

감시 카메라를 사용한 화재 감지 알고리즘에 관한 연구

뉴엔 만 둥*, 최 복 길*, 노 승 환^o

A Study on the Fire Detection Algorithm Using Surveillance Camera Systems

Nguyen Manh Dung*, Bokgil Choi*, Soonghwan Ro^o

요 약

본 논문에서는 감시 카메라에 의한 실시간 화재 감지 알고리즘을 제안한다. 화재 불꽃의 후보 영역은 프레임의 이미지 픽셀의 깜빡임(flicker) 에너지 및 색상 모델의 시간 분석에 의해 인식된다. 또한 여러 단계의 분류기를 실제 화재 및 화재가 아닌 영역을 구별 할 수 있는 강력한 분류기와 결합하는 종속(cascade) 모델을 사용하여 견고한 화염 분류기를 개발한다. 실험 결과에서 제안된 알고리즘이 높은 정확도를 갖는 실시간 화재 탐지에 적합하다는 것을 보여준다.

Key Words : fire detection, deep learning, CNN(Convolutional Neural Network), CaffeNet, cascade Model

ABSTRACT

In this paper, we propose a real-time fire detection algorithm for using surveillance camera system. Candidate regions of fire flames are recognized by temporal analysis of the flickering energy and color models of image pixels in frames. We also develop a robust fire flame classifier using a cascade model that joins many weak classifiers into one robust and precise classifier capable of distinguishing true fire and non-fire regions. Experimental results show that the proposed algorithm is absolutely sited for real-time fire detection with high precision.

1. 개요 및 관련 연구

화재는 가장 빈번하게 발생하는 재난이며, 화재로 인한 생명 및 재산의 손실은 매우 크다. 따라서 화재를 신속하게 감지를 한다면, 이러한 손실을 방지하거나 최소화 할 수 있다. 따라서 화재를 탐지하기 위해서 센서를 사용한 화재 감지를 포함한 다양한 방법이 개발되었다. 그러나 센서를 이용한 방법의 정확성은 센서가 설치된 밀도와 센서의 신뢰성에 의해 크게 영

향을 받는다. 따라서 많은 센서를 사용해야 하므로 설치를 하고 관리를 하는데 많은 어려움이 있으며, 특히 범위가 넓고 개방 된 지역에서는 센서를 이용하는 방법이 매우 제한적이다.

최근 보안 카메라 시스템(CCTV)이 일반화됨에 따라 영상 처리에 기반한 화재 감지 알고리즘이 많이 제안되고 있다. 영상처리 기반의 감시 시스템을 센서 기반 시스템과 비교할 때 보안 카메라는 설치가 훨씬 쉬우며 대용량 및 개방된 지역에 대한 감시가 매우 편리

※ 이 논문은 2018년 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임.(2018R1D1A1B07049146)

• First Author : (ORCID:0000-0001-6165-4137), Kongju National University, manhdungbk45@gmail.com, 학생회원

o Corresponding Author : (ORCID:0000-0001-6091-796X), Kongju National University, rosh@kongju.ac.kr, 종신회원

* (ORCID:0000-0003-1750-1568), Kongju National University, bgchoi@kongju.ac.kr

논문번호 : KICS2018-05-126, Received May 24 2018; Revised June 7, 2018; Accepted June 7, 2018

하다.^[1] 그러나 화재 감지를 위한 많은 방법이 제안되었지만, 그 중에서 일부는 상당한 성과를 보이지만, 여전히 성능과 결과에 있어서 개선되어야 할 부분이 많이 있다.

컴퓨터 비전에서 색상은 항상 중요한 단서이며 대부분의 알고리즘에서 화재를 감지하는 주요 기능이 된다^[2-7]. 이러한 특징에 의해 Gunawardena^[2]는 YCrCb 색 공간을 사용하여 화염 픽셀을 분류하기 위해서 색상 모델을 추정하였다. 이 알고리즘은 또한 화염을 움직이는 물체로 취급하고 배경 모델링 방법을 사용하여 가능한 화염 픽셀을 분할한다. 다음 단계는 후보 구역을 탐지하기 위해서 색상 화염 픽셀과 움직이는 화염 픽셀을 융합하는 것이다. 마지막으로 후보 지역은 시간적 및 공간적 강도의 변화와 같은 화재 화염의 특징 기반에 의해 확률 모델을 사용하여 실제 화재와 비 화재로 분류된다.

