

Faster R-CNN과 이미지 오그멘테이션 기법을 이용한 화염감지에 관한 연구

A Study on Flame Detection using Faster R-CNN and Image Augmentation Techniques

김재중*, 류진규*, 곽동걸[★], 변선준**

Jae-Jung Kim*, Jin-Kyu Ryu*, Dong-Kurl Kwak[★], Sun-Joon Byun**

Abstract

Recently, computer vision field based deep learning artificial intelligence has become a hot topic among various image analysis boundaries. In this study, flames are detected in fire images using the Faster R-CNN algorithm, which is used to detect objects within the image, among various image recognition algorithms based on deep learning. In order to improve fire detection accuracy through a small amount of data sets in the learning process, we use image augmentation techniques, and learn image augmentation by dividing into 6 types and compare accuracy, precision and detection rate. As a result, the detection rate increases as the type of image augmentation increases. However, as with the general accuracy and detection rate of other object detection models, the false detection rate is also increased from 10% to 30%.

요약

최근 딥러닝(deep learning) 인공지능 기반의 컴퓨터 비전 분야는 각종 영상분석 분야에서 화제로 떠오르고 있다. 본 연구에서는 딥러닝 기반의 여러 이미지 인식 알고리즘 중 이미지 내에서 객체를 검출하는 데 사용되는 Faster R-CNN 알고리즘을 이용하여 화재 이미지에서 불꽃을 검출하고자 한다. 학습 과정에서 소량의 데이터셋을 통한 화재검출 정확도 향상을 위해 이미지 오그멘테이션(image augmentation) 기법을 이용하고, 이미지 오그멘테이션을 6가지 유형별로 나누어 학습하여 정확도, 정밀도, 검출률을 비교하였다. 그 결과, 이미지 오그멘테이션의 종류가 늘어날수록 검출률이 상승하지만, 다른 객체 검출 모델들의 일반적인 정확도와 검출률의 관계와 마찬가지로 오검출률 또한 10%에서 최대 30%까지 증가하게 됨을 확인하였다.

Key words : Artificial intelligency, Deep leaning, Object detection, Faster R-CNN, Image augmentation

* Graduate School of Disaster Prevention, Kangwon National University

** Thermal-Hydraulic Design Team, KEPCO Nuclear Fuel

★ Corresponding author

E-mail : dkkwak@kangwon.ac.kr, Tel : +82-33-570-6823

※ Acknowledgment

• This study was supported by 2017 Research Grant from Kangwon National University(No. 620170151).

• This work(Grants No. S2686471) was supported by project for Cooperative R&D between Industry, Academy, and Research Institute funded Korea Ministry of SMEs and Startups in 2018.

Manuscript received Dec. 9, 2018; revised Dec. 21, 2018; Accepted Dec. 26, 2018

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

최근 5년간 서울시에서 발생한 화재사고 가운데 소방대의 도착 골든타임 5분 내에 도착한 경우 재산 피해는 292만 원, 인명피해는 0.044명이었고, 반면에 골든타임을 지나서 소방대가 도착한 경우의 재산피해는 1,061만 원, 인명 피해는 0.065명으로 집계되었다[1]. 그러므로 화재사고에서 골든타임을 지키는 것은 매우 중요한 요소이다. 그러나 현재의 소방설비에 준한 화재 예방시스템 및 기존의 화재감시 시스템으로는 세밀한 감시가 힘들어 초기 화재에 빠른 대응이 힘든 실정이다. 또한 사람이 직접 실시간 감시하는 경우 인력의 수요가 필요하고, 넓은 영역에 대해 감시 장비를 사용한다면 운용과 유지관리의 측면에서 비용적인 부담이 크다. 최근 IT 기반의 응용 프로그램을 이용한 안전사고 예방의 연구들이 많이 진행되고 있다. 특히 인공지능(artificial intelligency, AI) 기법을 이용한 기술들이 개발되고 있는데, JP모건이 개발한 LOXM이라 불리는 주식거래 알고리즘 AI는 인간보다 효율적인 성능을 보여주었다[2]. 또한 기계학습 알고리즘의 일종인 딥러닝 인공지능기법은 합성곱신경망(Convolutional Neural Network, CNN)의 등장 이후에 컴퓨터 비전 분야에서 큰 주목을 받고 있는 학제 간 분야이다.

CNN 기법의 객체검출(object detection)기법은 이미지분류(classification)만을 수행하는 모델보다 비교적 추론시간이 오래 걸리고, 오검출율이 높다. 그러나 객체검출기법은 이미지 하나로부터 한번에 여러 사물의 종류와 위치를 추론할 수 있는 장점이 주어진다[3][4].

