

논문 2017-54-4-7

S-FDS : 퍼지논리와 딥러닝 통합 기반의 스마트 화재감지 시스템

(S-FDS : a Smart Fire Detection System based on the
Integration of Fuzzy Logic and Deep Learning)

장 준 영*, 이 강 운*, 김 영 진*, 김 원 태**

(Jun-Yeong Jang, Kang-Woon Lee, Young-Jin Kim, and Won-Tae Kim[©])

요 약

최근 들어, 효과적인 화재감지를 위해 이중 화재센서 데이터들을 융합하는 방안들이 제안되었으나, 물 기반의 방법의 경우 적응성과 정밀도가 낮고, 퍼지추론의 경우 영상에 대한 고려 미흡으로 검출 속도와 정밀도가 떨어지는 등의 문제점들이 있다. 더불어 영상기반 딥러닝 기술들도 제안되었으나, 실제 상황에서 카메라가 없거나 카메라 영역 밖의 화재 발생에 대한 신속한 탐지가 어렵다. 이에 본 논문에서는 CNN 기반의 딥러닝 알고리즘과 온도·습도·가스·연기를 포함하는 이중 화재센서 데이터기반의 퍼지추론엔진을 결합시킨 새로운 방식의 화재 감지 시스템을 제안한다. 이로써 영상 데이터를 활용한 신속한 화재 감지와 이중 센서 데이터들을 이용한 신뢰성 있는 화재 감지가 가능해짐을 보인다. 또한, 대규모 시스템에서 컴퓨팅 파워의 지나친 서버 집중을 방지하기 위해 화재 인식 알고리즘에 분산 컴퓨팅 구조를 채택하여 확장성을 높인다. 마지막으로, NIST 화재 동역학 시뮬레이터를 이용한 화재 시뮬레이션 데이터와 화재영상을 활용하여 화재가 점진적으로 번지는 환경과 급작스럽게 폭발이 발생하는 환경에서 실험을 수행함으로써 시스템의 성능을 검증한다.

Abstract

Recently, some methods of converging heterogeneous fire sensor data have been proposed for effective fire detection, but the rule-based methods have low adaptability and accuracy, and the fuzzy inference methods suffer from detection speed and accuracy by lack of consideration for images. In addition, a few image-based deep learning methods were researched, but it was too difficult to rapidly recognize the fire event in absence of cameras or out of scope of a camera in practical situations. In this paper, we propose a novel fire detection system combining a deep learning algorithm based on CNN and fuzzy inference engine based on heterogeneous fire sensor data including temperature, humidity, gas, and smoke density. we show it is possible for the proposed system to rapidly detect fire by utilizing images and to decide fire in a reliable way by utilizing multi-sensor data. Also, we apply distributed computing architecture to fire detection algorithm in order to avoid concentration of computing power on a server and to enhance scalability as a result. Finally, we prove the performance of the system through two experiments by means of NIST's fire dynamics simulator in both cases of an explosively spreading fire and a gradually growing fire.

Keywords : fire detection, multi-sensors, fuzzy logic, deep learning, IoT

* 학생회원, 한국기술교육대학교 컴퓨터공학부(School of Computer Science and Engineering Koreatech University)

** 정회원, 한국기술교육대학교 컴퓨터공학부(School of Computer Science and Engineering Koreatech University)

© Corresponding Author(E-mail : wtkim@koreatech.ac.kr)

※ 본 연구는 미래창조과학부 정보통신기술센터 SW컴퓨팅산업원천기술개발사업의 연구비지원(R0114-16-0046)에 의해 수행되었습니다.

Received : December 7, 2016 Revised : January 7, 2017

Accepted : March 21, 2017

I. 서 론

기존의 온도, 연기 및 가스센서 기반의 독립적 화재 감지시스템은 탐지시간과 신뢰도에 있어서 골든타임을 만족시키는데 어려움이 있어, 성능을 향상시키는 방안으로 불꽃감지센서 등 새로운 디바이스를 도입하였다. 그러나, 탐지 범위가 넓은 불꽃감지센서는 큰 비용이 들며, 실내의 LED등 혹은 스파크에 반응을 하여 화재

오검출이 많이 발생한다^[1~2].

이와 같이, 기존의 화재검출 시스템에서는 고가 하드웨어 중심 다중 센서 데이터들의 단순 융합으로 인한 낮은 신뢰성 문제와 화재 탐지 영역 확장성 문제 등이 발생한다. 이러한 문제점을 해결하기 위해 각종 화재센서(온도·습도·가스·연기)와 영상데이터를 실시간 수집하고 융합하여 화재를 검출하는 인공지능엔진에 대한 연구가 필요하다. 또한, 화재검출 시스템의 신뢰성을 검증하기 위하여 정밀한 화재 시뮬레이터로부터 생성된 정밀 화재 데이터를 활용하는 방법에 대한 연구가 필요하다.

