

다중 센서 데이터를 활용한 오토인코더 기반 화재감지 모델

(Autoencoder Based Fire Detection Model Using Multi-Sensor Data)

김태성*, 최효린*, 정영선**

(Taeseong Kim, Hyo-Rin Choi, Young-Seon Jeong)

요약

대형 화재 발생과 그로 인한 피해가 증가하고 있는 상황에서, 화재감지 시설에 대한 신뢰는 낮아지고 있다. 현재 널리 사용되는 화학 화재감지기는 오경보가 빈번하게 발생하며, 비디오 기반 딥러닝 화재감지는 시간과 비용이 많이 소요되는 단점이 있다. 본 논문에서는 이러한 문제를 해결하기 위해 오토인코더 모델을 활용한 화재감지 모델을 제안한다. 오경보를 최소화하고 신속 정확한 화재감지를 목표로 한다. 제안된 모델은 오토인코더 방법론을 이용해 화재 데이터 없이 정상 데이터만으로 모델을 학습시킬 수 있어 새로운 환경에 적용이 용이하다. 5가지 센서 데이터를 종합적으로 반영하여 화재를 신속하고 정확히 감지할 수 있다. 다양한 초모수 조합을 실험하여 최적의 초모수를 선정하였으며, 오경보 문제를 줄일 수 있는 화재 시점 판단 규칙을 제안하였다. 제안한 모델로 화재감지 실험을 진행한 결과, 14개의 시나리오 중 13개의 시나리오에서 오경보 문제가 발생하지 않았고, 동일한 데이터로 임계치 비교 알고리즘과 결과를 비교하였을 때 더 빠른 화재 감지 성능을 보였다. 이를 통해 화재로 인한 피해를 최소화하고, 화재감지 시설의 신뢰도를 높일 수 있을 것이다.

■ 중심어 : 오토인코더 ; 화재감지 ; 이상 탐지 ; 시계열 데이터 ; 다중 센서

Abstract

Large-scale fires and their consequential damages are becoming increasingly common, but confidence in fire detection systems is waning. Recently, widely-used chemical fire detectors frequently generate lots of false alarms, while video-based deep learning fire detection is hampered by its time-consuming and expensive nature. To tackle these issues, this study proposes a fire detection model utilizing an autoencoder approach. The objective is to minimize false alarms while achieving swift and precise fire detection. The proposed model, employing an autoencoder methodology, can exclusively learn from normal data without the need for fire-related data, thus enhancing its adaptability to diverse environments. By amalgamating data from five distinct sensors, it facilitates rapid and accurate fire detection. Through experiments with various hyperparameter combinations, the proposed model demonstrated that out of 14 scenarios, only one encountered false alarm issues. Experimental results underscore its potential to curtail fire-related losses and bolster the reliability of fire detection systems.

■ Keywords : Autoencoder ; Fire detection ; Anomaly detection ; Time series data ; Multiple sensors

I. 서론

최근 이천 물류창고 화재(2020), 이천 쿠광물류센

터 화재(2021), 울산 에쓰오일 화재(2022) 등 산업 시설에서의 대형 화재 사례가 빈번하게 발생하고 있다. 소방청에서 공개한 총괄화재현황정보에 따르면, 2021년 한해 총 36,267건의 화재가 발생했으며, 이

* 학생회원, 전남대학교 산업공학과 학부생

** 정회원, 전남대학교 산업공학과 및 아트&디자인 테크놀로지 협동과정 교수

이 논문은 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. NRF-2022R1F1A1063174)

접수일자 : 2023년 12월 21일

수정일자 : 2024년 01월 25일

게재확정일 : 2024년 02월 08일

교신저자 : 정영선 e-mail : young.jeong@jnu.ac.kr

로 인해 사망 2664건, 부상 1854건의 인명피해가 발생했다. 재산피해는 10조가 넘는다. 그러나 화재감지 시설의 신뢰도는 낮아지고 있다. <그림 1>은 서울특별시에서 공개한 2016~2020년 서울시 전체 소방서의 화재 오인 출동 현황 통계이다. 통계를 따르면 ‘경보 오동작’으로 인한 출동 건수가 2016년의 119건에서 꾸준히 증가하여 2020년에는 376건으로 집계되었다. 빈번한 오경보로 인해 소방인력과 장비가 불필요하게 사용되고 있으며, 실제 화재 현장에 출동하지 못하는 상황이 일어날 수도 있다. 또한, 실제 화재 발생 시 경각심이 줄어들고 대응이 소홀해질 우려가 있다.