본 연구에서는 이미지 기반 인공지능 물체감지 검출기법 중 딥러닝 기반의 Faster R-CNN 기법을 이용하여 화재에서의 불꽃을 인식하고, 이미지 오그멘테이션기법을 이용하여 검출 정확성을 향상시키고자 한다. 이미지 오그멘테이션에서는 6가지의 유형을 설정하여 학습시키고, 사용된 유형에 따른 화재 이미지의 검출 평가를 통해 정밀도의 차이를 비교하였다.

II. 인공지능기법을 이용한 화재검출

1. 딥러닝 인공지능 기법의 개요

딥러닝은 인공지능 알고리즘 기법 중 동물의 신

경구조를 본떠 만든 퍼셉트론 알고리즘(perceptron algorithm)을 기초한 것으로서, 분석 데이터의 출력은 입력값과 가중치(weight)의 곱, 그리고 바이어스(bias)의 합으로 주어진다. 이 출력값이 예측값의 활성화함수(activation function) 리턴값과 다를 경우 가중치를 조정하여 또 다시 업데이트된 출력값을 활성화함수 리턴값과 비교해 나가며 분석하는 것으로써 임계치를 넘으면 1, 임계치를 넘지 못하면 0을 출력한다. 이렇게 임계치를 넘을 경우 활성화되고, 0과 1사이의 예측값은 계단함수(step function)로 표현된다. 실제 인공지능 모델들에서는 주로 Sigmoid나 Relu, Softmax 함수 등이 주로 사용된다[5].

본 연구에서 사용한 검출기법인 Faster R-CNN에서는 객체검출 최종단계에서 Softmax 함수를 이용한 분류기(classifier)가 사용되었다.

Softmax 함수는 Sigmoid 함수와 마찬가지로 각 장치의 출력을 0과 1 사이로 정규화하여 한정시키는 기능을 한다. Softmax함수는 식 (1)과 같이 정의되며 Sigmoid 함수의 일반화된 형태이다.

$$S_j = \frac{e^{x_j}}{\sum_{i=1}^j e^{x_i}} \quad (1)$$

여기서 S_j 는 j 번째의 출력을 의미하며 n 은 출력층의 뉴런의 수이다. 식 (1)의 분자는 $i=1\dots j$ 까지 입력신호 x_i 의 지수함수의 합이다.

과거 전통적인 인공지능 알고리즘은 은닉층(hidden layer)이 1개인 단층구조의 신경망(single layer)형태였다. 그러나 딥러닝 인공지능 기법은 은닉층이 2개 이상인 심층신경망(deep neural network)을 이용한 것으로써, 과거에는 은닉층이 여러 개인 복잡한 알고리즘을 하드웨어의 사양 한계의 문제로 객체검출이나 광범위한 데이터의 연산이 힘들기 때문에 주목받지 못하였으나, 현재는 하드웨어의 비약적 발전으로 심층신경망을 이용한 연산을 실행하기 용이해졌다[6].

또한 본 연구에서는 파이썬(Python)에서 사용되는 대표적인 인공지능 오픈소스 라이브러리인 텐서플로우(tensorflow)와 이것에 연동하여 사용할 수 있는 오픈소스 프레임워크인 Object Detection API를 활용하였고, Faster R-CNN 검출기법을 기반으로 객체검출모델을 구성하였다.

2. 화재검출을 위한 Faster R-CNN 알고리즘

이전의 CNN 기반의 객체검출모델들은 선택적 탐색(selective search)을 검출 알고리즘으로 사용하였다. 하지만 이 방법은 많은 데이터 소비로 인해 비용적, 시간적으로 비효율적이었다. 이를 개선하기 위해 입력 이미지에서 슬라이딩 윈도우(sliding window) 방식 즉, 일정한 크기를 가지는 윈도우를 가지고 이미지의 모든 영역을 탐색하면서 객체를 검출해내는 방식인 Region proposal 생성 알고리즘을 이용하여, 객체가 존재할 것으로 추정되는 Region proposal들을 추출해서 Bounding box에 의한 CNN을 거쳐 객체를 검출하는 R-CNN 기법이 소개되었다[7][8].

R-CNN은 모든 Region proposal 마다 하나의 CNN을 돌려야 하므로 속응성이 저조한 큰 단점이 있었다. 이를 보완하기 위해 개발된 Fast R-CNN은 검출 이미지 형상(feature)을 입력 이미지로부터 추출하는 것이 아니라 CNN을 거친 이미지 형상 맵(map) 상에서 공간적 피라미드 풀링(spatial pyramid pooling)의 특수한 형태인 RoI(Region of Interest) 풀링을 사용하여 이미지 형상을 추출하는 방식으로서 한번의 CNN 수행으로 객체검출이 이루어지는 특징이 주어진다. Fast R-CNN 또한 객체검출의 수행 속도에는 향상된 점은 있었지만, 이미지 검출 범위를 제안하는 Region proposal을 생성하기 위해서 선택적 탐색이라는 알고리즘이 사용되므로 많은 수의 Region proposal이 생성되어 데이터 프로세서의 병목현상이 발생하는 단점이 주어졌다.