II. 관련 연구

1. 기존 화재감지 알고리즘 분석

1.1 기계학습기반 알고리즘

기존에도 기계학습을 활용한 영상기반 화재 검출 알고리즘에 관한 연구가 이루어졌다^[4~5]. Borges 등은 컬러 기반 화염 감지를 위한 확률 모델을 제안하였는데^[4] 화염 모션의 양을 분석하기 위해 shape descriptor가 아닌 잠재적인 화염 영역의 boundary roughness를 사용함으로써 기존 방법들과 유사한 검출 성능을 보이면서 처리 속도 측면에서 향상된 결과를 보였다. Ko 등은 비전 센서와 Support vector machines(SVM)을 이용한 화염 검출 알고리즘을 제안하였다^[5]. 제안된 알고리즘은 화염의 색상 정보와 움직임 정보를 분석하여 후보 화염 영역을 검출하며, 웨이블릿 계수를 이용하여 시간적 화염 모델을 만들어 SVM에 적용함으로써 최종 화염 영역을 검출한다. 이를 통해 색상 정보 및 시각적 변화 등의 휴리스틱 특성을 이용한 기존 알고리즘이 오검출을 발생시키는 문제점을 해결하였다. 이러한 컬러 모델을 적용하거나^[4], 웨이블릿 변환 등의 비전을 통한 감지 방법들^[5]는 기계학습 알고리즘을 이용하기 위해 추출한 특성이 화재의 특성을 반영하지 못하거나, 여러 프레임에 걸쳐 화재의 특징을 추출함으로써 지연시간이 발생하는 문제점이 있다. 또한 촛불이나 라이터 등과 같은 인위적인 불꽃을 화재로 오경보를 일으킬 수 있다는 단점이 있다.

1.2 딥러닝 알고리즘

딥러닝은 여러 가지 비선형 변환기법을 조합하여 다량의 유의미한 정보를 추출해내는 알고리즘의 집합으로 정의 된다^[6]. 특히, 딥러닝 알고리즘 중에 Convolution

Neural Network(CNN)는 임의의 이미지 입력에 대해 해당 이미지가 어떤 이미지인지 판별하는 분류(Classification) 모델로써, 다양한 영상처리 응용에서 사용되는 알고리즘이다^[7]. 최근에 기존 기계학습 기반 알고리즘들의 단점을 보완하여 딥러닝을 활용한 영상기반 화재인식 알고리즘이 제안되었다^[8]. 제안된 딥러닝 기반 화재인식 알고리즘은 기계학습 기반 알고리즘과 달리 학습데이터로부터 자동으로 화재의 특성들을 추출함에 따라 기존 연구에서 발생하는 문제점들을 해결한다는 장점이 있으나, 카메라의 탐지 영역을 밖에서의 화재나 화재 특성상 불꽃보다 연기, 가스 혹은 온도가 변화되는 상황에 대한 고려가 미흡하다.

1.3 퍼지추론 기반 알고리즘

기존 제안된 퍼지논리와 다중센서를 이용한 화재감지시스템의 개발 사례가 있으나^[9], 퍼지기반 화재감지시스템 연구의 경우 결정적이고, 정적인 센서데이터 소속함수를 적용함으로써 다양한 화재상황에 대한 화재발생 결정에 신뢰성이 낮아진다는 단점이 있다. 또한, 기존 화재센서(온도, 연기)에 대한 퍼지추론뿐만 아니라 최근 확산되는 영상센서를 활용하는 로직에 대한 고려가 필요하다. 영상 데이터의 경우 퍼지추론보다는 딥러닝 알고리즘의 적용이 적합하다. 퍼지추론에 의한 이미지 분류는 멤버십함수의 종류와 규칙 정의에 따라서 검출 정확성이 떨어질 수 있다^[3]. 반면, 딥러닝 알고리즘은 다량의 이미지 데이터의 학습을 통해서 화재의 특징을 자동으로 추출하므로 알고리즘 설정에 상관없이 정확성이 높다^[10]. 따라서, 영상데이터에 대한 화재 판별은 딥러닝 알고리즘을 사용하며, 딥러닝 알고리즘으로 구한 영상데이터 화재 확률과 다중센서 데이터를 퍼지추론 알고리즘의 입력으로 취하는 통합적 방안이 요구된다.

III. S-FDS 설계 및 구현

1. S-FDS 아키텍처 구조 정의

제안하는 S-FDS 아키텍처를 그림 1에 도시한다. S-FDS는 크게 IoT 게이트웨이와 화재 판단 지능 서버로 구성된다.

