

## 임베디드 플랫폼을 위한 화재 조기 감지 시스템: 오경보 최소화를 위한 딥러닝 접근 방식

노성준<sup>1</sup> · 이광재<sup>1,\*</sup>

### Early Fire Detection System for Embedded Platforms: Deep Learning Approach to Minimize False Alarms

Seong-Jun Ro<sup>1</sup> and Kwangjae Lee<sup>1,\*</sup>

#### Abstract

In Korea, fires are the second most common type of disaster, causing large-scale damages. The installation of fire detectors is legislated to prevent fires and minimize damage. Conventional fire detectors have limitations in initial suppression of failures because they detect fires when large amounts of smoke and heat are generated. Additionally, frequent malfunctions in fire detectors may cause users to turn them off. To address these issues, recent studies focus on accurately detecting even small-scale fires using multi-sensor and deep-learning technologies. They also aim at quick fire detection and thermal decomposition using gas. However, these studies are not practical because they overlook the heavy computations involved. Therefore, we propose a fast and accurate fire detection system based on multi-sensor and deep-learning technologies. In addition, we propose a computation-reduction method for selecting sensors suitable for detection using the Pearson correlation coefficient. Specifically, we use a moving average to handle outliers and two-stage labeling to reduce false detections during preprocessing. Subsequently, a deep-learning model is selected as LSTM for analyzing the temporal sequence. Then, we analyze the data using a correlation analysis. Consequently, the model using a small data group with low correlation achieves an accuracy of 99.88% and a false detection rate of 0.12%.

**Keywords:** Pearson correlation coefficient, Moving average, Multiple gas sensors, Lightweight, LSTM

#### 1. 서 론

행정안전부의 재난연감에 따르면, 화재는 2020년부터 3년 동안 재난 발생률 2위를 차지했다[1]. 또한, 같은 기간의 소방청 화재통계연감에 따르면, 전국적으로 약 11만 건의 화재가 발생하며 약 2,909조 원의 금전적 손해를 끼쳤다[2]. 대한민국은 화재에 의한 피해를 대비하기 위해 2017년 2월부터 모든 건물에 화재감지기 설치를 의무화 하였지만, 설치된 대부분이 연기만 감지한다. 이러한 방법은 화재에서 연기나 연소 입자가 나타날 때 경보하므로, 실제로 건물 화재와 관련된 독성 배출로 인해

발생한 최근의 화재는 다수의 사망자를 발생시켰다[3]. 이러한 이유로 최근에는 연기보다 먼저 나타나는 휘발성 물질을 화학적 가스 센서를 이용해 탐지를 하고, 이에 인공지능을 접목하여 화재를 추론해 보다 빠르고 정확한 징후 감지를 위한 연구가 활발히 진행되고 있다.

연기가 나타나기 전의 징후 감지를 위해 화학적 가스 센서 기반한 빠른 화재 감지에 관한 연구가 제안되었다[3-5]. 이 연구들은 다수의 재료 조합을 통하여 사람이 말할 수 없거나 유해 화학 물질에 대해 목표 가스로 선정하여 선택성이 높은 가스 센서를 개발하였고, 이를 이용해 화재 감지가 가능하다는 것을 보였다. 하지만 목표 가스 외에 다른 가스에서 반응하는 가스 센서의 교차 선택성으로 가스가 혼합된 환경에서 목표 가스의 농도를 제대로 도출하지 못하는 문제를 가진다. 그 대안으로 반도체 금속 산화물 센서, 전기화학 센서, 광이온화 감지 센서의 조합 사용하는 다중 센서를 사용하여 감지하는 연구가 제안되었다[6-11]. 이 연구들은 공통으로 각 센서의 데이터 패턴을 분석하는 기계학습 통해 혼합 가스에서도 목표 가스를 탐지하였고 실험을 통해 화재를 정확히 감지함을 보였다. 그러나 학습된 패턴과 실제 환경의 패턴이 다르면 유사도가 떨어져 화재 감지 성

<sup>1</sup>상명대학교 정보보안공학과(Department of Information Security Engineering, Sangmyung University)  
31, Sangmyeongdae-gil, Dongnam-gu, Cheonan-si, Chungcheongnam-do 31066, Korea

\*Corresponding author: begleam@smu.ac.kr

(Received: Aug. 21, 2024, Revised: Aug. 28, 2024, Accepted: Sep. 2, 2024)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<https://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.

능이 저하되는 문제점을 보였다. 그래서 다양한 환경의 대규모 데이터 세트를 수집하여 화재를 판별하는 딥러닝 기반 연구들이 제안되었다. 또한 가스 센서 외에 다른 방식의 센서를 함께 사용하는 퓨전 센서 기반 연구들이 제안되었다[12-16]. 이 연구들은 다양한 환경에서 수집한 다중 센서 데이터를 이용해 화재 발생을 추론해 정확도를 매우 높였다. 또한 화재 및 열화상과 같은 비전 기반 센서를 함께 사용하여 화학적으로만 감지할 수 있었던 제한된 기존 방식에서 물리적인 방법을 추가해 정확도를 높일 수 있었다. 하지만 다수 센서에 더불어 비전 센서의 높은 가격과 함께 사용함에 따라 딥러닝 수행에 필요한 연산량 역시 대폭 늘어나면서 가격이 상용화에 큰 걸림돌로 작용하고 있다.