Faster R-CNN은 이러한 Fast R-CNN의 병목현상 문제를 해결하기 위해 Region proposal을 생성하는 방법 자체를 그림 1과 같이 CNN 내부에 RPN (Region Proposal Network)이라는 네트워크 구조를 첨부한 형태를 가진다[8].

또한 Faster R-CNN은 입력 이미지에 대해 3가지 크기와 3가지 비율을 갖는 총 9개의 앵커(anchor)를 이용하여 특징 맵으로부터 특징을 추출해 내고, 이렇게 추출된 특징은 RPN과 RoI 풀링 레이어가 공유하게 된다. RPN은 특징 맵에서 Region proposal들을 추출해 내고, 추출된 Region proposal들은 RoI 풀링 레이어를 통해 RoI 풀링을 수행한다.

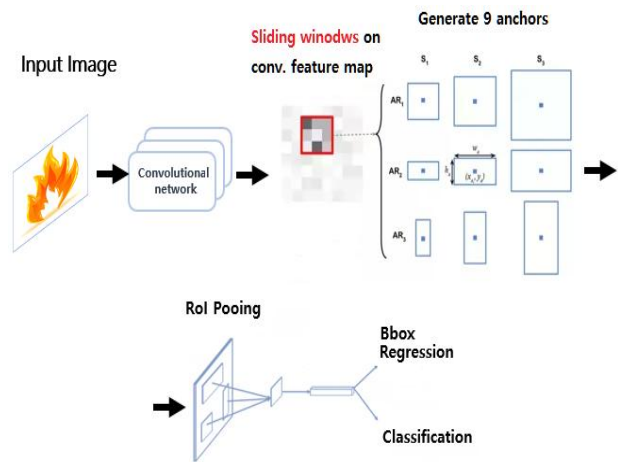


Fig. 1. Construction of Faster R-CNN detector technique.

그림 1. Faster R-CNN 검출기법의 구조

여기서 RPN은 추출된 특징 맵 위를 지정된 크기의 윈도우를 슬라이딩하면서, 윈도우가 지나가는 각 지점마다 지정된 크기의 앵커(anchor)를 지정된 개수만큼 생성시키고, 모든 앵커들에 대해서 Bounding 상자의 좌표와 그 안에 객체가 들어있을 확률을 계산한다. 앵커들 자체가 Bounding 상자의 후보군이 된다.

또한 RPN은 각각의 Window 위치에서 k 개의 앵커 상자들을 생성한 후 각각의 위치, 크기, Bounding 상자로서의 점수들을 계산한다. 그러므로 reg 레이어는 k 박스의 좌표, 즉 앵커의 x, y 좌표와 폭(width), 높이(height)를 인코딩하고, cls 레이어는 각 제안에 대해 객체의 유무와 확률을 추정하게 된다. 즉, cls 레이어는 해당 박스 안에 객체의 존재 여부를 분류하고 reg 레이어는 객체를 감싸는 Bounding 상자의 정확한 위치를 예측하게 된다. 두 레이어들의 학습을 통하여 객체가 들어 있는 정확한 Bounding 상자, 즉 RoI들을 추출할 수 있다. Faster R-CNN에서의 이미지에 대한 RPN 손실함수(loss function) $L(p_i, t_i)$ 는 식 (2)와 같이 주어진다. p_i^* 는 각 앵커의 두 가지 레이블(label)을 지정하는데 앵커가 Truth_box에 중첩하는 경우나 IoU (Intersection over Union)가 0.7보다 큰 중첩을 갖는 앵커인 경우 양수의 레이블을 지정하고, 0.3미만인 경우는 음수의 레이블을 지정한다. 양수도 음수도 아닌 레이블을 지닌 앵커는 학습에 관여하지 않도록 한다. 이러한 정의를 통해 다중 작업 손실에 따른 목적함수(objective function)를 최소화한다.

$$L(p_i, t_i) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (2)$$

p_i : Predicted probability of anchor
 p_i^* : Ground-truth label
 λ : Balancing parameter
 t_i : Predicted Bounding box
 t_i^* : Ground-truth box

i 는 미니배치에서 앵커의 색인(index)이고, p_i 는 앵커 i 가 객체를 감지하는 확률이다. Ground truth 레이블인 p_i^* 는 앵커가 양수이면 1이고 앵커가 음수이면 0이 된다. t_i 는 예측 경계 상자의 4개의 매개 변수 좌표를 나타내는 벡터이고, t_i^* 는 양수 앵커와 연관된 Ground truth_box의 매개 변수이다. 분류손실 L_{cls} 는 두 클래스(객체인 경우와 아닌 경우)에 대한 로그 손실이고, L_{reg} 는 위치 예측손실을 나타낸다[8][9].