2. S-FDS 지원 IoT 게이트웨이

IoT 게이트웨이는 각종 센서로부터 카메라 영상, 온도, 습도, 가스 농도를 받아들인다. 특히, 화재 후보영역 검출 알고리즘을 통해 카메라 영상에서 화재 후보영역을

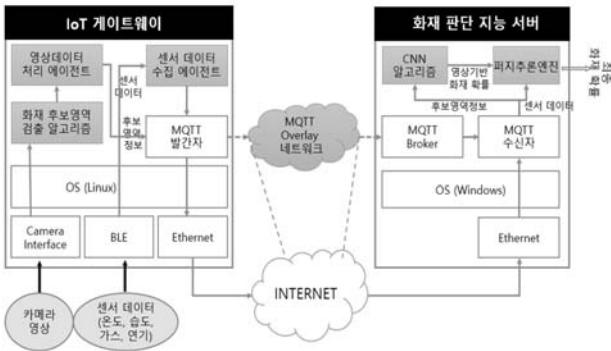


그림 1. S-FDS 아키텍처
Fig. 1. Architecture of S-FDS.

검출하여 사각영역의 리스트를 반환한다. 화재 후보 영역들과 센서 데이터를 MQTT(MQ Telemetry Transport) 메시지로 만들어서 화재 판단 지능 서버로 발행(publish)한다.

더불어, IoT 게이트웨이의 주요 역할 중 하나인 화재 후보 검출 알고리즘은 먼저 RGB 색상모델의 영상을 YCbCr 모델로 변환시킨다. 그 다음, 변환된 YCbCr 모델에서 룰 기반으로 화재 후보 영역에 대한 mask를 생성한다. 생성된 mask는 화재 후보 픽셀을 나타낸다. 마지막으로, 생성된 mask에 대해 라벨링을 하고, 라벨링된 영역을 사각형 모양의 Region of interest(ROI)로 추출한다. ROI는 화재 후보 영역으로써, 원본이미지에서 사각형의 좌표로 표현된다.

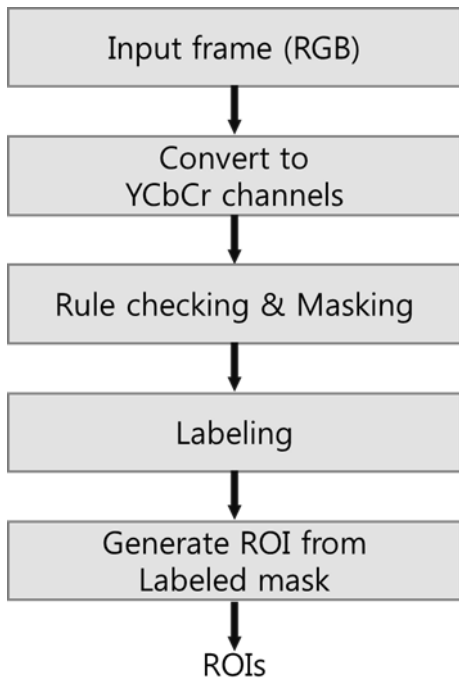


그림 2. 화재 후보 영역 검출 알고리즘 순서도
Fig. 2. Flowchart of fire candidate region detection algorithm.

3. 화재 판단 지능 서버

3.1 지능형 화재 인식 판단 로직




그림 3. 서버의 화재 인식 판단 로직 구성도
Fig. 3. Diagram of fire detection logic in server.

그림 3은 서버의 화재 인식 로직을 도시한다. 먼저, MQTT Broker를 통해 IoT 게이트웨이에서 보낸 MQTT 메시지를 받는다. 영상 데이터와 화재 후보 영역에 대한 정보는 CNN 알고리즘의 입력으로 들어가서 각 후보 영역에 대한 영상기반 화재 확률을 구한다. 최종적으로 영상기반 화재 확률과 각종 센서 데이터가 Fuzzy 알고리즘에 입력되어 최종 화재 확률을 구하게 된다.

3.2 Fuzzy 이론 기반의 화재 인식 알고리즘

(1) Fuzzification

퍼지화(Fuzzification)는 입력되는 값을 대응되는 퍼지집합(Fuzzy Set)의 원소들에 대한 소속 함수(Membership function)에 넣어서 소속도(Degrees of membership)로 변화시키는 과정이다. 소속 함수는 도메인의 지식에 의해 정해진다. 본 시스템에서는 퍼지 집합은 그림 4과 같이 입력 집합인 T(온도), H(습도), G(가스), S(연기), V(영상기반 알고리즘의 확률)와 출력집합인 F(화재 여부)를 정의하였고 대응하는 소속 함수(Membership Function)를 정의하였다.



그림 4. 퍼지추론기반 화재 검출 알고리즘의 퍼지 집합(Fuzzy Set) 정의
Fig. 4. Definition of Fuzzy set of fuzzy-inference-based fire detection algorithm.

