

CNN을 활용한 영상 기반의 화재 감지

김영진¹ · 김은경^{2*}

Image based Fire Detection using Convolutional Neural Network

Young-Jin Kim¹ · Eun-Gyung Kim^{2*}

¹Department of Computer Science & Engineering, Graduate School, Korea University of Technology and Education, Cheonan 31253, Korea

^{2*}School of Computer Science & Engineering, Korea University of Technology and Education, Cheonan 31253, Korea

요 약

기존의 센서 기반 화재 감지 시스템은 주변 환경이 센서에 미치는 요인들에 따라 성능이 크게 제한될 수 있다. 이러한 문제를 해결하기 위해 영상 기반의 화재 감지 시스템이 다수 등장했지만, 영상에서 화염의 특성을 사람이 직접 정의하여 알고리즘을 개발하기 때문에 유사 개체에 대해 오경보를 발생시킬 수 있다. 또한 영상 프레임간의 움직임을 이용할 경우, 네트워크가 원활하지 않은 환경에서는 의도한 알고리즘이 정확하게 동작하지 않는 단점이 있다. 본 논문에서는 입력 영상 프레임으로부터 색상정보를 이용하여 화염의 후보 영역을 먼저 검출한 다음, 학습된 CNN(Convolutional Neural Network)을 활용해서 최종적으로 화재를 감지하는, CNN을 활용한 영상 기반의 화재 감지 방법을 제안하였다. 또한, 검출률과 미검출률 및 오검출률의 비교를 통해서 기존 연구에 비해 성능이 크게 향상되었음을 보였다.

ABSTRACT

Performance of the existing sensor-based fire detection system is limited according to factors in the environment surrounding the sensor. A number of image-based fire detection systems were introduced in order to solve these problem. But such a system can generate a false alarm for objects similar in appearance to fire due to algorithm that directly defines the characteristics of a flame. Also fire detection systems using movement between video flames cannot operate correctly as intended in an environment in which the network is unstable. In this paper, we propose an image-based fire detection method using CNN (Convolutional Neural Network). In this method, firstly we extract fire candidate region using color information from video frame input and then detect fire using trained CNN. Also, we show that the performance is significantly improved compared to the detection rate and missing rate found in previous studies.

키워드 : 인공지능, Convolutional Neural Network, 딥 러닝, 영상 기반 화재 감지

Key word : Artificial Intelligence, Convolutional Neural Network, Deep Learning, Image-based fire detection

Received 31 May 2016, Revised 07 June 2016, Accepted 21 June 2016

* Corresponding Author Eun-Gyung Kim(E-mail:egkim@koreatech.ac.kr, Tel:+82-41-560-1350)

School of Computer Science & Engineering, Korea University of Technology and Education, Cheonan 31253, Korea

Open Access <http://dx.doi.org/10.6109/jkice.2016.20.9.1649>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

우리나라 국민안전처의 화재 출동 현황에 따르면, 지난 5년간 약 500,000건의 출동 중 오인으로 인한 건수가 290,000건 이상으로, 50% 이상의 오인 출동이 발생하고 있고, 화재 시스템의 경보 오동작으로 인해 발생한 오인 출동의 비율은 매년 증가하고 있는 추세이다[1]. 이러한 오인 출동은 인적, 물적 낭비를 초래하고, 실제 화재에 대해 신속한 대처가 어려워짐에 따른 추가적인 비용을 발생시킬 수 있다. 그러므로 경보 오동작에 따른 불필요한 사회적 비용을 줄이기 위해, 비 화재 요소를 화재로 판단하는 오경보를 줄이면서 화재를 정확하게 감지할 수 있는 화재 감지 방법에 대한 연구가 절실히 필요하다.

기존의 화재 감지 방법은 주로 화재 센서(연기, 불꽃, 온도 등) 기반의 화재 감지와 카메라를 이용한 영상 처리 기반의 화재 감지로 구분된다. 화재 센서 기반의 화재 감지는 주변 환경의 여러 요인에 따라 시스템의 성능이 크게 제한될 수 있다는 단점이 있다. 예를 들어, 연기 센서는 통풍이 잘 되는 공간이나 화재 발생 시 센서 주변으로 공기의 확산이 발생하면 화재를 잘 감지하지 못하고, 불꽃 센서의 경우 자외선 감지 기법을 사용하는 경우 연기 혹은 기타 요소에 의해 자외선이 흡수되어 감도가 떨어질 수 있다. 온도 센서 또한 주변의 온도가 이미 높아진 상태에서는 화재를 감지하는 속도가 느려질 수 있다. 특히 센서의 특성 상 센서가 설치된 위치로 화재 발생 요소가 도달할 때까지의 지연 시간이 발생하므로, 넓은 지역에 대한 감지가 필요할 경우 일정한 간격으로 여러 대를 설치해야 하는 비용적인 문제도 발생한다[2].

