

불꽃 감지를 위한 임베디드 시스템에 적합한 딥러닝 구조

Deep Learning Structure Suitable for Embedded System for Flame Detection

라 승 탁*, 이 승 호*

Seung-Tak Ra*, Seung-Ho Lee*

Abstract

In this paper, we propose a deep learning structure suitable for embedded system. The flame detection process of the proposed deep learning structure consists of four steps : flame area detection using flame color model, flame image classification using deep learning structure for flame color specialization, $N \times N$ cell separation in detected flame area, flame image classification using deep learning structure for flame shape specialization. First, only the color of the flame is extracted from the input image and then labeled to detect the flame area. Second, area of flame detected is the input of a deep learning structure specialized in flame color and is classified as flame image only if the probability of flame class at the output is greater than 75%. Third, divide the detected flame region of the images classified as flame images less than 75% in the preceding section into $N \times N$ units. Fourthly, small cells divided into $N \times N$ units are inserted into the input of a deep learning structure specialized to the shape of the flame and each cell is judged to be flame proof and classified as flame images if more than 50% of cells are classified as flame images. To verify the effectiveness of the proposed deep learning structure, we experimented with a flame database of ImageNet. Experimental results show that the proposed deep learning structure has an average resource occupancy rate of 29.86% and an 8 second fast flame detection time. The flame detection rate averaged 0.95% lower compared to the existing deep learning structure, but this was the result of light construction of the deep learning structure for application to embedded systems. Therefore, the deep learning structure for flame detection proposed in this paper has been proved suitable for the application of embedded system.

요 약

본 논문에서는 불꽃 감지를 위한 임베디드 시스템에 적합한 딥러닝 구조를 제안한다. 제안하는 딥러닝 구조의 불꽃 감지 과정은 불꽃 색깔 모델을 사용한 불꽃 영역 검출, 불꽃 색깔 특화 딥러닝 구조를 사용한 불꽃 영상 분류, 검출된 불꽃 영역의 $N \times N$ 셀 분리, 불꽃 모양 특화 딥러닝 구조를 사용한 불꽃 영상 분류 등의 4가지 과정으로 구성된다. 첫 번째로 입력 영상에서 불꽃의 색깔을 추출한 다음 레이블링하여 불꽃 영역을 검출한다. 두 번째로 검출된 불꽃 영역을 불꽃 색깔에 특화 학습된 딥러닝 구조의 입력으로 넣고, 출력단의 불꽃 클래스 확률이 75% 이상에서만 불꽃 영상으로 분류한다. 세 번째로 앞 단계에서 75% 미만 불꽃 영상으로 분류된 영상들의 검출된 불꽃 영역을 $N \times N$ 단위로 분할한다. 네 번째로 $N \times N$ 단위로 분할된 작은 셀들을 불꽃의 모양에 특화 학습된 딥러닝 구조의 입력으로 넣고, 각 셀의 불꽃 여부를 판단하여 50% 이상의 셀들이 불꽃 영상으로 분류될 경우에 불꽃 영상으로 분류한다. 제안된 딥러닝 구조의 성능을 평가하기 위하여 ImageNet의 불꽃 데이터베이스를 사용하여 실험하였다. 실험 결과, 제안하는 딥러닝 구조는 기존의 딥러닝 구조보다 평균 29.86% 낮은 리소스 점유율과 8초 빠른 불꽃 감지 시간을 나타내었다. 불꽃 검출률은 기존의 딥러닝 구조와 비교하여 평균 0.95% 낮은 결과를 나타내었으나, 이는 임베디드 시스템에 적용하기 위해 딥러닝 구조를 가볍게 구성한데서 나온 결과이다. 따라서 본 논문에서 제안하는 불꽃 감지를 위한 딥러닝 구조는 임베디드 시스템 적용에 적합함이 입증되었다.

Key words : embedded system, deep learning structure, resource occupancy rate, flame detection time, flame detection rate

* Dept. of Electronics Engineering, Hanbat National University

★ Corresponding author

E-mail : shlee@cad.hanbat.ac.kr, Tel : +82-42-821-1137

Manuscript received Mar. 7, 2019; revised Mar. 22, 2019; accepted Mar. 25, 2019

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

불꽃 감지 시스템은 화재를 조기 감지하여 진압, 피난 등을 빠르게 할 수 있는 기술로 최근 복잡한 내부의 건물들에 불꽃 감지 시스템을 보급하여 화재 발생을 조기 방지하는 추세이다. 국민안전처의 화재 통계연보에 따르면 불꽃 감지 시스템이 더욱 발전되고 보급된다면 화재의 피해가 현저히 낮아질 것으로 예상된다[1-2].