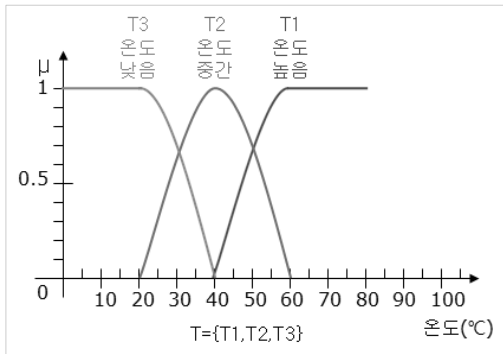


그림 5. 온도 소속 함수
 Fig. 5. Membership function of temperature.




그림 6. 습도 소속 함수
 Fig. 6. Membership function of humidity.




그림 7. 가스 소속 함수
 Fig. 7. Membership function of gas density.




그림 8. 연기 소속 함수
 Fig. 8. Membership function of smoke density.

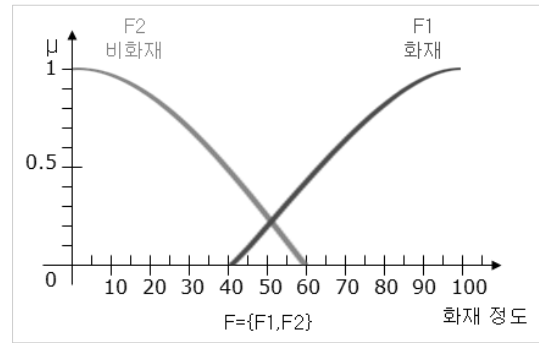


그림 9. 화재여부 소속 함수
 Fig. 9. Membership function of fire occurrence.

(2) Inference Rules

퍼지화 단계에서 얻은 각 퍼지집합에 대한 소속도 값을 이용하여 퍼지 규칙에 대한 소속도를 구하게 된다. 퍼지 규칙은 도메인에 대한 지식을 통해 정의된다. 본 시스템에서는 앞에서 정의한 퍼지집합을 기반으로 퍼지 추론 규칙을 정의하였다. 5가지의 입력 집합이 있고, 각 집합 당 3개의 원소가 있으므로 총 규칙의 수는 $3^5=243$ 개가 만들어진다.

표 1. 퍼지추론기반 화재 검출 알고리즘의 퍼지 규칙 정의 예시

Table1. Examples of Fuzzy rule definition in fuzzy-inference-based fire detection algorithm.

번호	온도	습도	가스	연기	영상기반	결과
1	낮음	낮음	낮음	낮음	낮음	비화재
2	낮음	낮음	낮음	낮음	중간	화재
3	낮음	낮음	낮음	낮음	높음	화재
...
242	높음	높음	높음	높음	중간	화재
243	높음	높음	높음	높음	높음	화재

소속함수 및 규칙을 기반으로한 퍼지 추론에서는 Mamdani의 min-max 중심법을 사용하였다.

(3) Defuzzification

역퍼지화에서는 규칙을 기반으로한 퍼지 추론의 결과로 얻어낸 각 규칙에 대한 소속도 값을 이용하여 제어 시스템에서 사용할 수 있는 단일 출력값을 구하는 과정이다. 본 시스템에서는 가장 일반적으로 사용되는 무게중심법을 이용하여 화재의 정도를 나타내는 값을 얻었다.

3.3 Deep Learning 기반 화재 인식 알고리즘

본 논문에서 사용한 CNN 알고리즘은 Berkeley Vision and Learning Center(BVLC) Reference CaffeNet^[10]을 일부 변경하여 화재 감지에 적합하도록 CNN을 구성하였다^[8]. CaffeNet의 컨볼루션 계층과 완전 연결 계층의 노드 수를 변화시키면서 성능을 테스트하였고 가장 학습 속도와 정확도에서 우수하도록 CaffeNet의 컨볼루션 계층과 완전 연결 계층의 노드 수를 1/2 감소시킨 구조를 사용하였다. CNN에서는 컨볼루션 계층과 풀링 계층이 서로 교차되어 이미지에서 여러 가지 변화(variation)에 불변인 특징들을 추출한다. 이후 연결된 3개의 Fully connected layer에서는 앞단에서 추출된 특징들을 사용하여 이미지 분류를 수행한다. CNN을 학습시키기 위해서 “fire” 혹은 “not fire”로 라벨링 된 16,529개의 이미지 학습 데이터를 이용하여 15만 번 학습을 반복하였다. 실사용 시에 이미지를 CNN에 입력으로 넣으면 그 이미지가 “fire”에 속하는 확률과 “not fire”에 속하는 확률을 얻을 수 있다.