유사하게, Jessica Ebert^[4]는 화재의 후보 영역을 먼저 검출하고 화재의 강도와 공간적 색상 변화에 대한 시간 변화를 사용하여 비 화재를 제거하기 위한 확률 모델을 추정하는 알고리즘을 제안하였다. 그러나 YCbCr 색상 모델과 배경 모델링을 사용하여 화염 픽셀을 감지하는 대신 RGB 색상 모델을 사용하여 불 깜빡임 에너지를 누적한다.

Toreyin은 컬러 비디오에서 화재 감지를 위한 알고리즘을 제안하였으며, 이 제안에서 전경 이동 객체를 감지하기 위해 하이브리드 배경 모델을 사용하고, RGB 색상공간에서 화염 색상 픽셀을 검출하기 위해 가우시안 모델을 사용하였다. 마지막으로 1 차원 웨이블릿(wavelet) 변환을 사용하여 시간적 색상 변화를 검사하고 2 차원 웨이블릿 변환을 사용하여 화재 불꽃의 공간 색상 변화를 확인한다.

위에서 언급 한 대부분의 알고리즘은 실제 화재와 비 화재 이동 객체를 구분하기 위해 확률 모델과 경험적인 규칙을 사용한다. 그러나 이러한 방법의 문제는 확률론적 모델이 구분을 하기 위해서 최적 임계값을 결정하는 것이 어렵다. 임계값을 엄격하게 정하면 실제 화재를 감지하지 못하는 경우가 발생하는 반면, 임계값을 관대하게 정하면 오탐(false positive)이 발생할 수 있다.

최근에는 Bag of Visual Words를 구성하고 기계 학습 기술을 적용하기 위해 로컬 이미지 특징(예 : HOG (Histogram of Oriented Gradients) 및 SIFT (Scale-Invariant Feature Transform))을 사용하는 이미지 분류 방법이 있다. 그 다음에 벡터 기계(vector machine) 또는 랜덤 포리스트(random forest)와 같은

기계 학습(machine learning) 기술을 사용하여 이미지 분류기(image classifier)를 학습시킨다^[7]. 이 접근법은 향상된 결과를 보여 주었지만 시각적 단어(visual words)에 의존하는 분류기는 패치(patch)간의 공간적 관계(spatial relationship)를 무시하고 객체의 상황(context)이 표현될 때 배경 정보를 혼동한다.

최근에는 컨볼루션 신경망 (convolutional neural networks, CNNs)^[8-10]이라고 하는 딥 러닝(deep learning) 알고리즘이 이미지 분류에 광범위하게 적용되고 있다. 이러한 알고리즘은 이미지를 분류하는 것뿐만 아니라 컴퓨터 비전 응용 프로그램에서 매우 뛰어난 성능을 보이고 있다. 그러나 CNN을 사용하는 알고리즘도 객체의 영역을 파악하는데(object localization) 문제가 있고 계산이 소요되는 비용이 매우 높지만(computationally expensive)이 비싸지만, 객체 감지를 위한 백그라운드 모델링과 CUDA와 같은 하드웨어 가속기를 이용해서 시스템 성능을 향상시킴으로써 이러한 문제를 해결할 수 있습니다. 따라서 CNN을 사용하는 이미지 분류 알고리즘은 화재를 분류하는데 잘 적용될 수 있다.

이 논문에서는 카메라 시스템과 함께 사용하기 위한 빠르고 안정적인 화재 감지 알고리즘을 제안한다. 2장에서는 제안된 알고리즘의 방법론과 구현에 대해서 설명하고, 3장에서는 알고리즘의 실험 결과를 보여 줄 것이다. 마지막으로, 4장에서는 추후 연구에 대해서 설명하고 결론을 맺는다.

II. 비디오 기반의 연기 감지

그림 1은 제안된 알고리즘의 구조를 보여준다. 여기에는 화재 후보 영역 감지, 화재 및 비 화재 영역 분류, 그리고 화재 경보의 최종 확인을 위한 시간 분석의 네 단계가 포함된다.