본 논문에서는 가스 센서를 활용해 화재를 빠르게 감지하고 다수의 센서를 사용함으로써 선택 범위를 확장하여 딥러닝 모델 학습을 수행하는 방법을 제안한다. 또한, 효율적인 학습을 할 수 있게끔 데이터 간의 상관관계 분석하여 사용 센서의 수를 줄인다. 이 방식은 딥러닝 수행에 필요한 연산량을 줄여 상용화할 수 있는 가격 경쟁력을 갖게 한다.

## 2. 연구 방법

본 논문에서 제안하는 임베디드 플랫폼을 위한 화재 조기 감지 시스템의 블록도는 Fig. 1과 같다. 이 시스템은 8개의 가스 센서를 이용해 초기 징후 감지 단계에서 화재를 감지하는 LSTM을 사용하였다. LSTM은 딥러닝 기법의 하나로 과거의 데이터와 현재의 필요한 데이터를 전달하는 게이트를 이용해 시계열 데이터를 처리하는 데 유리하다[17]. 그리고 오경보를 최소화하기 위해서 전처리 단계에서는 이상치 제거 및 화재 비율에 따른 슬라이딩 윈도우 라벨링을 수행하였다. 그리고 중간 과정에서 피어슨 상관 분석을 통해 불필요한 데이터를 선별해 센서의 수를 3~4개로 줄이고, 그로 인해 데이터의 양이 줄면서 연산 자원이 제한된 임베디드 플랫폼에서도 제안하는 시스템을 구현할 수 있게 하였다.

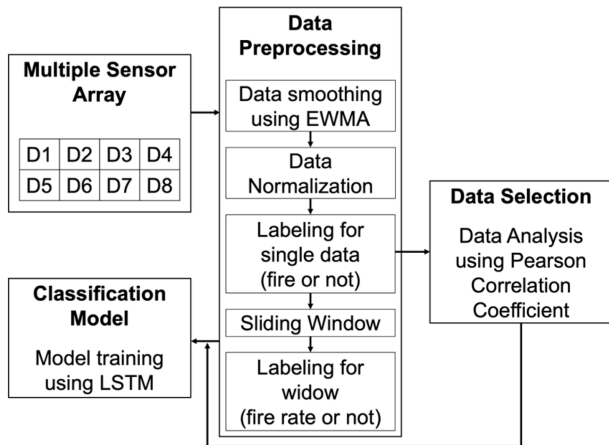


Fig. 1. A block diagram of a proposed early fire detection system.

### 2.1 초기 징후 감지 단계에서의 데이터 추출

제안하는 시스템은 화재 감지 수행을 위해 다음과 같이 환경을 조성하여 데이터를 수집한다. 산화물 반도체 가스 센서의 재료는 NiO, In2O3, SnO2, WO3, Fe2O3를 사용하고, Figaro사의 상용 센서인 TGS823과 TGS826을 사용해 8개로 구성하였다. 그리고 데이터 수집 환경은 유리 상자(90 cm × 45 cm × 45 cm)에서 Poly(vinyl chlorides) (PVC) 에서 방출되는 가스를 측정하였으며, 핫플레이트로 50, 100, 200, 350°C로 구성하여 1초 간격으로 수집하였다[18].

### 2.2 데이터 전처리

딥러닝 모델 학습을 위한 데이터 전처리는 데이터에 있는 이상치나 결측치를 해결하고, 데이터들의 값이 혼란 시 고른 영향을 주기 위해 정규화를 수행한다. 이 과정을 수행하지 않으면 센서 어레이로 데이터를 획득할 경우 측정 환경에 따라 결과가 크게 달라질 수 있고 각 센서에서의 출력의 범위가 달라 큰 범위를 가진 센서가 모델에 높은 영향력을 발휘해 모델 학습이 불안정할 수 있다[19]. 본 논문에서는 실험 환경과 유사한 특정 환경 뿐만 아니라 다양한 환경에서 적용 가능한 데이터를 얻기 위해서 어레이에서 화재가 민감하게 감지되었을 때 측정값을 평균화와 정규화를 한다.


