

# TBHP 처리 세포의 이미지 인식을 통한 세포 생존율 구분에 관한 연구\*

박연균, 윤종희  
 영남대학교 컴퓨터공학과  
 pyk2181@gmail.com, youn@yu.ac.kr

## A Study on the classification of cell viability through image recognition of TBHP treated cells

Yeon-Kyun Park, Jong-Hee Youn  
 Dept. of Computer Engineering, Yeungnam University

### 요 약

이미지에 대한 정보를 식별하는 기술인 이미지 인식은 현재 무인 자동차의 자율주행, 안면 인식, 의료 등의 여러 산업 분야에 적용되어 활발히 사용되고 있다. 이 중에서 이미지 객체 인식을 활용하여, 단순히 세포를 인식하는 것에서 더 나아가 TBHP 처리 세포에 대해 용액의 투입량과 시간 등의 다양한 조건을 고려함으로써 하나의 이미지에 포함된 세포의 전체 생존율을 판단하여 구분해보고자 한다.

### 1. 서론

컴퓨터 비전(Computer Vision) 기술 중 하나인 이미지 인식은 인공지능을 이용해 기계에게 사람의 시각적 인식 능력을 제공하는 것으로 정의할 수 있다. 이미지 인식의 분야로는 크게 이미지 분류(Image Classification), 이미지 찾기(Image Localization), 이미지 인식(Image Detection), 대상분할(Object Captioning)이 존재한다[1]. 이러한 인공지능을 사용한 이미지 인식은 무인 자동차의 자율주행, 안면 인식, 의료 등 다양한 산업 분야에 적용되고 있다.

의료 계열에서 이미지 인식의 연구는 암세포 등을 초기 단계에 감지하여 질병을 예방하는 목적으로 사용되는 경우가 많다[2]. 즉 암세포, 백혈구와 같은 세포 각각에 대한 인식을 진행하여 해당 세포가 무엇인지를 구분하는데 사용되는 것이 대부분이다.


본 연구에서는 Tensorflow의 Object Detection API[3]를 활용함으로써 TBHP 세포 이미지에 대한 객체 인식을 진행하여, 단순하게 세포를 인식하는 것에서 나아가 용액의 투입량에 따른 시간별 생존율을 확인하는 것과 더불어 시간과 용액 투입량에 관

계없이 세포의 생존율만을 판단하여 한 번에 구분해 내는 것을 목표로 한다.

### 2. 이미지 객체 인식

#### 2.1 연구 개요

TBHP 처리 세포의 이미지 객체 인식을 위한 전체적인 연구 진행 과정은 그림 1과 같다.



(그림 1) TBHP 처리 세포 이미지의 객체 인식 진행 과정

#### 2.2 Image Augmentation

본격적인 이미지 인식에 앞서, 현재 보유하고 있는 TBHP 시약 처리된 세포 이미지들에 대해 Image Augmentation을 진행한다. 이는 이미지 인식 과정에서 훈련에 사용된 이미지가 적어 훈련 중에 보지 못한 이미지를 인식하지 못하거나, 오히려 훈련 이미지를 과도하게 학습하는 과적합 문제가 존재할 수 있기에 이러한 문제를 해결하기 위함이다.

별도의 테스트에 사용될 이미지를 제외한 41장의

\* 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT연구센터육성지원사업의 연구결과로 수행되었음 (IITP-2021-2016-0-00313\*)

원본 이미지에 Image Augmentation 과정을 거치고, 지나치게 변형되어 사용하기 어려운 일부 이미지를 제외한 결과 총 137장의 이미지를 생성하였다.

### 2.3 Image Labeling

이미지에 대해 인공지능이 학습하기 위해선 이미지 데이터를 인공지능이 이해할 수 있도록 입력해야 한다. 어떻게 이미지를 labeling 하는가에 따라 학습 결과가 달라질 수 있는 만큼, 정밀한 labeling을 위해 일반적으로 label을 지정해주는 도구를 사용한다. 본 연구에서는 이미지의 labeling을 위해 labelImg[4]를 사용하였다.

labelImg는 Python과 Pyqt 기반의 오픈소스 이미지 주석 도구로, 이미지에 직접 bounding box를 지정하여 알맞은 클래스를 입력하면 이미지 데이터를 xml 파일로 저장할 수 있다. labeling은 세포 각각에 대해서 진행하며, 훈련과 테스트에 사용될 이미지의 비율은 약 5:1로 진행하였다.