IV. 검증 및 분석

1. 실험 환경

화재감지 알고리즘의 신뢰성 확보를 위해서는 실제 화재 관련 데이터를 확보하여 검증을 하여야 한다. 실제 화재를 일으켜서 관련 데이터를 수집하기에는 시간적, 경제적 소모의 비용이 크다. 무엇보다 똑같은 현상을 다시 구현하기에는 자연적인 변수가 많기 때문에 완전히 똑같은 현상을 다시 재현한다는 것은 불가능에 가깝다. 이러한 문제점을 해소하기 위해 화재시뮬레이션의 필요성이 대두되는데, 본 논문에서는 여러 가지 시뮬레이터 중에서 기존의 연구 사례들에서 그 활용성과 신뢰성이 입증된 미국표준기술연구소(National Standards and Technology, NIST)에서 개발한 공개 화재 시뮬레이션인 Fire Dynamics Simulator(FDS)를 사용하였다^[13]. FDS를 사용하여 화재가 발생하는 공간을 3D 모델링하였으며, 화재원의 연료 종류, 연소원의 재질 등을 설정하여 가상의 환경에서 화재를 시뮬레이션 하였다. 본 실험에서는 FDS 화재 시뮬레이션으로부터 생성되는 온도, 습도, 가스 및 연기 농도 센서 데이터와 FDS에서 시뮬레이션한 공간과 유사한 화재 영상 데이터를 사용하였다. 표 2는 FDS 시뮬레이션에서 사용된 화재원과 연료원 설정을 나타낸다.

표 2. 시뮬레이션에서 쓰인 화재원과 연료원 설정
Table2. Fire source and fuel source used in the simulation.

	연료명		화학식
	N-HEPTANE		Heptane, C_7H_{16}
	개체	성분	비고
	가스레인지 프레임	STEEL : PLASTIC [25 : 75] 비율	-
	이불 / 베개	FABRIC	이불, 베개 성분 일치, 두께는 다름
	소파	FABRIC : FOAM [20 : 80] 비율	'FOAM'은 발포 고무를 의미. 주로 매트릭스, 소파 등에 사용

실험 환경은 그림 10과 같이 복합센서모듈, IoT 게이트웨이, 서버로 구성된다. 복합센서모듈은 아두이노 Uno에 온도, 습도, 가스, 연기 센서를 연결하여 구성하였으며, 블루투스 통신을 통해 센서데이터를 IoT 게이트웨이로 전달한다. IoT 게이트웨이는 라즈베리파이3를 사용하였다. IoT 게이트웨이는 복합센서모듈과 연결하여 실제 센서 데이터를 전달할 수도 있고, FDS 센서 데이터와 연결하여 시뮬레이션 데이터를 전달할 수도 있다. 본 논문에서는 검증을 위해 실제 센서 데이터 대신에 FDS에서 생성된 센서 데이터를 사용하였다. IoT 게이트웨이와 서버간의 통신은 경량 Publish/Subscribe 메시징 프로토콜인 MQTT로 이루어진다.

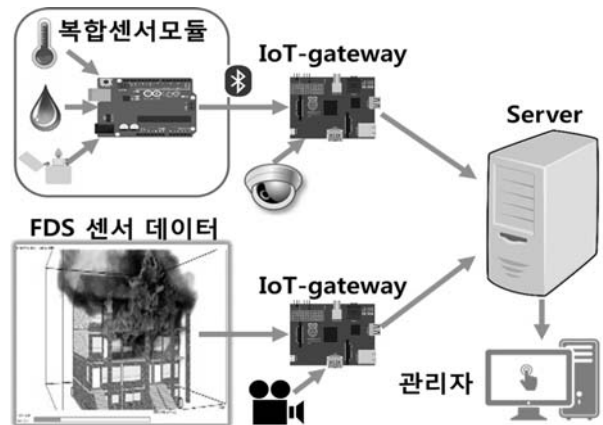


그림 10. 실험 환경 구성
Fig. 10. Configuration of experiment environment.

CNN 알고리즘을 구현하기 위해 Berkeley Vision and Learning Center(BVLC)에서 제공하는 딥러닝 프레임워크인 Caffe를 사용하였다. 화재 후보 영역 검출 알고리즘과 퍼지추론기반 화재 알고리즘은 C++언어로

작성하였다. 특히, 화재인식 알고리즘은 분산 구조로 설계함으로써 모든 화재인식 로직 중 화재 후보영역 검출 알고리즘을 각 IoT 게이트웨이에 배치하여 분산 컴퓨팅 구조를 취한다. 제안하는 알고리즘의 신뢰성을 판단하기 위해 두 가지 실험을 수행하였다. 첫 번째 실험에서는 작은 화재원에서 화재가 발생하여 점진적으로 번지는 상황을 모델링하였다. 두 번째 실험에서는 짧은 시간 내에 폭발이 일어나는 상황을 모델링하였다.