한편, 지금까지의 불꽃 감지 시스템은 고가의 장비들을 설치하여야 하거나 오작동의 빈번함 등의 문제점을 가지고 있다. 기존의 센서 기반 감지 시스템의 경우, 연기 및 온도센서 등의 설치를 통해 화재를 감지하였으나 많은 수의 센서들을 설치하여야 하기 때문에 비용적인 측면에서 문제가 있었다. 이를 보완하기 위하여 카메라의 영상만을 이용하여 영상처리를 통해 불꽃 감지를 할 수 있는 불꽃 감지 시스템들도 나왔지만, 알고리즘으로 영상을 판단하여 불꽃을 판단하여야 하는 한계 때문에 빨간 치마 등의 불꽃과 비슷한 객체도 불꽃으로 판단하는 오작동의 빈번한 문제가 있었다. 최근에는 딥러닝의 발달로 영상처리를 사용한 불꽃 감지의 오작동이 급격히 줄어들어 영상처리만으로도 거의 완벽한 불꽃 감지를 할 수 있게 되었으나, 고사양의 하드웨어 사양이 필요한 문제점이 있다[3]. 따라서 저사양의 임베디드 시스템에서도 완벽한 불꽃 감지를 할 수 있는 최적화된 딥러닝 구조의 개발이 필요한 실정이다[4]. 현재 불꽃 감지 분야에서 불꽃의 유무를 판단하기 위해 많이 사용하는 딥러닝 구조는 기본적으로 높은 하드웨어의 사양과 많은 메모리 및 연산량을 요구하여 높은 성능을 이끌어낸다.

따라서 본 논문에서는 불꽃의 색깔과 모양에 특화된 2가지의 가벼운 딥러닝 구조를 합쳐 임베디드 시스템에 적용 가능하면서 불꽃 검출률을 높인 딥러닝 구조를 제안한다.

그림 1은 본 논문에서 제안하는 딥러닝 구조의 불꽃 감지 과정을 나타내며 불꽃 색깔 모델을 사용한 불꽃 영역 검출, 불꽃 색깔 특화 딥러닝 구조를 사용한 불꽃 영상 분류, 검출된 불꽃 영역의 $N \times N$ 셀 분리, 불꽃 모양 특화 딥러닝 구조를 사용한 불꽃 영상 분류 등의 4가지 과정으로 구성된다. 불꽃 색깔 모델을 사용한 불꽃 영역 검출 과정에서는 입력 영상에서 불꽃의 색만을 추출한 다음 레이블링

하여 불꽃 영역을 검출한다. 불꽃 색깔 특화 딥러닝 구조를 사용한 불꽃 영상 분류 과정에서는 검출된 불꽃 영역을 불꽃 색깔에 특화 학습된 딥러닝 구조의 입력으로 넣고 출력단의 불꽃 클래스 확률이 75% 이상에서만 불꽃 영상으로 분류한다. 검출된 불꽃 영역의 $N \times N$ 셀 분리 과정에서는 앞 단의 75% 미만 불꽃 영상으로 분류된 영상들의 검출된 불꽃 영역을 $N \times N$ 단위로 분할한다. 불꽃 모양 특화 딥러닝 구조를 사용한 불꽃 영상 분류 고정에서는 $N \times N$ 단위로 분할된 작은 셀들을 불꽃의 모양에 특화 학습된 딥러닝 구조의 입력으로 넣고 각 셀의 불꽃 여부를 판단하여 50% 이상의 셀들이 불꽃 영상으로 분류될 경우 불꽃 영상으로 분류한다.