이동 평균 계산 방법 중 시계열 데이터 적용이 가장 유연한 지수 가중 이동 평균(Exponentially Weighted Moving Average; EWMA)을 식 (1)과 같이 적용하고, 중요한 시점에는 모든 센서 값을 0~1 사이의 값으로 변환하는 방법인 최소-최대 정규화(Min-Max Normalization)를 식 (2)와 같이 적용한다. 이러한 방식으로 평균화를 거친 데이터는 센서의 이상치를 줄여 화재 감지 시 오검출률을 낮추고 화재 감지 시 변화를 빠르게 포착하여 실시간 연산이 가능하며, 정규화된 데이터는 각 센서 데이터를 명확하게 비교한다.

$$S_t = \alpha \cdot Y_t + (1 - \alpha) \cdot S_{t-1} \tag{1}$$

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{2}$$

이렇게 처리된 데이터에 이후 화재 여부에 따른 라벨링을 한 후 슬라이딩 윈도우 알고리즘을 이용한다. 이 알고리즘은 특정 윈도우 크기  $k$ 와 데이터 스트림을 가로지르는 데이터 이동 크기를 슬라이딩 간격  $s$ 로 정하여  $k$ 와  $s$ 를 기준으로 시간 순서를 가지고 있는 데이터를 생성한다. 이렇게 생성된 윈도우 안에는 주변 환경에 대한 정보가 포함된 시계열 데이터를 가지고 있어 상대적인 변화나 이상 현상을 효과적으로 추출 가능하다[20-23]. Fig. 2는 윈도우의 크기가 5, 이동 크기는 1일 때 슬라이딩 윈도우의 방법이다.

슬라이딩 윈도우를 거친 데이터를 모델 학습에 사용하기 위



**Fig. 2.** Sliding window method with window size  $k$  of 5 and movement size  $s$  of 1.

Non-Fire Labeling						Fire Labeling							
time	t-5	t-4	t-3	t-2	t-1	step 2 Label	time	t-4	t-3	t-2	t-1	t	step 2 Label
step 1 Label	0	0	0	1	1		step 1 Label	0	0	0	1	1	
	(fire X)	(fire X)	(fire X)	(fire O)	(fire O)			(fire X)	(fire X)	(fire O)	(fire O)	(fire O)	

(a)

time	t-5	t-4	t-3	t-2	t-1	step 2 Label	time	t-4	t-3	t-2	t-1	t	step 2 Label
step 1 Label	0	0	0	1	1		step 1 Label	0	0	1	1	1	
	(fire X)	(fire X)	(fire X)	(fire O)	(fire O)			(fire X)	(fire X)	(fire O)	(fire O)	(fire O)	

(b)

time	t-5	t-4	t-3	t-2	t-1	step 2 Label	time	t-4	t-3	t-2	t-1	t	step 2 Label
step 1 Label	0	0	0	1	1	0	step 1 Label	0	0	0	1	1	1
	(fire X)	(fire X)	(fire X)	(fire O)	(fire O)			(fire X)	(fire X)	(fire O)	(fire O)	(fire O)	1

(c)

**Fig. 3.** Window labeling for non-fire and fire situations, window size  $k$  is 5, and the ratio of labeling standard  $r$  is 60%. (a) the window state when each time is  $t-1$  and when  $t$ , (b) check the amount of fire data included, (c) labeling window according to criteria met.

해서는 묶음 형태의 데이터의 클래스를 다시 계산해야 한다. 윈도우 내의 클래스의 0과 1의 개수를 클래스의 비율  $r$ 에 따라 최종 클래스를 라벨링한다. 이 과정에서 각 윈도우는 시간에 따라 연속적으로 생성되고, 모델을 훈련시키는 데이터셋으로 사용 가능하다. Fig. 3은 윈도우 크기가 5, 비율이 60%일 때의 윈도우의 라벨링 적용 예시를 나타낸다.

### 2.3 데이터 상관관계 분석

피어슨 상관관계 분석은 한 변수의 값이 증가함에 따라 다른 변수의 값도 증가하거나 감소하는 크기 변화와 연관된다. 그리고 상관관계 계수는 0에 가까워질수록 변수 사이에 선형 관계가 없음을 나타내고, 절대값이 1에 가까워질수록 관계가 강해짐을 의미한다[24]. 본 논문에서는 센서 데이터 간의 연관성을 측정하기 위해 피어슨 상관관계 분석을 사용한다. 연관성은 데이터 축소에 활용되므로 상관관계가 높은 데이터 그룹(data Group with High Correlation with Class; GHCC)과 상관관계가 낮은 데이터 그룹(data Group with Low Correlation between Data; GLCD)으로 구분하여 학습한다.

### 2.4 모델 구성

모델 구성은 순환 신경망(RNN)의 중 하나인 장단기 기억 신

경망(LSTM)을 이용하여 모델을 훈련하였다. 기존 RNN은 모든 시간대의 데이터를 고려하고 보존함에 따라 순환할수록 초반 입력 데이터의 영향이 사라지는 장기 의존성 문제가 단점으로 지적되었다. 이러한 문제를 해결하기 위해 LSTM은 망각게이트, 입력게이트, 출력게이트를 이용해 메모리 셀에 중요도에 따라 데이터를 조절하여 장기 의존성 문제를 완화한 모델이다. 이러한 특성으로 인해 LSTM은 문장 예측이나 현재 실험의 시계열 데이터에 주로 사용된다[25].

