

머신러닝 기반 화재감지용 센서 적합성 연구

임길환*, 김성렬**

Study of Machine Learning-based Fire Detection Sensor Suitability

Gil-Hwan Lim*, Sung-Ryul Kim**

이 연구는 금오공과대학교 학술연구비로 지원되었음(202103770001)

요약

본 연구에서는 화재감지기에 사용될 수 있는 다양한 센서 조합이 화재감지 성능에 미치는 영향에 분석하고자 한다. 화재/비화재 분류기 생성을 위해 화재와 일상 환경을 모사한 실제 테스트베드에서 다양한 센서를 통해 데이터를 수집하였으며 이를 이용하여 로지스틱 분류(Logistic regression) 및 K-최근접 이웃(K-Nearest neighbor), 나이브 베이즈(Naive bayes), 서포트 벡터 머신(Support vector machine), 랜덤 포레스트(Random forest) 모델을 학습하였다. 성능평가를 통해 CO, 연기, 온도 센서 및 이들의 조합이 화재감지에 우수함을 확인하였다. 또한, 주어진 데이터 세트에서 K-최근접 이웃과 랜덤 포레스트 알고리즘이 다른 머신러닝 알고리즘에 비해 높은 정확도를 보였다.

Abstract

In this study, we aim to analyze the impact of various sensor combinations that can be used in fire detectors on fire detection performance. To create a fire/non-fire classifier, data was collected through various sensors in an actual test bed that simulated fire situation and daily environments. Then we trained the logistic regression, K-nearest neighbor(KNN), naive Bayes, support vector machine(SVM), and random forest model with the training data set. The evaluation results reveals that CO, smoke, and temperature sensor and their combination are good for the fire detection. In addition, we observed that KNN and random forest algorithms outperform to the other machine learning algorithms on the given dataset.

Keywords

fire detection, unwanted alarm, machine learning, multiple sensors

* 다온(주) 기업부설연구소 선임연구원

- ORCID: <https://orcid.org/0009-0008-9968-0101>

** 금오공과대학교 컴퓨터소프트웨어공학과 조교수(교신저자)

- ORCID: <https://orcid.org/0009-0005-5218-1477>

· Received: Feb. 01, 2024, Revised: Feb. 23, 2024, Accepted: Feb. 26, 2024

· Corresponding Author: Sung-Ryul Kim

Dept. of Computer Software Engineering, Kumoh National Institute of Technology, Korea

Tel.: +82-54-478-7549, Email: sungryul@kumoh.ac.kr

I. 서 론

화재 피해를 예방하고자 다양한 정책과 기술, 시스템이 구축되고 있으나 화재로 인한 인명피해와 경제적 손실은 지속해서 발생하고 있다. 2023년 행정안전부의 보고에 따르면 화재 건수와 사망자의 수는 감소 추세이지만 여전히 화재로 인한 피해는 막대한 것으로 나타났다. 주요 원인으로는 부주의가 가장 높았으며 전기, 기계, 화학 등 산업시설에서 발생하는 화재요인도 높은 비중을 차지했다. 또한, 전체 화재 건수는 줄었지만, 아파트 화재는 오히려 늘었음을 나타내는 통계지표는 아파트 화재 방지를 위한 대책 마련과 개개인의 안전관리 강화가 필요함을 시사한다[1].

안전에 대한 국가의 행·재정적 지원이 뒷받침됨에 따라 다양한 화재 예방 시스템이 구축되고 있다. 예를 들어, 소방청은 전통시장 내 화재알림설비 감지기의 오작동을 방지하기 위한 자동보정 기능 의무화를 골자로 하는 ‘화재알림설비의 화재안전 성능기준’을 마련, 2023년 12월부터 시행한다고 밝힌 바 있다[2]. 이러한 기준마련의 근본적인 이유는 기존 화재감지기의 부정확성 때문이다. 실제로 감지기의 비화재보에 의해 발생하는 서울시 오인출동 현황은 2020년 752건으로 보고된 바 있다[3].

화재감지기는 감지 대상이나 감지 방식 따라서 크게 연기감지기, 열감지기, 불꽃감지기로 구분된다[4]. 연기감지는 우수한 범용성으로 인해 일반 가정부터 상업 시설까지 다양한 곳에서 활용되는 장점이 있으나 흡연이나 주방에서의 조리 등에서 발생하는 연기도 화재로 감지하는 단점이 있다. 열감지기는 연기감지기의 단점을 보완할 수 있지만 화재가 이미 발생한 경우에만 감지할 수 있으므로 조기 대응에 부적합하다. 불꽃감지기는 불꽃에서 발생하는 광학 특성의 변화를 통해 화재를 감지하는 기술로서 빠른 감지가 가능하나 센서 설치의 어려움 및 높은 단가로 인해 설치와 유지보수가 어렵다는 한계를 가진다.