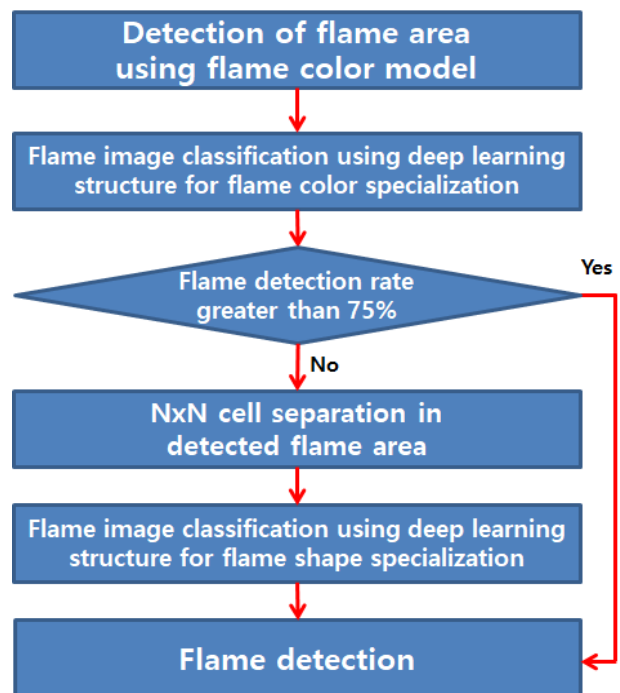


Fig. 1. The flame detection process of the proposed deep learning structure.

그림 1. 제안하는 딥러닝 구조의 불꽃 감지 과정

II. 본론

1. 불꽃 색깔 모델을 사용한 불꽃 영역 검출

불꽃 색깔 모델을 사용한 불꽃 영역 검출 과정은 입력된 영상에서 불꽃 영역을 검출하는 단계이다. 입력된 영상을 불꽃에서 발생하는 휘도와 색차를 보다 효과적으로 검출하기 위해 RGB 컬러 모델을 식(1)을 이용하여 YCbCr 컬러 모델로 변환한다. 다음으로 식 (2)를 이용해서 조도의 변화에 높은 강

인성을 보이는 불꽃 색깔 모델을 적용하여 불꽃 영역을 검출하게 되며, 그림 2는 불꽃 색깔 모델을 사용한 불꽃 영역 검출 과정을 나타내고 있다[5]. 왼쪽 영상은 입력된 불꽃 영상을, 오른쪽 영상은 τ 에 의해 다르게 검출된 불꽃 영역을 흰색으로 나타낸다. τ 는 경험적 임계값(상수)으로 이 값이 작으면 영상 안의 불꽃을 잘 감지하지만 유사 색상의 다른 개체에 대해서도 오류를 범하기 쉽다. 본 논문에서는 실험을 통해 불꽃 검출률이 가장 높았던 35로 τ 를 설정하였다.

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

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

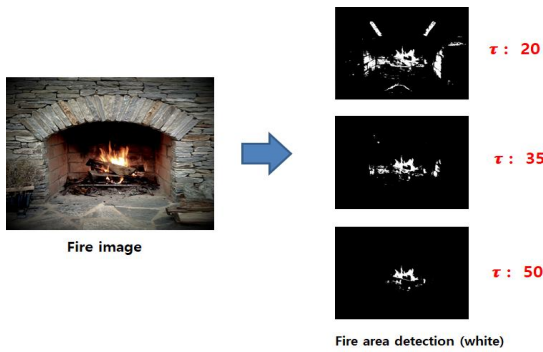


Fig. 2. Detection of flame area using flame color model.
그림 2. 불꽃 색깔 모델을 사용한 불꽃 영역 검출

한편, 불꽃 색깔 모델을 사용한 불꽃 영역 검출 영상은 레이블링 기법을 통해 더 정확하게 불꽃 영역을 검출하게 된다. 레이블링 기법이란 동일 객체에 속한 모든 픽셀에 고유한 번호는 매기는 작업으로써, 본 논문에서는 흰색의 픽셀들이 연속적으로 이어져 있는 부분을 찾게 된다. 레이블링 기법을 적용하여 불꽃 영역이 가장 많은 레이블링 영역을 선택하면 그림 3과 같이 더 정확하게 불꽃 영역을 검출하게 된다.




