

RGB Image Based U-Net Learning Representation for Efficient Flame Segmentation

Jong-Hyun Kim*

*Associate Professor, College of Software and Convergence (Dept. of Design Technology), Inha University, Incheon, Korea

[Abstract]

This paper proposes a method for efficiently detecting flame regions by extracting color-based features from RGB images and applying segmentation training using a U-Net architecture. The goal of the proposed approach is to accurately identify flame regions commonly observed in fire scenes. To achieve this, the fire images are preprocessed through smoke removal and color correction, followed by a reflection removal step to eliminate surrounding reflections caused by light. The segmented flame regions are then used to train a U-Net model, enabling stable flame segmentation in other fire images as well. Since the proposed method relies solely on RGB color features, it is lightweight in computation, allowing for efficient and reliable detection of flame regions. This makes it highly applicable across various device environments and market settings.

▶ **Key words:** Flame segmentation, U-Net, Fire detection, Flame region, Reflection removal, Fog removal, Learning representation, RGB image

[요 약]

본 논문에서는 RGB 이미지에서 색상 기반의 특징을 추출하고 U-Net 기반의 세분화 학습을 통해 화염 영역을 효율적으로 찾는 방법을 제안한다. 제안하는 방법에서는 화재 현장에서 일반적으로 나타나는 화염 영역을 찾는 것을 목표로 한다. 이를 위해 화재 이미지에서 연기 제거 및 색상 보정을 통해 이미지를 전처리하고, 반사 제거 과정을 추가하여 빛으로 인한 주변 반사 특징을 제거한다. 또한, 제안된 방법을 통해 화염 영역 이미지를 U-Net으로 학습시켜 다른 화재 이미지에서도 불 영역을 안정적으로 세분화한다. 제안된 방법은 영상의 RGB 색상만을 활용하여 특징을 계산하기 때문에 연산이 가벼워 효율적이고 안정적으로 화염 영역을 선별할 수 있으며, 다양한 디바이스 환경 및 시장에서 활용 가능성이 높다.

▶ **주제어:** 화염 세분화, U-Net, 불 감지, 화염 영역, 반사제거, 안개제거, 학습 표현, RGB 이미지

• First Author: Jong-Hyun Kim, Corresponding Author: Jong-Hyun Kim
*Jong-Hyun Kim (jonghyunkim@inha.ac.kr), College of Software and Convergence (Dept. of Design Technology), Inha University
• Received: 2025. 02. 17, Revised: 2025. 04. 14, Accepted: 2025. 04. 14.

I. Introduction

화재에도 골든타임이 존재한다. 화재가 발생하고 처음 '5분'을 골든타임이라 부르는데, 5분이 지나면 완전 연소 단계로 접어들어 인명 피해의 경우 2배 이상, 재산 피해의 경우 3배 이상의 더 큰 피해가 발생한다. 즉, 화재가 발생할 경우 인명 및 재산 피해를 최소화하기 위해 골든타임 내에 화재를 진압해야 한다[1]. 대부분의 연구실 및 건물에서는 온도 감지 센서를 기반으로 화재를 인식하고 일정 값 이상의 온도가 일정 기간 지속될 때 화재를 인식하는 온도 기반의 화재 진압 시스템을 사용하고 있다.

하지만 센서에 의존한 화재 감지 시스템은 실내 면적이 넓거나 천장이 높은 곳에서는 감지 시간이 지연될 수밖에 없는 한계가 있다. 결국 화재 감지 시스템이 해결해야 할 가장 큰 과제는 화재의 정확한 신속한 감지이다. 반면에 영상 기반의 화재 감지는 센서 기반의 화재 감지에서 발생하는 다양한 문제를 해결할 수 있는 장점이 있고, 기존의 CCTV를 사용할 수 있어 비용을 최소화할 수 있다.

일부 지역은 산불 및 기타 유사한 재난과 같은 재앙에 특히 취약하다[2-6]. 딥 뉴럴 네트워크(Deep Neural Networks)는 산불 감지를 위한 일반적인 도구가 되었다. 최신 머신 러닝 방법에는 YOLO와 같은 네트워크를 사용한 산불 감지 또는 U-Net 또는 DeepLab과 같은 아키텍처를 사용한 시맨틱 세분화(Semantic segmentation)를 사용하는 방법이 있다. 하지만, 계산량이 크고 알고리즘을 경량화하기에는 많은 데이터셋과 학습시간을 요구한다. 본 논문에서는 오직 화재 RGB영상만으로 부터 연무를 제거하고 영상을 전처리과정을 거친 후, 기존의 화재 영역 추출 기법으로 U-Net을 활용하여 좀 더 정밀하게 감지하는 기법을 제안한다.