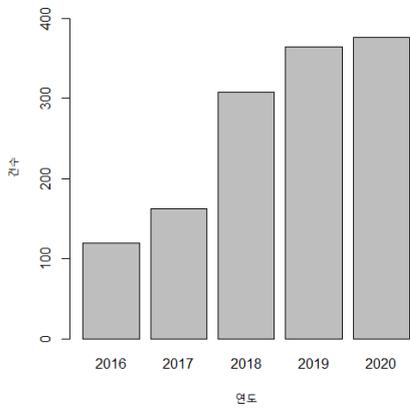


그림 1 . 경보 오동작으로 인한 출동 건수

현재 주로 사용되는 화학 화재감지기의 경우, 오경보가 빈번하게 발생한다. 2021년 1월부터 7월까지 전북 지역에서 발생한 763건의 오경보 중, 3회 이상 신고된 176개소를 점검한 결과, 전체 오경보의 93.1%는 건축물에 설치된 화재감지기에서 발생하였으며, 습기로 인한 결로현상(60.1%), 먼지 및 분진(16.1%)등 환경적인 요인이 주요 원인으로 나타났다. 구체적으로는 전체 오경보의 52.1%를 차지하는 연기 감지기는 증기나 습기에 의해, 31.7%를 차지하는 차동식 감지기는 습기나 결로현상으로 인해, 마지막으로 4.8%를 차지하는 불꽃감지기는 용접이나 절단 등 불꽃을 동반한 공장에서 오류가 자주 발생한다.

최근에는 비디오 이미지를 딥러닝을 통해 화재를 감지하는 연구가 진행되고 있다. 하지만, 고차원의 이미지 데이터를 분석하므로 센서 데이터를 분석하는 것보다 시간이 오래 걸려 화재가 어느 정도 지난 후 감지해내며, 장비 비용도 비싸다는 문제가 있다.

본 논문에서는 오경보를 최소화하고 신속 정확한 화재감지를 위해 오토인코더 모델을 활용한 화재감지 모델을 제안한다. 3가지 장소에 설치한 Temperature, CO, Ionization, Photoelectric, Smoke obscuration 5가지 센서 데이터를 사용하여 정상 상황에서의 데이터를 오토인코더 모델로 학습한 후, 화재 발생 시 이상치를 탐지하여 화재를 감지하고, 오경보 문제를 최소화할 수 있도록 3가지 모델의 결과를 종합적으로 검토하여 화재를 판단한다. 실험 결과 가장 좋은 성능을 보이는 초모수(hyperparameter)를 최종 결정한다. 이후 본 논문의 모델과 임계치 비교 알고리즘의 성능을 측정하고 비교한다.

II. 본론

1. 관련 연구

인공지능을 활용한 화재감지 성능을 분석한 선행 연구 내용은 다음과 같다.

류진구·곽동걸(2020)[1]은 영상 전처리를 통해 영상 내에서 관심영역을 검출하고 해당 영역의 화재 여부를 딥러닝 기반의 합성곱 신경망을 통해 추론하였다. 화재 이미지는 화염, 연기, 연무 세 가지로 분류하여 학습하였다. 영상 내에서 객체 검출의 어려움이 있는 연무 형태의 데이터셋을 추가하여 학습을 진행하였고, 평가결과 평균 92.3%의 정확도와 93.5%의 정밀도로 화재를 검출하였다.

박정규·남기훈(2020)[2]은 4개의 센서를 설치하고 정상 상황에서의 최댓값을 센서 별 임계치로 설정한 후, 2개의 센서에서 임계치를 넘으면 화재 상황으로

판단하는 임계치 비교 알고리즘을 사용하였다. 실제 화재 실험에서는 90%의 정확도를 보였다.

신승엽·김한준(2020)[3]은 화재 데이터만 존재하는 단일 클래스의 화재 건물 데이터에서 라벨이 없는 데이터를 오토인코더로 학습하여 추가한 후, 이를 기반으로 분류 기계 학습을 진행했다. 비지도 학습 기법인 오토인코더를 피쳐 추출기로 활용하여 화재위험 건물 탐지의 재현율을 높였다.

정순배·이천희·권택현(2015)[4]는 4가지 종류의 센서로 센서 다중화를 구현하고, 화재 감지의 신뢰성을 향상시켰다. 각 센서의 아날로그 신호를 활용하여 실시간 모니터링을 가능하게 하였으며, 센서별 가중치 설정으로 알람 조건을 조절할 수 있게 했다.

김원진·김병진·정기석(2011)[5]은 온도, 연기, 이산화탄소를 감지할 수 있는 다중센서 데이터를 LWPR알고리즘으로 학습하여 화재 여부를 판단했다. 비정상 데이터를 추가 보정하여 보정된 센서 데이터 검토를 통해 화재 발생 여부를 판단했다.

김경룡·임은혜·임유신·김영천(2015)[6]는 다중 센서 데이터를 활용하여 ATmega328 기반의 아도이드 우노 보드와 지그비 쉘드로 하드웨어를 구성하였다. 상태 변화에 따라 정상, 탐지, 경보 3가지 상태로 전이하는 알고리즘을 적용하여 이상 징후를 감지하고 화재 위험을 모니터링하도록 했다.

2. 연구의 차별성 및 착안점

이상의 선행연구들을 고찰한 결과, 기존 연구의 한계점 및 본 연구의 차별성은 다음과 같다.

정순배·이천희·권택현(2015), 김원진·김병진·정기석(2011) 등의 연구는 센서 다중화를 구현하고 화재 감지 신뢰성을 향상시켰지만, 환경적 특성 학습에 관한 사항은 고려되지 않았다. 본 연구는 센서가 설치되는

환경에서의 정상 데이터 학습 후, 화재 감지를 진행하기 때문에 각 환경적 특성에 맞는 학습 및 감지가 가능하다.

