

실시간 영상분석을 이용한 합성곱 신경망 기반의 실내 연기 감지 연구

류진규, 곽동걸, 이봉섭, 김대환*
강원대학교, *(주)부길전기

A Study on Indoor Smoke Detection Based on Convolutional Neural Network Using Real Time Image Analysis

Jin-Kyu Ryu, Dong-Kurl Kwak, Bong-Seob Lee, Dae-Hwan Kim*
Kangwon National University, *Bugil Electric Co.

ABSTRACT

Recently, large-scale fires have been generated as urban buildings have become more and more density. Especially, the expansion of smoke in buildings due to high-rise is a problem, and the smoke is the main cause of death in fires. Therefore, in this paper, the image-based smoke detection is proposed through deep learning-based artificial intelligence techniques to prevent possible damage if existing detectors are not detected. In addition, the detection model was not configured simply through only the smoke data set, but the data set in the haze form was additionally composed together to compensate for the accuracy.

1. 서 론

화재에서 연기흡입이 주된 사망원인으로 알려져 있듯이 화재 초기에 연기를 감지하는 것이 발화 또는 연소를 방지하는 대책과 더불어 아주 중요하다. 발화 후 연소가 진행되면 불꽃이 있는 연소와 불꽃이 없는 연소 두 가지로 나뉘는데 불꽃이 있는 연소는 확산연소, 예혼합연소, 자연발화가 있으며 불꽃이 없는 연소로는 혼소가 있다.^[1] 이러한 연소과정에서 연기는 불완전한 연소로 인하여 이산화탄소 대신 높은 일산화탄소 생성율을 보이고 인체에 치명적인 잠재력을 갖게 된다. 이러한 화재초기에 발생할 수 있는 연기를 최신기술을 통하여 보다 신뢰성 높게 감지하기 위해 본 논문에서는 영상 내에서 움직이는 영역을 검출하여 해당영역을 검출후보로 사용하고, 딥러닝(deeplearning) 기법 중 합성곱신경망(convolutional neural network, CNN)을 통하여 해당 검출후보가 연기인지 혹은 다른 사물인지 여부를 판단하게 된다.

2. 건축물의 화재성상과 인공지능 기법

2.1 최근 건축물의 화재성상과 감지기 오작동 실태

초고층 또는 고층건물에서는 사용자의 층간 이동을 위해 계단실 혹은 엘리베이터 등의 공간을 설치하게 된다. 이러한 공간은 건물의 난방이나 화재에 의한 연기 침투로 외부 공기의 온도보다 높아질 경우 굴뚝 효과가 발생할 가능성이 크다. 또한 화재 시 연기의 수직이동 속도는 굴뚝효과에 의해 3~5m/s에 이르게 되는 반면 사람의 수직이동을 통한 피난 속도는

0.5m/s 정도에 불과하다. 따라서 이러한 문제는 최근 도시 건 축물의 고층화로 인하여 화재발생시 인명피해와 재산피해가 큰 대형화재가 발생하는 사례가 늘어나는 원인 중 하나로 작용하게 된다.^[2] 하지만 2017년 기준 감지기의 오작동으로 인하여 소방관들이 출동한 건수는 11,310건으로 2013년에 비해 4배 가까이 증가하였다. 이로 인하여 소방력의 낭비뿐만 아니라 잦은 오작동으로 인해 관리자가 감지기나 화재수신기를 꺼놓는 사례 또한 늘어나고 있으며, 결과적으로 화재 초기의 골든타임을 놓치게 되는 요인이 된다. 이러한 문제를 해결하기 위해 주변에 널리 설치되어있는 CCTV를 이용하여 인공지능기반의 기술을 접목해 감시한다면 화재감시를 위한 인력의 의존도를 낮추고 기존 감지기들이 감지하지 못하는 연기발생을 감지하여 화재 예방에 기여 할 수 있을 것으로 예상된다.

