

딥러닝 기반 지하공동구 화재 탐지 모델 개발 : 학습데이터 보강 및 편향 최적화

김정수¹, 이찬우^{2*}, 박승화¹, 이종현², 홍창희¹
¹한국건설기술연구원 국가BIM연구센터, ²스핀어웹

Development of Fire Detection Model for Underground Utility Facilities Using Deep Learning : Training Data Supplement and Bias Optimization

Jeongsoo Kim¹, Chan-Woo Lee^{2*}, Seung-Hwa Park¹, Jong-Hyun Lee², Chang-Hee Hong¹

¹Korea BIM Research Center, Korea Institute of Civil Engineering and Building Technologies
²SPIN A WEB

요약 화재는 높은 비정형성으로 인해 딥러닝 모델을 이용한 영상인식 분야에서도 좋은 성능을 내기가 어려운 대상 중 하나이다. 특히 지하공동구 내 화재는 딥러닝 모델의 학습을 위한 화재 데이터 확보가 어렵고 열악한 영상 조건 및 화재로 오인할 수 있는 객체가 많아 화재 검출이 어렵고 성능이 낮다. 이러한 이유로 본 연구는 딥러닝 기반의 지하공동구 내 화재 탐지 모델을 제안하고, 제안된 모델의 성능을 평가하였다. 기존 합성곱 인공신경망에 GoogleNet의 Inception block과 ResNet의 skip connection을 조합하여 어두운 환경에서 발생하는 화재 탐지를 위한 모델 구조를 제안하였으며, 제안된 모델을 효과적으로 학습시키기 위한 방법도 함께 제시하였다. 제안된 방법의 효과를 평가하기 위해 학습 후 모델을 지하공동구 및 유사환경 조건의 화재 문제와 화재로 오인할 수 있는 객체를 포함한 이미지에 적용해 결과를 분석하였다. 또한 기존 딥러닝 기반 화재 탐지 모델의 정밀도, 검출률 지표와 비교함으로써 모델의 화재 탐지 성능을 정량적으로 평가하였다. 제안된 모델의 결과는 어두운 환경에서 발생하는 화재 문제에 대해 높은 정밀도와 검출률을 나타내었으며, 유사 화재 객체에 대해 낮은 오탐 및 미탐 성능을 가지고 있음을 보여주었다.

Abstract Fire is difficult to achieve good performance in image detection using deep learning because of its high irregularity. In particular, there is little data on fire detection in underground utility facilities, which have poor light conditions and many objects similar to fire. These make fire detection challenging and cause low performance of deep learning models. Therefore, this study proposed a fire detection model using deep learning and estimated the performance of the model. The proposed model was designed using a combination of a basic convolutional neural network, Inception block of GoogleNet, and Skip connection of ResNet to optimize the deep learning model for fire detection under underground utility facilities. In addition, a training technique for the model was proposed. To examine the effectiveness of the method, the trained model was applied to fire images, which included fire and non-fire (which can be misunderstood as a fire) objects under the underground facilities or similar conditions, and results were analyzed. Metrics, such as precision and recall from deep learning models of other studies, were compared with those of the proposed model to estimate the model performance qualitatively. The results showed that the proposed model has high precision and recall for fire detection under low light intensity and both low erroneous and missing detection capabilities for things similar to fire.

Keywords : Underground Utility Facility, Fire Detection, Deep Learning, Convolutional Neural Network, Bias Training

본 논문은 2020년도 정부(과학기술정보통신부, 국토교통부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2020-0-00061, 디지털트윈 기반의 지하공동구 화재-재난 지원 통합플랫폼 기술개발)

*Corresponding Author : Chanwoo Lee(SPIN A WEB)

email: chan@spinaweb.co.kr

Received November 2, 2020

Accepted December 4, 2020

Revised November 26, 2020

Published December 31, 2020

1. 서론

지하공동구는 도심지의 전력, 통신, 가스, 배수관 등의 기반시설을 효과적으로 수용하고 유지관리하기 위한 지하구조물이다. 지하공동구는 일반적으로 좁고 길어 인력에 의한 유지관리 효율이 낮을 뿐만 아니라 지하공동구의 위치 및 수용 시설의 특성상 화재 등의 재난 발생에 따른 경제적, 사회적 큰 피해를 야기할 수 있다. 최근 KT 서울 아현지사 화재(2018), 백석동 온수배관 파열(2018) 등과 같이 공동구 시설의 노후화로 인해 피해사태 또한 늘어가는 상황이므로, 지하공동구의 안전관리를 위한 효과적인 기술개발이 필요한 상황이다.

인공신경망을 응용한 딥러닝 기술은 GPU와 같은 하드웨어 발전의 가속화와 Convolutional Neural Networks(CNNs) 기반의 여러 이미지 분류 방법론이 제시됨에 따라 빠르게 발전하고 있고, 특히 영상인식 분야에서 뛰어난 성능을 보이고 있다[1]. 딥러닝에 기반한 자동화 기술을 실제 공학 문제 해결에 적용하기 위한 여러 연구들이 수행되어 오고 있으며, 최근 건설 분야에도 기계학습 및 딥러닝 기술을 적용하기 위한 연구들이 활발히 이뤄지고 있다[2-10].