또한 Bounding 상자 생성을 위한 4개의 매개 변수 좌표 벡터는 식 (3)~(6)과 같이 산출된다.

$$t_x = (x - x_a)/w, t_y = (y - y_a)/h_a \quad (3)$$

$$t_w = \log(w/w_a), t_h = \log(h/h_a) \quad (4)$$

$$t_x^* = (x^* - x_a)/w_a, t_y^* = (y^* - y_a)/h_a \quad (5)$$

$$t_w^* = \log(w^*/w_a), t_h^* = \log(h^*/h_a) \quad (6)$$

여기서 x, y, w 및 h 는 이미지 Bounding 상자의 중심 좌표와 폭 및 높이를 나타내며, 변수 x, x_a, x^* 는 예측상자, 앵커상자 및 Ground truth 상자를 나타낸다.

본 연구에서는 다양한 화재검출을 위하여, 화재가 포함된 이미지 사진을 총 400장 수집하여 데이터셋을 구성하였다. 라벨링(labeling)된 400장의 사진은 표 1과 같이 320장은 트레인셋(train set)으로 80장은 테스트셋(test set)으로 나누었다.

학습을 위한 트레인셋 이미지들은 Faster R-CNN 알고리즘 모델이 유추한 검출값과 실제값과의 오류 분석을 위해 사용되었고, 테스트셋 이미지들은 학습과정 중 RPN과 RoI 풀링의 학습모델의 가중치 조절을 위해 사용되었다.

Table 1. Classification of data set.

표 1. 데이터셋의 분류

Classification of data set	Number of data set
Train Set	320
Test Set	80

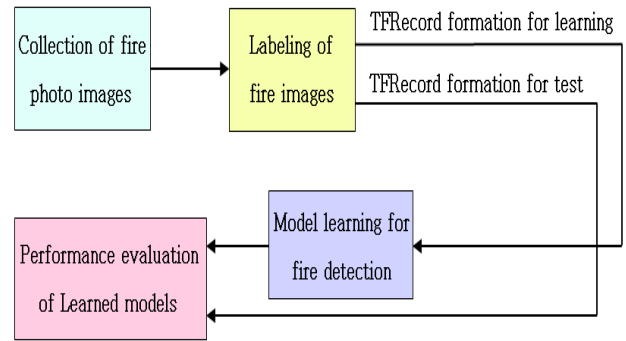


Fig. 2. Flowchart of data set processing.

그림 2. 데이터셋 처리 순서도

또한 수집된 이미지를 학습에 사용하기 위해서는 그림 2와 같이 이미지파일(jpg 등)에 화재에 해당되는 영역과 해당 객체의 이름을 라벨링하고, 텐서플로우에서 사용되는 대용량 데이터 스트리밍에 적합한 표준데이터 파일 포맷인 TF_record 파일로 변환된다.

대규모 이미지 데이터셋으로 작업하는 텐서플로우는 반복 학습을 하는 동안 이미지파일 포맷으로 매번 불러오게 되는데 이 경우 데이터셋 로딩에 많은 시스템 리소스의 손실이 발생하게 된다. 그러므로 데이터셋을 저장할 때 이진 파일 형식을 사용하면 데이터셋의 로드시 파이프 라인의 성능이 활성화되고, 학습된 모델의 교육시간을 향상시키는 효과가 주어진다. 그 결과, 이진형식의 데이터는 적은 디스크 공간을 요구하고 복사 시간이 짧으며 디스크에서 훨씬 효율적으로 읽을 수 있는 장점이 주어진다.

3. 이미지 오그멘테이션을 이용한 화재검출 정확도 향상

딥러닝 알고리즘에서 데이터셋 학습을 통해 우수한 이미지 검출 성능을 얻기 위해서는 많은 양의 데이터셋이 필요하다. 그러므로 제한된 적은 양의 학습용 데이터셋을 사용하여 강력한 이미지 검출 알고리즘을 모델링하려면 이미지 증강작업이 필수적이다. 입력된 이미지 데이터셋의 품질이 낮은 경

우에도 데이터셋의 모델에서 유용한 데이터를 추출할 수 있다면 실제로 알고리즘의 질이 높아질 수 있다. 예를 들어, 텍스트 음성 변환 및 텍스트 기반 모델은 구글에 의해 1조 단어의 자료집이 릴리스됨으로써 성능이 크게 향상 되었다[10]. 이 결과는 웹 페이지에서 수집된 필터링 되지 않은 많은 데이터들의 확보로 인한 것이다.