2.2 딥러닝 인공지능 기법과 합성곱신경망

최근 딥러닝기법은 음성인식, 물체 인식과 탐지, 자연어의 처리와 같은 고전적인 컴퓨터비전분야의 문제들뿐만 아니라 실제 현실에서 발생하는 복잡한 문제들을 해결해야하는 응용분야에서도 큰 해법이 되고 있다. 딥러닝이 오늘날처럼 큰 주목을 받게 된 것은 컴퓨터비전 분야에서 이미지를 인식하는 대회인 ILSVRC의 2012년 대회를 통해 알려졌다. 그 해 대회에서는 딥러닝기법을 통한 이미지 인식 모델인 AlexNet이 압도적인 성적으로 우승하며 주목을 받기 시작 하였다.

본 연구에서는 연기이미지들을 심층신경망을 통하여 학습하기 위해 가장 널리 사용되는 심층 학습 접근법인 합성곱신경망을 이용하고자 한다.^[3] 합성곱신경망은 합성곱(convolutinal)계층, 풀링(pooling)계층 그리고 완전연결(fully connected)계층으로 구성된 심층신경망 기반의 알고리즘이다. 기존에 연구되던 완전연결신경망은 완전연결계층에 인접하는 뉴런이 모두 연결되는 방식이었다. 하지만 이러한 완전연결계층만으로 이루어진 신경망의 문제는 인접한 데이터의 형상이 손실될 수 있다는 것이다. 하지만 합성곱신경망의 합성곱계층의 경우 입력이미지로부터 일정 칸 커널이 이동하며 그림 1과 같이 이미지의 픽셀값과 가중치의 곱 그리고 다시 커널 단위로 합을 수행하여 이미지 특징을 학습함으로써 픽셀간의 데이터 형상을 잃지 않고 보존시켜주는 장점을 갖게 된다. 이렇게 합성곱과정을 거친 데이터는 특징맵(feature map)이라 불리는 계층에 저장을 하게 된다.^[4]




그림 1 합성곱신경망의 커널 동작 수행 구조도
 Fig. 1 Structural of the kernel operation execution process of the convolutional neural network

3. 연기감지를 위한 합성곱신경망 모델의 구성

3.1 연기감지 모델 학습을 위한 데이터셋의 구성

연기 이미지를 감지하는데 있어 좀 더 정확도를 높이기 위하여 그림 2의 좌측과 같은 일반적인 연기(smoke)이미지와 그림 2의 우측과 같은 실내에 어느 정도 연기가 확산되어 시정이 흐려진 연무(haze)형태의 이미지로 데이터셋을 나누어서 각각 학습을 진행하였다. 두 가지 연기 형상의 차이에 따른 검출방법의 차이를 두고 추론하여, 화재 영상에서 신뢰성 있게 연기를 감지할 수 있도록 하였다.

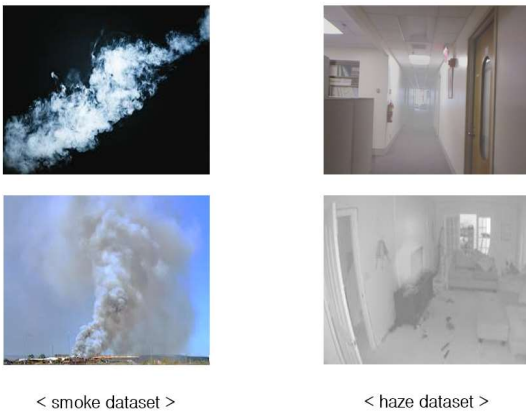


그림 2 연기감지를 위한 두 가지 형태의 데이터셋 구성
 Fig. 2 Two types of data sets for smoke detection

또한 연기 관련 이미지의 경우 총 780장의 데이터셋으로 이루어져있고, 연무형태로 연기가 확산된 실내 이미지의 경우는 1200장의 데이터셋으로 구성하였다.

3.2 합성곱신경망 계층의 구현 및 학습

본 연구를 위해 파이썬(python)기반의 오픈소스 신경망 라이브러리인 케라스(keras)를 통해 각 계층을 구성하였다. 아래 표 1은 본 연구에서 연기를 감지하기 위하여 사용된 합성곱신경망계층의 파라미터와 구조를 보여준다. 합성곱계층과 풀링계층의 형태는 기존의 일반적인 합성곱신경망 모델들로부터 크게 벗어나지 않았지만, 대부분 모델들이 주로 맥스풀링의 커널크기를 3x3으로 설정한 것과 달리 2x2크기를 사용함으로써 풀링 과정에서 공간적 특징차원이 크게 손실되지 않도록 하였다.