2. 실험 I

2.1 실험 환경 구축

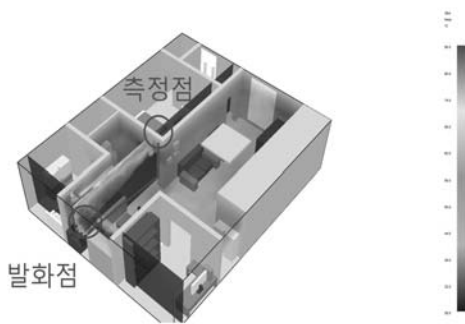


그림 11. FDS를 이용한 아파트 환경 모델링
Fig. 11. Apartment environment modeling using FDS.

실험 I은 작은 화재가 시간이 지남에 따라 큰 화재로 점진적으로 발전하는 상황을 모델링하였다. 화재 시뮬레이터 FDS를 이용하여 그림 11와 같은 아파트 환경을 만들고, 부엌에서 화재가 난 상황을 가정하였다.

FDS 시뮬레이션을 한 결과, 다음과 같이 온도, 습도, CO농도, 연기농도 그래프가 생성되었다.




그림 12. 시간에 따른 센서 데이터 변화
Fig. 12. Sensor data change over time.

실험에서 사용한 영상은 FDS에서 모델링한 환경과 유사한 영상을 YouTube에서 확보하였다^[11].



그림 13. 입력 카메라 영상
Fig. 13. Input camera video.

2.2 실험 결과 및 분석

2.1에서 제시한 실험 환경에서 제안 알고리즘의 성능을 평가하기 위해 세 가지 실험을 수행하였다.

- i) 영상 데이터 CNN 알고리즘만 적용 (CNN)
- ii) 센서 데이터 퍼지추론 기반 알고리즘만 적용 (Fuzzy)
- iii) 제안 알고리즘 (S-FDS)

시뮬레이션 결과, 시간에 따른 화재 확률은 그림 14과 같이 도출되었다.




그림 14. 화재 시뮬레이션 결과
Fig. 14. Result of fire simulation.

시뮬레이션 결과, CNN은 오직 영상만을 이용해 화재를 감지하기 때문에 화재가 일정 크기 이상으로 커진 시점부터 검출되었다. 빠르게 번지는 화재였다면 CNN을 통해서 빠른 화재 검출이 가능하다. 그러나 본 실험

에서는 작은 화재원에서 화재가 점진적으로 확산되는 상황이므로 화재가 일정 크기 이하일 경우에는 검출이 되지 않는다. 또한 카메라가 비추지 않은 영역에서 화재가 나거나 연기 때문에 화재로 식별할 수 없을 경우에도 화재 검출이 불가능하다는 단점이 있다. Fuzzy는 온도, 습도 등의 센서 데이터를 이용하기 때문에 시간에 따라 화재 확률이 완만하게 증가하는 양상을 보였다. 카메라가 비추지 않은 영역에서 불이 났을 때 Fuzzy를 통해서 효과적으로 화재를 검출할 수 있다. 그러나 센서 데이터가 서서히 증가하기 때문에 빠르게 번지는 화재이거나 센서가 화재로부터 멀리 설치된 경우에는 검출 시간이 늦어진다는 단점이 있다. S-FDS는 CNN과 Fuzzy의 장점을 결합한 결과를 도출한다. CNN의 장점을 활용하여 빠르게 번지는 화재를 영상 데이터를 통해 검출할 수 있으며, Fuzzy의 장점을 활용하여 카메라 영상이 비추지 않은 영역에서 화재가 나타라도 정확한 검출이 가능하다.

표 3. 알고리즘의 상대적인 화재 검출시간 비교
Table3. Comparison of relative fire detection time between algorithms.

평가 대상 알고리즘	기준 화재 확률 도달 상대시간
i) CNN	34,249ms
ii) Fuzzy	0ms
iii) S-FDS	0ms

표 4. 화재 상황 시 화재 확률에 대한 평균
Table4. The average of the probability of a fire in a fire situation.