- 화염 픽셀 분류 : 모든 픽셀들은 색상 맵과 깜빡임 에너지 맵을 이용하여 화염 픽셀과 비화염 픽셀로 구분된다.
- 화재 후보 영역 감지 : 깜빡임 에너지 맵과 컬러 맵을 융합하여 화재일 가능성이 있는 맵을 얻은 다음 형태학적 작업에 의해 잡음을 제거하고 화염 픽셀들을 화재 후보영역으로 분류한다.
- 화재 분류 : 종속(cascade) 모델을 사용하여 일련의 요소 분류자 결합하는 화재 분류기를 개발했다. 이 모델은 종속 모델의 모든 레이어를 통과하는 경우에만 후보 영역을 실제 화재로 분류한다.
- 시간 분석 : 화재 탐지의 정밀도를 높이기 위해 최

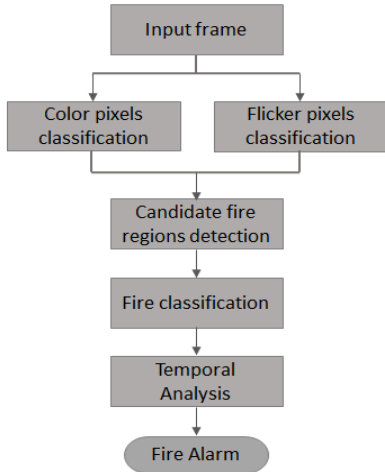


그림 1. 비디오 기반 화재 감지 알고리즘의 흐름도
Fig. 1. Video based Fire detection flow

중 결정을 내리기 전에 계단식 모델을 통과한 화재 영역에 대해서 일정 시간동안 분석한다.

2.1 화재 후보 영역 감지

색상은 화재를 인식하는 가장 중요한 단서이다. 일반적으로 화염의 색은 온도에 따라 노란색에서 빨간색으로 바뀐다. 그림 2는 HSV(Hue, Saturation, Value) 모델의 화재 색상범위를 보여준다.

유용한 화재 모델은 [5]에서 소개되었다. 이 모델을 기반으로 본 논문에서는 화염 픽셀을 분류하기 위해서 약간의 수정을 하였다. 만일 이미지의 픽셀이 다음 식 (1), (2) 그리고 (3)을 만족하면 화염 픽셀로 분류된다.

$$H_{T1} \leq H \leq H_{T2} \quad (1)$$

$$R > R_T \quad (2)$$

$$S > (255 - R) S_T / R_T \quad (3)$$




그림 2. HSV 색 공간에서의 화재 색상 모델
Fig. 2. Fire Color Model in HSV Color Space

여기서 H , R 및 S 는 각각 색조(hue), 적색 채널의 강도 및 이미지 픽셀의 채도를 나타낸다. H_{T1} , H_{T2} , R_T 및 S_T 값들은 많은 실험에 의해 정의됩니다. H_{T1} , H_{T2} 의 범위는 일반적으로 0 ~ 70 이며, S_T 는 약 60이고, R_T 는 약 120 이다.

화재 감지의 또 다른 중요한 특징은 화염의 깜빡임(flickering)이다. Marbach et al.^[3]는 휘도의 깜빡거림에 의해 효과적으로 화재를 감지하는 방법을 개발하였다. 이 방법을 따르면 누적 깜빡임 에너지 맵(flicker energy map)을 아래와 같이 추정 할 수 있습니다.

$$E(t) = I(t) - I(t - 1) \quad (4)$$

$$A(t) = aE(t - 1) + (1 - a)E(t) \quad (5)$$

여기서, $I(t)$ 및 $E(t)$ 는 시간 t 에서 이미지 픽셀의 강도 및 깜빡임 에너지이며, $A(t)$ 와 a 는 누적 깜빡임 에

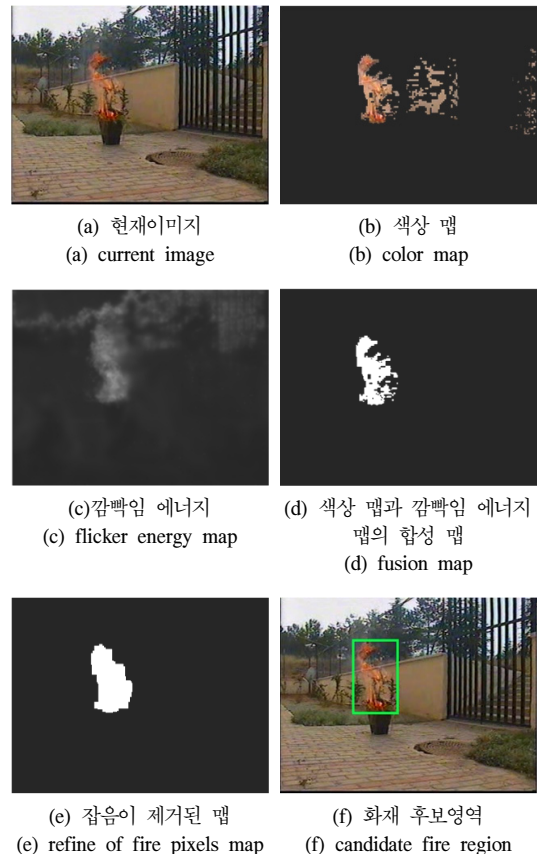


그림 3. 색상과 깜빡임 에너지 맵에 의한 화재 픽셀 맵의 추정
Fig. 3. Estimation of fire pixel map based on color and flicker energy maps

너지와 누적 인자를 각각 나타낸다.