류진구·곽동걸(2020), 김병준(2021) 등의 연구는 화재 상황의 비디오 이미지를 딥러닝하여 화재를 감지하였지만, 다음과 같은 한계점이 있다. 화재 및 정상 상태의 비디오 데이터가 모두 필요한 점, 고차원의 이미지 데이터 분석에 시간이 소요되는 점, 영상 촬영 장비나 영상 데이터 서버 등의 장비에 비용이 소모된다는 점이다. 이에 비해 본 연구에서 사용된 오토인코더 기반의 알고리즘은 화재 데이터 없이 화재 감지가 가능하고, 센서 데이터 분석 속도가 빨라 실시간 화재 감지가 가능하다. 또한, 5개의 센서로 구성된 단순한 구조로 비용을 절감해 대규모 시스템 구축에 유리하다.

또한, 신승엽·김한준(2020)은 본 연구와 동일하게 화재 연구에 오토인코더를 적용하였지만, 화재 발생 상황에서 실시간으로 화재를 감지하는 것이 아니라, 화재위험 건물 탐지에 중점을 두어 화재 감지에 대한 연구는 진행되지 않았다.

Z. Xu, Y. Guo and J. H. Saleh(2021)은 화재 감지에 LSTM 오토인코더를 적용하였으나, 온도 데이터 중심으로 진행되었다. 본 연구는 5개의 다중 센서 데이터를 활용하여 더 정확하고 신뢰성 있는 화재 감지가 가능하며, 다양한 환경에서 적용할 수 있다[14].

따라서 본 연구에서는 저가의 다중 센서 데이터를 활용하여 실시간으로 수집한 데이터를 이용하였고, 화재 데이터가 충분하지 않은 상태에서도 실시간 화재 감지가 가능한 모델을 제안한다.

3. 데이터 소개

본 연구에서 사용한 데이터는 Nist 사이트에서 제

공된 화재 실험 데이터이다. 해당 데이터는 화재 실험 부스를 제작하여 거실, 방, 부엌 3가지 장소에 5가지 화학 센서(Temperature, CO, Ionization, Photoelectric, Smoke obscuration)를 설치하고, 1초 단위로 얻은 시계열 데이터이다.

연구를 위해 화재 유형이 명시된 14개의 fire scenario를 이용하였다. 하나의 시나리오마다 3*5=15개의 시계열 데이터와 실제 화재 유무를 나타내는 하나의 열을 포함하여 총 16개의 열로 구성되어 있다.

본 연구에서는 각 fire scenario에서 시간에 따른 센서 값의 변화를 이용하였다. <그림 2>는 fire_scenario_11에서 시간에 따른 거실의 5가지 센서 수치를 시각화한 것이다. 화재가 시작한 이후, CO를 제외한 4가지의 센서 수치가 상승하는 것을 확인할 수 있다.

본 연구에서 사용된 시나리오마다 화재 유형과 화재 시점, 발화 장소 및 발생원이 다르기에 화재 유형 별로 성능을 비교하였다. <표 1>은 시나리오별 화재 유형과 화재 시점, 발화 장소 및 발생원을 나타낸 것이다.

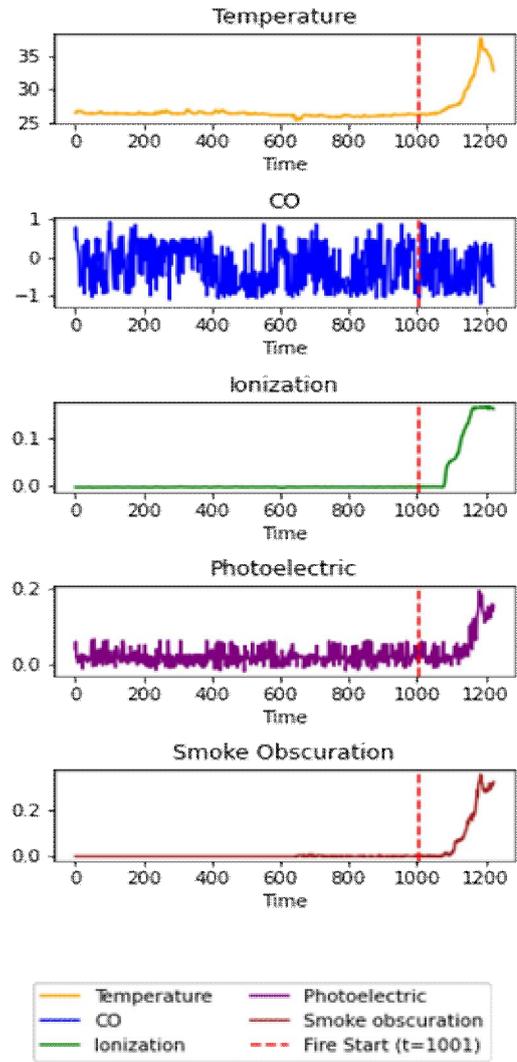


그림 2 . 거실의 센서 값 변화

표 1. 화재 시나리오별 구성

화재 유형	Sc#	화재 발생 시점	발화 장소	발생원
smoldering	3	957	bedroom	mattress
	4	667	living room	chair
heating	5	853	kitchen	oil
	6	678	kitchen	oil
	7	1000	kitchen	oil
flaming	8	1000	living room	chair
	9	651	living room	chair
	10	1000	living room	chair
	11	1000	living room	chair
	12	738	bedroom	mattress
	13	729	bedroom	mattress
	14	1000	bedroom	mattress
	15	1000	bedroom	mattress
	16	1000	bedroom	mattress