이러한 단일센서의 한계를 극복하기 위해서 다중센서를 이용한 화재감지기 개발 연구가 진행 중이다. 연구 [5]는 다중센서를 이용하여 랙크식 물류창고 조기 화재감지의 정확도가 향상됨을 보인다. 또

한, 연기/CO/열 복합형 화재감지기와 무선 IoT통신을 결합한 IoT 멀티화재감지기를 개발하여 실제 환경에서의 화재감지 능력을 검증하였다[6].

본 연구에서는 화재감지에 사용될 수 있는 다양한 센서와 그들의 조합이 화재감지 성능에 미치는 영향을 분석하고자 한다. 이를 위해 다운(주)에서 보유한 화재 분석용 테스트베드에서 화재 및 비화재 상황을 모사하고 각 센서를 통해 데이터를 수집하였다. 상용제품의 임계값 기반 화재감지 방식의 오동작을 완화하기 위해 머신러닝을 활용하고자 수집된 데이터에 fire 열을 새롭게 추가하고 화재는 1 비화재는 0으로 표시했다. 이후 데이터 세트에 대표적인 분류 알고리즘인 로지스틱 분류(LR, Logistic Regression), K-최근접 이웃(KNN, K-Nearest Neighbor), 나이브 베이즈(NB, Naive Bayes), 서포트 벡터 머신(SVM, Support Vector Machine), 랜덤 포레스트(RF, Random Forest) 알고리즘을 적용하였다. 분석 결과는 센서의 조합과 분류 알고리즘의 종류에 따른 화재감지 성능을 제시하며 이는 복합 화재감지기 개발에 중요한 통찰력을 제공할 것으로 기대한다.

본 논문의 구성은 다음과 같다. 2장에서는 기존의 머신러닝 기반 화재감지 기술을 소개한다. 3장에서 데이터 수집을 사용한 테스트베드 및 실험환경을 소개한다. 4장에서는 수집 데이터에 머신러닝 알고리즘 적용 방법을 설명한다. 5장에서는 실험 결과를 통해 다양한 센서 조합과 알고리즘이 화재감지 정확도에 미치는 영향을 규명하고 결론 및 향후 연구를 통해 본 논문을 마무리한다.

II. 머신러닝 기반 화재감지

최근 화재감지기의 오작동 완화 및 조기감지를 위해 머신러닝을 활용한 화재감지 연구가 활발히 진행되고 있다.

연구 [7]은 스페인의 지리적 특성 및 일일 기상 데이터, 일일 화재 발생 이력 등을 이용하여 화재 발생 예측 모델을 생성하기 위해 이진 분류에서 많이 사용되는 로지스틱 분류를 사용했다. 생성한 53개 모델에 대한 성능평가 결과, 화재를 정확하게 예측한 전체 비율은 47.4%~82.6% 범위에 있는 것으로 나타났다.

여러 개의 의사결정 나무(Decision tree)의 결과를 종합해 최종적으로 예측하는 랜덤 포레스트는 과적합 문제를 회피하고 데이터의 스케일(Scale) 차이에 영향이 받지 않으므로 분류 문제에서 자주 활용된다. 연구 [8]에서는 산불 발생 확률을 로지스틱 분류와 랜덤 포레스트로 모델링하고 그들의 성능을 비교하고 있다. 성능평가 결과 랜덤 포레스트 모델이 로지스틱 모델에 비해 전반적으로 더 나은 예측 성능을 보이는 것으로 나타났다.

클래스 간의 최대 간격(Margin)을 가지는 결정 경계(Decision boundary)를 찾아내는 서포트 벡터 머신은 다양한 분야에서 폭넓게 사용되고 있다. 특히 수치 데이터뿐만 아니라 이미지나 영상과 같은 멀티미디어 데이터의 분류에도 높은 정확도를 보인다는 장점이 있으며 화재감지 연구에서도 서포트 벡터 머신을 사용한 사례가 있다[9]-[11]. 연구 [11]에서는 본 논문과 유사하게 다중센서로 일산화탄소 및 연기, 온도, 습도에 대한 데이터를 획득한 후 서포트 벡터 머신, 랜덤 포레스트, K-최근접 이웃, 인공신경망(Artificial neural network) 알고리즘을 적용한 결과를 나타내고 있다. 다만, 해당 연구는 화재 상황에 대해서만 데이터를 수집했을 뿐 조리, 담배, 수증기 등 일상생활에서 자주 발생하는 비화재보 요인을 고려하지 않았다.

한편, 서포트 벡터 머신과 랜덤 포레스트를 결합한 앙상블(Ensemble) 기법을 통해 화재감지의 정확도를 높이는 연구도 있었다. 연구 [12]는 수집한 학습 데이터로 서포트 벡터 머신, 랜덤 포레스트, 이 둘을 결합한 앙상블 모델을 각각 생성 후 성능평가를 통해 앙상블 모델이 단일 모델 대비 더 우수한 성능을 나타냄을 보였다.