평가 대상 알고리즘	평균 화재확률
i) CNN	73.27 %
ii) Fuzzy	90.60 %
iii) S-FDS	91.59 %

표 3은 각 알고리즘에서 본 논문에서 정의한 기준 화재 확률인 50%까지 도달하기까지 걸린 시간을 상대적으로 나타낸다. CNN은 다중 센서 데이터에 대한 고려 없이 화재원이 일정 크기 이상으로 확산되었을 때 화재를 검출하기 때문에 검출 시간이 길어짐을 알 수 있다. 표 4는 실제로 화재가 발생한 시점부터 각 알고리즘이 도출해내는 화재 확률의 평균을 나타낸다. CNN은 화재원이 작은 시점에는 화재로 검출하지 못하므로 가장 낮은 검출률을 보인다. 반면, Fuzzy와 S-FDS는 다중 센서에 의한 화재 검출이 가능하므로 90%가 넘는 높은 검출률을 보이며, 특히 S-FDS는 CNN의 검출 결과까

지 반영되므로 Fuzzy보다 약간 더 높은 검출률을 보인다. 따라서, 제안하는 S-FDS 알고리즘이 점진적으로 진행되는 화재 상황에서 비교 알고리즘들에 비해 신속하고 신뢰도 높은 화재 검출이 가능함을 알 수 있다.

3. 실험 II

3.1 실험 환경 구축

실험 II은 짧은 시간에 폭발이 일어나는 상황을 모델링하였다. 화재 시뮬레이터 FDS를 이용하여 그림 15과 같은 빈 방에서 배터리가 폭발되는 상황을 가정하였다. FDS 시뮬레이션을 한 결과, 그림 16과 같이 온도, 습도, CO농도, 연기농도 그래프가 생성되었다. 실험 I과 달리, 10초 이내의 짧은 시간에 센서 데이터가 급격하게 변한다.




그림 15. FDS를 이용한 폭발 환경 모델링
Fig. 15. Explosion environment modeling using FDS.




그림 16. 시간에 따른 센서 데이터 변화
Fig. 16. Sensor data change over time.

실험에서 사용한 영상은 FDS에서 모델링한 환경과 유사한 영상을 YouTube에서 확보하였다^[12].



그림 17. 입력 카메라 영상
Fig. 17. Input camera video.

3.2 실험 결과 및 분석

실험 I과 같은 방법으로 시뮬레이션 결과, 시간에 따른 화재 확률은 그림 18과 같이 도출되었다.




그림 18. 화재 시뮬레이션 결과
Fig. 18. Result of fire simulation.

폭발 상황에서는 실험 I에 비해 CNN이 Fuzzy에 비해 빠른 기준 확률 도달 시간을 보인다. 이는 센서 데이터가 상승하는 시간보다 화재 영상이 감지되는 시간이 좀 더 빠르기 때문에 영상만을 사용하는 CNN의 성능이 우수함을 알 수 있다. 더불어, 제안하는 S-FDS는 초기 기준 확률 도달시간이 가장 짧았고, 이후 안정적인 화재 감지율을 유지하는 장점이 있어 센싱 오류에 안정성을 보여주고 있다.

표 5. 알고리즘의 상대적인 화재 검출시간 비교
Table5. Comparison of relative fire detection time between algorithms.

평가 대상 알고리즘	기준 화재 확률 도달 상대시간
i) CNN	245ms
ii) Fuzzy	896ms
iii) S-FDS	0ms

표 6. 화재 상황 시 화재 확률 평균

Table6. The average of the probability of a fire in a fire situation.

평가 대상 알고리즘	평균 화재확률
i) CNN	91.73 %
ii) Fuzzy	90.75 %
iii) S-FDS	96.55 %

표 5는 각 알고리즘에서 기준 화재 확률이 50%까지 도달하기까지 걸린 시간을 상대적으로 나타낸다. CNN과 S-FDS는 영상 데이터에 의해 빠르게 화재를 검출하였지만 다중 센서 데이터만을 사용하는 Fuzzy는 열이 전도되는 시간과 가스나 연기가 확산되는 시간이 더 소요되므로 상대적으로 늦게 화재를 검출한다. 표 6은 실제로 화재가 발생한 시점부터 각 알고리즘이 도출해내는 화재 확률의 평균을 나타낸다. 폭발성 화재 상황이므로 모든 알고리즘이 90% 이상의 높은 검출률을 보였다. 특히, S-FDS는 CNN과 Fuzzy의 검출 결과가 융합되어 96% 이상의 안정적인 검출 능력을 보였다.

결과적으로, 제안하는 S-FDS 알고리즘이 폭발적인 화재 환경에서도 보다 신속하고 신뢰도 높은 화재 검출이 가능함을 알 수 있다.