화재는 중요한 동시에 위험한 재질이다. 통제되지 않은 화재의 경우, 불길의 위치와 추세를 신속하게 파악하는 것은 소방관이 화재를 진압하는 데 큰 도움이 된다. 화염 세분화는 복잡한 환경에서 화재를 안정적으로 식별할 수 있는 기술이다. 이 기술은 소방 로봇의 환경 인식 능력을 향상시켜 소방관이 위험한 작업을 대신 수행하게 할 수도 있다.

현재 딥러닝 기술은 화재 감지에 널리 사용되고 있다. Ganesh et al.[7]은 비디오나 이미지에서 화염을 분할할 수 있는 슈퍼 픽셀 분할과 결합된 딥러닝의 기본 프레임워크를 제시한다. Yin et al.[8]은 동영상에서 먼 거리의 연기를 식별하고 감지하기 위해 RNN 네트워크를 적용하여 기존 표준보다 향상된 성능을 달성할 수 있다.

화염 픽셀의 분할은 화재 감지 시스템에서 가장 중요한 첫 번째 단계로, 후속 처리의 효율성과 정확성을 직접적으로 결정한다[9]. 또한 시맨틱 분할은 완전 합성곱 네트워크(FCN, Fully Convolutional Networks)[10]이 제안된 이후 딥러닝 분야에서 주목받는 분야 중 하나로, 지금까지 많은 우수한 네트워크 아키텍처가 제안되고 있다 [7,11-13]. 이미지 분할은 지능형 컴퓨터 비전의 중요한 부분으로, 자동 운전, 고장 진단, AR 모델링 및 지능형 로봇 내비게이션에서 중요한 연구 의의를 가지고 있다.

본 논문의 목표는 오직 RGB 이미지로 화재의 화염을 세분화하는 것이다. 그러나 일반적으로 사용하는 시맨틱 분할 방식으로 화염을 세분화하는 데는 어려움이 있다. 긴급한 상황인 만큼 모델의 효율성과 정확성을 동시에 보장하는 것이다. 화재 현장은 화염, 연기 및 기타 불확실한 요소들로 인해 복잡할 수 있다. Fig. 1에서 볼 수 있듯이 RGB 정보는 더 많은 세부 정보를 보존할 수 있지만 환경 간섭에 취약하다. 본 논문에서는 3C 알고리즘과 RGB 기반 U-Net 모델을 활용하여 화염 세분화를 검출하는 효율적인 시스템을 제안한다.



Fig. 1. The flames, smoke, and environmental features of a wildfire.

II. Related Work

Shelhamer et al.[10]이 제안한 완전 합성곱 네트워크(FCN)는 의미 분할 분야에서 심층 신경망 모델을 처음으로 도입했다. VGG[14] 및 GoogLeNet[15]과 같은 일부 이미지 분류 네트워크 모델의 전체 연결 계층은 컨볼루션 계층으로 대체되고 한다. 그런 다음 다운샘플링된 특징 맵을 업샘플링하여 디컨볼루션 계층(Deconvolutional layers)으로 이미지의 해상도를 복원한다. U-Net[16]은 처음에는 생체의학 영상 분할에 사용되었고, 그 구조는 다른 분야로 확장되었다. 인코더-디코더 구조는 SegNet[11]에서 처음 소개되었다. 인코더는 이미지에서 고차원 특징을 추출하고

디코더는 고차원 특징을 저차원 이미지로 매핑한다. 특징들은 인코더와 디코더 사이에서 스킵 연결을 통해 융합된다. Zhao et al.[17]의 연구에서는 서로 다른 영역의 컨텍스트 정보를 통합하여 신경망 모델의 성능을 향상시킬 수 있다는 점을 발견하고 PSPNet을 제안했다. 피라미드 풀링 모듈은 신경망 모델이 전체 정보를 얻는 능력을 향상시켜 복잡한 장면에서 분할 성능을 개선시켰다.

Chen et al.은 다양한 응용 시나리오에서 우수한 분할 결과를 달성하는 일련의 신경망 모델인 DeepLab을 제안했다[7,12,13,18]. 이 모델에서는 동일한 크기의 컨볼루션 커널로 수용 필드(Receptive field)를 확대할 수 있는 아트루스 컨볼루션(Atrous convolution)이 사용했다. 수용 필드는 세분화 네트워크의 성능을 향상시키는 데 매우 중요하다. 또한 샘플링 속도가 서로 다른 다양한 Atrous Convolution 레이어로 구성된 피라미드 구조를 제안하여, 멀티 스케일 이미지 처리를 가능하게 했다. He et al.이 제안한 APCNet[19]은 시맨틱 세분화에서 컨텍스트 벡터의 세 가지 이상적인 특징을 요약하고 이러한 특징에 기반하여 심층 컨텍스트 정보를 기반으로 한 시맨틱 세분화 방법을 제안했다. 동시에 다양한 규모의 문맥 정보를 적응적으로 구성할 수 있는 적응형 컨텍스트 모듈을 제안했다.