훈련데이터(Training data)에 잡음이 있는 경우에도 높은 성능을 나타내는 k-최근접 이웃 알고리즘도 분류 성능이 탁월하다고 알려졌다. 연구 [13]에서는 자체 개발한 임베디드 보드로 수집한 불꽃 및 온도, 습도, 연기 데이터를 이용하여 k-최근접 이웃 알고리즘과 나이브 베이즈(Naive bayes) 알고리즘을 이용해 분류기를 만들고 분석 결과를 통해 k-최근접 이웃 알고리즘이 높은 정확도로 화재를 감지함을 증명하였다.

최근에는 딥러닝 기술을 화재감지에 적용하는 다양한 연구도 진행 중이다. 연구 [14][15]에서는 이미지 내 객체 인식의 속도를 눈부시게 발전시킨 YOLO(You Only Look Once)를 활용하여 실시간으로 기록되는 영상에서 화재를 감지하는 방법을 제시하고 있다. 비록 영상 기반 화재감지 방식은 높은 정확도와 빠른 감지의 장점이 있지만 조명 및 날씨, 환경, 각종 장애물에 의해 그 성능이 현저히 떨어질 위험이 있다. 또한, 고가의 카메라로 제한된 위치만 감시할 수 있다는 한계를 가지므로 상용성이 떨어진다.

기존 연구들은 화재감지 정확도에 초점을 맞추고 있으나 실제 화재감지기의 가장 큰 문제 중 하나인 비화재보에 대한 고려는 미미하다. 반면 본 연구에서는 이를 고려하기 위해 학습 데이터에 조리, 담배 연기, 수증기 등 일상생활에서 발생하는 비화재보 요인을 포함한 데이터 수집을 진행하였다. 여기에 화재감지 연구에서 가장 많이 소개된 머신러닝 알고리즘인 로지스틱, k-최근접 이웃, 나이브 베이즈, 서포트 벡터 머신, 랜덤 포레스트 알고리즘을 적용하여 머신러닝 기술이 기존 임계치 기반 화재감지기의 오동작 문제를 완화할 수 있는지에 대한 가능성을 검토하고자 한다.

III. 데이터 수집

3.1 복합형 센서

본 연구에서는 가용한 센서로 CO, VOC, 연기, 가스, 온도, 습도 센서를 선정했다. 해당 센서들은 표 1과 같이 측정하는 대상과 단가가 상이하다. 또한, 해당 센서는 화재감지의 목적 이외에도 다양한 제품군에 포함되어 있다.

표 1. 센서별 용도 및 단가
Table 1. Usage and price per sensor

Sensor type	Detection target	Price
CO	CO	high
VOC	Air quality	medium
SMK	Smoke	low, medium, high
GAS	Gas	medium,high
TEMP	Temperature	low
HUM	Humidity	

따라서 각 센서의 화재감지 수행 정도를 파악하면 다른 용도로 사용되는 기존 제품과 결합한 통합 솔루션을 개발할 수 있을 것으로 기대한다. 또한, 매질의 특성이나 화재 시 수집되는 환경데이터의 특성을 고려하여 더 낮은 단가의 센서로의 대체 가능 여부도 검토할 수 있다.

3.2 테스트 베드

데이터 수집은 그림 1에 보인 쥘다온 기업이 보유한 테스트베드에서 실시하였다. 안전이 확보된 실험 환경에서 다양한 매질로 화재 상황을 모사하였으며 표 2는 이를 설명하고 있다. 특히, 특별한 물리적 현상이 없는 일반적인 상황과 일상 생활에서 자주 접하는 담배 연기, 기름, 수증기가 발생하는 환경을 함께 포함하여 센서의 비화재보 여부도 함께 고려하고 있다.



그림 1. 실험 환경
Fig. 1. Experiment environment

표 2. 화재상황/비화재보 상황
Table 2. Case of fire and unwanted alarm

		Ignition medium	
Fire	Paper	Non fire	Normal
	Wood		Cooking
	Plastic		Smoking
			Vapor(Boiling)

화재는 발화기, 최성기, 감쇠기의 단계로 구분되며 그림 2는 종이의 실제 발화부터 전소까지의 과정을 보인다. 매질에 따라 전소까지 걸린 시간이 상

이하지만 모든 물질은 주어진 실험환경에서 대략 5~10분 사이에 전소되었다. 이후 기록한 발화 시점과 전소 시점을 수집된 데이터의 타임스탬프와 비교하여 실제 실험에서 측정된 데이터를 전체 데이터에서 추출하였다.



그림 2. 종이를 이용한 화재 상황 모사
Fig. 2. Simulation of fire situation using paper

본 연구에서는 데이터 수집을 위한 자체 개발한 펌웨어를 사용하였다. I2C 및 ADC를 사용하여 센서의 측정 데이터를 수집하고 임계값을 설정하여 해당 값을 초과할 경우 이벤트를 발생시킨다. 또한, 아날로그 전압을 측정하는 센서의 경우에는 칼만 필터로 값을 보정하여 센서의 정확도를 높이고 있다.