지하공간에서 화재 탐지를 위한 영상 분석이 어려운 이유는 일반적인 영상데이터에 비해 조도가 낮고 먼지 등에 의해 영상 품질이 떨어지기 때문이다. 또한 영상 내 화재 형상이 불규칙하여 무한대의 경우의 수가 발생하기 때문에 영상처리 방식으로 수행하는 것은 정상적인 화재 감지에 한계가 있다[8]. 이러한 이유로 현장 영상 이미지를 활용한 화재 탐지는 영상처리와 딥러닝 기반 영상 탐지 기술이 병용되는 것이 일반적이며, 특히 초기 화재 발생 인식 및 진압이 어려운 터널과 같은 지하공간에 대한 딥러닝 영상 인식 기술 적용이 빠르게 늘어나고 있다[6-8].

지하시설물 내 화재 탐지를 위한 딥러닝 모듈 개발은 터널 시설에 국한되어 왔다[8-10]. 터널은 지하시설물 가운데 비교적 접근성이 용이하고 현장 CCTV를 통해 낮은 품질의 영상이지만 다량의 영상데이터 확보가 가능하다. 반면 지하공동구는 보안시설로써 관리인력 외에는 내부 접근이 용이하지 않아 화재 탐지 자동화를 위한 딥러닝 영상 인식 모델을 개발하기 위한 이미지 데이터의 절대적인 수량 확보가 어렵고, 활용 가능한 영상 데이터도 품질이 낮아 이를 극복하기 위한 고성능의 딥러닝 영상 인식 모듈 개발이 요구된다. 추가로 CCTV 특성상 24시간 상시 가동되어 프레임 용량과 FPS(frame per

second)가 높아 개발 모듈의 효율성 또한 고려되어야 한다. 이러한 이유로 본 연구는 지하공동구 내 화재탐지를 위한 딥러닝 모델을 개발하고 이를 학습시키기 위한 방법론을 함께 제시하였다. 먼저 본 연구의 지하공동구 환경의 화재 인식을 위한 학습 데이터 구축방법을 설명하였으며, 지하공동구 내 화재 탐지 최적화를 위한 편향학습법 및 딥러닝 알고리즘을 제안하였다. 제안된 모델의 화재 탐지 성능을 평가하고 화재 탐지와 관련된 기존 연구의 딥러닝 모델의 성능을 비교함으로써 제안된 모델의 화재 탐지 성능 수준을 검토하였다.

2. 모델학습 및 검증을 위한 데이터 구축

2.1 데이터 수집 개요

지하공동구는 출입이 통제되고, 영상 데이터 생성(촬영)뿐만 아니라 화재와 같은 재난상황에 대한 대량의 영상데이터 확보가 어렵다. 이러한 이유로 기존 지하공동구에 대한 화재 데이터를 직접 수집하는 대신, (1) 언론 매체 등을 통해 공개된 지하공동구 및 지하공동구와 같이 낮은 조도 환경에서의 화재 데이터, (2) 일반 상황에서의 화재 데이터를 수집하였고, 딥러닝 학습 모듈이 불규칙한 불꽃을 인지할 수 있도록 육안으로 대비되는 다양한 불꽃 형상을 포함한 데이터를 선별할 수 있도록 하였다.

영상 데이터는 직접 촬영과 자체 구축한 웹 크롤러 프로그램을 통해 수집되었다. Fig. 1은 개발된 웹 크롤러 시스템의 구조를 보여준다. 개발된 데이터 수집 프로그램은 데이터의 조회, 수집, 라벨링 등의 기능을 제공함으로써 효과적인 데이터의 수집, 가공, 검수를 가능하게 한다. 영상 데이터 구축을 위해 18명의 인력이 투입되었으며(수집: 5명, 수집검수: 1명, 라벨링: 10명, 라벨링 검수: 2명), 이를 통해 최종 확보된 데이터는 약 1만개이다.

2.2 데이터 전처리

각 데이터를 이미지 내에 있는 목표 객체의 위치, 크기 정보를 포함하도록 TLBR 직교좌표 방법(Fig. 2a)을 활용하여 라벨링 하였다. 실제 학습에 요구되는 데이터는 라벨링 박스의 중심 좌표이므로 중심좌표 방법(Fig. 2b)을 활용할 수도 있으나, 오차 손실 영향을 최소화하기 위해 TLBR 방법을 적용하였다.




Fig. 1. Image data collection system of Architecture



Fig. 2. Image labeling (a) TLBR rectangular coordinate (b) Centroid rectangular coordinate

데이터셋은 다양한 크기의 RGB 이미지와 불꽃 객체에 대한 TLBR 라벨링 박스로 구성된다. 본 연구의 모델이 학습하는 이미지 규격은 416x416 크기로 고정되도록 설계되었으므로 수집된 데이터셋은 여기에 맞게 resizing하였다. 또한 뉴런 내 가중치가 0을 중심으로 분포하도록 정규화하여 모델 학습이 용이하도록 하였다 (Normalized zero mean shift).

2.3 모델 성능평가 지표

본 연구는 모델 성능을 정량적으로 평가하기 위해 화재 객체 탐지에 대한 정확도(accuracy), 정밀도(precision), 검출률(recall), 정밀도와 재현율의 조화평균(F_1 -score)을 사용하며, 각각에 대한 산정방법은 Eq.(1)~(4)에 나타내었다. 모델의 성능이 높은 경우 각 지표 간의 차이는 작아야 하며, 조화평균값이 높으면 화재 탐지와 같은 안전문제를 해결하기 위한 상용모델로서 성능이 좋다고 평가할 수 있다.

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$F_1 = \frac{2PR}{P + R} \quad (3)$$

$$A = \frac{TN + TP}{TN + TP + FN + FP} \quad (4)$$

Where, P denotes precision, R denotes recall, F_1 denotes harmonic mean, A denotes accuracy, TP denotes true positive, FP denotes false positive, TN denotes true negative, FN denotes false negative.