본 연구에서 사용한 이미지 오그멘테이션은 객체 검출 API의 전처리기(preprocessor)을 이용하여, 그림 3과 같이 원본이미지를 무작위 회전, 좌우반전, 상하반전, 색채왜곡효과, 대비조정 등과 같은 방법을 통하여 인위적으로 학습에 필요한 이미지 데이터셋의 수를 보장하였다.

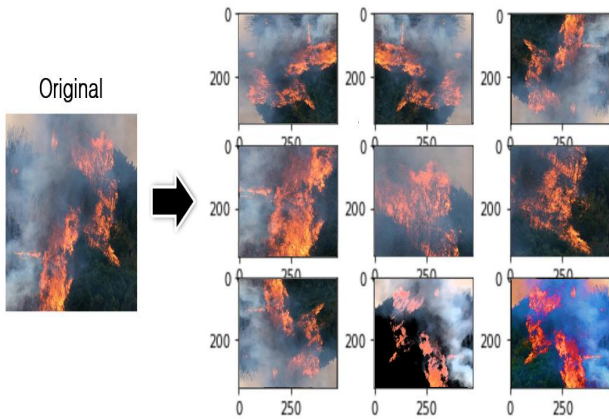


Fig. 3. Flame images using image augmentation.
그림 3. 이미지 오그멘테이션을 이용한 화염 이미지

표 2는 본 연구에서 제안한 이미지 오그멘테이션 요소별 유형을 나타낸다. 표와 같이 5개의 이미지 증강 요소들을 선정하여, A~F까지 6개의 유형별로 나누어 이미지 오그멘테이션의 증강기법을 적용하여 분석하였다.

Random Horizontal Flip은 학습 중 무작위로 이미지를 수평대칭 이미지를 생성시키고, Random Vertical Flip의 경우는 학습 중에 이미지를 수직대칭 이미지를 생성시킨다. 그리고 Random Rotation 90°는 무작위로 이미지를 반시계 90°방향으로 회전시킨 이미지를 만든다. Random Color Distortion은 원본 이미지를 밝기, 색조, 명암 및 색상의 조합을 사용하여 색상을 무작위로 왜곡된 이미지를 만들고, 마지막 Random Adjust Contrast는 무작위로 대비조정을 수행한 이미지를 만들게 된다.

Table 2. Proposed types of image augmentation.

표 2. 제안한 이미지 오그멘테이션 유형

Factors \ Types	A	B	C	D	E	F
Random Horizontal Flip		○	○	○		○
Random Vertical Flip			○	○		○
Random Rotate90°				○		○
Random Color Distortion					○	○
Random Adjust Contrast					○	○

III. 화재검출 모델 학습 및 실험결과

1. 화재검출 모델의 학습

본 연구에서 Faster R-CNN 알고리즘 모델과 이미지 오그멘테이션의 학습에 사용된 CPU 및 GPU 장비의 사양과 사용된 운영체제를 표 3에 나타낸다.

Table 3. Specification used to model learning.

표 3. 모델 학습에 사용된 사양

Devices	Specification
CPU	i7-8750H
GPU	GTX1060
OS	UBUNTU 18.04

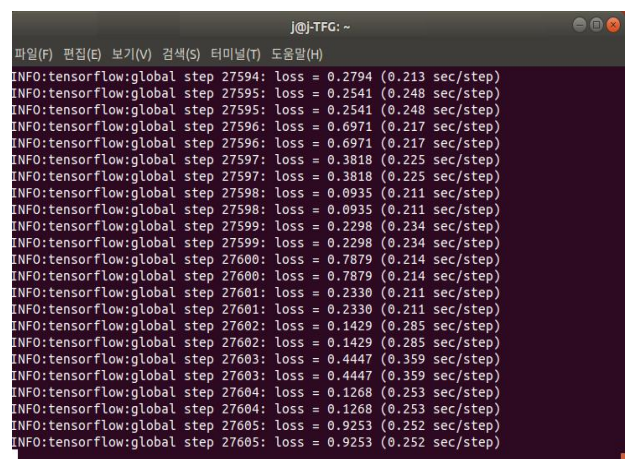


Fig. 4. Learning processing of fire detection model.

그림 4. 화재검출 모델의 학습처리 과정

반복학습의 횟수는 텐서보드를 통해 확인하였을 때 손실이 크게 줄어들지 않고 일정 수치에 수렴하

는 30,000회 까지 진행하였고, 이미지 오그멘테이션의 증강 요소를 늘리게 되면 학습 초반에 손실이 커졌지만, 학습 횟수가 20,000회 이후에서의 손실은 A~F까지의 경우가 모두 비슷하게 나타났다. 리눅스운영체제 기반의 딥러닝 Faster R-CNN과 텐서플로우를 이용한 학습과정 프로세서를 그림 4에 나타낸다. 각 Global step 우측으로 스텝 수, 손실 및 스텝당 소요된 시간을 나타낸다.

