작해 K=15까지 이용하였다.



Fig. 3. K-means algorithm results (from the left K=11,12,13,14)

Fig. 3과 같이 영상이 K개의 색상으로 clustering되었으면 각각의 cluster에 대해서 경계와 맞닿아 있는지 여부를 확인한다. 만약 N번째 cluster가 bounding box의 모서리와 닿아있는 경우 N번째 cluster는 배경과 밀접한 연관성이 있다고 판단하여 확률을 부여하지 않는다. N번째 cluster가 bounding box의 모서리와 닿아있지 않는 경우 객체일 가능성이 높다고 판단하여 확률값을 부여한다. 확률값은 다음 식을 사용한다.

$$p(x,y|K_n) = N(C_{(x,y)}|K_n) / \sum_{c=3}^K N(C_c|K_n). \quad (7)$$

식 (7)은 다음과 같다.  $K_n$ 번째 cluster의 위치  $(x,y)$ 에서의 확률값  $p(x,y|K_n)$ 은 전체 cluster의 수  $\sum_{c=3}^K N(C_c|K_n)$ 를  $(x,y)$ 가 포함되는 cluster의 수  $N(C_{(x,y)}|K_n)$ 을 나눈 값이다. 즉 현재 픽셀이 많은 영역을 차지하고 있다면 더 큰 값을 부여하는 형태이다.




Fig. 4. Probability map formation process




Fig. 5. Object's part image enlarged


Fig. 4는 K=4로 K-means 알고리즘을 수행한 결과를 이용해서 확률 맵을 만드는 과정을 나타내었다. K-means 알고리즘의 결과로 4개의 cluster로 영상이 분할되었고 이 중 cluster 1만 사각형 모서리와 닿아있지 않으므로 cluster 1에 해당하는 영역만 확률 맵에 값을 더한다. 값을 더하기 이전에 dilation 연산을 수행한다. 이는 Fig. 5에서 알 수 있듯이 전처리 과정에서 블러(blur) 작업을 하면서 경계가 배경 영역으로 판단되는 일이 발생하기 때문이다.

### 3. Position estimation with probability map

모든 K에 대해서 확률 맵을 구하였으면 확률 맵을 종합하여 최종 bounding box를 선정할 수 있다. 전 단계에서 K-means 알고리즘을 여러 번 수행하면서 얻은 확률 맵을 다 더하면 하나의 통합 확률 맵을 얻을 수 있다. 통합 확률 맵에서 객체와 배경을 나누는 임계값  $x$ 는 식 (8)을 이용한다.

$$\underset{0 < x < 1}{\operatorname{argmin}} (\operatorname{Var}(x) / N(x) * T). \quad (8)$$

통합 확률 맵을 0에서 1사이로 정규화한 뒤  $\operatorname{Var}(x) / N(x) * T$ 가 최소가 되는  $x$ 를 구한다.  $\operatorname{Var}(x)$ 와  $N(x)$ 는 각각 임계값  $x$ 를 기준으로 만들어진 통합 확률 맵의 분산과 유효한 확률 값을 가지고 있는 픽셀 수이다. 식 (8)은 분산을 작게 하면서 전체 픽셀 수는 많아지도록 유도한다.