3.3 데이터 구분

수집된 데이터를 살펴보면 매우 짧은 센싱 주기로 인해 중복된 데이터가 다수 포함되어 있다. 또한, 매질에 따라 전소까지의 소요시간이 상이하므로 수집된 모든 데이터를 학습에 사용할 경우 서로 다른 표본 개수로 인한 데이터 편향(Bias) 문제가 발생할 수도 있다. 이러한 상황을 고려하여 본 연구에서는 수집된 데이터 전체를 사용하는 것이 아닌 매질이 전소될 때까지 측정된 데이터를 일정한 간격으로 나누어 총 600개의 표본을 추출했다.

학습에 사용한 최종 데이터 세트는 종이, 나무, 플라스틱, 일반, 조리, 담배, 수증기 실험에서 각각 측정한 모든 데이터를 하나로 묶은 총 4200개의 표본으로 구성하였다.

IV. 데이터 분석

4.1 센서 특성

그림 3은 종이를 이용한 화재 테스트 시 수집된 센서별 데이터를 나타낸다. 그림에서 알 수 있듯이 발화기에서는 VOC센서의 값이 두드러지나 CO센서의 값 영향력이 점차 커지는 것을 확인할 수 있다. 이는 단일센서가 아닌 복합센서를 이용할 때 화재의 전 과정에서 상호보완 역할을 수행하여 화재감지의 정확성 및 비화재보의 에러를 낮출 수 있음을 시사한다.

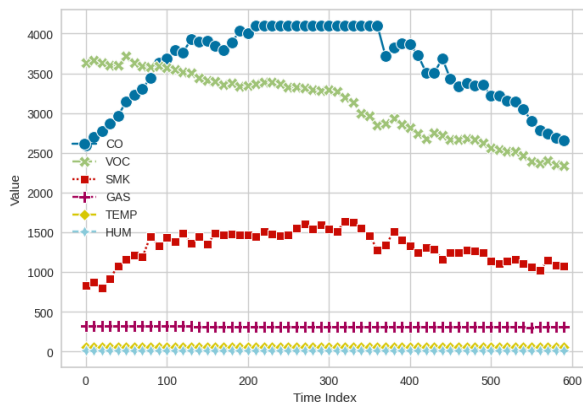


그림 3. 종이의 연소에 따른 센서값

Fig. 3. Sensor values according to paper combustion

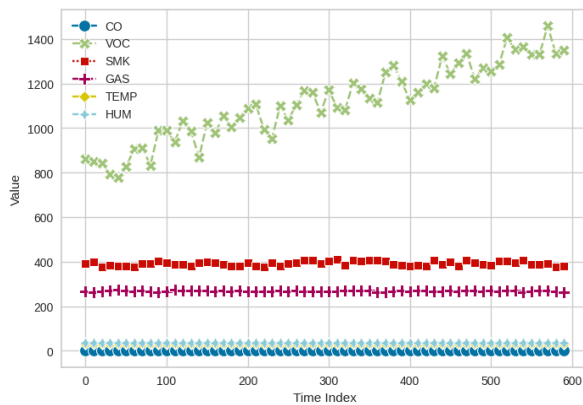


그림 4. 조리환경을 모사한 상황에서 수집된 센서값

Fig. 4. Sensor values collected in the simulation of cooking environment

그림 4는 조리환경을 모사한 상황에서 수집된 센서별 데이터를 나타낸다. 그림과 같이 조리환경은 화재 상황이 아님에도 VOC의 상승이 두드러짐이

나타난다. 이는 임계치를 이용하는 단일센서 환경에서 비화재보가 발생할 수 있음을 의미한다. 이런 경우에는 변동 폭이 거의 없는 다른 센서를 의사결정 척도에 포함하여 비화재보 문제를 완화할 수 있다.

한편, CO센서의 센서값은 오직 화재 시에만 큰 값으로 증가하는 반면 일상생활을 묘사한 실험 환경에서는 크게 변동이 없는 것을 확인할 수 있었다. 다시 말해, CO센서를 단독으로 사용하더라도 화재와 비화재를 명확히 구분할 수 있다. 화재감지를 위한 CO센서의 적용성을 연구한 결과에서도 CO센서의 우수성을 증명하고 있다[6]. 그러나 CO센서만 단독으로 사용할 경우, 일산화탄소 유출과 화재 발생에 대한 구분이 불가능하다는 치명적인 문제가 발생하므로 복합 센서의 사용이 필요하다.