Fig. 3. Detection of flame area using labeling technique.
그림 3. 레이블링 기법을 적용시킨 불꽃 영역 검출

2. 불꽃 색깔 특화 딥러닝 구조를 사용한 불꽃 영상 분류

불꽃 색깔 특화용 딥러닝 구조를 사용한 불꽃 영상 분류 과정은 불꽃 색깔 모델을 통하여 검출된 불꽃 영역을 입력으로 넣고 출력단의 불꽃 클래스 확률이 75% 이상에서만 불꽃 영상으로 분류하는 단계이다. 불꽃 영역으로 검출된 이미지는 불꽃의 색깔에 특화된 이미지로 분류될 수 있으며, 불꽃 색깔 특화 딥러닝 구조의 경우 불꽃 영역으로 검출된 이미지들의 학습을 통해 형성되게 된다. 그림 4는 불꽃과 유사한 색깔의 영상에서 불꽃 색깔 모델을 사용한 불꽃 영역 검출 수행 결과를 나타내며, 불꽃 색깔 모델은 이처럼 불꽃이 아니더라도 불꽃과 유사한 색상의 경우도 검출될 수 있다. 하지만, 이와 같은 불꽃 유사 영상을 불꽃 색깔 특화 딥러닝 구조의 입력으로 넣게 되면 출력단의 불꽃 클래스 확률은 대부분 50%~75% 사이의 값이 나오게 된다. 따라서 불꽃 색깔 특화 딥러닝 구조에서 75% 미만의 확률로 불꽃 분류가 될 경우는 불꽃 영상으로 판단하지 않게 된다.




Fig. 4. Detection as a similar flame area.
그림 4. 유사 불꽃 영역으로 판단

불꽃 색깔 특화 딥러닝 구조는 기존의 CNN 구조와 같이 기본적으로 Convolution, Sub sampling, Fully-connected 및 Drop out, Softmax 연산들의 조합으로 구성되어 있다.

첫 번째인 Convolution 연산은 그림 5와 식 (3)과 같이 입력 영상 또는 이전 Layer의 특징 영상을 여러 특징 필터와 Convolution 연산하여 특징 영상을 얻어 내는 단계이다. 특징 추출 필터는 불꽃의 특징을 부각 시키는 역할을 한다. 본 논문의 CNN 학습 구조 Convolution 연산은 총 8번 수행되며 필터는 3 X 3 랜덤값 필터이고 필터 개수는 첫 번째부터 각각 8, 16, 32, 32, 64, 64, 128, 128개이다. 특징 추출 필터의 필터 계수는 처음에만 랜덤값으로 지

정되며 이후, Softmax 끝단에서부터 역전파하여 학습을 통해 불꽃 검출의 에러율이 가장 적은 최적의 필터 계수로 바뀌게 된다. 활성화 함수는 CNN에서 보편적으로 많이 쓰이는 Lelu 함수를 활용하였다.

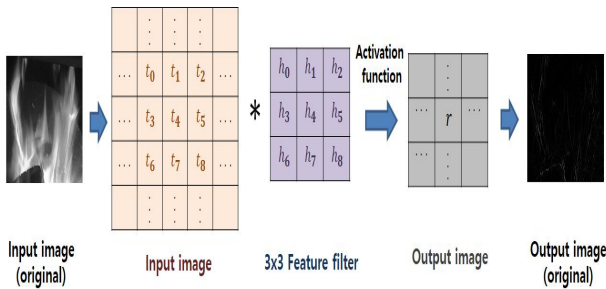


Fig. 5. Convolution operation process.

그림 5. Convolution 연산 과정

$$r = f\left(\sum_{i=0}^s (t_i \times h_i)\right) \quad (1)$$

두 번째로 Sub sampling 연산은 그림 6과 같이 Convolution 연산을 통해 추출된 특징 영상의 특징들 중에서 최적의 특징들만 선별하여 특징 영상의 크기를 감소시키는 과정이다. 즉, 추출된 특징 이미지에 불필요한 특징 데이터가 많아 최적의 특징 데이터를 추출함과 동시에 연산 속도를 높이기 위하여 크기를 축소하는 역할을 한다. 추출된 특징 이미지의 2×2 영역에서 가장 큰 값을 추출하는 max pooling을 사용하였다. 본 논문의 불꽃 색깔 특화 모델에서는 convolution 연산 다음인 No.2, 4, 7, 10, 13에서 한번씩 sub sampling 연산을 수행하였다.

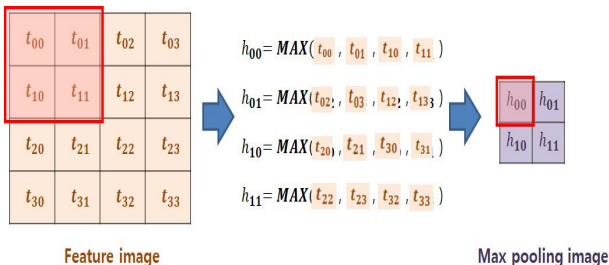


Fig. 6. Sub sampling operation process.