그림 3의 (c)는 화재가 포함 된 이미지 프레임의 누적 깜빡임 에너지 맵을 보여준다. 화재 프레임을 둘러싼 누적 깜빡임 에너지가 다른 영역보다 훨씬 높다는 것을 쉽게 알 수 있다. 이러한 특징에 따라 화염 픽셀의 누적 깜빡임 에너지가 실험적으로 정의된 임계값을 초과하면 이 픽셀은 화염 픽셀로 분류된다.

$$A(t) > e_T \quad (6)$$

화재 가능한 맵에서 가능성이 있는 모든 화재 픽셀을 화재 후보 영역의 서브 영역으로 묶는다.

2.2 화재 후보 영역 감지

화재 픽셀의 컬러 맵과 깜빡임 맵을 추정 된 후에는 색상 맵과 깜빡임 맵의 합성 맵을 픽셀 단위로 수행할 수 있으며, 이 과정에 의해 화재일 가능성이 있는 맵을 구성한다. 그 후 침식(erosing)이나 확장과 같은 형태를 수정하는 작업에 의해 화재 픽셀 맵을 개선할 수 있다.

마지막으로, 개선된 맵에서 모든 가능한 화재 픽셀을 후보 화재 서브 영역으로 클러스터링하여 화재 영역이 동시에 감지 될 수 있다. 그림 3은 컬러 및 깜빡임 에너지 맵을 기반으로 한 후보 화재 탐지의 예를 보여준다.

2.3 화재 분류

색상과 깜빡임은 화재 감지를 위한 좋은 특징을 제공하지만 이와 비슷한 현상을 갖는 움직이는 물체가 많다. 따라서 정확한 화재 영역을 탐지하고, 오탐(false positive) 제거하기 위해서 추가적인 분류 단계가 필요하다.

정확하게 화재를 화재가 아닌 개체와 구별하기 위한 몇 가지 좋은 추가 기능이 있으며, 각각은 고유한 장단점을 갖는다. 종속 모델은 다양한 기능을 하나의 분류기로 결합하고 그 이점을 활용하는 데 매우 유용한 모델이다. 이 모델에서의 각 계층은 실제 화재 영역이 될 확률이 낮은 영역 만 제거하도록 설계되었다.

그림 4는 캐스케이드 모델에 의한 화재 분류기의 흐름도이다. 모델의 최상위 계층은 약하지만 속도가 빠른 특징을 갖는 분류자이다. 마지막 계층은 무겁지만 높은 정확성을 갖는 CNN 분류자이다. 하나의 영역은 이 모델의 모든 계층을 통과하면 실제 화재로 분류된다.

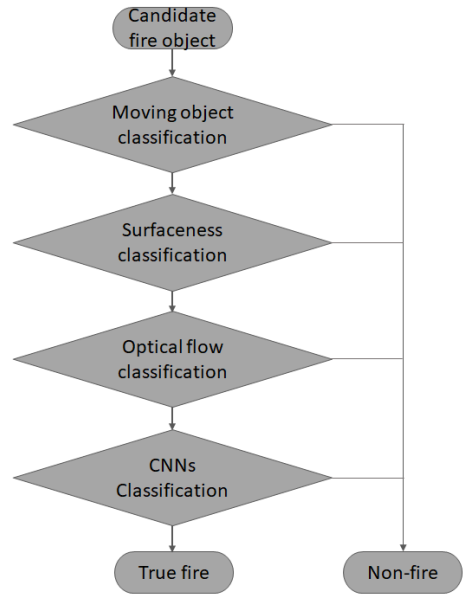


그림 4. 화재 분류를 위한 종속 모델
Fig. 4. Cascade model for fire classification

2.3.1 이동 물체의 분류

그림 5에서와 같이 화재가 발생하면 일반적으로 주변 환경으로 천천히 퍼진다. 대조적으로, 규칙적으로 움직이는 물체는 출현 위치에서 빠르게 이동하는 경향이 있다.