반면 영상 기반의 화재 감지는 위에서 언급한 센서 기반의 화재 감지에서 발생하는 여러 문제점들을 해결할 수 있고, 기존에 설치된 CCTV를 이용할 수 있으므로 설치비용을 최소화 할 수 있으며, 경보에 따른 출동 전에 현장의 화재 상태를 미리 확인함으로써 오인 출동의 비율을 줄일 수 있다는 장점이 있다. 하지만 기존 영상 기반의 화재 감지 방법은 경험적, 실험적 임계치 설정으로 인해 실제 상황에 적용이 어렵고, 화염과 유사한 개체에 대해 오경보를 발생시킬 수 있으며, 영상 프레임간의 움직임 이용을 이용하는 화재 감지의 경우 네트워크가 원활하지 않은 환경에서는 의도한 알고리즘이 정확하게 동작하지 않는다는 단점이 있다. 따라서 본 논문에서는 딥러닝(deep learning)을 이용한 화재 감지 방법에 대해 연구하

였으며, 특히 딥러닝의 지도학습(Supervised Learning) 모델 가운데 하나인 CNN (Convolutional Neural Network)을 활용해서 화염을 학습하여 화재를 감지하는 방법에 대해 연구하였다.

II. 관련 연구

2.1. 딥러닝

딥러닝은 여러 비선형 변환 기법을 이용해서 학습 데이터에 대한 높은 수준의 추상화를 통해 데이터의 주요 특징들을 추출한 다음, 데이터 군집 및 분류를 수행하는 기계학습의 일종으로, Auto Encoder, DBN (Deep Belief Network), CNN 등을 활용하는 방법이 있으며, 최근 영상인식을 포함한 여러 영역에서 탁월한 성능을 보이고 있다. 국제 영상 인식 대회인 ImageNet Challenge에서는 2012년 제프리 힌튼 교수의 Deep CNN이 기존의 다른 영상 처리 기술들을 크게 앞서며 상위권을 휩쓰는 높은 성능을 보였으며[3], 이후 지속적으로 딥러닝을 적용한 모델들이 상위권에 오르고 있다.

CNN은 1989년 얀 리쿤 교수가 손글씨 문자 인식을 위해 제안한 딥러닝 기술로, 인간의 시신경 구조가 비전 정보를 처리하는 것을 모방한 모형이다. CNN은 입력 이미지로부터 정보를 손쉽게 분류하기 위해 저차원의 정보를 고차원으로 확장해서 분류한다. 기본적으로 CNN은 그림 1과 같이 컨볼루션 계층(convolutional layer), 풀링 계층(pooling layer or sub-sampling layer), 그리고 분류 계층(classification layer)으로 구성된다.




Fig. 1 CNN Architecture

CNN은 컨볼루션 계층과 풀링 계층을 번갈아가며 수행함으로써 학습 영상으로부터 인식 대상의 특징을 자동으로 추출한다. 컨볼루션 계층은 이전 계층으로부터 들어오는 입력 데이터에 학습된 커널을 한 칸씩 움직이면서 컨볼루션 연산을 수행하여 이미지의 특성을 고려

하면서 특징을 추출할 수 있다. 그리고 통합 계층은 컨볼루션 계층을 통해 생성된 특징 맵(feature map)의 차원 수를 줄여주는 역할을 하며, 최대 풀링(max pooling)과 평균 풀링(average pooling) 등의 방법이 있는데 일반적으로 영상 내 더 자극적인 정보를 특징으로 취득하기 위해 최대 풀링을 많이 사용한다. 이처럼 컨볼루션 계층과 풀링 계층이 번갈아가며 여러 차례 수행되고 나면 주요 패턴 정보를 가진 특징들이 자동으로 추출되며, 이를 바탕으로 분류 계층에서 최종적으로 영상의 인식 결과를 출력하게 된다.