그림 6. Sub sampling 연산 과정

세 번째로 Fully-connected 및 Drop out 연산은 그림 7과 같이 Convolution과 Sub-sampling을 반복하여 추출된 최종 특징 데이터들을 일렬로 연결

하여 특징 벡터로 변환하는 과정이다. 즉, 13단계로 이루어진 Convolution, Sub-sampling 연산 후 모든 추출 특징을 연결하여 최종 특징 벡터를 생성하는 역할을 하게 된다. No.14는 단순히 특징 벡터를 이어 붙여서 총 3200개의 특징 벡터를 추출한다. No.15는 총 3200개의 특징 벡터에서 Drop out을 통해 일부 특징 벡터의 값을 0으로 만들어 딥러닝 학습의 Over Fitting을 줄이게 된다.




Fig. 7. Operation process of Fully-connected and Drop out layers.

그림 7. Fully-connected 및 Drop out 층의 연산 과정

네 번째로 Softmax(NN) 연산은 앞서 추출된 특징 벡터를 분류기의 입력으로 넣어 영상의 클래스를 선별하여 인식한다. Drop out까지 진행된 3200개의 특징 벡터를 신경망의 입력으로 넣고 신경망 출력층의 노드 수를 학습시키는 클래스의 수로 설정한다.

표 1과 같이 Convolution 연산은 총 8번 수행하며 필터는 3×3 랜덤값 필터이고 필터 개수는 No.1부터 각각 8, 16, 32, 32, 64, 64, 128, 128개이다. Convolution 연산 다음인 No.2, 4, 7, 10, 13에서 한번씩 Sub sampling 연산을 수행하게 되며 No.13까지 연산 후, No.14인 Fully connected 연산은 모든 추출 특징을 연결하여 최종 특징 벡터를 생성하는 역할이며, 단순히 특징 벡터를 이어 붙여서 총 3200개의 특징 벡터를 추출한다. No.15는 총 3,200개의 특징 벡터에서 Drop out을 통해 일부 특징 벡터의 값을 0으로 만들어 딥러닝 학습의 Over Fitting을 줄이게 된다. 마지막 No.16에서는 Drop out까지 진행된 3,200개의 특징 벡터를 신경망의 입력으로 넣고 신경망 출력층의 노드 수를 학습시키는 클래스의 수로 설정한다. 불꽃 검출의 경우, 학습시키는 클래스가 불꽃/비불꽃 2개 이므로 신경망 출력층 노드는 2개로 설정된다.

Table 1. Deep learning structure for flame color specialization.
표 1. 불꽃 색깔 특화 딥러닝 구조

No	Type	Filters	Size/Stride	Output
1	Conv	16	3×3 / 1	160×160
2	Max		2×2 / 2	80×80
3	Conv	32	3×3 / 1	80×80
4	Max		2×2 / 2	40×40
5	Conv	64	3×3 / 1	40×40
6	Conv	64	3×3 / 1	40×40
7	Max		2×2 / 2	20×20
8	Conv	128	3×3 / 1	20×20
9	Conv	128	3×3 / 1	20×20
10	Max		2×2 / 2	10×10
11	Conv	128	3×3 / 1	10×10
12	Conv	128	3×3 / 1	10×10
13	Max		2×2 / 2	5×5
14	FC			3200
15	Drop			3200
16	SM			