2. 실험결과 및 평가

화재 이미지 검출 평가는 화재 이미지에서 불꽃을 검출하지 못한 횟수를 FN(false negative), 불꽃을 검출한 경우를 TP(true positive), 비화재 이미지에서 불꽃을 검출하지 않아 비화재로 판단할 경우를 TN(true negative), 그리고 FP(false positive)는 비화재이미지의 평가에서 불꽃을 오검출하였을 경우의 횟수로 정의한다.

또한 이미지 내에서 원하는 객체의 검출비율이 높은 모델의 경우 검출률(Recall) 자체는 높으나, 검출하고자하는 객체가 없는 이미지 내에서 잘못된 검출을 하는 비율도 높아진다. 그러므로 거짓양성(FP)의 비율이 적어면서 참양성(TP)의 비율이 높은 균형적인 객체검출이 이루어져야 이상적인 모델로 정의된다. 그리고 본 연구에서의 TP는 PASCAL VOC2007 metrics에서 정의하는 식 (7)을 기준으로 설정하였고, IoU가 50% 이상일 때 즉, 검출하고자 하는 객체와 모델이 검출한 영역의 절반 이상 겹쳐지도록 예측한 인스턴스의 수를 TP로 정의하였다.

$$IoU = \frac{area(true\ boundingbox \cap predicted\ boundingbox)}{area(true\ boundingbox \cup predicted\ boundingbox)} > 0.5 \tag{7}$$

식 (7)을 기준으로 화재와 비화재에 대한 평가 결과가 올바르게 예측한 경우와 잘못 예측한 경우를 각각 구한 뒤, 식 (8)을 통해 정확도(accuracy), 식 (9)의 정밀도(precision), 그리고 식 (10)과 같이 검출률(recall)의 공식을 이용하여 각각의 결과값을 구하였다.

$$Accuracy = \frac{tp + tn}{tp + tn + fp + fn} \tag{8}$$

$$Precision = \frac{tp}{tp + fp} \tag{9}$$

$$Recall = \frac{tp}{tp + fn} \tag{10}$$

그림 5는 인위적인 화염에 대한 본 논문에서 제안한 Faster R-CNN과 이미지 오그멘테이션을 적용한 불꽃검출 결과를 나타낸다.




Fig. 5. Flame Detection results in fire images. 그림 5. 화재 이미지에서 불꽃의 검출 결과

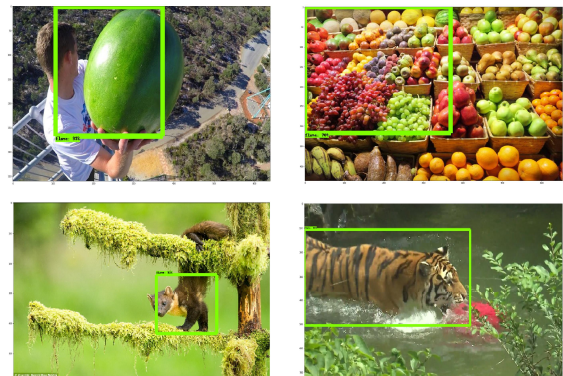


Fig. 6. Unrecognizable types in non_fire images. 그림 6. 비화재 이미지의 오검출 유형

이는 Faster R-CNN의 Region Proposal네트워크와 RoI 풀링 학습수행을 통해 올바르게 불꽃을 감지하고 불꽃 영역을 검출하였다. 또한 이미지 오그멘테이션의 각 유형에 대한 정확도, 정밀도, 그리고 검출률의 결과값을 나타낸다.

그림 6은 불꽃이 포함되지 않은 비화재 사진으로 학습모델이 오검출한 결과물을 보여주고 있다. 비화재사진에서 불꽃의 오검출은 대부분 복잡한 과일이나 꽃이 모여 있는 부분 혹은 무늬가 있는 부분을 불꽃으로 오검출하였다.

앞서의 표 2에서 정의한 이미지 오그멘테이션을 적용한 각 유형별 모델들에 대해 10,000회, 15,000회, 30,000회 학습을 수행하였고, 각 유형에 대한 화재, 비화재 이미지 검출 평가를 수행한 결과를 표 4에 작성하였다.

Table 4. Detection results on image augmentation types.