4.2 머신러닝 알고리즘

사용하는 센서에 따른 화재/비화재 데이터의 분포 정도를 확인하기 위해 (TEMP와 SMK), (VOC와 GAS) 센서값에 따른 각 클래스의 분포를 각각 그림 5과 6에 표현했다. 그림 5와 6을 통해 해당 데이터는 클래스별로 균집화 정도가 높다는 것을 확인할 수 있다.

한편 사용하는 센서에 따라 그림 6과 같이 두 클래스를 선형 기준으로 구분하기 힘든 경우가 발생한다. 다시 말해, 선형성을 전제하는 로지스틱 회귀 모델이나 선형 SVM의 경우 해당 데이터에 대한 분류 성능이 낮아질 수 있다.

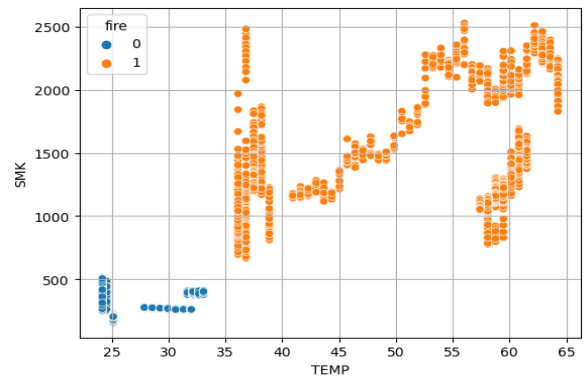


그림 5. TEMP와 SMK 센서값의 산점도 그래프

Fig. 5. Scatter graph for sensing value of TEMP and SMK sensor




그림 6. VOC와 GAS 센서값의 산점도 그래프
Fig. 6. Scatter graph for sensing value of VOC and GAS sensor

본 연구에서는 화재감지 문제에서 일반적으로 사용되는 로지스틱 분류(LR) 및 K-최근접 이웃(KNN), 나이브 베이즈(NB), 서포트 벡터 머신(SVM), 랜덤 포레스트(RF)의 분류 모델로 선정하였다. 다만, 데이터가 수집되는 환경 및 센서의 종류, 화재/비화재 발생 모사 방법, 센서와 발화점의 거리 등 각 연구에서 수집된 데이터가 서로 다르므로 모델의 절대적인 성능 지표보다는 머신러닝이 화재감지에서 활용될 수 있는지에 대한 가능성에 초점을 맞춘다.

V. 모델 분석

5.1 상관관계 분석

데이터 분석 파이프라인에서 가장 먼저 확인되어야 할 사항 중 하나는 특징(Feature) 간의 상관성 여부다. 머신러닝은 결국 서로 연관이 있는 데이터의 상관 패턴을 추출하는 작업이므로 데이터의 상관성이 떨어진다면 어떤 알고리즘을 적용해도 높은 성능을 발휘하기 어렵다. 각 센서의 측정값과 화재/비화재의 상관성을 시각적으로 파악하기 위해 변수 간 피어슨 상관계수(Pearson correlation coefficient)를 그림 7과 같이 히트맵(Heatmap)으로 표현하였다.

피어슨 계수는 변수 간 선형적 상관성이 높을수록 1이나 -1에 근접하는 특성이 지닌다. 피어슨 계수는 변수 간 선형 관계를 나타내는 지표이므로 비선형 관계에 대한 통찰력은 제공하지 못하지만, 일반적으로 화재가 발생하면 센서값이 점차 증가한다

는 사실에 기인하여 해당 분석을 수행했다. 그림과 같이 특징값과 목적(Target) 값인 fire 사이의 상관계수 절대값이 GAS를 제외하고 모두 0.5 이상이므로 센서 대부분이 화재감지 능력이 어느 정도 있음을 확인할 수 있다.

다만, 피어슨 계수가 높다는 것이 해당 특징이 학습 모델에서 반드시 가장 높은 영향력을 발휘한다는 의미는 아니다. 선형회귀의 일종인 LR에서는 선형성이 중요하지만 변수의 스케일이나 선형성에 크게 영향을 받지 않는 KNN이나 RF모델에서는 피어슨 상관계수가 낮은 데이터가 높은 데이터보다 더 높은 영향력을 발휘할 수도 있다. 참고로 GAS 센서의 경우 화재시에도 큰 변동이 없어야 하지만 화재로 발생하는 재와 소자 내부의 쇼트로 예상과 다른 데이터가 수집되었다.




그림 7. 상관관계 분석을 위한 히트맵
Fig. 7. Heatmap to analyze correlations

5.2 성능평가

모델 학습 및 성능평가는 대표적인 기계학습 프레임워크인 Scikit-learn을 통해 수행되었다. 본 연구의 목적은 모델 성능 최적화에 있지 않고 센서 조합이 화재 판별 정확도에 미치는 영향을 파악하는 것이 우선이므로 프레임워크에서 제공하는 기본값으로 각 모델 학습을 진행했다. 다만, 선형 SVM의 경우 AUC를 도출하는 데 어려움이 있으므로 가우시안 방사 기저 함수(RBF, Radial Basis Function) 커널(Kernel)을 적용하였다.