## 3. 실험 결과 및 고찰

### 3.1 데이터셋

사용한 데이터셋은 센서를 이용해 화재에 대한 정보를 가지고 있는 선행연구에서 가져왔다[18]. 데이터셋 구성은 Table 1과 같이 8개의 산화물 반도체 가스 센서이며 재료로는 NiO, In<sub>2</sub>O<sub>3</sub>, SnO<sub>2</sub>, WO<sub>3</sub>, Fe<sub>2</sub>O<sub>3</sub>를 사용하고, Figaro사의 상용 센서인 TGS823과 TGS826을 사용하였다. 그리고 수집된 정보는 1초마다 측정하며, 4개의 온도 50, 100, 200, 350°C에서 화재, 비화재 상태에 대한 데이터를 포함한다.

### 3.2 데이터 전처리

데이터 전처리 과정은 데이터의 이상치와 결측치를 없애고 정규화 후 슬라이딩 윈도우를 이용해 데이터를 형성한다. 슬라이드 윈도우 크기가 커질수록 반응이 느려지기 때문에 임의의 크기를 적용해 여러 실험 후 원본 데이터에 큰 손상이 없고 시간간성도 놓치지 않는 윈도우 크기를 10, 15, 20으로 결정했다. 이를 마친 데이터의 라벨링의 경우 화재의 비율이 60%일 때와 40%일 때 2개의 경우를 기준으로 사용하여 실험을 진행했다.

### 3.3 데이터 상관관계 분석

모델을 학습시키기 전에 앞서 데이터의 상관관계에 대해서 분석

**Table 1.** Dataset configuration by material or part ID.

Sensor Number	Material or Part ID
D1	NiO
D2	In <sub>2</sub> O <sub>3</sub>
D3	SnO <sub>2</sub>
D4	TGS823
D5	In <sub>2</sub> O <sub>3</sub>
D6	WO <sub>3</sub>
D7	Fe <sub>2</sub> O <sub>3</sub>
D8	TGS826




Fig. 4. After preprocessing the data collected through eight sensors, the correlation was analyzed including classes.

을 했다. 상관관계의 경우 전처리 과정 중 슬라이딩 윈도우를 적용하기 전 데이터를 사용하였고, Fig. 4와 같이 나타났다. 클래스와의 상관 계수를 확인했을 때 D1의 계수의 절대값은 0.73으로 매우 강한 상관관계를 보여줬으며 그 외의 데이터들은 D4, D8, D3, D5, D2, D6, D7 차례로 클래스와의 높은 상관 계수 수치를 보여주었고 이들은 0.4-0.7 사이의 계수로 강한 상관관계가 있음을 보여주었다. 클래스와 상관관계가 가장 높은 D1은 클래스와의 상관관계가 강한 D3, D8과 0.9가 넘는 상관 계수가 나왔고, D4역시 0.89로 높은 수치를 보여준다. 데이터 간의 클래스와 상관관계는 높은 순위를 보여주는 데이터들이지만 서로 간의 상관 계수는 매우 강한 상관관계를 확인했다.

### 3.4 LSTM 학습

LSTM 학습은 TensorFlow API 함수를 이용하여 레이어를 쌓아 진행하였다. 모델 구성은 입력 레이어에서는 (40,1) 형태의 데이터를 받는다. 이후 256개의 노드로 구성된 LSTM 레이어를 거치고 활성화 함수 ReLU가 진행되며, 1개의 노드로 구성된 Dense 레이어를 거치고 활성화 함수 시그모이드를 사용하여 화재에 대한 판단을 할 수 있도록 하였다. 학습 데이터와 테스트 데이터는 8:2 비율로 분할 후, 검증 데이터는 학습 데이터의 25%를 사용하여 검증해 6:2:2의 비율로 나뉘었다. 데이터의 경우 LSTM 학습을 위해 3D 변환 후 학습을 구동하였다. 활성화 함수로 시그모이드를 사용하여 출력 레이어를 구성하였으며, 모델 컴파일 시 최적화 함수로 Adam을 사용하였다. 모델 구동 시 배치 사이즈는 32, 에포크는 9로 지정했다.

### 3.5 실험 시나리오 및 결과

실험 시나리오는 Table 2와 같다. 먼저 GHCC와 GLCD로 데

이터를 한정하여 모델을 학습한다. 다음으로 학습된 모델 중 좋은 결과를 나타내는 데이터 조합을 이용하며, 추가적으로  $k$ 와  $r$ 을 조절해 다시 학습하며, 최종 모델을 결정한다. 마지막으로 최종 모델의 단계별 소요 시간을 분석한다.