세 가지 화재 유형의 특성은 다음과 같다. smoldering fire는 물질 내부에서 연소가 진행되는 형태로, 화염이 없거나 미세한 불꽃만 발생하며, 연기와 열이 천천히 발생한다. 이러한 특성상 발견하기가 어렵고, 발견하더라도 소멸해버리기에 감지에 많은 어려움이 있는 유형이다. heating fire는 연소하지 않고 전기, 가스 등에 의해 열이 발생하는 형태로, 전기적 결함으로 인한 장치 과열이나 가스누설 등이 해당한다. 마지막으로 flaming fire는 산소와 연소체의 작용으로 불꽃과 화염이 발생하는 형태이며, 불꽃이 번지면서 빠르게 확산할 우려가 있는 유형이다.

화재 유형별로 센서 데이터의 시계열 흐름이 다르게 나타난다. <그림 3>은 3가지 화재 유형의 시간(초)에 따른 거실 온도 변이며, 위에서부터 차례로 smoldering, heating, flaming이고, 빨간색 세로선은 화재 시작 시점을 나타낸다.

4. 분석 모형

가. 슬라이딩 윈도우

슬라이딩 윈도우 기법은 시계열 데이터에서 이동하는 윈도우 창을 사용하여 데이터를 처리하는 기법이다. 이 기법은 특정 크기의 윈도우를 정의하고, 이 윈도우를 일정한 간격으로 이동시켜가며 데이터를 처리한다.

<그림 4>와 같이 32개의 행을 하나로 묶고, 일정 크기의 frame을 옮겨가며 데이터를 생성하는 슬라이딩 윈도우를 적용하였다[7][8]. train data의 frame은 데이터의 길이에 따라 다르게 설정했고, test data는 1 frame(1초)으로 고정했다.

시나리오별로 화재 시점과 데이터 크기가 다르지만, 슬라이딩 윈도우를 적용하면 모델에 입력되는 데이터 차원이 일정하게 된다. test data는 화재 데이터로만 구성하지 않고, 시계열 데이터의 특징을 살려 데이터를 구성하였다. fire_scenario_16의 경우에는 950번째 데이터부터 test data로 사용하였다. 그렇게 구성하면 실시간으로 정상 상황의 데이터가 들어오다가 969~1000이 묶인 윈도우가 들어오는 시점부터 화재 상황에 해당하는 데이터가 하나씩 차례로 포함되며, 화재 데이터가 처음 들어오는 시점을 화재가 시작되는 시점으로 판단했다.

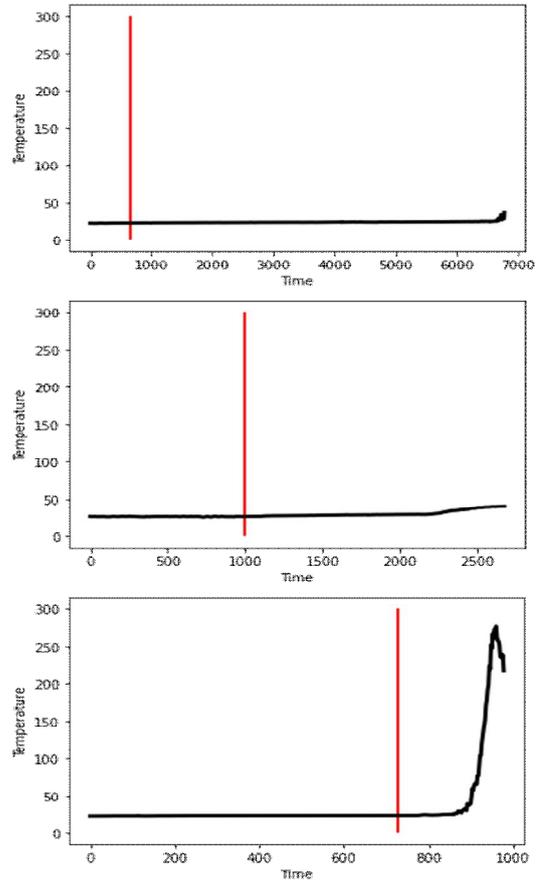


그림 3 . 화재 유형별 거실 온도 센서의 변화

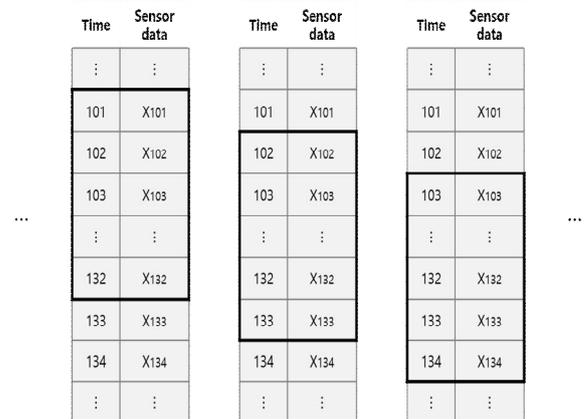


그림 4 . 슬라이딩 윈도우의 예시

나. 오토인코더

오토인코더(Auto-encoder, AE)는 1980년대에 제안된 비지도학습 알고리즘이다. 입력 데이터를 압축하는 인코더(encoder)와 압축된 데이터에서 원본 데이터를 복원하는 디코더(decoder)로 구성된다. 오

토크인코더의 핵심 아이디어는 입력 데이터를 재구성하는 과정에서 입력 데이터의 핵심적인 특징을 학습하는 것이다.