TP 는 화재탐지 문제에서 불꽃을 포함한 이미지에 불꽃이 있다 평가한 경우이며, FP 는 이미지에 불꽃이 포함되지 않았으나 불꽃이 있다고 평가한 경우를 의미한다. P 가 높을수록 모델의 오탐(false detection) 확률이 낮으며, R 이 높을수록 모델의 미탐(missing detection) 확률이 낮다. F_1 은 정밀도와 검출률을 통합적으로 평가하는 지표이며, A 는 모델의 정확성을 나타낸다.

3. 화재 탐지 딥러닝 모델 및 훈련

3.1 데이터 변조

딥러닝 모델은 기존 Bayesian model 기반의 신경망 모델에 비해 매우 복잡하기 때문에 기본적으로 많은 데이터를 요구하며, 데이터가 불충분한 경우 과적합(overfitting) 문제가 발생할 수 있다. 이를 극복하기 위해 일반적으로 영상인식 문제에 대한 딥러닝 학습 시 데이터 변조(data augmentation) 방법을 사용해 부족한 데이터를 증폭시킬 수 있으나, 불꽃은 이 방법이 잘 통하지 않는다.

딥러닝 모델 특성 상 scale 변화를 통한 데이터 증폭은 학습효과가 높지 않으나 회전을 통해 이미지의 변화를 주면 다량의 데이터를 학습한 것과 유사하게 모델의 성능을 확보할 수 있다. 특히, 고양이와 같이 비교적 형상 및 특징이 정형화된 대상을 인식하는 모델은 flip, rotation 등의 방법을 이용하여도 학습 효과를 크게 개선할 수 있다. 그러나 불꽃은 형상이 비정형적이므로 이러한 방법을 통한 학습 효과가 반감되며, 적용 시 과적합 현상이 쉽게 발생되므로 본 연구의 모델 학습에 활용하는 것은 부적절하다.

이러한 이유로 본 연구는 절대적인 데이터가 부족한 지하공동구 화재 영상을 변조하는 대신, 일반 환경 조건의 화재 이미지를 함께 모델에 학습시켰고, 데이터를 구분해 학습시킴으로써 화재에 대한 모델의 이해도를 향상하고 예측 성능을 개선하도록 하였다.

수집된 데이터를 지하공동구 화재 탐지에 부합하는 영상 데이터 (targeted data, Fig. 3)와 지하공동구 환경과

다소 차이는 있으나 학습에 도움되는 특징 및 객체가 있는 데이터(supporting data, Fig. 4)로 구분하였다. 이와 같은 학습 데이터 구분은 불꽃의 객체 특성상 기하학적 특징을 모델이 이해하도록 학습시키는 대신 모델이 불꽃의 본질을 광학적 특성으로 이해할 수 있도록 유도한다. 즉, 화재 데이터에서 지하공동구와 같은 환경적 특성을 편차(bias)로 부여함으로써, 모델이 기본적인 불꽃의 특성만 이해하고 지하공동구 환경에서 발생된 불꽃을 탐지하도록 의도적인 편향을 갖게 할 수 있다.

3.2 지하공동구 화재탐지를 위한 딥러닝 모델

본 장은 제안된 지하공동구용 화재 탐지 딥러닝 모델 구성과 관련된 핵심적인 내용만을 포함한다. 딥러닝에 대한 기본적인 내용 및 방법론은 관련된 다른 문헌들을 참고할 수 있다[1,11].

본 연구의 딥러닝 모델은 LeNet, ResNet을 병합한 구조로 설계되었다 (Fig. 5). 어두운 환경에서의 불꽃 객

체 탐지에 유리하도록 기본 합성곱(convolution)을 갖는 LeNet에 GoogleNet의 Inception block with bottleneck(Fig. 6)과 ResNet의 skip connection(Fig. 7)을 추가하였다. 이를 통해 모델의 압축 및 경량화를 가능하게 하였다.

먼저 Inception block은 크기가 다른 필터 및 풀링을 여러 개 적용하여 복잡한 형상의 객체를 탐지해낼 수 있으나 신경망 층의 두께가 두꺼워지면서 계산 효율이 떨어지게 된다(navie inception block). 이를 개선하기 위해 기존 Inception module에 1x1 합성곱 층을 추가(bottleneck layer)한 다중 필터 층을 통과하도록 구성된 Fig. 6을 사용하였다. Inception block with bottleneck을 사용함으로써 입력 영상의 차원 수를 축소하고 매개변수 제거 및 데이터 크기 압축이 가능하다. 또한 모델의 복잡성을 유지하면서도 데이터의 특징을 압축할 수 있어 고속 처리할 수 있다. 다만, 원래 1개의 convolutional layer를 분할된 구조로 변화시키면서 매