먼저 모델 학습은 GHCC과 GLCD로 나누어 상관관계 분석을 기반으로 각 그룹에 맞게 데이터를 정했다. 사용 데이터 수를 2, 3, 4, 8개를 이용해 데이터를 조합하여 9개로 구성하였고 GHCC는 ●, GLCD는 ○로 표시하였다.  $k$ 는 100,  $r$ 은 60%로 학습하였고, 결과는 Table 3과 같다. Data에 명시한 데이터 순서는 각 그룹에 따라 GHCC의 경우 클래스와의 상관관계가 큰 순서, GLCD의 경우 데이터 간의 상관관계가 작은 순서대로 나열하였고, Rank의 경우 클래스와의 상관관계에 대한 순위를 나타낸다. 데이터 8개를 이용한 학습을 제외한 모든 모델에서 90% 이상의 정확도를 확인했다. 이는 데이터 수를 늘리는 것만이 답이 아닌 학습의 목표인 클래스와의 관계성을 고려하거나 비슷한 상관관계의 데이터 학습을 줄이고 다양한 데이터 학습이 클래스 구별에 혼란을 줄여 클래스와 데이터의 관계에 집중할 수 있도록 하여 도움이 됨을 확인할 수 있었다. 이러한 결과에서 GHCC의 조합 중 (1,4), (1,8), (1,4,8,3)을 이용한 3개의 모델과 GLCD의 조합 중 (1,6), (1,7,4), (1,7,4,2)를 이용한 3개의 모델의 학습의 정확도는 95%를 넘기는 결과를 얻었고 이를 Table에 색으로 표시하였다.

하지만 이는  $k$ 와  $r$ 을 각각 100과 60%로 설정해서 화재 감지

Table 2. Experimental scenario for reliable and efficient model generation using correlation analysis.

Sequence	Scenario
1	Training the model by limiting the correlation to the considered conditions
2	Model retraining and result validation by adjusting $k$ and $r$
3	Check performance by changing the model
4	Check fire detection delay

Table 3. Learning a model considering data correlation,  $k$  is 100, and  $r$  is 60%. '●' is Data group with high correlation with class, '○' is Data group with low correlation between data.

Num	Data	Rank	Accuracy	Loss
2	● 1, 4	1, 2	0.9903	0.0580
	● 1, 8	1, 3	0.9952	0.0292
	○ 1, 7	1, 8	0.9361	0.1825
3	○ 1, 6	1, 7	0.9662	0.1297
	● 1, 4, 8	1, 2, 3	0.9011	0.2848
4	○ 1, 7, 4	1, 8, 2	0.9903	0.0521
	● 1, 4, 8, 3	1, 2, 3, 4	0.9867	0.0699
8	○ 1, 7, 4, 2	1, 8, 2, 6	0.9771	0.0833
			0.8926	0.2841

의 모델로 쓰기에는 60초의 딜레이가 있어 사용하기에는 부적절하다. 높은 성능을 보여준 데이터를 이용해  $k$ 는 20, 15, 10  $r$ 은 앞서 사용했던 비율인 60%와 조금 줄인 40% 경우로 나누어 학습하였고, 결과는 Table 4와 같다.  $k/r$ 은 각각 3, 2개로 6개의 조합이 나타났다. 데이터 2개를 사용한 모델에서는 정확도

가 대부분 높지만 유일하게 80%의 정확도를 보유하는 결과가 나왔으며 화재 탐지 시스템에서 가장 경계해야 할 화재가 발생했을 때 발생하지 않았다는 판단을 내리는 False Negative (FN)는 역시 데이터 3개 4개를 사용했을 때에 비해 상당히 큰 수치를 보여준다. 그 외 모델의 경우 데이터에서는 전체적으로 98%가 넘는 높은 정확도를 보여주고 FN 역시 한자리 수를 보여주었다.

가장 훌륭한 모델을 선택했을 때 FN이 0이 나온  $k$ 가 20,  $r$ 이 60%, 데이터 (1,7,4)로 사용한 모델과,  $k$ 와  $r$ 이 각각 10과 4로 가장 작고 정확도와 손실 값 역시 99.88%와 0.0083으로 가장 훌륭하게 나타났으며 FN 역시 1로 낮은 값을 보여준 데이터 (1,7,4,2)을 이용한 모델로 2개의 모델이 . 본 논문에서는 시스템은 화재 조기 탐지가 주요 연구 목적이므로  $k$ 와  $r$ 을 20과 60으로 했을 때와 10과 40으로 했을 때 12초와 4초로 8초의 차이가 있으며 FN은 1밖에 차이가 나지 않으므로 데이터 (1,7,4,2)를 사용한 모델을 선택하였다.

**Table 4.** Experimental results of 20, 15, 10  $k$  and 60% and 40%  $r$  using data that showed good results from previous test results.