인코딩 단계에서 주어진 입력 데이터를 저차원의 잠재 벡터(Latent Vector)로 압축하면 입력 데이터의 중요 특징이 압축되어 나타나게 된다. 디코딩 단계에서는 잠재 벡터를 사용하여 원본 데이터와 유사한 형태로 재구성한다. 원본 데이터와 재구성된 데이터의 차이를 비교하여 이상 탐지를 수행할 수 있다.

본 연구에서 최초로 고려한 오토인코더 모델은 <그림 5>와 같이 160(32*5)차원의 input과 output, 80차원의 hidden layer, 40차원의 latent space로 구성되어 있다.

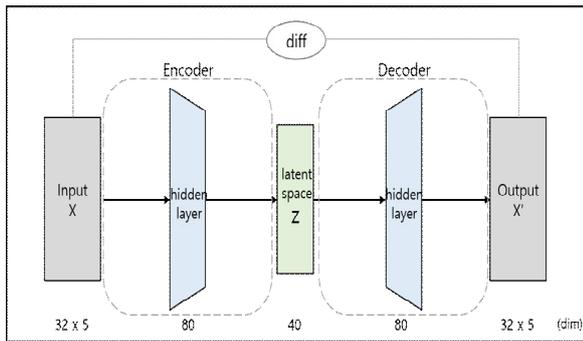


그림 5. 오토인코더 설계 과정

실제 화재 데이터가 존재해야 학습할 수 있는 다른 방법론들과 달리, 오토인코더는 비지도 학습 기법으로 정상 상태의 비화재 데이터만으로 학습이 가능하다. 따라서 새로운 환경에 모델을 설치하여 이전의 화재 데이터가 존재하지 않아도 새로운 환경에서 화재감지를 진행할 수 있다는 장점이 있다.

기존 연구와 비교하면 다양한 센서를 종합적으로 활용하여 화재를 감지하기 때문에 단일 화학 센서를 사용하는 기존 방법보다 신뢰성이 높으며, 고화질의 이미지 감지 방식보다 데이터 처리 속도가 빨라 조기 화재감지가 가능하다[9]. 또한, 필요한 데이터양이 적고 구조가 간단하여 장비 구성에 큰 비용이 들

지 않아서 대규모 시스템 구축에 유리하다[4].

다. 화재시점 판단 규칙

본 연구에서 장소별 3개 모델의 결과를 통해 화재시점을 판단한 방법은 다음 2가지이다.

첫째, 화재를 연속하여 5초간 감지한 시점을 최초 화재감지 시점으로 판단하여 순간적인 이상치 발생에 의한 false alarm 문제를 방지한다. 실제 화재가 일어나기 전부터 오경보가 발생해 지속해서 화재를 감지한 경우는 화재감지 소요 시간을 0으로 표현하였다. 아래의 <표 2>는 실험 결과의 예시이다. 1번째 시나리오의 거실은 오토인코더 모델이 5초 동안 화재를 감지한 시점이 화재 발생 32초 후라는 뜻이며, 방에서는 화재가 발생하기 전부터 오경보가 울렸고 이를 0으로 나타낸 것이다.

표 2. 화재 시점 판단 규칙 예시1

화재 유형	Sc#	화재감지에 소요된 시간(sec)		
		거실	방	부엌
flaming	1	32	0	74
	2	56	82	101

둘째, 3개 중 2개의 모델에서 동시에 화재를 감지한 시점을 최종 화재감지 시점으로 판단하였다. 이를 통해 오경보(false alarm)을 줄이고 모델의 신뢰성을 높였다. <표 3>을 보면 1번째 시나리오의 방에서 오경보가 발생한 것을 확인할 수 있다. 각각의 모델을 합하여 화재감지를 하지 않는다면, 실제 화재가 발생하기 전부터 방에 설치된 오토인코더 모델에서는 오경보가 울리게 된다. 본 연구는 오경보를 최소화하여 신뢰할 수 있는 모델을 만드는 것이기에 2개의 모델에서 동시에 화재를 감지한 시점을 최종 화재감지 시점으로 판단하였다.

표 2. 화재 시점 판단 규칙 예시1

화재 유형	Sc#	화재감지에 소요된 시간(sec)			
		거실	방	부엌	최종
flaming	1	32	0	74	32
	2	56	82	101	82

아래의 <표 4>는 화재시점 판단 규칙을 따라 최초로 선정된 모델의 화재감지 결과이다. 모든 시나리오에서 최초로 화재감지가 일어난 이후에 지속해서 화재를 감지하였다. 화재 시점 판단 규칙의 두 번째 규칙을 따라 최종 화재감지 시점을 정하면 오경보의 수를 줄여 신뢰 높은 화재감지가 가능한 것을 확인하였다. 다만, scenario 9의 경우 방과 부엌에서 화재 직전부터 오경보가 5개 연속으로 발생하였고, 이에 오경보로 판단하였다.