최근 많은 연구자들이 몇 가지 혁신적인 모델을 제안했다. 하지만 위에서 언급한 대부분의 모델은 실화상 카메라로 캡처한 RGB 영상에만 적합하다. Hazirbas et al.이 제안한 FuseNet[20]과 Sun et al.이 제안한 RFNet[21]은 RGB-D 카메라가 제공하는 RGB와 깊이 이미지를 병합한다. 다른 시맨틱 세분화 모델과 마찬가지로 인코더-디코더 아키텍처를 사용한다. 구체적으로, 두 개의 동일한 인코더가 RGB 및 깊이 이미지의 고차원 특징을 병렬로 추출하고 특징 융합 모듈을 통해 융합한다. 디코더는 융합된 특징 맵에서 해상도를 복원하여 세분화된 이미지를 얻는다.

RGB-D 기반 시맨틱 분할 모델과 유사하게, 어둡거나 안개가 낀 환경에서 분할 모델의 성능을 향상시키기 위해 RGB와 열화상을 시맨틱 분할에 사용하는 모델도 있다. MFNet[22], FuseSeg[23], RTFNet[24]이 대표적이다. RGB-T(Thermal)는 두 개의 동일한 특징 추출기가 각각 RGB와 열화상 이미지용으로 설계되었다. MFNet에서는 특징 추출을 위해 MiniInception이라는 모듈을 제안하고, 디코딩 단계에서 인코더의 입력은 스킵 연결을 통해 디코더의 해당 레이어 출력에 추가된다. 또한 RTFNet의 인코더는 ResNet을 기반으로 하며, 객체 가장자리를 정확하게 분할할 수 있는 새로운 디코더를 제안했다. FuseSeg는 DenseNet의 백본을 인코더로 사용하고, 2단계 융합 전략을 적용하여 특징 맵을 융합하여 손실된 정보를 복구한다.

III. The Proposed Scheme

1. Flame Image Collection

본 논문에서는 Kaggle에서 제공하는 불 이미지 데이터셋과 크롤링을 통해 수집한 불 이미지를 약 8,000개 수집한다. 데이터는 RGB 데이터인 컬러 이미지로, 이 이미지를 전처리하여 불 세분화 추출을 위한 마스크 이미지도 생성한다. 이렇게 수집한 이미지는 $128 \times 128 \times 3$ (높이 \times 너비 \times 채널) 크기로 일괄적으로 크기를 조절한다.

2. Detection of Flame Area with 3C Algorithm

불 세분화 추출을 위해서는 화재 현장 영상에서 연기 영역을 제외한 이미지 기반 불 영역 검출 기법에서 제안한 알고리즘을 활용한다[25]. 3C 알고리즘을 통해 이미지의 색상을 보정하고[28], 보정한 이미지에서 Dark Channel Prior 기법을 통해 안개를 제거한다[26]. 그런 다음, 이미지의 CIELAB 색 공간에서 밝기 채널과 적색 채널을 통해 불 영역을 검출한다.

2.1. Basic 3C Algorithm

3C 알고리즘[28]은 불균일한 색상 스펙트럼 분포로 인한 문제를 해결한다. 화재 현장 이미지도 적색 채널의 값이 일반적인 이미지보다 높으며, 반대 색상인 녹색 채널의 값은 매우 낮은 경우가 많다. 3C 알고리즘은 하나의 색상 채널에 포함된 정보가 거의 완전히 손실되어 기존 향상 기술이 노이즈와 색상 변화에 노출된다는 특징을 기반으로 설계되었다.




Fig. 2. Comparison results of between original image and the photo applied with the 3c algorithm : (a) original image (without 3C algorithm), (b) with 3C algorithm.

3C 알고리즘의 전처리 방법은 상대 색상 채널을 기반으로 손실된 채널을 재구성하는 방법을 제안한다. 상대 색상 픽셀에서 로컬 평균을 빼면 상대 색상 채널에 포함된 두 가지 색상(빨강-녹색 또는 파랑-노랑)에서 손실된 색상을 부분적으로 복구한다. 따라서 안개 제거 알고리즘이 잘 적용되도록 이미지의 전체적인 색상을 조정하기 위해 3C 알고리즘을 사용한다 (Fig. 2 참조).