$k/r$	Data	Accuracy	Loss	FN
20/60	1,4	0.9929	0.0382	6
	1,8	0.9811	0.0693	16
	1,6	0.9763	0.1027	20
	1,7,4	0.9870	0.0371	0
	1,4,8,3	0.9923	0.0326	3
	1,7,4,2	0.9941	0.0239	5
15/60	1,4	0.9764	0.0890	19
	1,8	0.8960	0.3141	88
	1,6	0.9622	0.1270	31
	1,7,4	0.9965	0.0155	3
	1,4,8,3	0.9953	0.0165	3
	1,7,4,2	0.9988	0.0161	1
10/60	1,4	0.9882	0.0692	8
	1,8	0.9847	0.1148	12
	1,6	0.9894	0.0501	8
	1,7,4	0.9988	0.0171	1
	1,4,8,3	0.9953	0.0220	3
	1,7,4,2	0.9929	0.0418	6
20/40	1,4	0.9905	0.0263	8
	1,8	0.9941	0.0332	3
	1,6	0.9775	0.0843	19
	1,7,4	0.9917	0.0258	7
	1,4,8,3	0.9953	0.0253	4
	1,7,4,2	0.9917	0.0156	4
15/40	1,4	0.9622	0.1515	32
	1,8	0.9764	0.0910	18
	1,6	0.9444	0.2026	47
	1,7,4	0.9988	0.0226	1
	1,4,8,3	0.9953	0.0133	1
	1,7,4,2	0.9976	0.0118	1
10/40	1,4	0.9917	0.0566	7
	1,8	0.9540	0.1698	39
	1,6	0.9906	0.0792	8
	1,7,4	0.9976	0.0129	2
	1,4,8,3	0.9988	0.0086	1
	1,7,4,2	0.9988	0.0083	1

### 3.6 모델 성능 평가

학습을 위한 모델을 선택하기 위해 순차 데이터를 다루는 모델 RNN과 LSTM과 비슷하게 2개의 게이트를 이용한 GRU, 그리고 LSTM 총 3개의 모델을 이용해 모델의 성능을 확인하였고, 결과는 Table 5와 같다. RNN은 3개의 모델 중 유일하게 90% 이하의 정확도를 보여주었고, FN 수치 또한 매우 크게 나와 좋지 않은 모델 성능을 보여줬다. GRU은 최고의 성능을 보여준 LSTM보다 1.65% 낮은 성능을 보여주고 손실 역시 0.0411의 차이를 보여주었으며 FN 수치는 15를 보였다. 그리고 LSTM은 정확도 99.88%, 손실 0.0083, FN 1로 3개의 모델 중 가장 우수한 성능이 나타남을 확인했다.

모델의 성능을 보다 자세한 평가를 위하여 혼동 행렬(Confusion Matrix)을 사용했다. 나타난 결과는 True Positive는 177, True Negative는 669, False Positive는 1, False Negative는 0이 나왔으며, 이 결과는 Fig. 5에서 확인 할 수 있다. 그리고 제안하는 시스템이 화재 조기 탐지기이기 때문에 시스템의 작동을 위한 연산 시간 역시 중요한 지표이다. 해당 기능을 측정하기 위해 시스템의 연산을 Table 6과 같이 분류하고 200번을 반복하여 평균값을 ms 단위로 측정하였다.

새로운 데이터가 들어왔을 때 적용해야 하는 슬라이딩 윈도우는 4.077 ms, 이상치와 결측치를 완화하기 위한 지수 가중 이동 평균은 3.536 ms, 안정적인 학습을 위한 정규화는 2.929 ms,

**Table 5.** Performance of each model with data (1,7,4,2),  $k$  of 10, and  $r$  of 40%.

Model	RNN	GRU	LSTM
Accuracy	0.8737	0.9823	99.88
Loss	0.3779	0.0494	0.0083
FN	107	15	1

		Prediction	
		Positive	Negative
Actual	True	108	1
	False	0	728

Fig. 5. Confusion matrix with matrix with data (1,7,4,2),  $k$  is 10, and  $r$  is 40%.

Table 6. Average delay results of 200 tests per system function.

Function	Delay (ms)
Sliding window	4.077
EWMA	3.536
Normalization	2.929
Reconfiguration	0.333
Model	117.3
Total delay (1-cycle delay)	128.2

모델에 데이터를 넣기 위한 데이터 재구성은 0.333 ms, 재구성된 데이터를 모델에 넣고 결과를 얻는데 까지의 모델 연산시간은 117.3 ms로, 이러한 5개의 기능을 한 주기로 총 128.2 ms의 결과를 얻었다. 사용한 데이터의 데이터 수집은 1초마다 이루어졌고, 사용한  $k$ 는 10,  $r$ 는 40%이다. 따라서 화재 발생의 판단은 최소 4초가 지나야 결정할 수 있다. 즉, 화재 판단에 있어서 4초의 지연시간이 발생하고, 시스템 연산의 지연시간이 128.2 ms이므로 화재 탐지 시간은 총 4.128초가 걸림을 확인할 수 있었다.