표 4. 최초 선정 모델의 화재감지에 소요된 시간

화재 유형	Sc#	화재감지에 소요된 시간(sec)			
		거실	방	부엌	최종
smoldering	3	719	-	0	719
	4	-	17	-	-
heating	5	94	135	86	94
	6	108	0	352	108
	7	150	0	121	121
flaming	8	70	85	0	70
	9	80	0	0	오경보
	10	6	78	105	78
	11	25	90	116	90
	12	37	0	103	37
	13	4	28	122	28
	14	0	52	236	52
	15	0	31	102	31
16	80	26	122	80	

(‘-’ : 감지하지 못한 경우)

마. 초모수(hyperparameter) 결정

오토인코더에는 여러 초모수(hyperparameter)가 존재하며, 모델의 성능에 영향을 끼친다. 본 연구에서는 반복수(epoch)를 150으로 고정하고, 은닉층의 차원과 개수를 주요 초모수로 고려한다. 4개의 모델 각각에 대해 다양한 초모수 조합을 시도한 뒤, 그중에서 가장 우수한 성능을 보이는 초모수 조합을 최종적으로 선정하였다[11]. 모든 모델의 반복수(epoch)는 150으로 고정했다.

아래의 <표 5>는 각 모델의 은닉층(hidden layer) 구성에 따른 시나리오별 감지시간 평균과 false alarm rate 평균을 나타낸다. 위의 <표 4>를

참고하면 화재 유형 중 ‘smoldering’ 유형의 화재에 해당하는 scenario 3은 화재감지 속도가 매우 느리고, scenario 4에서는 화재를 감지하지 못하는 결과를 보였으므로 ‘smoldering’ 유형의 화재는 제외하였다. 따라서 ‘heating’, ‘flaming’ 유형의 시나리오 12개에 대해 4개 모델의 시나리오별 화재 감지시간과 false alarm rate를 실험하였다. 아래의 <표 5>는, 각 모델별로 12개 시나리오의 화재 감지시간 평균과 false alarm rate 평균을 나타낸다.

표 5. 4가지 모델의 은닉층 구성에 따른 시나리오별 감지시간 평균과 false alarm rate 평균

모델 번호	은닉층 구성	화재감지 시간 평균(sec)	false alarm rate 평균
1	(40,10,40)	68.5	23.88
2	(80,40,80)	68.33	22.5
3	(120,60,120)	69.59	23.38
4	(80,40,20,40,80)	68.33	24.21

(소수점 아래 셋째 자리에서 반올림)

아래의 <그림 6>은 <표 5>에 기반하여 생성한 산점도이다. 이 산점도에서 x축은 시나리오별 화재 감지 시간 평균을, y축은 false alarm rate의 평균을 나타낸다. 두 값이 모두 작을수록 화재 감지 성능이 우수하다는 것을 의미하므로, 가장 원점에 가까운 ‘모델 2’를 최종 모델로 선정하였다. 따라서 최종 선정 모델의 초모수 구성은 은닉층 개수 3개이며, 각 은닉층의 차원은 (80, 40, 80)이다.

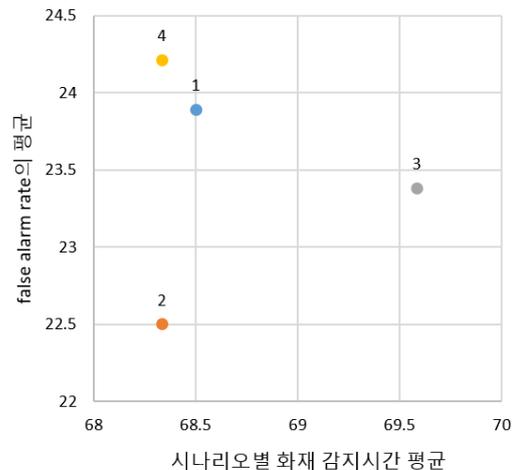


그림 6. 화재 감지 성능 비교 산점도

5. 실험 결과

가. 화재 유형별 감지 결과

본 연구에서 제안하는 오토인코더 모델의 화재감지 실험 결과는 아래의 <표 6>과 같다. False Alarm Rate의 허용 범위 내에서 높은 True Positive Rate를 유지하기 위하여, 화재 감지 성능을 시간을 기준으로 판단하였다. scenario 9의 경우 오경보 현상이 나타났으나, 이를 제외한 모든 시나리오에서는 오경보 없이 준수한 감지시간을 보인다.