모델의 성능 지표로는 AUC(Area Under the ROC Curve), 정밀도(Precision), 재현율(Recall), F1 점수로 삼았으며 특히 화재임에도 화재가 아니라고 판단하는 거짓음성(False negative)의 발생은 심각한 결과를 초래할 수 있으므로 F1 점수를 주의 깊게 관찰해야 한다.

데이터 분석 결과 GAS센서를 제외하면 모든 수집 데이터가 화재와 비화재 상황에서 뚜렷한 차이를 보였으며 이러한 특성으로 인해 대부분의 성능 지표가 1에 도달했다. 특히 CO, SMK, TEMP 센서 센서의 우수한 분별능력으로 인해 해당 센서가 포함된 실험에서는 대부분 정확한 판별이 가능했다. 또한, 센서의 조합이 세 개 이상일 경우, 1) 분류에 우수한 특성을 가진 센서값이 데이터 세트에 포함되는 경우가 많고, 2) 여러 센서의 정보 결합으로 정확한 화재감지가 가능함을 확인하였다. 따라서 본 장에서는 단일센서를 사용한 경우와 두 개의 센서 조합을 사용한 경우의 결과에 대해 초점을 맞춘다.

표 3은 단일센서값을 사용한 모델의 성능을 나타낸다. 화재/비화재 상황에서 측정되는 값의 차이가 큰 CO, SMK, TEMP센서로 학습한 모델들의 F1은 1이었으나 VOC, HUM, GAS의 경우에는 낮은 F1 수치를 보였다. 실제로 화재가 발생하더라도 주위 습도가 급격하게 떨어지지 않는 물리적 특성이 있으므로 HUM센서만 단독으로 사용하는 화재감지기는 적절하지 않은 것으로 판단된다.

표 3. 단일센서: 센서의 종류에 따른 평균 모델 성능
Table 3. Single sensor: Average model performance according to the sensor

Feature	AUC	Recall	Prec.	F1
CO	1	1	1	1
SMK	1	1	1	1
TEMP	1	1	1	1
VOC	0.994	0.971	0.966	0.968
HUM	0.938	0.824	0.822	0.817
GAS	0.828	0.780	0.667	0.714

표 4는 각 분류 모델별 성능을 보인다. 표와 같이 F1을 기준으로 RF와 KNN 알고리즘이 높은 정확도를 보인다. 이는 비선형 데이터에도 강인한 RF와 KNN의 특성으로 인해 화재/비화재 데이터의 분포가 선형적인 결정 기준으로 분류가 어려운 환경에서도 화재/비화재를 잘 예측할 수 있는 것으로 분석된다.

표 4. 단일센서: 모델별 평균 성능

Table 4. Single sensor: Average performance of each model

Model	AUC	Recall	Prec.	F1
RF	0.979	0.946	0.926	0.934
KNN	0.974	0.932	0.938	0.933
NB	0.972	0.976	0.916	0.942
SVM	0.958	0.943	0.919	0.927
LR	0.916	0.849	0.842	0.844

단일센서가 아닌 임의로 선택된 두 개의 센서 조합으로 분류 모델을 생성할 경우, 성능지표 대부분이 1에 도달했다. 다만 단일센서 환경에서 낮은 성능을 보였던 VOC, HUM, GAS 센서가 조합에 포함될 경우 표 5와 같이 성능이 낮아짐을 알 수 있다. 비록 센서를 단독으로 사용하는 경우보다 높은 성능을 나타내지만, 여전히 해당 센서의 조합만으로는 상용 화재 탐지기 개발에 무리가 있을 것으로 판단된다.

표 5. 다중센서: 센서 조합에 따른 평균 모델 성능(하위 7개)
Table 5. Multiple sensors: Average model performance according to sensor combination(Bottom 7)

Feature	AUC	Recall	Prec.	F1
VOC,TEMP	1	0.998	0.984	0.99
SMK,HUM	1	1	0.981	0.99
VOC,HUM	1	0.997	0.98	0.988
SMK,GAS	1	1	0.973	0.986
VOC,GAS	1	0.995	0.964	0.978
VOC,SMK	0.995	0.928	0.957	0.908
GAS,HUM	0.943	0.867	0.785	0.821

표 6을 통해 여러 센서를 결합하면 모델의 종류와 상관없이 분류 성능이 개선됨을 알 수 있다. 이는 모델 학습 시 우수한 분류 특성을 가지는 CO, SMK, TEMP 센서가 포함되었기 때문이다. 이는 표 7에 정리한 각 특징이 학습에 미친 영향을 나타내는 RF의 특징 중요도(Feature importance)를 통해서도 확인할 수 있다. 높은 특징 중요도를 가지는 TEMP 센서로 수집된 데이터는 실제로 매질의 종류와 상관없이 화재와 비화재의 구분이 뚜렷하며 그 변화 추이도 일정하다. 그러나 한국소방산업기술원에서 제시하는 감지기의 기술기준에는 임계값을 기준으로 화재의 여부를 판단해야 하므로 화재와 비화재시 차이가 큰 CO나 SMK 센서의 활용도 고려

해야 한다. 향후 학습된 두 모델의 변수는 화재감지기의 화재/비화재 판단 값을 설정하는 중요한 근거로 삼을 것이다.