#### 4. 결 론

본 논문에서는 빠르고 정확한 화재 탐지 실현을 위해 가스 센서를 이용해 화재에 대한 데이터셋을 슬라이딩 윈도우와 화재 비율 기준을 이용해 전처리 하였다. 그리고 더 효율적이고 안정적인 모델 생성을 위해 데이터의 상관관계 분석해 클래스와 데이터 간의 상관관계도 고려해 4개의 데이터를 선택하여 모델을 학습시켰다. 그 결과 99.88%의 정확도와 0.0031의 손실을 나타내며 상당한 성능 향상을 보여줬다. 이 모델은 화재 탐지 시스템에서 가장 경계해야 할 화재가 발생했을 때 발생하지 않았다는 판단을 내리는 False Negative가 1이므로 화재 감지 시스템으로써 매우 우수하다. 그러나 해당 시스템은 딥러닝을 통해 화재를 판단하기 때문에 안정적인 판단을 위해서는 데이터의 중요성이 높다. 제안하는 시스템에서 사용한 데이터는 실제 화재 환경과 유사한 화재 환경을 조성하여 데이터를 수집하였기 때문에 화재 재료와 온습도 변화에는 판단 정확도가 크게 떨어지지 않는다. 하지만 센서의 long-term drift와 같이 시간이 지남에 따라 출력이 변화하는 현상에 대해서는 대응할 수 없다. 이 점은 추가 연구를 통해 해결이 필요하다. 본 논문에서는 화재 탐

지를 위해 단순히 데이터를 많이 넣어 훈련하는 것이 아니라 클래스와의 상관관계와 데이터 간의 상관관계 역시 고려하면서 적절한 데이터를 선택해 모델을 학습시켰을 때 가격 경쟁력을 높이고 더 좋은 결과를 얻어낼 수 있음을 보여주었다. 이를 이용해 데이터를 수집하기 전 데이터 간의 상관관계를 사전에 조사해 불필요한 데이터 수집 비용을 줄인다. 이러한 이점은 시스템의 상용화 뿐만 아니라 화재에 대한 빠른 대응으로 재산과 인명피해를 줄이는데 기여할 수 있을 것이다. 또한, 멀티 센서를 사용하는 환경이라면 본 논문에서 수행한 상관관계 분석 과정을 통해 센서를 줄여 여러 이점을 얻을 수 있을 것이다.

#### 감사의 글

본 연구는 2024학년도 상명대학교 교내연구비를 지원받아 수행하였음(2024-A000-0294).

#### REFERENCES

- [1] Ministry of the Interior and Safety, *2022 Disaster Yearbook*, Sejong Printing Information of the Korea Culture and Sports Education Association, Sejong, 2022.
- [2] National Fire Agency, *2022 Fire Statistical Yearbook*, Yun Planning, Daejeon, 2022.
- [3] S. Y. Jeong, Y. K. Moon, T. H. Kim, S. W. Park, K. B. Kim, Y. C. Kang, and J. H. Lee, "A new strategy for detecting plant hormone ethylene using oxide semiconductor chemiresistors: exceptional gas selectivity and response tailored by nanoscale  $\text{Cr}_2\text{O}_3$  catalytic overlayer", *Adv. Sci.*, Vol. 7, No. 7, p. 1903093, 2020.
- [4] S. Y. Jeong, J. S. Kim, and J. H. Lee, "Rational design of semiconductor-based chemiresistors and their libraries for next-generation artificial olfaction", *Adv. Materials*, Vol. 32, No. 51, p. 2002075, 2020.
- [5] S. Li, W. Zhang, C. Wang, and G. Li, "Au nanoparticles decorated  $\text{ZnIn}_2\text{S}_4/\text{WO}_3$  core-shell heterostructures as highly sensitive and selective ethylene glycol gas sensors", *J. Alloys Compd.*, Vol. 998, p. 175027, 2024.
- [6] W. Ku, G. Lee, J.-Y. Lee, D.-H. Kim, K. H. Park, J. Lim, D. Cho, S.-C. Ha, B. G. Jung, H. Hwang, W. Lee, H. Shin, H. S. Jang, J.-O. Lee, and J.-H. Hwang, "Rational design of hybrid sensor arrays combined synergistically with machine learning for rapid response to a hazardous gas leak environment in chemical plants", *J. Hazard Mater. Adv.*, Vol. 466, p. 133649, 2024.
- [7] A. Gaur, A. Singh, A. Kumar, K. S. Kulkarni, S. Lala, K. Kapoor, V. Srivastava, A. Kumar, and S. C. Mukhopadhyay, "Fire sensing technologies: A review", *IEEE Sens. J.*, Vol. 19, No. 9, pp. 3191-3202, 2019.
- [8] G. Son and S. So, "A Study on Fire Alarm Test of IoT Multi-Fire Detector Combined Smoke/CO and Smoke/Temperature Sensors", *J. Soc. Disaster Inf.*, Vol. 17, No. 2, pp.