(a)Input image

(b)Primary

(c)Expansion

(d)GrabCut

(e)Proposed

Fig. 6. Results using GrabCut and proposed algorithm

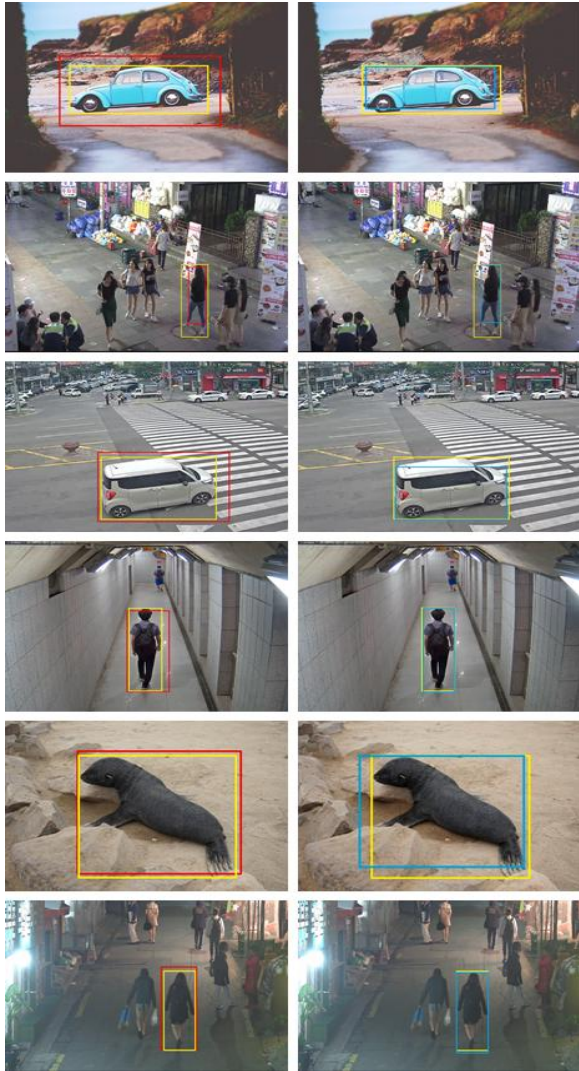


Fig. 7. Bounding box modification results (red: before, blue: after, yellow: ground truth)

#### IV. Experiment Results

본 논문에서는 K-means 알고리즘을 이용하여 객체 검출 결과로 주어지는 bounding box를 보정하는 내용을 소개하였다. Fig. 6은 지금까지 소개한 내용을 바탕으로 테스트한 결과이다. (a)는 원본 이미지이며 (b)는 딥러닝(deep learning) 기반 알고리즘으로 생성된 bounding box이다. (c)는 GrabCut 및 제안된 알고리즘을 사용하기 위해 (b)에서 확장된 bounding box이고 (d)는 GrabCut으로 나온 객체 분할 결과, (e)는 제안하는 알고리즘의 결과이다.

Fig. 6에서 쓰인 이미지들의 특징을 살펴보면, 첫 번째 자동차 이미지와 두 번째 길거리 이미지는 배경이 복잡하며, 세 번째 도로 이미지는 객체인 자동차와 주변 환경의 색이 유사한 특징을 지닌다. 네 번째 이미지와 다섯 번째 이미지는 비교적 단조로운 배경을 가지고 있고, 여섯 번째 이미지는 전체적으로 어두운 환경이다.

GrabCut의 결과 (d)와 제안하는 알고리즘의 결과 (e)를 비교하여 보면 단조로운 배경을 가지고 있는 네 번째 이미지에서는 GrabCut이 더 뛰어난 성능을 보였으나 나머지 경우에는 모두 제안하는 알고리즘이 우위에 있음을 확인할 수 있다. 특히 배경이 복잡할 수록 제안하는 알고리즘은 GrabCut에 비해 상대적으로 더 나은 결과를 보였다.

Fig. 7과 Fig. 8은 처음 객체 검출 결과로 나온 bounding box와 제안하는 알고리즘을 거쳐 나온 결과인 Fig. 6의 (e)를 기반으로 재구성한 bounding box를 비교한 결과이다. 이미지의 순서는 Fig. 6과 같으며, Fig. 7의 왼쪽 이미지는 기존 bounding box(빨간 실선)와 진리값(노란 실선)을 비교한 것이고, 오른쪽 이미지는 제안하는 알고리즘으로 보정한 bounding box(파란 실선)와 진리값(노란 실선)을 비교한 이미지이다.

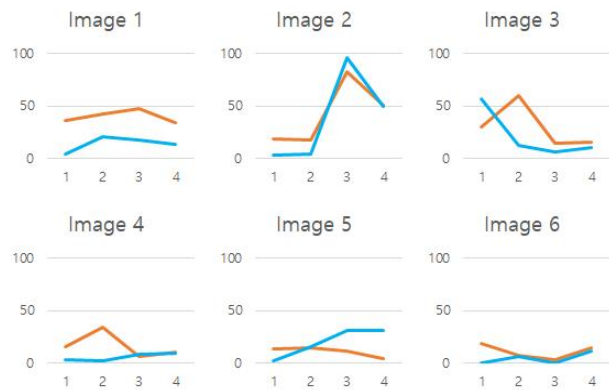


Fig. 8. Bounding box modification results graph (red: before, blue: after)

Fig. 8의 그래프는 Fig. 7의 결과를 그래프로 표현한 것으로 x축은 순서대로 top, right, bottom, left 위치를 나타내고, y축은 해당 위치에서 bounding box와 진리값과의 차이값이다. 제안하는 알고리즘은 Image 5를 제외한 모든 이미지에서 기존 bounding box보다 더 정확한 결과를 생성하였음을 확인할 수 있다. Table 1은 Fig. 7을 수치화한 것으로, BX, BY는 기존 bounding box와 진리값과의 x,y좌표 차이값이고, AX, AY는 보정 후 bounding box와 진리값과의 x,y좌표 차이값이다. 제안하는 알고리즘은 6장의 이미지 중 5장의 이미지에서 평균 45% 이상의 차이값 개선 효과를 보였다.