Fig. 3. Targeted data for fire detection in underground space



Fig. 4. Supporting data for fire detection

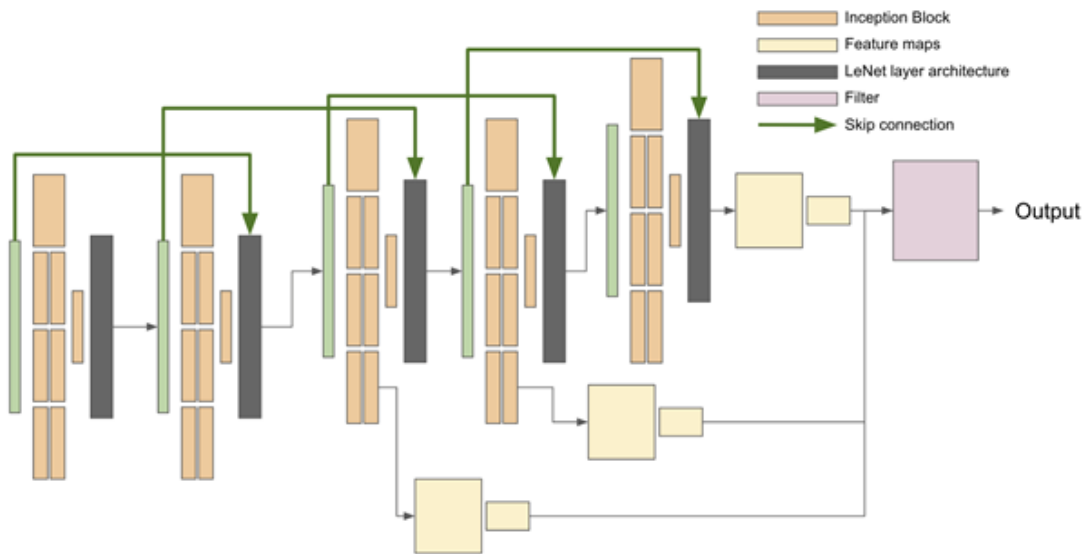


Fig. 5. Deep learning module for fire detection: bias optimization model

개변수는 적어지더라도 layer마다 포함된 활성화함수 개수가 늘어나기 때문에 모델의 비선형성 및 복잡도 (complexity)는 증가한다. 이러한 특성은 불규칙한 불꽃 형상을 탐지하는데 유리하나, 학습을 위해 더 많은 데이터를 필요로 하게 된다.

지하공동구 내 화재 사례는 일반적인 딥러닝 모델을 학습시키기에 절대적으로 부족하므로, 이 경우 과적합 문제가 예상된다. 이러한 문제를 최소화 할 수 있도록 본 연구의 화재 탐지 모델은 Inception block과 함께 ResNet의 Skip connection(Fig. 7)이 추가로 포함된다. Skip connection은 Fig. 7에 나타난 바와 같이 이전 층의 입력값을 출력 층에 직접적으로 산술 덧셈을 해 줌으로써 데이터 학습(back propagation) 중의 가중치 감소를 막아주는 역할을 한다. 또한 Inception block 추가로 인해 높아진 전체 모델의 복잡도를 완화시켜줌으로 확률적 경사하강법(stochastic gradient descent)을 통한 신경망층의 가중치 학습 속도를 개선시킨다.




Fig. 6. Inception block with bottleneck in GoogleNet[12]




Fig. 7. Skip connection in ResNet[13]

제안된 지하공동구용 화재탐지 딥러닝 모델의 네트워크의 파라미터에 대해 Table 1에 나타냈다. 이미지 데이터가 네트워크 모델에 들어가면 filter 를 거쳐 다음의 합성곱 층에 적용된 후, max pooling을 포함한 여러 사이즈의 convolution layers를 통과하여 Inception Block에 입력된다. 이 block 내부에서 concatenation

등의 과정을 거친 후 LeNet 형태의 convolution layer를 통과하여, 하나 이상의 layer를 건너뛰는 residual 방식으로 skip connection을 진행한다. 이와 같은 딥러닝 구조를 사용함으로써 deep residual nets 깊이가 크게 증가하여도 전체 연산에는 크게 영향을 끼치지 않으면서 최적화와 정확도 측면에서 좋은 성능을 이끌어 낼 수 있다.

딥러닝 모델을 통해 도출되는 최종 결과는 불꽃 객체에 대한 다량의 경계박스(bounding box)이며, 이 중에는 영역이 중복되거나 예측 신뢰도가 낮은 경계박스들이 포함된다. 불꽃 탐지에 필요한 경계박스만 최종적으로 도출되도록 딥러닝 모델 끝단에 k-means clustering 방법을 적용한 filter block을 추가하여 하였다(Fig. 5).

4. 모델 학습 및 성능평가

4.1 화재 탐지 모델 학습 및 결과

제안된 모델을 학습하고 모델의 성능을 평가하였다. 지하공동구 내 화재 탐지를 위해 활용된 데이터셋의 수량을 정리하여 Table 2에 나타내었다. 또한 딥러닝 모델의 성능평가 지표들과 오차행렬을 Tables 3 and 4에 나타냈다. Table 3은 제안된 모델의 모든 성능평가지표가 92% 이상으로 높게 나타나고 있고, 각 지표 간의 편차가 크지 않음을 보여준다. 또한 정밀도와 검출률의 조화평균 값이 95% 수준으로 높다. 이는 개발된 딥러닝 모델의 화재 탐지 능력이 높고 안정적인임을 의미한다. 정확도 값 역시 높게 나타났으나, 이 지표는 검증에 사용된 이미지에 따라 결과가 크게 달라질 수 있으므로 큰 의미를 갖지 않는다. 가령, 검증에 화재를 포함한 이미지가 그렇지 않은 이미지에 비해 절대적으로 많은 경우 정확도는 모델의 실제 성능에 비해 높아질 수 있다.

Fig. 8은 각 confidence에 대한 threshold를 총 16번 변경해가며 학습모델의 성능을 평가한 PR (precision-recall) curve를 나타낸다. PR curve를 통해 recall 값의 변화에 따른 precision값을 확인함으로써 객체 인식을 위한 딥러닝 학습모델의 성능을 평가할 수 있다. Confidence 레벨에 대해 설정된 threshold 값 이상의 confidence를 가져야만 검출된 것으로 인정되므로, confidence가 낮으면 인식 정확도가 낮은 결과를 걸러내는 역할도 가능하다. 이번 불꽃 검출 학습 모델의 PR curve 선의 아래 면적인 Average Precision(AP)을 구한 결과 0.97이 도출되어 면적이 1에 가까운 높은 수준의 우수한 알고리즘으로 평가할 수 있다.