표 1 연기이미지 감지를 위한 합성곱신경망 계층 구조
 Table 1 Convolutional Neural Network layer for smoke image detection

| Layer | Size | Kernel Size | Activation |
|----------------|------------|-------------|------------|
| Input Image | 120x120x3 | - | - |
| Convolutional | 120x120x32 | 3x3 | relu |
| MaxPooling | 40x40x32 | 2x2 | - |
| Convolutional | 40x40x64 | 3x3 | relu |
| Convolutional | 40x40x64 | 3x3 | relu |
| MaxPooling | 20x20x64 | 2x2 | - |
| Convolutional | 20x20x128 | 3x3 | relu |
| Convolutional | 20x20x128 | 3x3 | relu |
| MaxPooling | 10x10x128 | 2x2 | - |
| Dropout | 0.5 | - | - |
| FullyConnected | 1x512 | - | sigmoid |

또한 학습 중 발생할 수 있는 과적합을 방지하기 위해 완전 연결층 바로 이전 단계에서 드롭아웃(dropout)을 통해 무작위의 노드 탈락률을 50%로 지정하였다. 마지막으로 완전연결층을 구성 할 때 활성화함수로 sigmoid를 사용하였는데 모든 범위의 실수를 취하고 0에서 1사이의 출력값을 반환하게 되어 합성곱신경망에서 학습모델의 클래스가 두 가지인 2진 분류 형태일 경우에 사용하게 된다.




그림 3 합성곱연산이 수행된 연기이미지에 대한 첫 번째와 다섯 번째 합성곱계층의 특징맵

Fig. 3 The feature maps of the first and fifth convolutional layers for the smoke image on which the convolutional operation is performed

그림 3은 연기이미지에 대한 합성곱연산이 수행된 후 특징맵에 저장된 이미지로 상단의 첫 번째 합성곱계층에서는 설정된 커널 수(32개) 만큼 특징맵이 생성된 모습이고 하단은 다섯 번째 합성곱계층의 특징맵을 보여주며, 설정된 커널 수(128개) 만큼 저장되었다. 합성곱계층이 깊어질수록 이미지는 추상적으로 변하고, 시각적인 정보들 중 불필요한 요소들은 걸러져 학습에 용이하도록 사물을 강조할 수 있는 특징들만 남게 된다.

4. 연기 검출 및 성능평가

일반적인 연기 이미지 데이터셋으로 학습된 모델은 영상내에서 일정 프레임 간격을 두고 각 프레임을 가우시안 혼합 모

텔링과 영상차분을 통해 움직임이 발생한 영역을 검출하여 해당 객체가 연기인지 판단하도록 하였다. 성능평가용 영상 하나당 움직임이 발생하여 검출된 이미지 중 100장에 대해서 몇 장을 모델이 연기로 분류하였는지 표 2에 나타내었다. 그리고 연무형태의 연기 이미지 데이터셋으로 이루어진 모델은 별도의 검출후보영역을 탐색하지 않고 이미지 전체 화면에 대해 연기가 연무형태로 확산된 실내인지 아닌지를 판별하도록 하였고, 결과를 표 3에 표시하였다.

표 2 일반적인 연기 형태의 데이터셋으로 이루어진 모델에 대한 성능평가

Table 2 Performance evaluation of a model with a smoke dataset

| Model | Smoke video | Predict (TP) | Non-Smoke video | Predict (FP) |
|---------------|-------------|--------------|-----------------|--------------|
| Smoke dataset | video 1 | 97/100 | video 1 | 17/100 |
| | video 2 | 90/100 | video 2 | 15/100 |
| | video 3 | 85/100 | video 3 | 10/100 |
| | video 4 | 90/100 | video 4 | 8/100 |
| | video 5 | 95/100 | video 5 | 21/100 |
| | video 6 | 89/100 | video 6 | 13/100 |
| | video 7 | 90/100 | video 7 | 10/100 |
| | video 8 | 96/100 | video 8 | 8/100 |