3. 검출된 불꽃 영역의 $N \times N$ 셀 분리

불꽃 색깔 특화 딥러닝 구조에서 75% 미만으로 유사 불꽃 영상으로 분류된 모든 영상은 불꽃 모양 특화 딥러닝 구조를 통해서 불꽃 영상 분류를 수행하게 된다. 이때 불꽃 모양 특화 딥러닝 구조에 입력하기 전에 $N \times N$ 셀 분리 과정을 거치게 된다. 검출된 불꽃 영역의 $N \times N$ 셀 분리 과정은 불꽃 모양 특화 딥러닝 구조의 입력으로 쓰일 불꽃 모양에 최적화된 작은 이미지를 얻기 위하여 검출된 불꽃 영역을 $N \times N$ 단위로 분할하는 단계이다. 이때 분할되는 N 값에 따라 딥러닝 구조에 입력되었을 때 결과에 많은 영향을 미치게 된다. 실험 결과 $N=3$ 이상일 경우에, 너무 작은 셀로 분할되기 때문에 딥러닝 학습이 되지 않는 문제점이 발생되었다. $N=2$ 일 경우, 최소한의 불꽃으로 판단될 수 있는 특징들이 남아있다고 판단되며, 학습이 가능하였기 때문에 본 논문에서는 본 논문에서는 $N=2$ 로 결정하였다. 2×2 로 분할된 셀들은 이후 사용되는 제안된 딥러닝 구조에 맞추어 일정한 크기로 조정되어야 한다. 불꽃 모양 특화 딥러닝 구조의 첫 Convolution 연산의 입력으로는 128×128 의 이미지

가 들어가므로 2×2 로 분할된 셀들은 모두 128×128 의 일정한 크기로 조정된다. 한편, 불꽃 모양 특화 딥러닝 구조에 입력하기 전에 $N \times N$ 셀 분리 과정을 거치는 이유는 다음과 같다. 전체 이미지와 셀 분리된 이미지는 각각의 특징이 존재한다. 전체 영상은 불꽃의 색깔 정보에 특화되어 있는 이미지로 분류될 수 있으며, 학습을 통해 불꽃 색깔 정보에 특화된 딥러닝 구조 형성이 가능하다. 셀 분리된 영상은 불꽃의 모양 정보에 특화되어 있는 이미지로 분류될 수 있으며, 학습을 통해 불꽃 모양 정보에 특화된 딥러닝 구조 형성이 가능하다. 불꽃 색깔 특화 딥러닝 구조에서 불꽃의 색깔이 다소 부족하여 불꽃 영상으로 분류되지 못한 불꽃 영상도 $N \times N$ 셀 분리 과정을 거쳐 불꽃 모양 특화 딥러닝 구조로 수행하게 되면 불꽃 영상으로 분류될 수 있다. 셀 분리를 하게 되면 불필요한 영역이 존재하는 불꽃 영상의 경우 더욱 명확하게 불꽃 영상으로 분류할 수 있게 되기 때문이다.

그림 8은 불꽃 영상으로 분류되지 못한 불꽃 영상의 2×2 셀 분리 과정을 나타낸다. 우측 영상에서 우상단 셀은 불꽃 색깔 모델을 통해 검출된 불꽃 영역에서 불필요한 영역으로 볼 수 있다. 따라서 이러한 불필요한 영역인 셀은 불꽃으로 판단되지 않게 되고 나머지 셀들은 불꽃으로 판단되어 불꽃의 색깔이 다소 부족한 불꽃 영상도 불꽃 영상으로 분류될 수 있다. 따라서 불꽃 색깔 특화 딥러닝 구조에서 75% 미만으로 유사 불꽃 영상으로 분류된 모든 영상들을 $N \times N$ 셀 분리 과정을 거쳐 불꽃 모양 특화 딥러닝 구조로 수행하게 되면 정확한 불꽃 영상 분류를 할 수 있게 된다.




Fig. 8. 2×2 cell separation process of flame image not classified as flame image.

그림 8. 불꽃 영상으로 분류되지 못한 불꽃 영상의 2×2 셀 분리 과정

4. 불꽃 모양 특화 딥러닝 구조를 사용한 불꽃 영상 분류

불꽃 모양 특화 딥러닝 구조를 사용한 불꽃 영상

분류 과정은 $N \times N$ 단위로 분할된 작은 셀들을 불꽃의 모양에 특화 학습된 딥러닝 구조의 입력으로 넣고 각 셀의 불꽃 여부를 판단하여 50% 이상의 셀들이 불꽃 영상으로 분류될 경우에 불꽃 영상으로 분류하는 단계이다. 검출된 불꽃 영역의 $N \times N$ 셀 분리 이미지들은 불꽃의 모양에 특화된 이미지로 분류될 수 있으며, 불꽃 모양 특화 딥러닝 구조의 경우 $N \times N$ 셀 분리된 이미지들의 학습을 통해 형성되게 된다.