표 4. 이미지 오그멘테이션 유형별 검출결과

Learning steps	10,000		15,000		30,000	
	Fire (TP)	No_F. (FP)	Fire (TP)	No_F. (FP)	Fire (TP)	No_F. (FP)
A	33	5	34	5	34	5
B	35	5	35	4	35	5
C	34	6	35	5	35	5
D	35	8	36	7	36	7
E	37	11	37	10	37	10
F	37	12	38	10	38	12

400장의 다소 적은 수의 양으로 구성된 기본 데이터셋을 통해 학습하였고, 평가를 위해 화재이미지 40장과 비화재(No_F.)이미지 40장을 사용하였으며, 화재이미지에서는 30,000회 학습 기준으로 평균 37.7장의 이미지에서 불꽃의 위치를 올바르게 검출하였다. 최종 학습의 종료시점인 30,000회 학습하였을 경우를 기준으로 정확도, 정밀도, 검출률을 그림 7과 같이 그래프로 표시하였다.

아무런 이미지 증강 요소를 적용하지 않은 A의 경우 정확도 0.86, 정밀도 0.87 또한 검출률 0.85로 나타났다. 그리고 Random horizontal flip만을 적용한 B의 경우는 전체적으로 TP와 FP의 수치가 좋아져 정확도, 정밀도, 검출률 모두 0.88로 상승하였다. Random horizontal flip과 Random vertical flip




Fig. 7. Graphs of Accuracy, Precision, and Recall.

그림 7. 정확도, 정밀도, 검출률 그래프

을 적용한 유형 C의 경우도 동일한 정확도와 정밀도 그리고 검출률을 보였다. 그러나 유형 D의 경우부터는 기존보다 검출률은 0.9로 상승하였으나 오검출 비율이 많이 증가하여 정밀도는 약 0.84까지 떨어졌다. 유형 E의 경우는 검출률 0.93으로 대부분의 화재사진에서 불꽃을 정확하게 검출하였으나 비화재사진에서 높은 오검출로 인해 FP의 수치가 증가하여 background error가 급격히 증가함을 보여주었다. 유형 F의 경우는 검출률 0.95, 정밀도 0.76, 정확도 0.83으로 이번 연구에서 10,000회 학습에서 FP의 비율이 가장 높은 12장까지 검출되어 정확도 하락의 높은 원인이 되었다. 이것은 이미지 오그멘테이션의 종류가 늘어날수록 검출률이 상승하지만, 오검출을 또한 10%에서 최대 30%까지 증가하게 됨을 확인하였다.

연구 초기 15,000회까지 학습하였을 때에는 이러한 이유가 A~C 유형의 경우는 기본 데이터셋이 소량인 점과 단순히 뒤집기 반전의 이미지 오그멘테이션의 기법을 사용하여 과적합이 발생하여 TP와 FP의 비율이 적은 것으로 분석되었고, 반면에 유형 E와 F의 경우는 이미지 오그멘테이션의 요소 증가로 인한 데이터셋의 다양성이 증가하여 안정적으로 FP의 비율과 학습손실이 줄어든 결과를 가진다. 그리고 실제 학습 횟수 2만회 초반부터는 A~F 경우 모두 FP는 크게 줄어들지 않고 손실 또한 큰 변화가 없어 30,000회에서 학습을 종료하게 되었다.

결과적으로 Random adjust contrast와 Random color distort를 적용한 유형 E와 5가지 오그멘테이

션을 모두 적용한 유형 F의 경우 모두 검출률은 좋아 지었으나 정확도와 정밀도는 크게 떨어지는 것으로 이미지 오그멘테이션 기법이 원본이미지에 비해 변화가 크거나 종류가 많아질수록 background error가 많이 나타남을 알 수 있다. 그 결과 가장 학습이 잘된 케이스는 background error가 적으면서 검출률이 비교적 높아 정확도가 증가한 유형 B와 C로 분석되었다. 이는 이미지 오그멘테이션의 효과를 많이 추가한 유형 D, E, F의 경우는 학습초반 손실이 커졌고, 학습 진행을 오래하더라도 정확도가 떨어지게 된다는 결과를 얻었다.