$p_0(x_0, y_0)$ 는 객체의 첫 번째 위치이고 $pt(x_t, y_t)$ 는 일정 시간 후 객체의 위치라고 가정하면, 이 시간 동안 물체의 이동 거리는 다음과 같다.

$$D(t) = \sqrt{(x_t - x_0)(x_t - x_0) + (y_t - y_0)(y_t - y_0)} \quad (7)$$

개체의 이동 거리가 주어진 임계값보다 큰 경우, 이는 일반적인 이동 물체로 분류하고 화재 후보에서 제외한다. 여기에서 화재 가능성이 낮은 영역을 제거하기 위해서 기준을 관대하게 선택해야 한다.

식 (8)은 물체가 움직이는 거리에 따라 물체가 움직이는 지 아닌지를 결정하는데 사용된다. 그러나 식 (7)



그림 5. 화재와 화재가 아닌 물체의 궤적(녹색 선)
Fig. 5. Trajectory of fire and non-fire objects(green line)

에서 계산된 이동 거리는 픽셀 단위이므로 물체의 실제 이동 거리를 추정하는 것은 쉽지 않다. 따라서 실제 이동 거리를 추정하기 위해서는 객체의 폭을 기준으로 사용할 수 있다. 객체의 이동 거리가 식 (8) 조건을 만족하면 움직이는 객체로 분류된다.

$$D(t) > n_T \times \text{Obj_width}(t) \quad (8)$$

식 (8)에서 $D(t)$ 는 시간 t 에서 물체 이동 거리이고, $\text{Obj_width}(h)$ 는 시간 t (픽셀단위)에서의 객체의 폭이고, n_T 는 미리 정의된 임계값이다. 본 실험에서 n_T 를 2로 설정하면 움직이지 않는 물체를 거의 제거할 수 있다.

2.3.2 표면 특징 분류(Surface feature classification)

그림 6은 화염의 표면과 사람의 옷을 보여준다.

그림 6에서 옷의 표면이 화염의 표면보다 훨씬 더 미세하고 가변적이라는 것을 쉽게 볼 수 있다. 이 속성을 기반으로 다음 방정식을 사용하여 화염 분류기를 개발할 수 있다.

$$std^I = \sqrt{1/n \left(\sum_1^{n-1} (I_R - \bar{I}) \right)} \quad (9)$$

식 (9)에서 std^I , \bar{I} , I_R 는 후보 영역 내의 이미지 픽셀의 표준 편차, 평균 및 개별 강도이다. std^I 가 실험적으로 정의된 임계값보다 큰 경우 후보 영역이 화염으로 분류된다.



그림 6. 화염과 사람 옷 객체의 표면
Fig. 6. Surface of fire and non-fire objects

2.3.3 시각적 흐름 분류(Optical flow classification)

대부분의 고체로 구성된 물체는 동시에 모든 부분이 같은 방향으로 움직이는 반면에 화염의 각 부분은 다른 방향으로 움직일 수 있다.

이 특징을 기반으로 화재 분류기를 개발하기 위해 후보 물체에 대한 모든 시각적 흐름 벡터의 각도를 계산한다. 시각적 흐름의 벡터 각도 범위가 주어진 임계값보다 크면 물체는 화염으로 분류되어 다음 계층인 CNN 분류기로 전달된다. 딥 러닝 화재 분류 모델의 구현은 다음 절에서 자세히 설명한다.



그림 7. 고체물체와 화염의 시각적 흐름
Fig. 7. Optical flow of solid object and fire object

2.4 CNN을 이용한 화재 분류를 하기 위한 딥 러닝

기계 학습 알고리즘의 딥 러닝 분야에서 [7, 8]에서 소개된 CNN (Convolutional Neural Network)은 이미지 분류에 있어서 가장 최신 기술로 간주된다. 본 논문에서는 종속 모델 화재 분류 방법의 마지막 레이어에 대한 CNN 분류기를 구현하였다. CNN의 높은 정확도는 전체 분류 모델의 신뢰성을 향상시킨다. CNN을 사용한 이미지 분류에는 학습 및 예측의 두 단계로 구성된다. 학습 단계에서는 해당 객체 유형으로 레이블이 지정된 알려진 이미지 데이터 세트를 사용하여 CNN을 학습했다. 그 후 훈련된 모델을 적용하여 새로운 이미지의 객체 유형을 예측한다.