Table 1. Deep learning module for fire detection: network parameters

Type	Layer				Filter
Input	512 x 512 x 1				3 x 3 x 32
Convolution	512 x 512 x 32				1 x 1 conv, 1 x 1 conv, 1 x 1 conv , 3 x 3 max pooling
Inception Block	512 x 512 x 1	512 x 512 x 1	512 x 512 x 1	512 x 512 x 32	3 x 3 conv, 5 x 5 conv, 1 x 1 conv
		512 x 512 x 1	512 x 512 x 1	512 x 512 x 1	concatenate
	512 x 512 x 4				3 x 3 x 4 x .32 (conv)
	512 x 512 x 32				3 x 3 x 32 x 64
Convolution	512 x 512 x 64				1 x 1 conv, 1 x 1 conv, 1 x 1 conv, 3 x 3 maxpooling
Inception Block	512 x 512 x 1	512 x 512 x 1	512 x 512 x 1	512 x 512 x 32	3 x 3 conv, 5 x 5 conv, 1 x 1 conv
		512 x 512 x 1	512 x 512 x 1	512 x 512 x 1	concatenate
	512 x 512 x 4				3 x 3 x 4 x 32 (conv)
	512 x 512 x 32				Residual
...	...				

Table 2. Number of dataset for training and test

Training data			Test data
Total dataset	Targeted data	Supporting data	
25,050	10,200	14,850	7,205

Table 3. Number of dataset for training and validation (P: precision, R: recall, F1: harmonic mean, A: accuracy)

P	R	F1	A
0.923	0.986	0.954	0.935

Table 4. Confusion matrix

Actual values	N=7,205		
		Predicted values	
		False	True
False	1,877 (TN)	403 (FP)	
True	69 (FN)	4,856 (TP)	

Train set과 validation(test) set에 대해서 각각의 loss를 학습 중간마다 검토하기 위해 Fig. 9에 loss curve를 나타내었다. Fig. 9는 validation loss가 상승하기 직전까지의 결과만 나타낸 것이며, 만약 학습을 지속하면 모델의 과적합 문제가 발생하므로 이후 훈련은 중단하였다. 1,000,000 epochs 학습에 대한 train loss는 0.184 이며 validation loss는 0.217이다.




Fig. 8. Precision-recall curve




Fig. 9. Loss Curve




Fig. 10. Application of Deep learning model for Fire detection: (a) Underground utility facility(UUF): 88%, (b) UUF: 88%, (c) Building: 98%, (d) Tunnel: 100%, (e) UUF: 92%, (f) UUF: 58%, (g) Building: 95%



Fig. 11. Deep learning module for fire detection: bias optimization model

개발된 딥러닝 화재 탐지 모듈을 지하공동구 또는 이와 유사한 환경에서 발생한 화재에 대해 적용한 결과 사례를 Fig. 10에 나타내었다. Fig. 10에서 a, b, e, f는 지하공동구에서 발생한 화재 영상, d는 터널 내 화재, c와 g는 건물 내 낮은 조도 환경에서의 화재를 대상으로 화재 탐지를 수행해 얻은 결과이며, 화재로 인지하기 어려운 영상 조건에서도 이를 감지해내고 있음을 보여준다. 개발된 모델이 구조물 사이에 발생한 불꽃뿐만 아니라 불꽃에 대한 반사 빛 영역까지 감지해내고 있어 화재로 보기 모호한 영상에 대해서도 좋은 성능을 보여주고 있음을 확인할 수 있다. 이를 통해 3.1절에서 제시된 딥러닝 모델 편향학습 방법이 유사 지하공동구 조건의 화재 인식 성능을 높일 수 있음을 알 수 있다.

추가로 화재로 오인할 수 있는 조명, 빛 반사 등의 객체에 대한 필터링 능력을 검토하였다(Fig. 11). 터널 내 조명 및 차량 전조등, 화재 잔상, 조명 빛 반사를 포함한 영상에 개발된 딥러닝 모델을 적용하였으나, 경계박스는 해당 객체들 위로 나타나지 않았다.

4.2 화재 탐지 모델 성능평가 비교 및 분석

본 연구의 딥러닝 모델 성능평가와 함께 기존 유사 연

구에서 개발된 딥러닝 모델의 성능을 비교하여 Table 5에 정리하였다. 본 연구의 결과가 기존 연구의 딥러닝 모델 검출률에 비해 높게 평가되고 있다. 여기서 기존 연구에 비해 본 연구의 데이터셋의 크기가 크어도 검출률이 높은 것은 모델의 신뢰성이 훨씬 높음을 의미한다. 일반적으로 검출률이 높으면 정밀도가 떨어지는 것이 보통이나 본 연구에서 제안된 학습방법에 의해 도출된 딥러닝 모델은 92%의 높은 정밀도를 보여주고 있다.

조화평균 비교에서 비록 본 연구의 딥러닝 모델의 정밀도가 Elastic-YOLO v3 모델을 사용한 연구[18]에 비해 낮기는 하지만, 실제 상황에 적용 시 검출률이 더 중요하므로 본 연구의 딥러닝 모델이 상용화 측면에서 더 유리하다 할 수 있다. 한편, NightFire-DB를 포함한 기존 연구에서 사용된 데이터셋은 대부분 야간 화재 이미지로 구성된다. 본 연구의 모델은 학습 시 야간 화재 데이터를 supporting data로 학습하였기 때문에 지하공동구 내 화재 탐지뿐만 아니라 일반 야간 화재에서도 좋은 성능을 보일 것이라 판단할 수 있다.