2.2. 딥러닝 오픈소스 툴

최근 딥러닝이 이슈화되면서 표 1과 같이 딥러닝과 관련된 많은 툴들이 오픈소스로 공개되었다. 이 가운데 C++언어로 개발된 Caffe[4]는 GPGPU(General purpose computing on Graphics Processing Units) 기술인 CUDA(Compute Unified Device Architecture)를 사용하여 딥러닝을 빠르게 수행할 수 있다. 또한 여러 유형의 CNN 구조를 Protobuf(Protocol Buffers) 형태로 제공하고 있으므로, Caffe의 핵심 코드를 변경하지 않고 기존의 CNN 구조를 수정하거나 새로운 CNN을 구성하는 것이 가능하기 때문에 활용이 용이하다는 장점이 있다. 특히, Caffe는 지금까지 개발된 여러 유형의 CNN 정의 및 ImageNet[3]에서 제공하는 다양한 이미지들을 활용해서 미리 학습시킨 여러 가지 학습된 모델(pretrained model)들을 함께 제공한다. 또한, Python 및 Matlab 인터페이스를 지원하여 개발이 용이하므로, 본 연구에서는 화재 감지를 위한 CNN을 구성하는데 Caffe를 활용하였다.

Theano는 몬트리올 대학 LISA 연구실에서 Python으로 개발된 딥러닝 라이브러리이다. Theano는 상대적으로 저수준의 라이브러이므로 보다 유연하고 상세한 딥러닝 모델을 개발할 수 있다는 장점이 있지만, 히든 레이어 수가 많은 경우 컴파일 시간이 길어진다는 단점이 있다. Torch7은 Lua 언어로 개발된 딥러닝 라이브러리로, Caffe처럼 미리 학습된 여러 모델들을 제공하는 장점이 있지만, Lua라는 보편적이지 않은 언어를 사용해야 하므로 개발이 어려운 단점이 있다.

Tensor flow는 최근 구글에서 오픈소스로 공개한 딥러닝 툴로, Caffe와 유사하게 데이터 플로우 그래프(data flow graph)를 통해 효과적인 모델 구현 및 수정이

가능하지만, 다른 툴들에 비해 늦게 오픈되어 관련 자료 및 미리 학습된 모델들이 상대적으로 부족하다는 단점이 있다. 표 1은 딥러닝 오픈 소스 툴들이 개발된 언어 및 인터페이스 가능한 언어와 딥러닝 모델을 표현할 수 있는 방법을 비교한 것이다.

Table. 1 Deep learning Open Source Tools

Tool	Core language	Bindings	Deep Learning Model Expression
Caffe	C/C++	Python Matlab	Protobuf
Theano	Python	-	hard coding
Torch7	Lua	-	hard coding
Tensor Flow	Python	C/C++	Data flow graph

2.3. 기존의 영상 기반 화재 감지 방법

지금까지 개발된 센서 기반의 화재 감지 시스템들은 주변 환경에 따라 정확한 성능을 보장할 수 없고, 넓은 공간에 설치될 경우 비효율적인 문제가 발생한다. 따라서 최근에는 주로 영상 처리를 기반으로 한 화재 감지 시스템들이 연구되고 있다.

Celik 등은 화염 픽셀 분류를 위해 규칙 기반 칼라 모델을 적용하였다. 즉, 화염에서 발생하는 휘도(luminance)와 색차(chrominance)를 효과적으로 검출하기 위해, RGB 컬러 모델을 식 (1)을 이용하여 휘도와 색차를 보다 효과적으로 분리할 수 있는 YCbCr 컬러 모델로 변환하고, 식 (2)를 이용해서 조도의 변화에 높은 강인성을 보이는 화재 감지 방법을 제안하였다[2].

$$\begin{pmatrix} Y \\ Cb \\ Cr \end{pmatrix} = \begin{pmatrix} 0.2568 & 0.5041 & 0.0979 \\ -0.1482 & -0.0910 & 0.4392 \\ 0.4392 & -0.3678 & -0.0714 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} + \begin{pmatrix} 16 \\ 128 \\ 128 \end{pmatrix} \quad (1)$$

$$F(x, y) = \begin{cases} 1, & Y > Y_{mean}, Cb < Cb_{mean}, Cr > Cr_{mean}, \\ & |Cr - Cb| \geq \tau \\ 0, & otherwise \end{cases} \quad (2)$$