IV. 결론

본 연구에서는 이미지 기반 인공지능 물체감지 검출기법 중 딥러닝 기반의 Faster R-CNN 기법을 이용하여 다양한 화재에서의 불꽃을 검출하였고, 소량의 이미지 데이터로 화재검출의 정확성을 높이기 위해 이미지 오그멘테이션 기법을 이용하여 향상시켰다. 제안한 이미지 오그멘테이션에서는 400장의 기본 이미지 데이터셋과 6가지의 유형을 설정하여 학습시켰고, 사용된 유형에 따른 화재 이미지의 검출 평가를 통해 정확도의 차이를 비교하였다. 본 연구를 통해 소량의 데이터셋으로도 불꽃을 95%이상의 비율로 검출할 수 있음을 확인하였으며, 단순히 이미지 오그멘테이션의 종류를 늘리거나 복잡한 변조를 많이 할 경우 실제 정확도는 80%아래까지 떨어지는 경우가 발생함을 확인하였다. 이것은 이미지오그멘테이션의 종류가 늘어날수록 검출률은 상승하지만, 오검출을 또한 10%에서 최대 30%까지 증가하게 됨을 확인하였다. 이는 Lecoutre et al.[11]과 Hussain et al.[12]의 논문에서도 마찬가지로 선택된 이미지 오그멘테이션 효과가 단순히 이미지를 scale, rotate, flips 등의 효과를 통해 학습한 경우보다 노이즈가 심한 이미지 오그멘테이션을 통해 학습하였을 때 정확도가 더 낮게 나타났다. 본 연구에서도 case B, C, D와 같이 뒤집기, 회전과 같은 사물에 대한 데이터가 원본의 패턴을 갖는 경우 이미지 오그멘테이션 기법이 정확도 향상에 도움이 되었고, 반면 Color Distortion 과 Adjust Contrast의 경우는 다양한 데이터셋을 확보할 수는 있으나, 원본에서 특징을 갖는 많은 정보들이 변형되고 손실 되어 데이터셋안

의 데이터들로부터 학습하려는 사물에 대한 적절한 상관관계나 특징을 얻지 못하여 학습과정 중의 손실이 크고, 이미지 검출에 대한 정확도가 낮게 나타났다. 이미지검출 모델 학습에 있어서 검출률보다 background error의 비율을 줄여 정확도와 정밀도를 증가시키는 것이 객체검출 알고리즘에서 중요한 요소로 분석되었다.

References

- [1] J. S. Won, "A Study Focused on Responding to Fire-Related Accidents", *The Seoul Institute Policy Report*, Vol. 239, pp.1-21, 2017.
- [2] L. Xiao, "A Distributed Reinforcement Learning Solution With Knowledge Transfer Capability for A Bike Rebalancing Problem," arXiv preprint, arXiv: 1810.04058, 2018.
- [3] Y. Bengio, "Learning Deep Architecture for AI," *Foundations and trends® in Machine Learning*, Vol.2, No.1, pp.1-127, 2009.
- [4] G. Hinton, S. Osindero, "A Fast Learning Algorithm for Deep Belief Nets," *Neural Computation*, Vol.18, No.7, pp.1527-1554, 2006.
- [5] G. Huang, Z. Liu, K. Q. Weinberger, "Densely Connected Convolutional Networks," arXiv preprint, arXiv:1608.06993, 2018.
- [6] F. Pereira, P. Norvig, A. Halevy, "The Unreasonable Effectiveness of Data," *IEEE Intelligent Systems*, Vol.24, pp.8-12, 2009.
- [7] R. Girshick, J. Donahue, T. Darrell, "Rich feature hierarchies for accurate object detection and semantic segmentation," arXiv preprint, arXiv:1311.2524v5, pp.1-20, 2014.
- [8] S. Ren, K. He, R. Girshick, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," arXiv preprint, arXiv:1506.01497, 2016.
- [9] M. K. Lee, K. S. Seo, "Comparison of Region-based CNN Methods for Defects Detection on Metal Surface," *The Transactions of the Korean Institute of Electrical Engineers*, Vol.67, No.7, pp.865-870, 2018.
- [10] L. Perez, J. Wang, "The Effectiveness of

Data Augmentation in Image Classification using Deep Learning,”arXiv preprint, arXiv:1712.04621, 2017.

[11] A. Lecoutre, B. Negrevergne, F. Yger, “Recognizing Art Style Automatically in painting with deep learning,” *Proceedings of Machine Learning Research*, Vol.77, pp.327-342, 2017.

[12] Z. Hussain, F. Gimenez, D. Yi, “Differential Data Augmentation Techniques for Medical Imaging Classification Tasks,” *AMIA Annu Symp Proc.*, pp.979-984, 2017.

Sun-Joon Byun (Member)



2013 : PHD degree in Mechanical Engineering, Korea University.
presently a senior researcher in the Thermal-Hydraulic Design Team, KEPCO Nuclear Fuel.

BIOGRAPHY

Jae-Jung Kim (Member)




1999 : BS degree in Humanity, Kyungpook National University.
2002 : MS degree in Humanity, Andong National University.
presently PhD degree course in the Graduate School of Disaster Prevention, Kangwon National University.

Jin-Kyu Ryu (Member)



2018 : BS degree in Control and Instrumentation Engineering, Kangwon National University.
presently a master course in the Graduate School of Disaster Prevention, Kangwon National University.

Dong-Kurl Kwak (Member)



1990, 1993, 1997 : BS, MS and PHD degree in Electrical Engineering, Kyungnam University.
presently an associate professor in the Graduate School of Disaster Prevention, Kangwon National University.