본 연구의 딥러닝 모델이 기존 연구결과 대비 우수한 성능지표를 보인 이유는 1) 지하공동구 및 유사환경 내 화재 탐지에 유리하도록 편향학습 데이터를 구성한 것과

Table 5. Comparison with performance metrics of deep learning models for fire detection

Technique	P	R	F ₁	data information
Current study	0.92	0.99	0.95	Spider underground fire dataset (SPIN A WEB) - Training data: 10,200 (targeted) + 14,850 (supporting) - Test data: 7,205
Roy(2020), YOLO v3[14]	0.81	0.75	0.78	N. A.
Liu et al. (2016), SSD[15]	0.99	0.67	0.80	NightFire-DB (Keimyung Univ.) [18]* - Training data: 14 (fire) + 10 (non-fire) videos : average 1030 frames, 30Hz frame rate - Test data: 10 (fire) + 10 (non-fire) videos : average 1030 frames, 30Hz frame rate * The total number of frames for training and test are different from each other case. The numbers are specified in Table 1 of the paper[18].
Wu and Zhang (2018) Faster R-CNN[16]	0.82	0.95	0.87	
Redmon and Farhadi (2018), YOLO v3[17]	0.98	0.91	0.94	
Park and Ko (2020), ELASTIC-YOLO v3[18]	0.99	0.97	0.98	
Muhammad et al. (2018a) : After fine tuning (FT)[19]	0.80	0.93	0.86	- Training data: 62,690 : Dataset1[19], Verstockt et al. (2013)[25], Ko et al. (2011)[26] - Test data: 226 : 119 (fire class) + 107 (non-fire class)
Muhammad et al. (2018a) : Before FT[19]	0.86	0.89	0.88	
Muhammad et al. (2018b) : After FT[20]	0.82	0.98	0.89	
Muhammad et al. (2018b) : Before FT[20]	0.85	0.92	0.88	
Chino et al. (2015)[21]	0.40~0.60	0.60~0.80	0.60~0.70	
Rudz et al. (2013)[22]	0.60~0.70	0.40~0.50	0.50~0.60	
Rossi et al. (2011)[23]	0.30~0.40	0.20~0.30	0.20~0.30	
Celik and Demirel (2009)[24]	0.40~0.60	0.50~0.60	0.50~0.60	

2) 이러한 편향 학습 효과를 극대화하기 위한 딥러닝 신경망 층 구성하였기 때문에 판단된다.

편향학습은 딥러닝 모델의 과적합 문제를 야기할 수 있다. 그러나 본 연구는 훈련데이터를 targeted data와 supporting data로 구분함으로써 딥러닝 모델이 화재를 빛과 기하형상 특성을 갖는 객체로 이해할 수 있도록 유도하였다. 또한, 데이터셋 규모를 달리한 반복적인 시행착오를 통해 지하공동구 및 유사환경 화재 데이터(targeted data) 대비 요구되는 화재 데이터 비율을 도출하고, 이에 바탕하여 딥러닝 모델의 복잡도에 상응하는 데이터를 학습시켰다.

추가로 딥러닝 모델이 빛과 형상을 구분하여 학습할 수 있는 합성곱 층을 활용한 점이 모델 성능 개선에 기여한 것으로 판단된다. 제안된 딥러닝 모델에 포함된 Inception block은 고속처리뿐만 아니라 불꽃 이미지 데이터 관점에서도 의미가 있다. 불꽃은 형상이 불규칙적 해서 일반적인 객체와 달리 형상 특징의 중요성이 떨어지고 불꽃과 배경 간의 대비가 더 중요하다. Inception block 내 합성곱이 bottleneck layer와 3x3x1 합성곱으로 나뉘어 순차적으로 연산되기 때문에(Fig. 6), bottleneck layer에 의해 빛나는 특성을 먼저 학습하고 이후 3x3x1 합성곱을 통해 빛나는 객체의 형상을 이해하게 된다. 이와 같이 객체에 대한 인식체계가 나뉘짐으로써 적은 매개변수로 중요 정보를 구분하여 학습할 수 있고 불꽃을 효과적으로 영상에서 구분해낼 수 있다.

5. 결론

본 논문은 지하공동구 및 이와 유사한 환경에서 발생하는 화재를 탐지하기 위한 딥러닝 기반 모델과 이에 대한 학습 방법을 제시하고, 제안된 방법을 화재 영상에 적용하여 모델의 성능을 평가하였다. 이를 통해 얻은 주요 결론을 정리하면 다음과 같다.

첫째, PR curve 평가(AP: 0.97)로부터 제안된 딥러닝 모델의 구조가 화재 감지에 높은 정밀도를 가질 수 있음을 확인할 수 있다. 또한 Loss curve를 확인함으로써 모델의 과적합을 검토함으로써, 학습모델이 특정 데이터셋에 최적화되지 않고 다양한 데이터셋에 대해서도 일반화된 성능을 가지는 것을 확인하였다.

둘째, 화재 탐지 문제에 대해 inception block과 skip connection 모듈을 포함한 합성곱 기반의 딥러닝 모델을 사용하는 조건에서 지하공동구 환경의 화재 데이

터 부족 문제에 기여할 수 있는 편향 학습방법을 제시하였다. 어두운 환경에서의 화재 데이터와 일반 환경의 화재 데이터를 조합하여도 지하공동구 환경의 화재에 대해 높은 객체 인식 성능을 확보할 수 있음을 확인하였다. 모델 성능 최적화를 위한 각 데이터셋의 비율에 대해서는 추가 연구가 필요하다.