### 2.4 xml to TFRecord

TFRecord 파일은 Tensorflow의 딥러닝 학습에 필요한 데이터들을 보관하기 위한 바이너리 데이터 포맷이다. 학습속도를 개선하고 데이터 파일 크기를 줄일 수 있는 등, 대규모 데이터 학습에 이점을 가지고 있으므로 이를 이용하기 위해 labeling을 통해 생성된 xml 파일을 TFRecord로 변환시킬 필요성이 있다. labelImg를 통해 작성된 여러 개의 xml 파일을 하나의 csv 파일로 병합한 후, labeling에서 사용된 클래스의 정보가 담긴 label map과 사용된 이미지를 합쳐 TFRecord를 생성한다.

### 2.5 Training


객체 인식을 위한 학습 모델은 다양하게 존재한다. 본 연구에서는 앞에서 생성한 데이터셋을 학습시키기 위해 비교적 가볍고 훈련 속도가 느리지 않은 ssd mobilenet v1 coco 모델을 사용하였다.

## 3. 실험 결과

### 3.1 TBHP 처리 세포 이미지 객체 인식

먼저 용액의 투입량, 시간, 이미지 배율을 모두 고려한 데이터셋으로 훈련시킨 모델을 통해 TBHP 처리 세포의 객체 인식을 진행하였다. 용액의 투입량은 100µM, 500µM, 1000µM로 총 3가지, 시간은 3, 6, 12, 24, 48시간 간격으로 총 5가지, 이미지 배율은


10배율과 20배율 2가지로 구분된다.




(그림 2) 100µM after 12 hours (viability-97.66%)

100µM의 용액이 투입된 지 12시간이 지난 후의 세포 이미지로 결과를 확인하였다. 전체적으로 label에 맞게 인식했으나 그림 2의 왼쪽 이미지(10배율)의 경우 작은 세포를 제대로 감지하지 못했다는 것을 알 수 있다. 이를 미루어 보아 비교적 낮은 정확도를 보이는 10배율의 데이터와 크기가 작아 구분하기 어려운 작은 크기의 세포를 제거한다면 세포 인식의 정확도가 높아질 것으로 보인다.

위의 가정을 고려하여, 용액 투입량과 시간에 관련없이 세포의 생존율만을 구분해보고자 하였다. 먼저 생존율에 대한 구간을 10단위로 설정하여 labeling을 한 후, bounding box의 크기와 관련없이 모든 세포 이미지에 대한 훈련을 거친다. 그리고 bounding box의 크기를 조절하여 새로운 데이터셋을 추가로 생성한다. labelImg를 통해 이미지 객체의 labeling을 진행할 경우 bounding box의 좌표를 확인할 수 있는데, 이 값을 통해 bounding box의 크기를 계산하여 크기가 10,000픽셀 이상인 데이터로만 구성된 데이터셋과 그 미만으로 구성된 데이터셋으로 나누어 훈련한 후 그 결과를 확인하였다.



(그림 3) (box size >= 10,000) 데이터셋 훈련 모델 결과



(그림 4) (box size < 10,000) 데이터셋 훈련 모델 결과

### 3.2 Evaluation


인공지능에서 모델을 일반화하기 위해 다양한 평

가지표가 존재하는데, 이미지의 객체 인식에서는 모델의 성능을 평가하기 위해 Precision-Recall(PR) 곡선과 Average Precision(AP)을 사용한다.

| Ground Truth | Predict Result      |                     |
|--------------|---------------------|---------------------|
|              | Positive            | Negative            |
| Positive     | TP (True Positive)  | FN (False Negative) |
| Negative     | FP (False Positive) | TN (True Negative)  |

(그림 5) Confusion Matrix


객체 인식에서 객체의 TP과 FP를 결정하는 기준은 IoU(Intersection over Union)이다. Ground truth의 bounding box와 예측된 bounding box간 중첩되는 부분의 면적을 합집합의 면적으로 나눈 값이 0.5 이상이면 TP로, 0.5 미만이면 FP로 판단하는 것이다.