위의 식 (1), (2)에서 Y는 휘도, Cb와 Cr은 색차 값, τ 는 ROC(Receiver Operating Characteristic)의 분석에 의해 결정되는 상수값이다[2]. 즉 τ 값은 경험적 임계값(threshold)으로, 이 값이 작으면 영상 안의 화재를 잘 감지한다는 장점이 있지만 유사 색상의 다른 개체에 대해

오경보를 발생시킬 확률이 높아진다는 단점이 있다. 반대로 임계값이 크면 오경보를 발생시킬 확률은 낮아지지만, 화재를 잘 감지하지 못하는 단점이 있다.

그밖에 컬러 모델을 활용해서 화재를 검출하는 방법으로는 HSI 컬러 공간에서 화염을 검출하는 방법[5]과 YIQ 컬러 모델을 이용하여 화염 후보를 검출한 다음 검출된 후보 영역간의 비교를 통해 화재를 감지하는 방법[6] 등이 있지만, 컬러 모델만 적용한 화재 감지 방법은 공통적으로 유사 색상에 대해 오경보를 발생시킬 수 있다는 문제점이 있다.

III. CNN을 활용한 화재 감지 방법

기존의 컬러 모델을 이용한 화재 감지 방법은 유사 개체에 대해 오경보를 발생시킬 수 있고, 대개 실험적으로 임계값을 설정하므로 실제 환경에 적용하기에는 적합하지 않다. 컬러 모델을 이용하지 않고 영상 처리를 통해서 화염을 감지하는 방법은 사람이 직접 정의한 화염의 특성을 이용해서 화염 발생 여부를 감지하게 되는데, 이런 감지 방법은 사람이 인식하지 못한 화염의 특성을 고려할 수 없기 때문에 화염을 제대로 감지하는데 한계가 있다. 따라서 본 논문에서는 학습 데이터로부터 영상 내 화염의 특성을 자동으로 추출해서 화염을 검출할 수 있도록, 딥러닝 알고리즘 가운데 하나인 CNN을 활용해서 화재를 감지하는 방법을 제안하였다.

3.1. 데이터 셋 구성

본 논문에서는 ImageNet[7]에서 획득한 화염 이미지와 유튜브에서 검색한 화재 실험 동영상으로부터 추출한 화염 이미지를 포함해서 8,077장의 화염 이미지와 조명, 광원 등 화재와 유사한 개체 이미지를 포함하는 비화염 이미지 12,582장을 활용했는데, 화염 이미지 가운데 약 6,463장과 비화염 이미지 가운데 약 10,066장은 학습 데이터 셋(training data set)으로 활용하고, 나머지는 검증 데이터 셋(validation data set)으로 활용하였다. Caffe를 이용해서 CNN을 학습시키기 위해 먼저 준비된 학습 데이터 셋과 검증 데이터 셋을 LMDB (Lightning Memory-mapped DataBase)라고 불리는 공개 데이터베이스로 변환하였다. LMDB는 key-value 쌍으로 저장되는 데이터베이스로, 데이터의 읽기 연산 시 윈도우나 리

눅스 같은 운영체제의 파일시스템의 읽기 연산보다 속도가 빠르기 때문에 CNN 학습과 같이 반복적으로 자료를 읽어야 하는 문제에 매우 효과적이다.

3.2. 화재 감지를 위한 CNN 구성

본 논문에서는 Caffe에서 제공하는 CNN 유형 가운데 하나인 BVLC(Berkeley Vision and Learning Center) Reference CaffeNet[4]의 구조를 일부 변경해서 화염 감지에 최적화된 CNN을 구성하였다. CaffeNet은 Krizhevsky[3]가 ILSVRC(Imagenet Large-Scale Visual Recognition Challenge) 2012의 1000개 클래스로 구성된 120만개의 이미지를 분류하기 위해 제안한 CNN인 AlexNet을 약간 수정한 것으로, 그림 2와 같이 컨볼루션 계층과 풀링 계층이라는 2개 계층이 서로 교차되어 이미지의 특징을 추출하고, 이어서 연속되는 컨볼루션 계층을 통해 여러 가지 변화(variation)에 불변인 특징들을 추출하게 된다. 이후 3개의 완전 연결 계층(Fully Connected Layer)에서는 앞에서 추출된 특징들을 사용해서 이미지 분류를 수행하게 된다.