셋째, 제안된 모델은 모든 성능평가지표가 92% 이상이며 기존 화재 감지 딥러닝 모델과 비교할 때도 높은 정밀도와 검출률을 보여주고 있어 화재 탐지 능력이 높고 안정적이라 판단된다. 또한 제안된 모델을 지하공동구 및 이와 유사한 환경의 시설물에서 발생한 화재 영상에 적용한 경우, 화재뿐만 아니라 화재로 인식하기 모호한 객체에 대해서도 잘 구별해내고 있음을 확인할 수 있다.

References

- [1] J. W. Shin, "Introduction of Recent Deep Learning Algorithms for Image Identification," *The Journal of the Korea Institute of Communication Sciences*, vol.34, no.7, pp.25-30, 2017. (In Korean)
- [2] S. Shim, S. I. Choi, "Development on Identification Algorithm of Risk Situation around Construction Vehicle Using YOLO-v3," *Journal of the Korea Academia-Industrial Cooperation Society*, vol.20, no.7, pp.622-629, July 2019. (In Korean)
DOI: <https://doi.org/10.5762/KAIS.2019.20.7.622>
- [3] S. Chung, S. Moon, S. Chi, "Bridge Damage Factor Recognition from Inspection Reports Using Deep Learning," *Journal of the Korean Society of Civil Engineers*, vol.38, no.4, pp.612-625, August 2018.
DOI: <https://doi.org/10.12652/Ksce.2018.38.4.0621>
- [4] K. J. Kim, Y. S. Park, S. W. Park, "Development of Artificial Neural Network Model for Estimation of Cable Tension of Cable-Stayed Bridge", *Journal of the Korea Academia-Industrial Cooperation Society*, vol.21, no.3, pp.414-419, March 2020. (In Korean)
DOI: <https://doi.org/10.5762/KAIS.2020.21.3.414>
- [5] J. Choi, "Development of Estimation Model for Hysteresis of Friction Using Artificial Intelligent," *Journal of the Korea Academia-Industrial Cooperation Society*, vol.12, no.7, pp.2913-2918, July 2011. (In Korean)
DOI: <https://doi.org/10.5762/KAIS.2011.12.7.2913>
- [6] B. Lee, D. Han, "Flame and Smoke Detection Method for Early and Real-time Detection of Tunnel Fire," *The Institute of Electronics Engineers of Korea-Signal Processing*, vol.45, no.4, pp.59-70, July 2008. (In Korean)
- [7] J. Yim, H. Park, W. Lee, M. S. Kim, Y. T. Lee, "Deep Learning Based CCTV Fire Detection System,"