CNN을 교육하려면 많은 양의 데이터 세트와 많은 계산량이 필요하기 때문에 다른 객체 카테고리에 대한 CNN 모델을 다시 학습할 때 어려움이 발생한다. 대신 전달 학습(transfer learning) 방법^[8]을 사용하여 이미 학습된 모델을 미세 조정(fine tune)^[9]함으로써 원래 학습된 범위 밖에서도 동작하도록 할 수 있다.

이 논문에서는 CNN 화재 분류 모델을 학습하기 위해 미세 조정 접근법을 사용했으며 상세한 접근 방식 구현은 다음과 같다.

2.4.1 모델 정의

BAIR Reference CaffeNet 모델^[10]은 Berkeley AI Research (BAIR)에 의해 개발되었으며, [7]에서 설명

한 학습된 CNN 모델이다. 이 모델은 수백만 개의 이미지와 1,000개의 객체 유형을 포함하는 Image Net Dataset^[11]에서 학습되었다. 그림 8은 CNN의 아키텍처를 보여주며, 모델의 처음 5개 레이어는 컨벌루션 레이어(convolution layer)이고, 일부는 최대 풀링 레이어(max pooling layer)가 이어진다. 다음은 완전히 세 개의 완전 연결 레이어(fully connected layer)가 이어지며, 마지막으로 각 이미지에 대해 1,000개의 객체 유형에 대한 분류 점수를 계산하는 분류 레이어(classification layer)이다. 본 논문에서는 화재 영역을 분류하기 위해서 최종 레이어를 화재 및 화재가 아닌 영역의 두 가지 객체 카테고리 만 있는 새로운 레이어로 대체했다. 이 레이어는 데이터 집합에서 역전파 미세 조정(back-propagation fine-tune) 접근법을 사용하여 처음부터 학습될 것이다.




그림 8. CNN 구조
Fig. 8. Diagram of CNN architecture

2.4.2 학습을 위한 데이터

화재 이미지 분류를 위해 CNN을 학습시키기 위해서는 학습을 위한 데이터 세트와 평가를 위한 데이터 세트를 각각 준비해야 한다. 본 논문에서 학습을 위한 데이터 세트는 10,000개의 화재 이미지와 10,000개의 화재가 아닌 이미지를 가지고 있는 반면, 평가를 위한 데이터 세트는 2,000개의 화재 이미지와 2,000개의 화재가 아닌 이미지를 사용하였다. 화재가 아닌 이미지는 차량, 사람 또는 동물과 같이 규칙적으로 움직이는 물체 또는 단순히 배경 이미지 일 수도 있다. 그림 9는 데이터 세트의 대표 이미지를 보여준다.

2.4.3 CNN의 학습

사전에 훈련된 CNN 가중치가 상대적으로 양호하고, 너무 빨리 또는 너무 많이 왜곡되지 않게 하기 위해 처음에는 미세 조정 과정에서 작은 학습율(learning rate)를 사용했다. 최적화 프로세스는 최대 50,000 번 반복 실행되었으며, 훈련된 CNN 분류기의 정확도는 98%이다.




그림 9. 불과 불이 아닌 이미지 샘플
Fig. 9. Sample of fire and non-fire images

2.5 시간적 분석(Temporal analysis)

화재와 비 화재의 결정에 대한 신뢰성을 높이기 위해 일정 기간 동안 이미지 프레임의 이력을 분석에 포함 시킨다. 예를 들어, 최신 n개의 프레임에서 화재 객체가 포함 된 프레임의 수를 nfire로 한다. 만일 nfire와 n 사이의 비율이 특정 임계값을 초과하면 화재가 발생한 것으로 판단하고 시스템에서 화재 경보를 발령해야 한다. 실험을 위해 분석 기간을 20 프레임으로 설정하고 임계 값 0.8을 사용했다.

III. 테스트 및 평가

실험을 위해서 VS2015와 오픈 소스 라이브러리 OpenCV 2.4.10, NVIDIA CUDA SDK 및 Caffe Deep Learning을 사용하였다. 또한 Intel® core™ i7-4790, 윈도우 10 및 NVIDIA GeForce GTX 750을 장착 한 컴퓨터에서 실험을 실시했다.