Fig. 2 Architecture of CaffeNet[4]

CaffeNet은 120만개의 이미지를 분류하기 위해서 5개의 컨볼루션 계층과 2개의 완전 연결 계층으로 구성되어 있으며, 각각의 컨볼루션 계층은 5*5*96, 3*3*256, 3*3*384, 3*3*384, 3*3*256개의 특징 맵으로 구성되어 있고, 완전 연결 계층은 각각 4096개의 노드로 구성되어 있다. 따라서 각 파라미터의 수가 매우 많아서 학습에 아주 많은 시간이 소요되고, 충분한 학습 데이터가 없으면 제대로 학습이 되지 않아 오분류를 발생시킬 수 있다. 따라서 본 연구에서는 화염 분류에 적합한 CNN을 구성하기 위해 CaffeNet의 컨볼루션 계층과 완전 연결 계층의 노드 수를 변화시키면서 CNN의 성능을 테스트하였다. 그 결과 각 계층의 노드 수를 1/8 이상 감소시킬 경우 CNN의 규모가 너무 작아져서 학습이 제대로 이루어지지 않았고, 1/4로 감소시켰을 때는 학습 속도

는 빠르지만 학습 데이터에 과적합(overfitting)되는 경향을 보였다. 한편, 1/2로 감소시켰을 때 학습 속도와 정확도 면에서 가장 우수하였다. 따라서 본 연구에서는 CaffeNet의 컨볼루션 계층과 완전 연결 계층의 노드 수를 1/2로 감소시켜서 화재 감지를 위한 CNN을 구성하였다.

3.3. 화재 감지를 위한 CNN 학습

CNN의 학습은 그림 3과 같이 전방향 전파(forward propagation)와 역방향 전파(backward propagation)를 통해 이루어진다. 먼저 학습 데이터를 CNN의 전방향으로 전파시킴으로써 학습 데이터의 클래스를 추정한다. 이후 추정된 학습 데이터 클래스와 라벨(target value)간의 오차를 오차함수 중 하나인 Softmax를 이용해서 계산한다. 오차함수를 통해 계산된 오차를 오류 역전파(error backpropagation) 알고리즘을 통해 CNN의 역방향으로 전파하면서 CNN의 파라미터들을 수정하며, 이런 과정을 반복함으로써 CNN을 학습시키게 된다.




Fig. 3 CNN Training

CNN은 학습 데이터 셋을 이용하여 오류 역전파 알고리즘을 통해 CNN의 파라미터들을 수정하면서 학습을 진행하기 때문에, Softmax를 이용해 계산된 오차는 지속적으로 감소된다. 그러나 CNN을 계속 학습시키면 어느 시점에서 오차가 발산할 수 있는데, 이는 CNN의 구조가 학습 데이터 셋의 크기나 클래스의 수에 비해 너무 작거나 너무 커서 생기는 문제로, CNN 구조를 변경해야 해결할 수 있다. 한편, 오차가 0으로 수렴하더라도 CNN이 학습 데이터에 과적합될 수 있으므로, 반드시 검증 데이터 셋을 활용해서 CNN의 학습 결과에 대한 검증이 필요하다. 본 연구에서는 그림 3과 같이 4,130개의 검증 데이터를 이용하여 CNN의 학습 결과를 검증하였다. 본 논문에서는 Intel Core i7-5930의

CPU와 GTX Titan X GPU의 컴퓨팅 환경에서 CNN의 학습과 검증을 수행하였다. 화재 감지에 활용한 CNN은 16,529개의 학습 데이터를 이용해서 15만 번 학습을 반복했으며, 학습에 소요된 시간은 약 25시간 정도다. 학습 결과 그림 4와 같이 약 5만 번째 학습부터 학습 데이터에 대한 오차가 0에 수렴하였다. 또한, 4,130개의 검증 데이터에 대한 정확도(accuracy)도 그림 5와 같이 약 0.95로 수렴하였다.