2.2. Detection of Flame Area

본 논문에서는 Dark Channel Prior를 사용하여 안개를 제거한다[26]. 전달량 보존을 위해 가이드 필터링(Guided filtering)을 적용했다[27]. Fig. 3에서 (a)는 3c 알고리즘을 적용한 사진이고, (b)는 가이드 필터링을 사용하여 안개 제거를 마친 결과이다.




Fig. 3. The result of haze removal based on the color-corrected photo with the 3C algorithm: (a) with 3C algorithm, (b) with fog removed using Guided filtering.

안개 제거가 완료된 이미지에서 색상 채널을 분리한다. CIELAB 색 공간에서는 밝기 채널인 L^* 채널과 적색 채널인 a^* 채널, 청색 채널인 b^* 채널이 있다. 이 채널로부터 불 영역을 검출하는 조건은 Kim et al.이 제안한 방법을 개선하여 적용한다[25]. Fig. 4에서 볼 수 있듯이, 화염은 밝기와 적색 계열의 특징이 두드러지기 때문에, 본 논문에서는 L^* 과 a^* 채널을 활용하여 화염을 검출한다.




Fig. 4. Features for each channel in the CIELAB color space : (a) L^* , (b) a^* .

화염의 바깥쪽 부분은 주위의 연기보다 적색 채널의 값이 크고 동시에 더 밝다는 사실을 이용해 밝기 채널의 값(L^*), 적색 채널의 값(a^*)이 모두 임계값을 넘을 경우에 불의 바깥쪽 부분으로 판정한다 (Equation 1 참조).

$$L^* \geq \alpha, a^* \geq \beta \quad (1)$$

여기서 α 와 β 는 각각 L^* 채널과 a^* 채널의 값을 제어하기 위한 임계값으로써 본 논문에서는 각각 10으로 설정했다. 이 값이 너무 큰 경우 불에 해당하는 픽셀이 불로 인식되지 않을 수 있으며, 반대로 값이 너무 작은 경우 주위 연기까지 불로 검출될 수 있다. 본 논문에서 사용한 임계값은 이전 연구에서 사용한 임계값을 똑같이 사용한 값이

며[25], 실제로 이 값은 실험 결과를 통해 결정된 값이다. 절대적 수치는 아니지만 이 값을 통해 사용자가 원하는 화염의 영역 세분화를 제어할 수 있다.

화염의 안쪽 부분은 각 픽셀의 밝기가 임계값 이상일 경우에 불의 중심 부분이라고 판단한다 (Equation 2 참조).



Fig. 5. The result of detecting the center of the flame as the gamma value changes : (a) $\gamma=40$, (b) $\gamma=150$

$$L^* \geq \gamma \quad (2)$$

여기서 γ 는 화염의 중심부를 찾기 위한 임계값으로 본 논문에서는 40으로 설정한다. 이 값이 너무 큰 경우에는 화염의 중심부가 화염으로 검출되지 않을 수 있으며, 반대로 이 값이 너무 작은 경우에는 화염의 바깥 부분이나 연기까지 화염의 중심부로 검출될 수 있다 (Fig. 5 참조).

하지만 화염은 대부분 열과 강한 빛을 발생시키기 때문에, 연기나 주변 환경에 반사되는 특성을 가진다. 본 논문에서는 이러한 특징을 완화하기 위해 반사를 제거하는 과정을 추가한다. Kim et al.은 물리 기반 렌더링으로부터 얻어진 데이터셋을 기반으로 반사를 제거하는 방법을 제시했다[29]. 이들은 SP-Net을 사용해 예측한 앞면(Front)과 유리 효과가 있는 뒷면(Back)으로 영상을 분리한다. 여기서 유리와 같은 반사효과가 있는 뒷면을 훈련된 역추적 네트워크인 BT-Net을 이용해 유리/렌즈 효과를 제거하여 최종적으로 깔끔한 뒷면을 얻어낸다. 본 논문에서는 이 방법을 활용하여 반사효과가 포함된 화재영상에서도 화염 세분화를 추출할 수 있도록 한다.




Fig. 6. The result of image preprocessing through the reflection removal algorithm.

Fig. 6은 반사제거 알고리즘을 통해 이미지 전처리를 진행한 결과이다. 이렇게 분리해낸 뒷면 이미지, 즉 (d)와 (a)를 빼주면 (e)와 같은 결과를 만들어낸다. 불에서 발생하는 반사광을 제거하면서 좀 더 화염의 위치를 정확하게 파악된 것을 볼 수 있다.