- 236-244, 2021.
- [9] A. Solórzano, J. Eichmann, L. Fernández, B. Ziems, J. M. Jiménez-Soto, S. Marco, and J. Fonollosa, "Early fire detection based on gas sensor arrays: Multivariate calibration and validation", *Sens. Actuators B Chem.*, Vol 352, p. 130961, 2022.
- [10] J. Baek, T. J. Alhindi, Y. S. Jeong, M. K. Jeong, S. Seo, J. Kang, W. Shim, and Y. Heo, "Real-time fire detection system based on dynamic time warping of multichannel sensor networks", *Fire Saf. J.*, Vol. 123, p. 103364, 2021.
- [11] J. Baek, T. J. Alhindi, Y. S. Jeong, M. K. Jeong, S. Seo, J. Kang, and Y. Heo, "Intelligent multi-sensor detection system for monitoring indoor building fires", *IEEE Sens. J.*, Vol. 21, No. 24, pp. 27982-27992, 2021.
- [12] L. Wu, L. Chen, and X. Hao, "Multi-sensor data fusion algorithm for indoor fire early warning based on BP neural network", *Inf.*, Vol. 12, No. 2, p. 59, 2021.
- [13] X. Huang and L. Du, "Fire detection and recognition optimization based on virtual reality video image", *IEEE Access*, Vol. 8, pp. 77951-77961, 2020.
- [14] B. Venuste, G. Geoffrey, and N. J. Pierre, "Smart Approach for Fire Detection Systems in Kigali", *J. Appropriate Technol.*, Vol. 9, No. 3, pp. 152-161, 2023.
- [15] L. Kou, X. Wang, X. Guo, J. Zhu, and H. Zhang, "Deep learning based inverse model for building fire source location and intensity estimation", *Fire Saf. J.*, Vol. 121, p. 103310, 2021.
- [16] P. Narkhede, R. Walambe, S. Mandaokar, P. Chandel, K. Kotecha, and G. Ghinea, "Gas detection and identification using multimodal artificial intelligence based sensor fusion", *Appl. Syst. Innov.*, Vol. 4, No. 1, p. 3, 2021.
- [17] S. Mekruksavanich and A. Jitpattanakul, "Lstm networks using smartphone data for sensor-based human activity recognition in smart homes", *Sens.*, Vol. 21, No. 5, p. 1636, 2021.
- [18] S. Kim and K. Lee, "LSTM-based Early Fire Detection System using Small Amount Data", *J. Semicond. Display Technol.*, Vol. 23, No. 1, pp. 110-116, 2024.
- [19] H. Cheng, Z. Xie, L. Wu, Z. Yu, and R. Li, "Data prediction model in wireless sensor networks based on bidirectional LSTM", *EURASIP J. Wirel. Commun. Netw.*, Vol 2019, pp. 203(1)-203(12), 2019.
- [20] L. Dong, D. Fang, X. Wang, W. Wei, R. Damaševičius, R. Scherer, and M. Woźniak, "Prediction of Streamflow Based on Dynamic Sliding Window LSTM", *Water*, Vol. 12, No. 11, p. 3032, 2020.
- [21] D. Tomar, P. Tomar, A. Bhardwaj, and G. R. Sinha, "Deep learning neural network prediction system enhanced with best window size in sliding window algorithm for predicting domestic power consumption in a residential building", *Comput. Intell. Neurosci.*, Vol. 2022, No. 1, p. 7216959, 2022.
- [22] M. Jaén-Vargas, K. M. R. Leiva, F. Fernandes, S. B. Gonçalves, M. T. Silva, D. S. Lopes, and J. J. S. Olmedo, "Effects of sliding window variation in the performance of acceleration-based human activity recognition using deep learning models", *PeerJ. Comput. Sci.*, Vol. 8, p. e1052, 2022.
- [23] S. Dong, L. Wang, L. Zeng, X. Du, C. Ji, J. Hao, X. Yang, and H. Li, "Fracture identification in reservoirs using well log data by window sliding recurrent neural network", *Geoenergy Sci. Eng.*, Vol. 230, p. 212165, 2023.
- [24] P. Schober, C. Boer, and L. A. Schwarte, "Correlation coefficients: appropriate use and interpretation", *Anesth. Analg.*, Vol. 126, No. 5, pp. 1763-1768, 2018.
- [25] J. H. Lee, T. H. Gong, and J. H. Kim, "Deriving Optimal Health Indicators Based on Fuzzy Logic using Lithium-ion Battery EIS Measurement Data and Developing SOH Estimation Based on LSTM Algorithm", *Trans. Korean Inst. Power Electron.*, Vol. 29, No. 4, pp.308-315, 2024.