우리의 테스트 데이터에는 화재가 포함 된 10 개의 비디오와 화재가 아닌 객체를 포함하는 5 개의 비디오가 포함되어 있다. 그림 10은 테스트 비디오의 예제



그림 10. 테스트 비디오의 샘플 프레임(붉은 경계선 : 불, 녹색 경계선 : 불이 아닌 객체)
 Fig. 10. Sample frames from test videos(Red boundary are fire object and green boundary is non-fire object)

프레임을 보여준다. 왼쪽 위는 비디오 1이고 오른쪽 아래는 비디오 15 이다. 첫 10 개의 비디오는 화재 영상을 포함하고 나머지 5개 비디오는 화재와 비슷한 색을 갖는 움직이는 물체를 포함한다.

표 1은 테스트 결과를 보여준다. 화염의 색상과 깜빡임이 명확하기 때문에 화재로 감지하기 쉬우므로 알고리즘의 대부분이 화재 감지가 잘 이루어지는 것을 볼 수 있다. 그러나 문제는 화염과 비슷한 색의 움직이는 물체를 구분하는 것이다.

Gunawaardena^[2]는 화염 경계 픽셀의 휘도 값의 변화를 분석하였으며, 만일 이 값이 변동을 하면 화염이지만 그렇지 않으면 화염이 아닌 것으로 가정하였다. 그러나 이 가정은 물체가 직선으로 이동하는 경우에만 정확하며, 비디오 11에서와 같이 차량의 후방 등이 깜빡이거나 비디오 14와 같이 물체가 흔들거리는 경우에는 부정확하여 화재로 잘 못 감지를 한다.

Jessica Ebert^[4]에서는 움직이는 물체를 제거하기 위해 시간 분석을 사용하였다. 이 알고리즘에 따르면 컬러 맵과 깜빡임 에너지 맵에 의한 화염 픽셀을 일정 시간동안 추적하면, 실제 화염의 값은 무작위로 변한다. 그러나 붉은 벽 건물 앞에서 바람에 흔들리는 나뭇잎, 또는 노란색 또는 붉은 색의 잎이 바람에 흔들리는 것과 같은 화염이 아닌 픽셀의 값은 반복적으로 변한다.

그러나 이러한 기능은 화재를 감지하는데 매우 유용하다. 그러나 비디오 11과 같이 자동차 후방 등이 조명 효과와 함께 깜빡 거리거나, 비디오 14에서와 같이 거친 표면을 가진 물체가 흔들려서 빛 반사각을 변하게 할 때에는 픽셀 변화의 값을 예측할 수 없게 만들기 때문에 잘못된 감지를 할 수 있다.

이 알고리즘은 또한 공간적 색상 변화를 사용하지만 동영상 11의 자동차 후방 등 및 비디오 14의 표면이 거친 물체에서는 이 알고리즘이 정확하지 않다는 것을 쉽게 알 수 있다.

표 1. 실험 결과
 Table. 1. Experiment result

Video No.	Description	Fire detected/False positive			
		Gunawaardena [1]	Jessica Ebert [3]	Toreyin [5]	Our algorithm
1	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
2	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
3	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
4	In door day fire	Fire detected	Fire detected	Fire detected	Fire detected
5	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
6	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
7	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
8	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
9	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
10	Out door day fire	Fire detected	Fire detected	Fire detected	Fire detected
11	Car tail light	False detected	False detected	False detected	No fire
12	Walking human like fire	No fire	No fire	No fire	No fire
13	Walking human like fire	No fire	No fire	No fire	No fire
14	Swaying human like fire	False detected	False detected	False detected	No fire
15	Walking human like fire	No fire	No fire	No fire	No fire

B.U Toreyin^[6], 또한 화재가 아닌 객체를 제거하기 위해 시간 및 공간 변화 분석을 사용하였다. 그러나 이 알고리즘은 시간 분석을 위해 1_D 웨이블릿 변환을 사용하고 공간 분석을 위해 2_D 웨이블릿 변환을 사용하였다. 이러한 분석 방법은 다르지만 본질적인 특성은 Jessica Ebert^[4]와 동일하므로 여전히 비디오 11과 비디오 14에서 잘 못 감지를 하였다.

기존의 다른 알고리즘은 비디오 11과 비디오 14에서 불의 화염과 비슷한 동적인 특징을 가진 물체가 움직일 때 여전히 같은 문제가 있지만, 본 논문에서 제안한 알고리즘은 CNN 이미지 분류기의 높은 정확도로 이러한 문제를 쉽게 해결하였다.

또한 움직이는 물체 및 표면 특징 분류에 필요한 시간이 1ms 미만이고 시각적 흐름에 의한 분류가 약 2 ~ 3 ms가 필요했다. CUDA 하드웨어 가속기를 사용했을 때, CNN 화재 분류는 약 10 ms가 필요했으며,

다른 단계를 포함하여 이미지 프레임을 처리하는 전체 시간은 약 20ms 이므로 본 논문의 알고리즘은 실시간 응용 프로그램에 적합하다.