최종적으로 앞에서 검출된 화염의 내부와 외부를 합쳐 전체 불 세분화 영역을 검출한다 (Fig. 7 참조).



Fig. 7. Comparison results of between the original image and the detection of the fire area with our method : (a) original image, (b) detection of flame area.



Fig. 8. Comparison results of between previous method(a)[25] and our method(b).

Fig. 8은 본 논문에서 제안한 방법과 이전 기법을 비교한 결과이다. Fig. 8a를 보면 알 수 있듯이 도로 환경의 화재 사진에서는 불뿐만 아니라 가로등의 불빛도 함께 검출되는 것을 볼 수 있다. 또한, 연기의 색상은 항상 불과 비슷한 색상이 아니라 짙은 회색빛이 나타나기도 한다. 화재 현장 이미지들의 색상 분포는 모두 같지 않기 때문에 불 영역이 성공적으로 검출되지 않는 이미지들도 존재한다. 이러한 문제는 학습 과정에서 마스크를 생성하고 이미지 전처리 단계가 매우 중요하다는 것을 의미한다. 본 논문에서 제시한 방법은 단순히 빛을 반사하는 부분을 제거할 수 있기 때문에 좀 더 안정적으로 화염 세분화 영역을 추출할 수 있다 (Fig. 8b 참조).

3. Solver Extension : Learning Representation

본 논문에서는 앞에서 제시한 화염 세분화 방법을 학습으로 표현하기 위해 U-Net을 이용한다[16]. U-Net은 Biomedical 분야에서 이미지 세분화를 위해 제안된 End-to-End 방식의 Fully-Convolutional Network 기반 모델이다 (Fig. 9 참조).

본 논문에서는 불 세분화 추출을 위해 약 8,213개의 이미지를 사용했으며, 이를 8,000개의 학습 데이터와 213개의 테스트 데이터로 나누었다. 이미지 전처리를 통해 생성한 마스크와 불 이미지를 사용하여 U-Net으로 학습한다.




Fig. 9. U-Net architecture[16].

본 논문에서는 인공 신경망 기반 학습 모델의 구조를 Fig. 9와 같이 구성한다. 딥러닝 모델이 과적합되기 시작하면 새로운 데이터에서 예측 성능을 신뢰하기 어려워진다. 이를 방지하기 위해 학습 중에 검증 세트에서 손실이 더 이상 감소하지 않을 때 학습을 중단하는 방법을 사용한다. 모델의 성능을 확인한 결과 훈련 데이터로는 85%의 정확도가, 테스트 데이터에서는 82%의 정확도가 측정되었다 (Fig. 10 참조).




Fig. 10. Learning results of U-Net.

IV. Experiment and Results

1. Uniqueness and Originality of This Study

본 연구는 RGB 이미지 기반으로 화염을 세분화하는 효율적인 방법을 제안함으로써 기존의 화재 감지 방식과 다음과 같은 차별성과 독창성을 가진다. 첫째, 기존의 많은 화재 감지 연구들이 RGB-D, RGB-T와 같은 복합 센서 기반의 고차원 데이터를 활용하거나 연산량이 많은 복잡한 네트워크 구조를 사용하는 반면, 본 연구는 오직 RGB 영상만을 활용하여 화염 영역을 정확히 검출할 수 있는 경량화된 화재 감지 기법을 제안하였다. 이를 통해 다양한 디바이스 환경에서 실시간 적용이 가능한 범용성과 효율성을 확보하였다.

둘째, 화재 영상의 왜곡된 색상 정보를 보정하기 위해 3C(Color Channel Compensation) 알고리즘을 적용하였으며, 이후 CIELAB 색공간의 밝기(L^*) 채널과 적색(a^*) 채널을 활용하여 화염의 외곽과 중심 영역을 정밀하게 추출하였다. 이러한 전처리 과정은 연기, 안개, 조도 변화 등 복잡한 환경 요인에 강건한 화염 검출이 가능하도록 한다는 점에서 기존 기법과의 뚜렷한 차별점을 가진다.

셋째, 물리 기반 렌더링을 활용한 반사 제거 기술(SP-Net, BT-Net)을 적용함으로써, 유리나 물체 표면에서 발생하는 빛 반사로 인한 화염 경계 왜곡 문제를 효과적으로 해결하였다. 이를 통해 실제 화재 영상에서도 보다 정밀한 화염 세분화가 가능하게 되었으며, 이는 실환경 적용에서의 실용성을 높이는 요소로 작용한다.