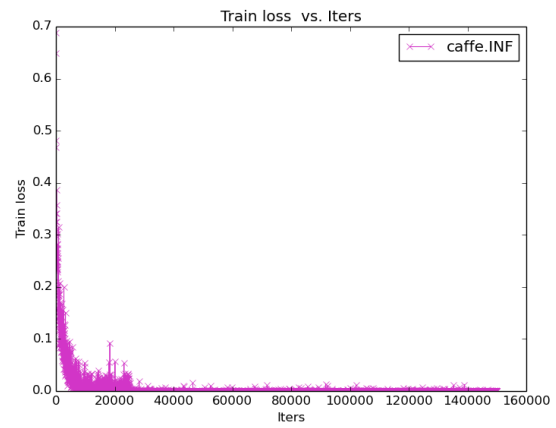


Fig. 4 Training Results of the Trained CNN

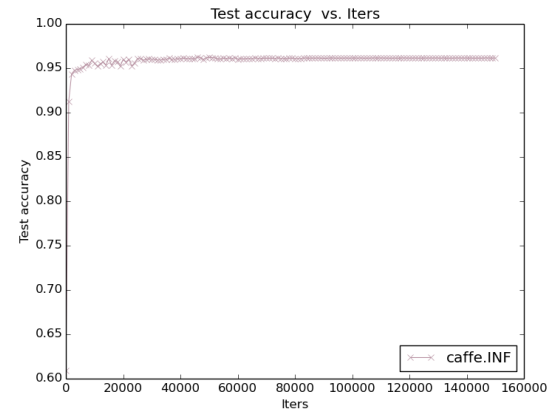


Fig. 5 Validation Results of the Trained CNN

3.4. 학습된 CNN의 커널과 특징 맵

본 논문에서 최종적으로 학습된 CNN의 첫 번째 컨볼루션 계층의 커널(kernel)과 특징 맵은 그림 6과 같다. CNN에 입력되는 이미지는 첫 번째 컨볼루션 계층에서 그림 6의 좌측의 커널을 이용해서 컨볼루션 연산을 수

행하며, 연산 수행 결과 그림 6의 우측의 특징 맵들이 커널의 수만큼 생성된다. 이후 생성된 특징 맵들은 풀링 계층을 통해 차원이 축소되고, 연결된 나머지 컨볼루션 계층들은 첫 번째 컨볼루션 계층과 같은 방식으로 연산이 수행되며, 최종적으로 완전 연결 계층을 통해 입력 이미지의 화염 여부를 판단하게 된다.

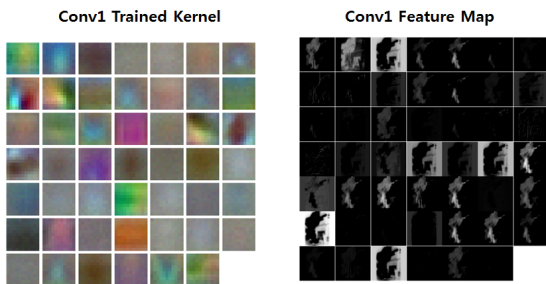


Fig. 6 Kernel and Feature Map of the First Convolution Layer

3.5. CNN을 활용한 화재 감지 프로세스

본 논문에서 제안한 CNN을 활용한 화재 감지 프로세스는 그림 7과 같다.

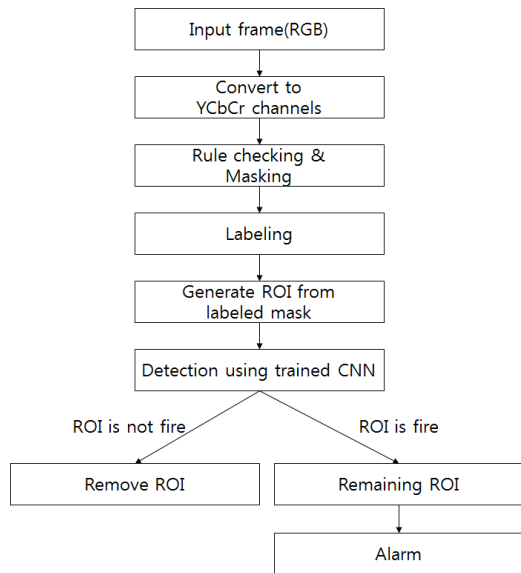


Fig. 7 CNN based Fire Detection Process

먼저 화염의 위치와 후보 영역을 검출하기 위해 영상으로부터 들어오는 원본 RGB 프레임을 그림 8과 같이

2.3에서 언급한 식 (1)을 이용해서 YCbCr 컬러 모델로 변환한다. 이후 앞의 식 (2)를 이용해서 화염 후보 영역을 검출해서 mask를 생성한다. 한편, 연구 [2]에서는 τ 값을 1000장의 이미지로부터 ROC 분석을 통해 90%의 검출율을 보이지만 40%의 오검출을 발생시키는 상수 값 40으로 설정하여 사용하였다. 하지만 본 논문에서는 τ 값을 최대한 줄여서 오검출이 발생하되 최대한 화염 픽셀을 감지할 수 있도록 35로 설정하였다.