표 6. 최종 모델의 감지시간과 오경보 개수

화재 유형	Sc#	감지시간	오경보 개수		
			거실	방	부엌
smoldering	3	719	0	0	6
	4	-	0	0	0
heating	5	94	0	17	49
	6	108	0	32	0
	7	121	0	28	0
flaming	8	70	0	0	60
	9	오경보	3	47	60
	10	78	10	0	0
	11	90	0	7	0
	12	37	0	51	0
	13	28	2	0	0
	14	52	60	0	0
	15	31	60	0	0
16	80	0	0	0	

(‘-’ : 감지하지 못한 경우)

나. 임계치 비교 알고리즘과 결과 비교

본 논문에서 제안하는 오토인코더 알고리즘은 화재 데이터가 부족한 상황에서, 정상 데이터만으로 모델을 학습시킨 후 화재를 감지할 수 있는 비지도 학습 알고리즘이다. 따라서, 정상 데이터만으로 활용 가능한 임계값 기반의 알고리즘으로 모델 성능 비교를 진행하였다. 공정한 평가를 위해 동일한 데이터를 적용하여 모델 성능을 비교해보았다[2]. 임계치 비교 알고리즘의 화재 판단 기준은 5가지 센서 데이터의 비화재 상황의 최댓값을 임계치로 설정하

여 실험을 진행하였고, 장소별로 화재감지 실험을 진행한 후에 2가지 장소에서 센서 데이터가 임계치가 넘은 지점을 화재감지 시간으로 판단했다.

아래의 <표 7>은 임계치 비교 알고리즘의 각 임계치 별 화재 감지 속도이다. 정상시의 max값을 사용하여 임계치 비교 알고리즘을 적용해보았을 때, fire scenario 6에서만 오경보가 발생하였다. 임계치를 정상시의 상위 2%값과 5%값으로 설정하여 진행한 실험에서는 화재 감지 시간이 비교적 빨랐지만, 각각 5번과 7번의 오경보가 나타났다. 화재 감지 시간의 단축도 중요하지만, 실험 케이스의 과반수가 가까이 오경보를 보이는 것은 화재감지에 대한 신뢰를 떨어트릴 우려가 있다고 판단하였다. 따라서 정상시의 max 값을 임계치로 사용해 오토인코더 모델과 성능을 비교하였다.

표 7. 임계치 기반 알고리즘의 임계치 별 화재감지 속도

화재 유형	Sc#	임계치 별 화재감지 속도		
		max	상위 2%	상위 5%
smoldering	3	682	678	548
	4	569	*	*
heating	5	98	83	*
	6	*	*	*
	7	256	105	33
flaming	8	74	*	*
	9	135	*	*
	10	110	*	*
	11	113	79	65
	12	38	*	*
	13	57	37	*
	14	152	149	137
	15	82	41	21
	16	109	41	25

(* : 오경보 발생)

아래의 <표 8>은 임계치 비교 알고리즘(TA;Treshold Algorithm)과 오토인코더 모델(AE;Auto-Encoder)의 화재 감지 시간을 비교한 결과이다. 임계치 비교 알고리즘의 경우, 화재 감지가 늦어 오경보 현상이 나타나지 않아 감지 시간을 비교 기준으로 했다. 오토인코더의 감지 시간에서 임계치 비교 알고리즘의 감지 시간을 차감한 값을

통해 두 모델을 비교하였다. 따라서 표에서 밑줄 볼드체로 표시된 음수값은 감지 속도 측면에서 오토인코더 모델이 임계치 비교 알고리즘보다 더 우수함을 의미한다.

임계치 비교 알고리즘에서 오토인코더에서 감지하지 못한 scenario4의 화재를 감지하였지만, 이를 제외한 시나리오 중 단 2개의 시나리오에서만 오토인코더보다 빠른 화재감지 성능을 보였다. 또한, scenario6에서는 오토인코더 모델의 오경보 현상이, scenario9에서는 임계치 비교 알고리즘에서의 오경보 현상이 나타났다.

표 8. 임계치 비교 알고리즘(TA)과 화재 감지 시간 비교

화재 유형	Sc#	AE	TA	AE-TA
smoldering	3	719	682	37
	4	-	569	569
heating	5	94	98	-4
	6	108	오경보	-
	7	121	256	-135
flaming	8	70	74	-4
	9	오경보	135	-
	10	78	110	-32
	11	90	113	-23
	12	37	38	-1
	13	28	57	-29
	14	52	152	-100
	15	31	82	-51
16	80	109	-29	

(‘-’ : 감지하지 못한 경우)

III. 결론

본 논문은 5가지 센서 데이터를 활용하여 이상 탐지를 통해 화재를 감지하는 오토인코더 모델을 제안하였다. 하이퍼파라미터값을 변화시켜가며 false alarm을 최소화하고 조기 화재감지가 가능한 최적의 모델을 설계하였다. 제안한 모델은 3가지 장소에 각각 5개의 센서를 설치하여 장소별 1개의 모델이 화재감지를 수행하고, 3개 중 2개의 모델에서 화재를 감지한 시점을 최종 화재감지 시점으로 판단한다.

실험 결과를 요약하면, 첫째, 14개의 시나리오에서 false alarm이 발생하지 않았고, smoldering을 제외한 화재 유형에서 준수한 화재감지 성능을 보였다. 둘째, 임계치 비교 알고리즘과 동일 데이터로 실험한 결과에서는 14개 시나리오 중 11개 시나리오에서 우수한 화재감지 성능을 보였다.