넷째, 제안한 전처리 기반의 화염 검출 결과를 활용하여 U-Net 기반의 학습 모델을 구성하였으며, 이는 전처리된 화염 마스크를 입력으로 사용함으로써 학습 효율성을 높이고, 테스트 데이터에서 82%의 정확도를 달성하였다. 이와 같이 본 연구는 전처리, 학습 표현, 반사 제거, 경량 모델 설계를 통합적으로 고려하여 실제 환경에서도 적용 가능한 실용적인 화염 세분화 기술을 제시하였으며, 이는 기존 연구들과 명확히 구분되는 독창적인 접근법이다.

2. Color Characteristics of the Data and Scope of Preprocessing

본 연구에서 제안한 화염 세분화 기법은 CIELAB 색공간의 밝기(L^*)와 적색 채널(a^*)의 값을 기반으로 화염 영역을 검출하기 때문에, 주로 붉은색 계열의 화염(적색, 주황색 등)에 대해 높은 성능을 보이는 특징이 있다. 실제로 RGB 이미지에서 붉은 계열의 화염은 상대적으로 강한 채널 신호를 가지며, 본 연구의 방법론이 가장 안정적으로 작동하는 조건이다.

Kaggle과 웹 크롤링을 통해 수집한 약 8,000여 개의 화재 이미지들은 대부분 실제 화재 장면을 기반으로 하며, 대다수는 붉은색 계열의 불꽃을 포함하고 있다. 이는 일반적인 야외 화재, 실내 화재, 차량 화재 등 다양한 상황을 포함하고 있으나, 푸른색 또는 흰색 계열의 화염은 일부 특수 환경(예: 금속 연소, 연료 화염 등)에서만 나타나므로 본 연구의 데이터셋에는 거의 포함되지 않았다.

또한 본 논문에서는 특정 색상 계열의 화염을 의도적으로 제거하는 전처리 과정은 수행하지 않았다. 다만, 3C 알고리즘과 안개 제거(DCP, Guided Filter), 반사 제거(SP-Net, BT-Net) 등의 전처리는 전체적인 영상 품질 향상과 노이즈 감소를 위한 것으로, 색상에 따른 선택적 제거는 이루어지지 않았다.

따라서 본 연구는 일반적인 RGB 화재 영상에서 자주 등장하는 전형적인 붉은색 계열의 화염에 대해 높은 성능을 보이는 것을 목표로 하며, 색상 스펙트럼이 다른 특수 화염에 대해서는 제한이 있을 수 있다. 이에 따라 향후 연구에서는 다양한 색상의 화염을 포함하는 확장된 데이터셋을 구축하고, 채널 의존도를 줄이기 위한 다채널 특성 추출 기법 및 다중 분류 모델 도입을 통해 일반화 성능을 향상시킬 계획이다.

3. Solver Extension : Learning Representation

본 연구의 결과들을 만들기 위해 실험한 환경은 Intel Core i7-7700K CPU, 32GB RAM, Geforce GTX 1080Ti GPU가 탑재된 컴퓨터를 이용하였다.




Fig. 11. Flame segmentation with our method.

Fig. 11은 U-Net을 통해 학습하고 예측한 불 세분화 결과를 표로 나타낸 것이다. 이 표는 본 논문에서 제안한 방법을 통해 만들어졌으며, X_train은 학습에 사용된 불의 이미지이고, Y_train은 불의 이미지에 직접 전처리를 적용하여 만든 불 세분화 마스크이다. 또한 pred_Label은 학습을 통해 추론한 불의 세분화 영역이다.




Fig. 12. A comparison of flame segmentation using the previous method and our method : (a) original image, (b) Gunawaardena et al.[30], (c) Premal et al.,[31], (d) Chen et al.[13], (e) our method.

Fig. 12는 이전 기법들과 본 논문에서 제안한 방법을 비

교한 결과이다. 단순하게 화염의 특징만을 고려한 것이 아닌, 화재 현장으로부터 발생하는 연기, 반사 등을 고려했기 때문에 기존 방법보다 안정적으로 화염 영역을 찾는 결과를 보여준다 (Fig. 12e 참조).

V. Conclusion

본 논문에서는 이미지 기반 불 세분화 검출 시스템을 제안했다. 이전에는 불 이미지에서 연기를 제거하고 불을 추정하기 위해 주변 환경(배경), 색상 특성(붉거나 노란색 계열), 밝기 채널 및 적색 채널의 임계값에 의존하는 방법이 사용되었다. 또한 화재현장에서 발생할 수 있는 안개와 반사와 같은 특징을 고려하여 좀 더 안정적으로 화염을 세분화할 수 있도록 했다. 또한 제안하는 방법을 U-Net으로 학습하여 큰 계산 없이 화염을 효율적으로 표현할 수 있도록 해법을 확장했다.