표 3 연무 형태의 데이터셋으로 이루어진 모델에 대한 성능평가

Table 3 Performance evaluation of a model with a haze dataset

| Model | Haze image (TP) | Non-Haze image (FP) |
|--------------|-----------------|---------------------|
| Haze dataset | 49/50 | 3/50 |

표 2의 TP(true positive)의 경우는 실제 정답이 연기인 영역 대해 모델이 연기로 추론한 횟수를 나타내며, FP(false positive)의 경우는 연기와 관련 없는 영상에서 움직임을 통해 추출된 영역을 모델이 연기로 잘못 판단한 횟수이다. TN(true negative)은 연기가 아닌 것을 연기가 아닌 것으로 바르게 분류한 것이고, FN(false negative)는 연기를 연기가 아닌 것으로 추론한 횟수에 해당된다. 이러한 결과를 통해 아래 식 1을 이용하여 정확도(accuracy)를 계산하면 89.38%, 식 2를 이용한 정밀도(precision)는 87.78%로 나타났다. 표 3의 TP는 연무가 형성된 실내 이미지를 연기가 발생한 것으로 판단한 횟수, FP는 연무가 없는 일반 실내이미지를 연기가 발생한 실내로 잘못 판단한 횟수에 해당되며, 정확도는 96% 정밀도는 94.23%로 나타났다.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

그림 4는 두 가지 형태의 데이터셋에 대한 각각의 검출방법을 통해 추론한 결과를 보여준다. 상단의 연기 검출은 상술한 것 과같이 움직임이 발생한 영역에 대해 연기인지 아닌지를 검출한 결과이고, 하단의 연무 분류는 영상 전체영역에 대해 연무가 형성된 실내인지 여부를 판별하게 되는 모습을 보여준다.




그림 4 두가지 유형의 데이터셋으로 이루어진 모델 각각의 추론 결과

Fig. 4 Inference results for each model of two types of datasets

5. 결론

본 연구는 일반적인 연기 데이터셋만을 학습하는 것과 더불어 연무가 형성된 실내 데이터셋을 학습하고 각각의 유형에 적합한 검출방법을 복합적으로 사용하여 연기감지를 수행하였다. 연기 데이터셋의 경우 영상에서 움직임 변화를 이용한 검출시스템이 인식할 수 있을 정도의 이동속도를 가지고 있는 경우 검출이 가능하였고, 연무 데이터셋을 학습한 모델의 경우 실내에 천천히 확산되는 연무를 감지할 수 있는 이점을 갖고 있어 각각의 장점을 통해 서로 보완하며 연기를 감지할 수 있게 하였다. 또한 사람이 인식하는 것 보다 빠르고 높은 정확도의 인공지능기반의 화재감시 시스템을 만들고자 한다면 영상기반의 객체검출기법과 다양한 데이터셋에 대한 연구가 많이 필요할 것이고, 실제 화재 영상들로부터 데이터셋을 수집하여 보강하는 것도 필요할 것이다. 또한 불꽃 및 연기감지에 대해 정확도를 높인다면 기존의 적응성의 한계로 불꽃 혹은 연기 감지기를 설치하지 못했던 환경에서 영상기반의 인공지능 기법을 통해 합리적인 화재 감시가 가능할 것으로 기대된다.

- 본 논문은 행정안전부장관의 재난관리분야 전문인력양성 사업으로 지원되었음.
- 또한, 본 연구는 중소벤처기업부에서 지원하는 2018년도 산학연협력 기술개발사업(No. S2686471)의 연구수행으로 인한 결과물임.

참고 문헌

- [1] 이동명 외2명, “제연공학”, 동화기술, pp. 112-156.
- [2] 권용일, 박명식, “초고층건물에서 발생하는 굴뚝효과 방지 대책”, 대한설비공학회, 설비저널 33(12), pp. 32-38, 2004.
- [3] 배준, 김장영, “소프트맥스를 이용한 딥러닝 음악장르 자동 구분 투표 시스템”, 한국정보통신학회논문지 제 23권 제1호, pp. 27-32, 2019.
- [4] 최희정 외6명, “해상 이미지 데이터와 합성곱 신경망을 활용한 유의과도 예측”, 대한산업공학회 추계학술대회 논문집, pp. 956-982, 2018.