표 2는 불꽃 모양 특화 딥러닝 구조를 나타낸다. convolution 연산은 총 5번 수행하며 필터는 3×3 랜덤값 필터이고 필터 개수는 No.1부터 각각 8, 16, 32, 64, 128개이다. 필터 개수를 불꽃 색깔 특화 딥러닝 구조보다 적게 설계한 이유는 빠른 불꽃 감지 시간의 도출을 위함이다. Convolution 연산 다음인 No.2, 4, 6, 8, 10에서 한번씩 Sub sampling 연산을 수행하고 No.10까지 연산 후, No.11인 Fully connected 연산은 모든 추출 특징을 연결하여 최종 특징 벡터를 생성하는 역할이며, 단순히 특징 벡터를 이어 붙여서 총 2,048개의 특징 벡터를 추출한다. No.12는 총 2,048개의 특징 벡터에서 Drop out을 통해 일부 특징 벡터의 값을 0으로 만들어 딥러닝 학습의 Over Fitting을 줄이게 된다. 마지막 No.13에서는 Drop out까지 진행된 2,048개의 특징 벡터를 신경망

Table 2. Deep learning structure for flame shape specialization.
표 2. 불꽃 모양 특화 딥러닝 구조

No	Type	Filters	Size/Stride	Output
1	Conv	8	$3 \times 3 / 1$	128×128
2	Max		$2 \times 2 / 2$	64×64
3	Conv	16	$3 \times 3 / 1$	64×64
4	Max		$2 \times 2 / 2$	32×32
5	Conv	32	$3 \times 3 / 1$	32×32
6	Max		$2 \times 2 / 2$	16×16
7	Conv	64	$3 \times 3 / 1$	16×16
8	Max		$2 \times 2 / 2$	8×8
9	Conv	128	$3 \times 3 / 1$	8×8
10	Max		$2 \times 2 / 2$	4×4
11	FC			2048
12	Drop			2048
13	SM			

의 입력으로 넣고 신경망 출력층의 노드 수를 학습시키는 클래스의 수인 2개로 설정한다. 불꽃 검출의 경우, 학습시키는 클래스가 불꽃/비불꽃 2개 이므로 신경망 출력층 노드는 2개로 설정된다.

그림 9는 최종적으로 분류된 불꽃 영상과 불꽃 유사 영상을 나타내고 있다.




Fig. 9. Finally classified flame image and similar flame image.
그림 9. 최종적으로 분류된 불꽃 영상과 불꽃 유사 영상

5. 실험

가. 실험 방법

실험에 사용된 임베디드 보드는 Raspberry pi3로 채택하였으며, 하드웨어 사양은 Quad Core 1.4GHz CPU, RAM 1GB, Broadcom VideoCore IV MP2 400MHz GPU 등으로 구성되어 있다. Raspbian 운영체제에서 개발도구는 python3과 Tensorflow 라이브러리를 사용하였다.

또한 ImageNet의 불꽃 데이터베이스를 대상으로 기존의 딥러닝 구조인 VGG, Inception-v3 구조와 실험하여 신뢰성을 평가하였다. ImageNet 데이터



Fig. 10. ImageNet flame database.
그림 10. ImageNet 불꽃 데이터베이스

베이스는 총 5,063장의 불꽃 형광등, 선풍 등의 이미지로 구성되며 그 중에서 70%인 3,545장은 학습에 사용하였으며, 30%인 1,518장은 실험에 사용하였다. ImageNet 불꽃 데이터베이스는 그림 10과 같이 모닥불, 난로, 장작 등의 여러 불꽃 이미지를 포함한다.

나. 실험 결과

표 3은 제안하는 딥러닝 구조와 기존의 딥러닝 구조의 리소스 점유율을 나타낸다. 제안하는 딥러닝 구조의 경우에 46.5%의 리소스 점유율이 측정되었고 VGG 구조의 경우 66.47%, Inception-v3 구조의 경우 86.25%가 측정되어서, 기존의 딥러닝 구조와 비교하여 평균 29.86% 낮은 리소스 점유율을 나타내었다.

Table 3. Comparison of resource occupancy rate.