그럼에도 불구하고 몇 가지 한계점이 존재한다. 실제 생활에서 불의 색상은 붉은색과 노란색뿐만 아니라 푸른빛 등 다양한 색상이 존재하지만, 제안하는 방법을 적색만을 가정한다. 물론 열화상 센서를 이용하면 되지만, 그렇게 되면 알고리즘이 복잡해지기 때문에 좀 더 효율적으로 이 문제를 해결할 수 있는 방법이 필요하다. 같은 장소에서 발생한 화재임에도 불구하고 날씨와 낮/밤에 따라서 인식이 달라질 수 있다. 밤과 낮을 일관된 색상으로 변환하고 이를 통해 일관성 있는 화염 세분화 결과가 만들어질 수 있도록 알고리즘을 확장할 필요가 있다. 향후 이 문제를 해결할 수 있도록 해법을 확장할 것이다. 또한 드론 기반 산불 감시, 스마트 시티 CCTV 연계, 산업현장 화재 조기 감지 등에서 실용화 가능하며, 향후 소방 로봇/자율 주행과의 접목 가능성도 구체화될 수 있을 거라 기대한다.

ACKNOWLEDGEMENT

The National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. RS-2023-00254695, Contribution Rate : 50%). This work was supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government(MSIT) (No.RS-2022-00155915, Artificial Intelligence Convergence Innovation Human Resources Development (Inha University), Contribution Rate : 50%)

REFERENCES

- [1] Jang, Ki-hun, Seong-Beom Cho, Yong-Sung Cho, and Seung-neo Son. "Development of fire engine travel time estimation model for securing golden time." *The Journal of The Korea Institute of Intelligent Transport Systems*, vol. 19, no. 6, pp. 1-13, 2020. DOI: 10.12815/kits.2020.19.6.1
- [2] N. Center, "Wildland fire summary and statistics annual report," Tech. rep., National Interagency 16 Coordination Center, Tech. Rep., 2017.
- [3] K. Hoover and L. A. Hanson, "Wildfire statistics," Congressional Research Service, Tech. Rep., 2021.
- [4] A. Akagic and E. Buza, "A study of rule-based flame pixel classifiers in still images," in *2022 30th Telecommunications Forum (TELFOR)*, pp. 1-4, 2022. DOI: 10.1109/TELFOR56187.2022.9983767
- [5] D. Dzidal, A. Akagic, E. Buza, A. Brdjanin, and N. Dardagan, "Forest fire detection based on color spaces combination," in *2019 11th International Conference on Electrical and Electronics Engineering (ELECO)*, pp. 595-599, 2019. DOI: 10.23919/ELECO47770.2019.8990608
- [6] A. Akagic and E. Buza, "Lw-fire: A lightweight wildfire image classification with a deep convolutional neural network," *Applied Sciences*, vol. 12, no. 5, pp. 2646, 2022. DOI: 10.3390/app12052646
- [7] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs," *IEEE transactions on pattern analysis and machine intelligence*, vol. 40, no. 4, pp. 834-848, 2018. DOI: 10.1109/TPAMI.2017.2699184
- [8] M. Yin, C. Lang, Z. Li, S. Feng, and T. Wang, "Recurrent convolutional network for video-based smoke detection," *Multimedia Tools and Applications*, vol. 78, no. 1, pp. 237-256, 2019. DOI: 10.1007/s11042-017-5561-5
- [9] T. Toulouse, L. Rossi, A. Campana, T. Celik, and M. A. Akhloufi, "Computer vision for wildfire research: An evolving image dataset for processing and analysis," *Fire Safety Journal*, vol. 92, pp. 188-194, 2017. DOI: 10.1016/j.firesaf.2017.06.012
- [10] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440, 2015. DOI: 10.1109/CVPR.2015.7298965
- [11] V. Badrinarayanan, A. Kendall, and R. Cipolla, "Segnet: A deep convolutional encoder-decoder architecture for image segmentation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 12, pp. 2481-2495, 2017. DOI: 10.1109/TPAMI.2016.2644615
- [12] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "Semantic image segmentation with deep convolutional