Table 1. Difference from ground truth

	(a)BX + BY	(b)AX + AY	(a) - (b)
Image 1	160	56	104
Image 2	171	153	18
Image 3	120	85	35
Image 4	65	22	43
Image 5	42	79	-37
Image 6	43	17	26

## V. Conclusions

본 논문에서는 clustering 알고리즘을 통한 배경-객체 분할과 이를 이용한 객체 검출 결과로 나온 bounding box의 보정에 대해서 제안하였다. 기존 bounding box에서 확장된 크기의 bounding box는 효과적으로 배경을 예측하였고, 여러 번의 clustering은 배경과 객체를 효과적으로 분리하였다. 그 결과 제안하는 알고리즘은 GrabCut과 segmentation 성능을 비교하였을 때 상대적으로 더 정확하게 객체를 표현하였고, 이를 바탕으로 새롭게 생성한 bounding box는 처음 bounding box에 비해 대부분의 이미지에서 객체를 더 정확하게 표현하였다. 제안하는 알고리즘은 복잡한 환경에서 발생하는 저조한 객체 검출 성능을 개선하는 도구로 쓰일 수 있다. 하지만 객체를 세밀하게 분리하는 능력은 아직 부족하기 때문에, bounding box와 진리값의 차이가 적을 때는 bounding box의 보정 효과가 조금 떨어질 가능성이 있다. 이에 향후 개선으로 각 cluster간의 상관관계 및 배경 모델링을 이용해 객체를 더 정교하게 검출하는 알고리즘을 설계하여 이러한 단점을 극복할 계획이다.

## REFERENCES

- [1] S. W. Jang, S. W. Byun, "Robust Detection of Body Area Using an Adaboost Algorithm," *Journal of the Korea Academia-Industrial*, Vol. 17, No. 11, pp. 403-409, June 2017.
- [2] Pedro F. Felzenszwalb, Ross B. Girshick, "Object Detection with Discriminatively Trained Part Based Models," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 32, No. 9, pp. 1627-1645, Sep. 2009.
- [3] Joseph Redmon, Santosh Divvala, "You Only Look Once: Unified, Real-Time Object Detection," *Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [4] Y. Y. Boykov, M. P. Jolly, "Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images," *Proceedings of Internation Conference on Computer Vision*, Vol. 1, pp. 105-112, July 2001.
- [5] H. J. Park, K. B. Kim, "Improved k-means Color Quantization based on Octree," *Journal of The Korea Society of Computer and Information*, Vol. 20, No. 12, Dec. 2015.
- [6] Dawei Yang, Lin Mao, "A Superpixel Segmentation Algorithm with Region Correlation Saliency Analysis for Video Pedestrian Detection", *36th Chinese Control Conference (CCC)*, pp. 5396-5399, Sep. 2017
- [7] Brian Fulkerson, Andrea Vedaldi, "Class segmentation and object localization with superpixel neighborhoods," *IEEE 12th International Conference on Computer Vision*, pp.670-677, Oct. 2009.
- [8] Xiaodi Hou, Liqing Zhang, "Saliency Detection: A Spectral Residual Approach," *IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-8, June 2007.
- [9] Hiba Ramadan, Hamid Tairi, "Pattern mining based video saliency detection," *Intelligent Systems and Computer Vision (ISCV)*, pp.1-6, Oct. 2017.
- [10] Xiaoou Tang, Heung-Yeung Shum, "Background Cut," *ResearchGate*, Jan. 1970.
- [11] Nyma Alamgir, J. M. Kim, "Effective Image Segmentation using a Locally Weighted Fuzzy C-Means Clustering," *Journal of The Korea Society of Computer and Information*, Vol. 17, No. 12, Dec. 2012.
- [12] C. Rother, V. Kolmogorov, A. Blake, "GrabCut - Interactive Foreground Extraction using Iterated Graph Cuts," *ACM Transactions on Graphics(SIGGRAPH'04)*, Vol. 23, No. 3, pp. 309-314, August 2004.

### Authors



Poo Reum Lee received the B.S., degrees in Computer Communication and Engineering from Kangwon National University, Korea, in 2015. Lee joined the Department of Computer Science at Kangwon National University, Kangwon,

Korea, in 2009. He is currently a Student in the Department of Computer Communication and Engineering, Kangwon National University. He is interested in computer vision, image processing.



Yoon Kim received the B.S., M.S. and Ph.D. degrees in Electronics Engineering from Korea University, Korea, in 1993, 1995 and 2003, respectively. Dr. Kim joined the faculty of the Department of Computer Communication and Engineering at

Kangwon National University, Kangwon, Korea, in 2004. He is currently a Professor in the Department of Computer Communication and Engineering, Kangwon National University. He is interested in computer vision, image processing, machine learning, digital signal processing.