V. 결 론

본 논문에서는 퍼지추론, 영상기반 딥러닝 알고리즘 및 화재 후보영역 검출 알고리즘을 통합한 알고리즘과 사물인터넷 환경을 고려한 사물인터넷 통신 미들웨어인 MQTT를 기반으로 데이터를 수집하는 스마트 화재감지 시스템인 S-FDS를 제안하였다. 화재 검출 알고리즘은 카메라 영상, 온도, 습도, 가스 및 연기 농도 데이터를 바탕으로 신뢰도 높은 화재 검출이 가능하도록 설계하였다. 제안하는 알고리즘의 신뢰성을 검증하기 위해 NIST의 화재 시뮬레이터인 FDS를 사용하여 아파트에서의 누전 등으로 인한 일반적인 화재 환경과 실험실이나 작업 현장에서의 폭발적인 화재가 발생하는 환경 시뮬레이션을 실시하였다. 그 결과, 제안 알고리즘은 기존 영상기반 CNN 및 다중 센서 기반 Fuzzy 대비 최대 34,249ms 빠른 검출 시간과 18.32% 이상의 높은 신뢰성을 보였다. 이를 통해 제안 알고리즘이 카메라가 감지하는 영역을 포함하여, 카메라 사각지대에서도 다중 센서데이터를 이용하여 신뢰도 높은 화재 검출할 수 있음을 검증하였다.

REFERENCES

- [1] B. U. Toreyin, Y. Dedeoglu, and A. E. Cetin, "Contour based smoke detection in video using wavelets," European Signal Processing Conference, pp. 1-5, Sep, 2006.
- [2] S.H. Paik, Y.W. Kim, S.H. Yang, S.I. Oh, and H.B. Park, "Flame Detection System for Fire Location Detecting," the proceeding of IEIE Summer conference, pp. 1834-1837, June 2012.
- [3] M. Sharma, R. Gupta, D. Kumar and R. Kapoor, "Efficacious approach for satellite image classification," Journal of Electrical and Electronics Engineering Research, vol. 3(8), pp. 143-150, Oct, 2011.
- [4] P. V. K. Borges and E. Izquierdo, "A probabilistic approach for vision-based fire detection in videos," IEEE Transactions on Circuits and Systems for Video Technology, vol. 20, no. 5, pp. 721-731, 2010.
- [5] B. C. Ko, K. H. Cheong, and J. Y. Nam, "Fire detection based on vision sensor and support vector machines," Fire Safety Journal, vol.44, no. 3, pp.322-329, 2009.
- [6] Y. Bengio, A. Courville, and P. Vincent, "Representation Learning: A Review and New Perspectives," IEEE Trans. PAMI, special issue Learning Deep Architectures, 2013.
- [7] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. "Gradient-based learning applied to document recognition," Proceedings of the IEEE, 1998.
- [8] Y.J Kim, E.G. Kim, "Image based Fire Detection using Convolutional Neural Network," Journal of the Korea Institute of Information and Communication Engineering, v.20, no.9, pp. 1649-1656, 2016.
- [9] S. Hong and D. Kim, "The Development of Fire Detection System Using Fuzzy Logic and Multivariate Signature," Journal of the KIIS, vol. 19, no. 1, pp. 49-55, 2004.
- [10] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks," Advances in Neural Information Processing Systems, pp. 1097-1105, 2012.
- [11] AK Fire Training & Education. "NIST Flashover. mpg," Online video. Youtube, May, 4, 2010.
- [12] "Shocking Video Of NASA's Robot Humanoid Exploding Catching Fire Robosimian," Youtube, Oct, 28, 2016.
- [13] S.Y. Mun, C.H. Hwang, J.S. Park, and K.S. Do, "Validation of FDS for Predicting the Fire Characteristics in the Multi-Compartments of Nuclear Power Plant", The Journal of Fire Science and Engineering, vol.27, no.2, pp. 31-39, 2013.

— 저 자 소 개 —



장 준 영(학생회원)
2017년 2월 한국기술교육대학교 컴퓨터공학부 공학사
<주관심분야: 인공지능, 사물인터넷>



이 강 운(학생회원)
2017년 3월 현재 한국기술교육대학교 컴퓨터공학부 재학생
<주관심분야: 사물인터넷, 모델링 & 시뮬레이션, 컴퓨터 네트워크>



김 영 진(학생회원)
2014년 7월 한국기술교육대학교 컴퓨터공학부 공학사
2016년 8월 한국기술교육대학교 컴퓨터공학부 공학석사
2016년 8월 ~ 한국기술교육대학교 컴퓨터공학부 박사과정
<주관심분야: 딥 러닝, 트리즈, 컴퓨터 하드웨어 시스템>



김 원 태(정회원)-교신저자
1994년 2월 한양대학교 전자공학과 학사 졸업
1996년 2월 한양대학교 전자공학과 석사 졸업
2000년 8월 한양대학교 전자공학과 박사 졸업
2001년 1월 ~ 2005년 2월 (주)로스텍테크놀로지 기술 이사
2005년 3월 ~ 2015년 8월 한국전자통신연구원 CPS 연구실 실장/책임연구원
2016년 9월 ~ 현재 한국기술교육대학교 컴퓨터공학부 조교수
<주관심분야: CPS, IIoT 미들웨어, 고신뢰 네트워크, 모델링&시뮬레이션>