표 6. 다중센서: 모델별 평균 성능
Table 6. Multiple sensors: Average performance of each model

Model	AUC	Recall	Prec.	F1
KNN	0.997	0.992	0.985	0.989
RF	0.996	0.986	0.987	0.987
LR	0.996	0.987	0.986	0.986
NB	0.997	0.992	0.983	0.986
SVM	0.992	0.964	0.927	0.932

표 7. 다중센서: 랜덤 포레스트 모델의 특징 중요도
Table 7. Multiple sensors: Feature importance of the random forest

TEMP	SMK	CO	VOC	HUM	GAS
0.303	0.259	0.235	0.144	0.059	0

발화부터 전소에 도달할 때까지 수집한 전체 데이터를 화재감지에 사용한다는 것은 초기대응 관점에 어긋난다. 센서의 복합적인 사용과 머신러닝 알고리즘이 화재 초기에 발생한 일부 데이터만으로도 잘 동작하는지 확인하기 위해 각 센서가 수집한 600개의 데이터가 아닌 초기 60개의 데이터(대략 1분 정도)로만 모델 평가를 진행하였다. 그 결과 표 8과 9에 정리한 것처럼 초기에 발생한 데이터만을 사용하더라도 전체 데이터를 사용한 것과 성능 차이가 거의 없는 것으로 확인되었다. 따라서 짧은 주기에 수집된 데이터만으로도 센서를 조합하여 신속하고 정확하게 화재감지가 가능할 것으로 기대한다.

표 8. 단일센서: 센서의 종류에 따른 평균 모델 성능
Table 8. Single sensor: Average model performance according to the sensor

Feature	AUC	Recall	Prec.	F1
CO	1	1	1	1
SMK	1	1	1	1
TEMP	1	1	1	1
VOC	0.993	0.971	0.966	0.968
HUM	0.941	0.824	0.822	0.817
GAS	0.827	0.781	0.665	0.713

표 9. 다중센서: 센서 조합에 따른 평균 모델 성능(하위 7개)
Table 9. Multiple sensors: Average model performance according to sensor combination(triple bottom)

Feature	AUC	Recall	Prec.	F1
VOC,TEMP	1	0.998	0.984	0.99
SMK,HUM	1	1	0.981	0.99
VOC,HUM	1	0.997	0.98	0.988
SMK,GAS	1	1	0.973	0.986
VOC,GAS	1	0.995	0.964	0.978
VOC,SMK	0.995	0.928	0.957	0.908
GAS,HUM	0.943	0.867	0.785	0.821

VI. 결론 및 향후 과제

화재감지 정확도 향상 및 비화재보 문제를 해결하기 위해 다양한 연구와 제품개발이 이루어지고 있으나 여전히 화재감지기의 오작동으로 인해 초기 대응 실패 및 오인출동 문제가 야기되고 있다. 따라서 정확한 화재감지를 위해선 단일센서가 아닌 다중센서를 이용한 복합 화재감지기 개발이 필요하다.

본 연구에서는 화재감지기에 사용될 수 있는 다양한 센서들로부터 수집한 데이터를 바탕으로 머신러닝 기법을 적용하여 각 센서 및 센서의 조합이 화재감지 정확도에 미치는 영향에 관해 연구하였다. 본 논문에서 제시한 다양한 센서 조합에 따른 감지 정확도는 복합 화재감지기 개발의 통찰력을 제공할 것으로 기대한다.

본 연구에서 머신러닝 기술만을 고려하고 있으나 향후에는 수집 데이터에 딥러닝 기술을 적용할 예정이다. 또한, 개발 중인 다중센서 기반 화재감지기에 학습 모델을 탑재하여 화재감지기에서 머신러닝 활용 가능성을 검증할 계획이다.