Fig. 8 Detection of Fire Candidate Region using YCbCr Color Model

생성된 mask는 화염의 후보 픽셀을 나타내는 것으로, 이를 픽셀의 군집 형태에 따라 라벨링한다. 라벨링은 그림 9와 같이 8-neighbors를 이용하여 인접 픽셀이 임계값 내에 있을 경우 같은 라벨로 선택한다.

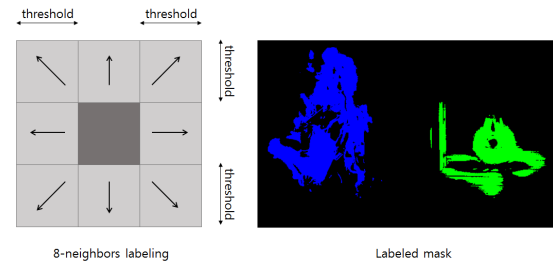


Fig. 9 8-neighbors labeling and the labeling result

라벨링된 mask를 이용해서 각 라벨 별로 사각형 영역을 생성하고, 원본 이미지로부터 생성된 사각형 영역에 해당하는 부분 이미지(ROI : Region Of Interest)를 그림 10과 같이 추출한다.



Fig. 10 ROI extraction using labeled masks

화염 후보 영역에 해당하는 추출된 부분 이미지는 미리 학습된 CNN을 통해 화염 여부를 확인하며, 후보 영역이 화염 영역이면 입력 영상 프레임에 표시하고, 그렇지 않으면 해당 영역을 제거하여 최종적으로 화재 여부를 판단하게 된다.

IV. 테스트 및 결과 분석

본 논문에서 제안한 CNN을 활용한 화재 감지 방법의 성능을 객관적으로 평가하기 위해, 기존의 관련 연구[8, 9]에서 활용한 6개의 화재 동영상을 그대로 사용하였으며, 그림 11과 같이 Ceilk[2]과 Toreyin[8], 그리고 Kwang-Ho Cheong[9]의 연구 결과와 비교하였다.



Fig. 11 Comparison of CNN-based fire detection with previous studies

3.3절에서 언급한 컴퓨팅 환경에서 6개의 화재 동영상을 테스트한 결과, 프레임 당 처리 속도는 평균 0.12 초 정도이며, 초당 10개 내외의 프레임을 처리하였다.

성능 평가를 위해 사용한 3가지 척도는 검출율 (detection rate)과 미검출율(missing rate), 그리고 오검출율(false rate)이다. 검출율은 화염이 존재하는 프레임 중에서는 화염을 제대로 탐지하고, 화염이 존재하지 않는 프레임에서는 화염으로 오검출하지 않는 프레임의 비율이고, 미검출율은 화염이 존재하는 프레임 중 화염 영역을 제대로 검출하지 못한 프레임의 비율이다. 오검출율은 화염이 존재하지 않는 프레임에서 화염으로 잘못 검출한 프레임의 비율이다. 성능 평가 결과 그림 11에서 알 수 있듯이 본 연구에서 제안한 CNN을 활용한 화재 감지 방법의 검출율은 평균 99.05%로, Movie 2를 제외한 나머지 동영상에서는 100%의 검출율을 보이면서 기존 연구들 보다 우수한 성능을 보이고 있다. 미검출률에 있어서도 Movie 2를 제외하고는 0%로 다른 연구들 보다 우수하며, 오검출율 또한 0%로 모든 영상에 대해서 오검출이 전혀 발생하지 않았다.