- nets and fully connected crfs,” *Computer Science*, no. 4, pp. 357–361, 2014. DOI: 10.48550/arXiv.1412.7062
- [13] L.-C. Chen, G. Papandreou, F. Schroff, and H. Adam, “Rethinking atrous convolution for semantic image segmentation,” *arXiv preprint arXiv:1706.05587*, 2017. DOI: 10.48550/arXiv.1706.05587
- [14] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” in *International Conference on Learning Representations*, 2015. DOI: 10.48550/arXiv.1409.1556
- [15] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9, 2015. DOI: 10.1109/CVPR.2015.7298594
- [16] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *International Conference on Medical image computing and computer-assisted intervention*, pp. 234–241, 2015. DOI: 10.48550/arXiv.1505.04597
- [17] H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, “Pyramid scene parsing network,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2881–2890, 2017. DOI: 10.1109/CVPR.2017.660
- [18] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, “Encoder-decoder with atrous separable convolution for semantic image segmentation,” in *Proceedings of the European conference on computer vision*, pp. 801–818, 2018. DOI: 10.1007/978-3-030-01234-2_49
- [19] J. He, Z. Deng, L. Zhou, Y. Wang, and Y. Qiao, “Adaptive pyramid context network for semantic segmentation,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 7519–7528, 2019. DOI: 10.1109/CVPR.2019.00770
- [20] C. Hazirbas, L. Ma, C. Domokos, and D. Cremers, “Fusenet: Incorporating depth into semantic segmentation via fusion-based cnn architecture,” in *Asian conference on computer vision*, pp. 213–228, 2016. DOI: 10.1007/978-3-319-54181-5_14
- [21] L. Sun, K. Yang, X. Hu, W. Hu, and K. Wang, “Realtime fusion network for rgb-d semantic segmentation incorporating unexpected obstacle detection for road-driving images,” *IEEE Robotics and Automation Letters*, vol. 5, no. 4, pp. 5558–5565, 2020. DOI: 10.1109/LRA.2020.3007457
- [22] Q. Ha, K. Watanabe, T. Karasawa, Y. Ushiku, and T. Harada, “Mfnet: Towards real-time semantic segmentation for autonomous vehicles with multi-spectral scenes,” in *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 5108–5115, 2017. DOI: 10.1109/IROS.2017.8206396
- [23] Y. Sun, W. Zuo, P. Yun, H. Wang, and M. Liu, “Fuseseg: Semantic segmentation of urban scenes based on rgb and thermal data fusion,” *IEEE Transactions on Automation Science and Engineering*, vol. 18, no. 3, pp. 1000–1011, 2021. DOI: 10.1109/TASE.2020.2993143
- [24] Y. Sun, W. Zuo, and M. Liu, “Rtfnnet: Rgb-thermal fusion network for semantic segmentation of urban scenes,” *IEEE Robotics and Automation Letters*, vol. 4, no. 3, pp. 2576–2583, 2019. DOI: 10.1109/LRA.2019.2904733
- [25] Kim, SeungNam, MyungJin Choi, Sun-Jeong Kim, and Chang-Hun Kim. “Image-based fire area segmentation method by removing the smoke area from the fire scene videos.” *Journal of the Korea Computer Graphics Society*, vol. 28, no. 4, pp. 23-30, 2022. DOI : 10.15701/kcgs.2022.28.4.23
- [26] He, Kaiming, Jian Sun, and Xiaoou Tang. “Single image haze removal using dark channel prior.” *IEEE transactions on pattern analysis and machine intelligence*, vol. 33, no. 12, pp. 2341-2353, 2010. DOI: 10.1109/CVPR.2009.5206515
- [27] K. He, J. Sun, and X. Tang, “Guided image filtering,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 6, pp. 1397–1409, 2012. DOI: 10.1109/TPAMI.2012.213
- [28] C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and M. Sbert, “Color channel compensation (3c): A fundamental preprocessing step for image enhancement,” *IEEE Transactions on Image Processing*, vol. 29, pp. 2653–2665, 2019. DOI: 10.1109/TIP.2019.2951304
- [29] Soomin Kim, Yuchi Huo, Sung-Eui Yoon, “Single Image Reflection Removal with Physically-Based Training Images” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 5164-5173. DOI: 10.1109/CVPR42600.2020.00521
- [30] Gunawaardena, A. E., R. M. M. Ruwanthika, and A. G. B. P. Jayasekara. “Computer vision based fire alarming system.” *2016 Moratuwa Engineering Research Conference (MERCOn)*. IEEE, 2016. DOI: 10.1109/MERCOn.2016.7480162
- [31] Vipin, V. “Image processing based forest fire detection.” *International Journal of Emerging Technology and Advanced Engineering*, pp. 87-95, 2012. DOI: 10.1109/ICCPCCT.2014.7054883

Authors



Jong-Hyun Kim received the B.A. degree in the Department of Digital Contents at Sejong University in 2008. He received M.S. and Ph.D. degrees in the Department of Computer Science and Engineering at Korea University,

in 2010 and 2016. Prof. Kim is an Associate Professor in the College of Software and Convergence (Dept. of Design Technology) in Inha University. His current research interests include fluid animation and virtual reality.