본 연구는 사전 화재 데이터 없이도 새로운 환경에서 학습할 수 있으며, 여러 센서 데이터를 종합적으로 활용하여 이상 탐지 정확도가 높다는 점에서 의미가 있다. 또한, 데이터 처리 속도가 빠르고, 필요한 데이터양과 장비가 적어 시스템 구축에 큰 비용이 들지 않으므로 IoT 화재감지 시스템 구축에 유리할 것으로 기대된다[6]. 특히, heating과 flaming 화재 유형 감지에 높은 성능을 보이므로, 산업 시설에 적용하기 적절하다. 5개의 센서를 단일 장치로 여러 장소에 설치하여 본 연구의 오토인코더 알고리즘으로 화재감지를 수행하고, 관리자에게 실시간 데이터 전송 및 정보 알림을 제공할 수 있다.

본 논문의 한계점은 다음과 같다. 첫째, smoldering 유형 화재감지의 어려움을 완전히 극복하지 못하였다. 둘째, 확보한 데이터 외의 다른 화재 데이터의 적용성이 불확실하다는 점이다. 셋째, 정상데이터와 화재데이터가 충분히 존재하는 경우, 지도학습 모델의 정확도가 더 높을 가능성이 있다.

향후 연구과제로 본 연구에 사용한 데이터 외의 다른 화재 상황의 데이터가 추가로 수집이 된다면, 다양한 상황에서의 화재감지 정확도가 향상될 것으로 기대된다. 또한, 추가적인 연구를 통해 모델을 수정하고, smoldering 유형 화재감지의 어려움을 개선할 필요가 있다.

REFERENCE

- [1] 류진규, 곽동걸, “딥러닝 기반의 합성곱 신경망을 이용한 화염 및 연기 감지 알고리즘에 관한 연구”, *한국방재학회논문집*, 제20권, 제1호, 223-232쪽, 2020년 2월
- [2] 박정규, 남기훈, “화재 감지 시스템을 위한 다중 센

- 서 데이터 퓨전 알고리즘의 구현”, 한국컴퓨터정보학회논문지, 제25권, 제7호, 9-16쪽, 2020년 7월
- [3] 신승엽, 김한준, “오토인코더를 이용한 단일 클래스 화재위험 건물 탐지 성능의 개선”, 한국정보과학회 학술발표논문집, 853-855쪽, 2019년 6월
- [4] 정순배, 이천희, 권택현, “센서 다중화를 통한 화재 감지센서의 감지성능 향상”, *대한기계학회 춘추학술대회*, 19-20쪽, 2015년 5월
- [5] 김원진, 김병진, 정기석, “센서 네트워크 기반 신뢰성 향상 화재감지 기법”, *한국통신학회 학술대회논문집*, 998-999쪽, 2011년 6월
- [6] 김경룡, 임은혜, 임유신, 김영천, “다중 센서와 ZigBee 기반의 화재 경보 알고리즘 및 장치 구현”, *한국정보과학회 학술발표논문집*, 2039-2041쪽, 2015년 6월
- [7] Jaeseung Baek, Taha J.Alhindi, Young-Seon Jeong, Myong K. Jeong, Seongho Seo, Jongseok Kang, Jaekyung Choi, Hyunsang Chung, “Real-time fire detection system based on dynamic time warping of multichannel sensor network”. *Fire Safety Journal*. 제123호, 103364, 2021년 7월
- [8] 전건우, 오승택, 임재현, “자연광의 색온도 주기 재현을 위한 슬라이딩 윈도우 기반 이상치 판정 알고리즘”. *멀티미디어학회논문지*, 제24권, 제1호, 30-39쪽, 2021년 1월
- [9] Jaeseung Baek, Taha J. Alhindi, Young-Seon Jeong, Myong K. Jeong, Seongho Seo, Jongseok Kang, Yoseob Heo, “Intelligent Multi-Sensor Detection System for Monitoring Indoor Building Fires,”, *IEEE Sensors Journal*, 제21권, 제24호, 27982-27992쪽, 2021년 12월
- [10] 서명교, 윤원영, “오토인코더를 이용한 열간 조압 연설비 상태모니터링과 진단”. *한국품질경영학회*. 제27권, 제1호, 75-86쪽, 2019년 2월
- [11] Z. Xu, Y. Guo and J. H. Saleh, “Advances Toward the Next Generation Fire Detection: Deep LSTM Variational Autoencoder for Improved Sensitivity and Reliability,”, *IEEE Access*, 제9권, 30636-30653쪽, 2021년 2월



김태성(학생회원)

2018년~현재 전남대학교 산업공학과 학사과정
<주관심분야 : 머신러닝, 딥러닝, 데이터 마이닝>



최효린(학생회원)

2020년~현재 전남대학교 산업공학과 학사과정
<주관심분야 : 데이터마이닝, 스마트 워크, 공정관리>



정영선(정회원)

1997년 전남대학교 산업공학과 학사 졸업
2001년 고려대학교 산업공학과 석사 졸업
2011년 뉴저지주립대학교 산업시스템 공학과 박사 졸업
2014년~현재 전남대학교 산업공학과 교수
<주관심분야 : 통계적 데이터마이닝, 반도체 공정 자동화>