IV. 결 론

즉각적인 화재 경고가 화재로 인한 인명 및 재산 피해를 줄이는 자동 화재 감지는 매우 중요하다. 본 논문에서는 조기 화재 경보 시스템에 사용하기 위한 비디오 기반 화재 감지 알고리즘을 제안 하였다. 제안된 방안에서는 다중 특징 분류의 장점을 활용하기 위해 중속 모델을 사용하였으며, 이미지 분류를 위해서 딥 러닝 컨벌루션 신경망을 사용함으로써 높은 정확도로 화염을 감지하였다. 제안된 알고리즘은 기존의 방법에 비해 향상된 결과를 보였으며, 실험 결과는 실시간 감지 시스템에서 사용하기에 적합하고 빠르고 신뢰할 수 있는 알고리즘임을 보여주었다.

추후 연구로는 모델의 정확성을 향상시키기 위한 다른 특징을 인식하기 위한 연구가 진행될 계획이다. 또한 완전한 화재 경보 시스템을 개발하기 위해 청색 및 백색 불길을 감지하기 위한 모델에 대한 연구가 진행될 계획이다

References

[1] N. M. Dung and S. Ro, "Fire detection algorithm by image recognition," in *Proc. KICS Winter Conf.*, Pyeongchang, Jan. 2018.

[2] A. E. Gunawaardena, R. M. M. Ruwanthika, and A. G. B. P. Jayasekara, "Computer vision based fire alarming system," *MERCon*, pp. 325-330, Sri Lanka, Apr. 2016.

[3] G. Marbach, M. Loepfe, and T. Brupbacher, "An image processing technique for fire detection in video images," *Fire Safety J.*, vol. 41, no. 4, pp. 285-289, Jun. 2006.

[4] X. Qi and J. Ebert, "Computer vision based method for fire detection in color videos," *Int. J. Imaging and Robotics*, vol. 2, no. S09, 2009.

[5] P.-H. Huang, J.-Y. Su, and J.-S. Pan, "A fire-alarming method based on video processing," *Int. Conf. Intell. Inf. Hiding and Multimedia Sign. Process.*, pp. 359-364, 2006.

[6] B. U. Toreyin, Y. Dedeoglu, U. Gudukbay,

and A. E. Cetin, "Computer vision based method for real-time fire and flame detection," *Pattern Recognition Lett.*, vol. 27, pp. 49-58, 2006.

[7] A. Bosch, A. Zisserman, and X. Munoz, "Image classification using random forests and ferns," *Int. Conf. Computer Vision*, pp. 1-8, 2007.

[8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *INIPS*, vol. 1, pp. 1097-1105, Lake Tahoe, Nevada, Dec. 2012.

[9] Angie K. Reyes, Juan C. Caicedo, and Jorge E. Camargo, "Fine-tuning deep convolutional networks for plant recognition," *CLEF*, 2015

[10] BAIR/BVLC CaffeNet Model, https://github.com/BVLC/caffe/tree/master/models/bvlc_reference_caffenet

[11] ImageNet, <http://www.image-net.org>

뉴엔 만 등 (Nguyen Manh Dung)



2005년 7월 : Hanoi Univ. of Science and Tech. Dept. of Electronic and Telecommunication(공학사)
 2009년 2월 : 공주대학교 정보통신과(공학석사)
 2017년 3월~현재 : 공주대학교 정보통신과 박사과정

<관심분야> 영상처리, 임베디드 시스템

최 복 길 (Bokgil Choi)



1979년 2월 : 고려대학교 전기
공학과 졸업(공학사)
1983년 8월 : 고려대학교 전기
공학과 석사(공학석사)
1990년 8월 : 고려대학교 전기
공학과 박사(공학박사)
1992년 3월~현재 : 공주대학교
교수

<관심분야> 반도체 센서, 에너지 하베스팅

노 승 환 (Soonghwan Ro)



1987년 8월 : 고려대학교 전자
공학과 졸업(공학사)
1989년 8월 : 고려대학교 전자
공학과 석사(공학석사)
1993년 8월 : 고려대학교 전자
공학과 박사(공학박사)
1994년 3월~현재 : 공주대학교
교수

<관심분야> 임베디드 시스템, 영상처리, 열화상카메
라, 네트워크