References

- [1] National Fire Agency, "Last year, 3,000 apartment fires occurred. The most in the last 5 years", Jan. 2024. <https://www.nfa.go.kr/nfa/news/pressrelease/press/?mode=view&cntId=2079> [accessed: Jan. 20, 2024]
- [2] Korea Industrial Safety Association, "Mandatory function of automatic correction of fire detectors in traditional market", Dec. 2023. <https://www.anjunj.>

- com/news/articleView.html?idxno=38238 [accessed: Jan. 03, 2024]
- [3] Seoul Statistics Integration Platform, "2020 Fire Occurrence Status in Seoul", Dec. 2017. <https://data.seoul.go.kr/dataList/10950/S/2/datasetView.do> [accessed: Jan. 3, 2024]
- [4] S. Son and S. Suh, "Deep Learning Based Fire and Smoke Detection Systems in Camera", *Journal of Knowledge Information Technology and Systems*, Vol. 17, No. 6, pp. 1251-1258, Dec. 2022. <https://doi.org/10.34163/jkits.2022.17.6.016>
- [5] S. H. Hong, M. W. Hong, and Y. S. Yoo, "An Experimental Study on the Fire Detection Performance of Combined Fire Detector Using Multi-sensor for Rack-type Warehouse", *Korean Journal of Hazardous Material*, Vol. 7, No. 2, pp. 59-63, Dec. 2019. <https://doi.org/10.31333/kihm.2019.7.2.59>.
- [6] G. S. Son and S. H. So, "A Study on Fire Alarm Test of IoT Multi-Fire Detector combined Smoke/CO/Temperature sensor", *Journal of The Korean Society of Disaster Information*, Vol. 17, No. 2, pp. 236-244, Jun. 2021. <https://doi.org/10.15683/kosdi.2021.6.30.236>.
- [7] M. Padilla and C. Vega-García, "On the comparative importance of fire danger rating indices and their integration with spatial and temporal variables for predicting daily human-caused fire occurrence in Spain", *International Journal of Wildland Fire*, Vol. 20, No. 1, pp. 46-58, Feb. 2011. <https://doi.org/10.1071/WF09139>.
- [8] S. Milanović, N. Marković, D. Pamučar, L. Gigović, P. Kostić, and S. D. Milanović, "Forest Fire Probability Mapping in Eastern Serbia: Logistic Regression versus Random Forest Method", *Forests*, Vol. 12, No. 1, pp. 1-17, Dec. 2020. <https://doi.org/10.3390/f12010005>.
- [9] 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 Apr. 2009. <https://doi.org/10.1016/j.firesaf.2008.07.006>.
- [10] J. S. Baek, T. J. Alhindi, Y. S. Jeong, M. K. Jeong, S. H. Seo, J. S. Kang, J. K. Choi, and H. S. Chung, "Real-Time Fire Detection Algorithm Based on Support Vector Machine with Dynamic Time Warping Kernel Function", *Fire Technology*, Vol. 57, No. 6, pp. 2929-2953, Jan. 2021. <https://doi.org/10.1007/s10694-020-01062-1>.
- [11] S. Chen, J. Ren, Y. Yan, M. Sun, F. Hu, and H. Zhao, "Multi-sourced sensing and support vector machine classification for effective detection of fire hazard in early stage", *Computers and Electrical Engineering*, Vol. 101, pp. 108046, Jul. 2022. <https://doi.org/10.1016/j.compeleceng.2022.108046>.
- [12] L. Gigović, H. R. Pourghasemi, S. Drobnjak, and S. Bai, "Testing a New Ensemble Model Based on SVM and Random Forest in Forest Fire Susceptibility Assessment and Its Mapping in Serbia's Tara National Park", *forests*, Vol. 10, No. 5, pp. 1-21, May 2019. <https://doi.org/10.3390/f10050408>.
- [13] J. S. Baek, T. J. Alhindi, Y. S. Jeong, M. K. Jeong, S. H. Seo, J. S. Kang, and Y. S. Heo, "Intelligent Multi-Sensor Detection System for Monitoring Indoor Building Fires", *IEEE Sensors Journal*, Vol. 21, No. 24, Dec. 2021. <https://doi.org/10.1109/JSEN.2021.3124266>.
- [14] J. C. Park and D. S. Kang, "RFDSys: Real-time Fire Detection System using AIoT-based K-NN and Motion Detection", *Journal of KIIT*, Vol. 19, No. 10, pp. 115-123, Oct. 2021. <https://doi.org/10.14801/jkiit.2021.19.10.115>.
- [15] J. S. Kim and D. S. Kang, "A Study on the Improvement of Fire Misunderstanding using Bayesian Neural Network", *Journal of KIIT*, Vol. 22, No. 1, pp. 151-160, Jan. 2024. <https://doi.org/10.14801/jkiit.2024.22.1.151>.

저자소개

임 길 환 (Gil-Hwan Lim)



2017년 : 한국기술교육대학교
컴퓨터공학부(공학사)
2022년 : 금오공과대학교
컴퓨터IT공학과(공학석사)
2016년 ~ 현재 : 다운(주)
기업부설연구소 선임연구원

김 성 렬 (Sung-Ryul Kim)



2010년 2월 : 부산대학교
컴퓨터공학과(학사)
2017년 8월 : 부산대학교 대학원
컴퓨터공학과(공학박사)
2019년 3월 ~ 현재 :
금오공과대학교
컴퓨터소프트웨어공학과 조교수

관심분야 : 빅데이터, 머신러닝