(그림 6) IoU(Intersection over Union)

Recall과 Precision을 구하여 각각 x축과 y축으로 나타낸 그래프를 PR 곡선이라 한다. PR 곡선은 객체 인식의 성능 평가지표로 적절하지만, 숫자로 평가를 나타내는 것이 편리하고 직관적이라 그래프의 면적을 구해 대신 사용하며 이 값이 바로 AP이다.

이를 이용해 위에서 실험한 bounding box의 크기가 10,000픽셀 이상인 데이터셋으로 훈련된 모델과 그 미만으로만 구성된 모델, 크기 구분없이 모든 데이터를 포함하고 있던 생존율을 10단위로 labeling한 기존의 모델 총 3가지의 AP를 비교해 보았다.



(그림 7) bounding box 크기에 따른 AP 비교

IoU는 0.5:0.05:0.95가 가장 기본적인 지표로 설정되어 있다. IoU가 0.5부터 시작해 0.05씩 0.95까지 증가해가며 서로 다른 IoU 임계값에 대한 AP를 나타내는 것이다.

첫 번째의 실험과 유사하게, 작은 세포만을 labeling한 10,000픽셀 미만의 bounding box로 훈련된 모델의 경우 AP가 기존 모델보다 하락했으며, 이는 용액 투입량과 시간별로 큰 차이를 보이지 않는 작은 세포로 label이 구성되어 판별이 어렵기 때문으로 보인다. 반면에 10,000픽셀 이상으로 훈련된 모델은 기존 모델과 비교하여 전체적으로 AP가 증가했으며, 세포의 인식을 비교적 정확하게 했음을 알 수 있다. 이 밖에도 bounding box의 최소 크기를 다양하게 조절하며 AP를 평가했으나 그 크기의 범위를 지나치게 제한하는 것보다 인식하기 어려운 작은 크기의 box만 제외하는 것이 데이터가 다양하여 더 긍정적인 결과값이 나왔음을 확인하였다. 이를 통해 정확도가 높은 10,000픽셀 이상으로 훈련된 모델을 사용하여 이미지에 포함된 전체 세포들에 대한 최종적인 생존율을 출력하였는데, 일반적으로 한 이미지에 포함된 경우 같은 생존율을 가지고 있으므로, 세포 인식 과정에서 출력되는 세포 생존율의 결과를 카운트하여 최종 생존율을 판단하였다.

#### 4. 결론

본 논문에서는 TBHP 처리 세포의 이미지 인식을 진행하여 용액의 투입량과 시간 등의 다양한 조건을 고려해 데이터셋을 구성하였다. 또한, 한 이미지에 포함된 세포들은 일반적으로 같은 생존율을 가지고 있다는 점을 통해 세포 각각의 생존율 데이터를 카운트하여 이미지 전체에 대한 세포의 생존율을 판단하여 구분해 보았다.

향후에는 본 연구에서 더 나아가 인식된 세포 객체에 대한 label과 그 정확도를 통해 수치를 적절하게 계산하는 등의 과정을 거쳐 생존율에 대한 이미지 인식의 정확도를 높이는 연구로 확장해 나갈 것이다.

#### 참고문헌

[1] CS231n (Stanford) Lecture Slides, Accessed 209. <http://cs231n.stanford.edu/slides/2017>

[2] Priyank Hajela, Ambika Vishal Pawar, Swati Ahirrao. Deep Learning for Cancer Cell Detection and Segmentation: A Survey, IEEE Punecon, 2018

[3] "Object Detection API", [https://github.com/tensorflow/models/tree/master/research/object\\_detection](https://github.com/tensorflow/models/tree/master/research/object_detection)

[4] "labelImg", <https://github.com/tzutalin/labelImg>