- Proceeding of the Korea Institute of Broadcast and Media Engineers*, pp.139-141, 2017. (In Korean)
- [8] H. S. Shin, K. B. Lee, M. J. Yim, D. G. Kim, "Development of a Deep-Learning Based Tunnel Incident Detection System on CCTVs," *Journal of Korean Tunnelling and Underground Space Association*, vol.19, no.6, pp.915-936, 2017. (In Korean)
DOI: <https://doi.org/10.9711/KTAJ.2017.19.6.915>
- [9] H. S. Shin, D. G. Kim, M. J. Yim, K. B. Lee, Y. S. Oh, "A Preliminary Study for Development of an Automatic Incident Detection System on CCTV in Tunnels Based on a Machine Learning Algorithm," *Journal of Korean Tunnelling and Underground Space Association*, vol.19, no.1, pp.95-107, 2017. (In Korean)
DOI: <https://doi.org/10.9711/KTAJ.2017.19.1.095>
- [10] K. B. Lee, H. S. Shin, "Effect on Self-Enhancement of Deep-Learning Inference by Repeated Training of False Detection Cases in Tunnel Accident Image Detection," *Journal of Korean Tunnelling and Underground Space Association*, vol.21, no.3, pp.419-432, 2019. (In Korean)
DOI: <https://doi.org/10.9711/KTAJ.2019.21.3.419>
- [11] T. H. Kim (2017) Deep Learning from Scratch, p.312, Hanbit Media, pp.268-272, 2017. (In Korean)
- [12] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, "Going Deeper with Convolutions," *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-9, 2015.
- [13] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition," *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.770-778, 2016.
- [14] R. Roy. Using YOLOv3 for Real-Time Detection of PPE and Fire [Internet]. Towards Data Science, c2020 [cited 2020 May 12]. Available From: <https://towardsdatascience.com/using-yolov3-for-real-time-detection-of-ppe-and-fire-1c671fcc0f0e> (Accessed Oct. 29, 2020)
- [15] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, A.C. Berg, "SSD: Single shot multibox detector," *In Proceedings of European Conference on Computer Vision(ECCV)*, Amsterdam, Netherlands, pp.1-17, Oct. 2016. quoted in Park and Ko (2020) [18]
- [16] S. Wu, L. Zhang, "Using popular object detection methods for real time forest fire detection," *In Proceedings of the 11th International Symposium on Computational Intelligence and Design (SCID)*, Hangzhou, China, pp.280-284, Dec. 2018. quoted in Park and Ko (2020) [18]
DOI: <https://doi.org/10.1109/ISCID.2018.00070>
- [17] J. Redmon, A. Farhadi, "YOLOv3: Incremental Improvement," *ArXiv Preprint arXiv:1804.02767*, 2018. quoted in Park and Ko (2020) [18]
- [18] M. Park, B.C. Ko, "Two-Step Real-Time Night-Time Fire Detection in an Urban Environment Using Static ELASTIC-YOLOv3 and Temporal Fire-Tube," *Sensors*, vol.20, no.8, 2202, April 2020.
DOI: <https://doi.org/10.3390/s20082202>
- [19] K. Muhammad, J. Ahmad, I. Mehmood, S. Rho, S. W. Baik, "Convolutional Neural Networks Based Fire Detection in Surveillance Videos," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol.49, no. 7, pp.1419-1434, April 2018.
DOI: <https://doi.org/10.1109/TSMC.2018.2830099>
- [20] K. Muhammad, J. Ahmad, I. Mehmood, S. W. Baik, "Early Fire Detection Using Convolutional Neural Networks during Surveillance for Effective Disaster Management", *Neurocomputing*, vol.288, pp.30-42, May 2018. quoted in Muhammad et al. (2018) [19]
DOI: <https://doi.org/10.1016/j.neucom.2017.04.083>
- [21] D. Y. T. Chino, L. P. S. Avalhais, J. F. Rodrigues, A. J. M. Traina, "BoWFire: Detection of Fire in Still Images by Integrating Pixel Color and Texture Analysis," *in Proc. 28th SIBGRAPI Conf. Graph., Patterns Images*, pp.95-102, August 2015. quoted in Muhammad et al. (2018) [19]
- [22] S. Rudz, K. Chetehouna, A. Hafiane, H. Laurent, O. Sero-Guillaume, "Investigation of a Novel Image Segmentation Method Dedicated to Forest Fire Applications," *Meas. Sci. Technol.*, vol.24, no.7, p.075403, 2013. quoted in Muhammad et al. (2018) [19]
- [23] L. Rossi, M. Akhloufi, Y. Tison, "On the Use of Stereovision to Develop a Novel Instrumentation System to Extract Geometric Fire Fronts Characteristics," *Fire Safety Journal*, vol.46, pp.9-20, 2011. quoted in Muhammad et al. (2018) [19]
DOI: <https://doi.org/10.1016/j.firesaf.2010.03.001>
- [24] T. Celik, H. Demirel, "Fire Detection in Video Sequences Using a Generic Color Model," *Fire Safety Journal*, vol.46, no.2, pp.147-158, 2009. quoted in Muhammad et al. (2018) [19]
DOI: <https://doi.org/10.1016/j.firesaf.2008.05.005>
- [25] S. Verstockt, T. Beji, P. D. Potter, S. V. Hoecke, B. Sette, B. Merci, R.V. Walle, "Video Driven Fire Spread Forecasting (f) Using Multi-Modal LWIR and Visual Flame and Smoke Data," *Pattern Recognition Letters*, vol.34, no.1, pp.62-69, 2013. quoted in Muhammad et al. (2018) [19]
DOI: <https://doi.org/10.1016/j.patrec.2012.07.018>
- [26] B.C. Ko, S. J. Ham, J. Y. Nam, "Modeling and Formalization of Fuzzy Finite Automata for Detection of Irregular Fire Flames," *IEEE Trans. Circuits Syst. Video Technol.*, vol.21, no.12, pp.1903-1912, Dec. 2011. quoted in Muhammad et al. (2018) [19]
DOI: <https://doi.org/10.1109/TCSVT.2011.2157190>

김 정 수(Jeongsoo Kim)

[정회원]



- 2016년 2월 : 연세대학교 일반대학원 토목환경공학과 (공학박사)
- 2016년 3월 ~ 2018년 9월 : 한국건설기술연구원 박사후연구원
- 2018년 10월 ~ 현재 : 한국건설기술연구원 전임연구원

<관심분야>

전산역학, 지하구조물, 딥러닝, 수치해석

이 종 현(Jong-Hyun Lee)

[정회원]



- 2005년 2월 : 고려대학교 경제학과 (경제학 석사)
- 2017년 10월 ~ 현재 : ㈜스핀어웹 대표이사
- 2020년 9월 : 딥러닝 화재감지 관련 특허 발명 및 등록

<관심분야>

인공지능, 화재감시

이 찬 우(Chan-Woo Lee)

[정회원]



- 2015년 8월 : 건국대학교 전자공학과 공학사
- 2015년 4월 ~ 2016년 6월 : 시냅스이미징 머신비전엔지니어
- 2016년 6월 ~ 2016년 12월 : 라이프시맨틱스 메디컬AI연구원
- 2017년 8월 ~ 2018년 11월 : orbis.ai 최고기술책임자
- 2018년 12월 ~ 현재 : Spinaweb 최고기술책임자

<관심분야>

머신러닝, 대용량실시간서비스, 무중단감시서비스

홍 창 희(Chang-Hee Hong)

[정회원]



- 1999년 8월 : 인하대학교 인하대학원 토목공학 (공학석사)
- 2006년 8월 : 서울대학교 서울대학원 환경조경학 (박사수료)
- 1999년 10월 ~ 현재 : 한국건설기술연구원 연구위원
- 2020년 4월 ~ 현재 : 한국건설기술연구원 국가BIM연구센터 센터장

<관심분야>

BIM, BIM/GIS, 스마트건설

박 승 화(Seung-Hwa Park)

[종신회원]



- 2015년 2월 : 경희대학교 일반대학원 건축공학과 (공학박사)
- 2013년 12월 ~ 2016년 2월 : (사)빌딩스마트협회 선임연구원
- 2015년 6월 ~ 2016년 2월 : 경희대학교 건축학과 연구교수
- 2016년 3월 ~ 현재 : 한국건설기술연구원 수석연구원

<관심분야>

건설정보기술, BIM/GIS 통합플랫폼, 디지털트윈