V. 결론

본 논문에서는 RGB 입력 영상 프레임을 YCbCr 채널로 변환하여 화염 후보 픽셀을 masking하고, 8-neighbors labeling을 통해 영역 라벨링을 수행한 다음, 마지막으로 학습된 CNN을 활용해서 최종적으로 화염 여부를 판단하는, CNN을 활용한 영상 기반의 화재 감지 방법을 제안하였다. 본 연구에서는 CaffeNet의 구조를 그대로 사용하지 않고 충분한 테스트를 거쳐, 화재 감지에 최적화되도록 각 노드들을 1/2로 줄여 학습 속도 및 성능을 최적화시켰다. 또한 기존의 컬러 모델을 이용한 화재 감지 방법이 유사 색상에 대해 오경보를 발생시키는데 반해, 본 연구에서는 CNN을 이용해 화염 후보 영역에 대해서만 최종적으로 화염 여부를 판단함으로써 기존의 연구에 비해 오경보 비율을 크게 낮추는 결과를 얻었다. 특히 촛불, 램프, 라이트 등과 같이 화재로 오인될 수 있는 이미지들을 비 화염 클래스로 정의하여 학습시킴으로써 불필요한 오경보를 발생시키지 않도록 하였다.

일반적으로 화재 발생 시 화염 뿐 만 아니라 연기가

함께 발생하는데, CNN을 이용해서 화재가 아닌 연기와 화재의 연기와 구분하기 위해서는 매우 많은 학습 데이터가 필요하다.

따라서 본 연구에서는 우선 화염 감지에 초점을 맞춰 연구하였으며, 향후 비 화재 연구 및 화재 연구에 대한 충분한 학습 이미지를 확보하여 연구할 계획이다. 또한, 향후 다양한 학습 데이터를 확보해서 화재 발생 여부뿐만 아니라 사람이나 애완동물, 폭발물 등의 존재 여부도 감지할 수 있는 화재 감지 시스템으로 확장할 계획이다.

REFERENCES

- [1] Ministry of Public Safety and Security National Fire Data System, statistics from 2011 to 2015 [Internet]. Available: http://www.nfds.go.kr/fr_base_0001.jsf.
- [2] T. Celik and H. Demirel, "Fire Detection in Video Sequences Using a Generic color Model," *Fire Safety Journal*, vol. 44, no. 2, pp. 147-158, Feb. 2009.
- [3] A. Krizhevsky, I. Sutskever, and G. Hinton, "Imagenet classification with deep convolutional neural network," in *Advances in Neural Information Processing Systems*, pp. 1097-1105, 2012.
- [4] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell "Caffe: An open source convolutional architecture for fast feature embedding," in *Proceeding of the ACM international Conference on Multimedia*, ACM, pp. 675-678, 2014.
- [5] W. B. Horng, J. W. Peng, and C. Y. Chen. "A new image-based real-time flame detection method using color analysis," in *Proceeding of the IEEE Networking, Sensing and Control*, pp. 100-105, 2005.
- [6] Y. T. Do, "Visual Sensing of Fires Using Color and Dynamic Features", *Journal of Sensor Science and Technology*, vol. 21, no. 3, pp. 211-216, Mar. 2012.
- [7] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, L. and Fei-Fei, "Imagenet large scale visual recognition challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211-252, April. 2015.
- [8] B.U. Toreyin, Y. Dedeoglu, U. Gudukbay, and A. E. Cetin, "Computer vision based method for real-time fire and flame detection." *Pattern recognition letters*, vol. 27, no. 1, pp. 49-58, Jan. 2006.
- [9] K. H. Cheong, B. C. Ko, and J. Y. Nam, "Automatic fire detection system using Bayesian Network," *Korea Information Processing Society*, vol. 15, no. 2, pp. 87-94, Feb. 2008.



김은경(Eun-Gyung Kim)

1983년 2월 : 숙명여자대학교 물리학과 졸업
1986년 2월 : 중앙대학교 전자계산학과 석사
1991년 2월 : 중앙대학교 컴퓨터공학과 박사
1992년 3월 ~ 현재 : 한국기술교육대학교 컴퓨터공학부 교수
※관심분야 : 딥 러닝, 트리즈, 지능형 에이전트 등



김영진(Young-Jin Kim)

2014년 7월 : 한국기술교육대학교 컴퓨터공학부 공학사
2016년 8월 : 한국기술교육대학교 컴퓨터공학부 공학석사
2016년 8월 ~ 현재 한국기술교육대학교 컴퓨터공학부 박사과정
※관심분야 : 딥 러닝, 트리즈, 컴퓨터 하드웨어 시스템