표 3. 리소스 점유율 비교

Experimental model	Proposed deep learning structure	VGG	Inception-v3
Resource occupancy rate	46.5%	66.47%	86.25%

표 4는 제안하는 딥러닝 구조와 기존의 딥러닝 구조의 불꽃 검출률을 나타낸다. 제안하는 딥러닝 구조의 경우 98.2%의 검출률이 측정되었고 VGG 구조의 경우 98.7%, Inception-v3 구조의 경우 99.6%의 검출률이 측정되었다. 기존의 딥러닝 구조와 비교하여 평균 0.95% 낮은 결과를 나타내었으나, 이는 임베디드 시스템에 적합한 딥러닝 구조를 개발하기 위하여 기존의 딥러닝 구조보다 가볍게 구성한데서 나온 결과이다.

Table 4. Comparison of flame detection rate.

표 4. 불꽃 검출률 비교

Experimental model	proposed deep learning structure	VGG	Inception-v3
Flame detection rate	98.2%	98.7%	99.6%

표 5는 제안하는 딥러닝 구조와 기존의 딥러닝 구조의 불꽃 감지 시간을 나타낸다. 제안하는 딥러닝 구조의 경우 19.3초가 측정되었고 VGG 구조의

경우 23.4초, Inception-v3 구조의 경우 31.2초가 측정되어서, 기존의 딥러닝 구조와 비교하여 평균 8초 빠른 불꽃 감지 시간을 나타내었다.

Table 5. Comparison of flame detection time(sec).

표 5. 불꽃 감지 시간 비교(초)

Experimental model	Proposed deep learning structure	VGG	Inception-v3
Flame detection time	19.3	23.4	31.2

III. 결론

본 논문에서는 불꽃의 색깔과 모양에 특화된 2가지의 가벼운 딥러닝 구조를 합쳐 임베디드 시스템에 적용 가능하면서 효과적인 불꽃 검출률을 보이는 딥러닝 구조를 제안하였다. 제안된 딥러닝 구조의 효용성을 입증하기 위하여 ImageNet의 불꽃 데이터베이스를 사용하여 실험하였다. 실험 결과, 제안하는 딥러닝 구조는 기존의 딥러닝 구조보다 평균 29.86% 낮은 리소스 점유율과 8초 빠른 불꽃 감지 시간을 나타내었다. 불꽃 검출률은 기존의 딥러닝 구조와 비교하여 평균 0.95% 낮은 결과를 나타내었으나, 이는 임베디드 시스템에 적용하기 위해 딥러닝 구조를 가볍게 구성한데서 나온 결과이다.

향후 연구 방향으로 임베디드 시스템에 적용 가능한 빠른 불꽃 검출 시간과 불꽃 검출률의 향상을 위한 딥러닝 구조 개선에 대한 연구가 필요하다고 사료된다.

References

[1] Su, Kuo L. "Automatic fire detection system using adaptive fusion algorithm for fire fighting robot," *Systems, Man and Cybernetics, 2006. SMC'06. IEEE International Conference on*. Vol. 2. 2006.

[2] H. J. Kim, J. K. Ryu, et al. "A Study on Flame Detection using Faster R-CNN and Image Augmentation Techniques," *j.inst.Korean.electr.electron.eng*, Vol. 22, No. 4, pp 1079-1087, 2018. DOI: 10.7471/ikeee.2018.22.4.1079

- [3] Muhammad, Khan, et al. "Convolutional Neural Networks Based Fire Detection in Surveillance Videos," *IEEE Access* 6, pp. 18174–18183, 2018. DOI: 10.1109/ACCESS.2018.2812835
- [4] H. Y. Lee, S. H. Lee, "A Study On Memory Optimization for Applying Deep Learning to PC," *j.inst.Korean.electr.electron.eng*, vol. 21, no. 2, pp 136–141, 2017. DOI: 10.7471/ikeee.2017.21.2.136
- [5] Celik, Turgay, and Hasan Demirel. "Fire detection in video sequences using a generic color model," *Fire Safety Journal*, Vol. 44, NO. 2, pp. 147–158, 2009. DOI: 10.1016/j.firesaf.2008.05.005

BIOGRAPHY

Seung-Tak Ra (Member)



2017 : BS degree in Electronics & Control Engineering, Hanbat National University.
 2019 : MS degree in Electronics Engineering, Hanbat National University.

Seung-Ho Lee (Member)



1986 : BS degree in lectronic Engineering, Hanyang University.
 1989 : MS degree in Electronic Engineering, Hanyang University.
 1994 : Ph. D degree Electronic Engineering, Hanyang University.

1994~current : Professor, Department of Electronics & Control Engineering, Hanbat National University.