

GCN 모델을 이용한 화재 상황인식

김시진¹, 박지수², 손진곤³

¹(주)쿠노소프트

²전주대학교 컴퓨터공학과

³한국방송통신대학교 대학원 정보과학과

sizin@kounosoft.com, jisupark@jj.ac.kr, jgshon@knou.ac.kr

Recognition of Fire Situation Using GCN model

Si Jin Kim¹, Ji Su Park², Jin Gon Shon³

¹Kounosoft Co. Ltd

²Dept. of Computer Science and Engineering Jeonju University

³Dept. of Computer Science, Graduate School, Korea National Open University

요 약

우리나라에서는 지난 10년간 매년 4만 건 내외의 화재가 발생하여 많은 인명 피해와 경제적 손실이 발생하고 있다. 화재가 발생했을 때는 화재를 신속히 진압하여 인명 피해와 경제적 손실을 최소화하여야 한다. 또한, 화재 사고를 예방하기 위해 화재의 발화 원인이 무엇인지 알아내야 한다. 기존의 화재 경보 시스템에서는 온도, 연기, 불꽃 센서 등으로 화재를 감지하였으나 오경보나 화재를 인식하지 못하는 문제, 화재 원인을 구분하지 못하는 문제 등이 있었다. 또한, 사람이 화재 발생을 인지하기까지 시간이 많이 소요될 수 있고 부재로 인해 화재 상황인식이 늦어질 수도 있는 문제가 있었다. 이러한 문제를 해결하기 위해 본 논문에서는 GCN(Graph Convolutional Network) 모델을 이용하여 화재 상황에서의 복합 센서 상황을 학습해서 실제 화재 사고가 발생했을 때 화재의 원인을 구분할 수 있는 모델을 제안한다.

Keywords : 화재, GCN(Graph Convolutional Network) 모델, 화재 원인 구분, 복합 센서

1. 서론

소방청 국가 화재 정보 시스템에서 실시간으로 제공하는 전국 화재 현황분석 표에 따르면 우리나라에서는 최근 10년간 매년 4만 건 내외의 화재가 발생하여 많은 인명피해와 경제적 손실이 발생하고 있는 것을 알 수 있다[1]. 화재 예방은 국민의 생명과 재산을 보호하기 위하여 화재가 발생하지 않게 사전에 조치를 취하는 활동을 말한다[2]. 화재는 불로 인한 재난으로 인명 피해와 물적 피해 등 심각한 피해를 주고 있다. 따라서 초기에 화재를 신속하고 정확하게 감지해서 피해를 막을 필요가 있다. 화재 상황인식은 실내의 위험을 예측할 수 있고 화재의 원인을 구분할 수 있기 때문에 중요하다. 실내의 위험은 일반화재, 전기화재, 가스화재, 등이 있다.

화재 상황인식은 실험실에서 실험으로 인한 화재를 예측하기 위해서 가스누출 탐지나 불꽃을 감지할 수 있고, 또한 주택, 아파트, 공장, 실험실, 고층 건물 등 여러 장소에서 화재가 발생할 수 있는데, 이


를 예측하기 위해서 복합센서의 탐지가 필요하다. 복합센서는 습도, 온도, 프레온가스(MQ139), 총 휘발성 유기화합물(TVOC), 등가 이산화탄소(eCO2), 화재 감지 센서 등으로 이루어져 있다. 화재의 종류에는 일반화재, 전기화재, 유류화재, 금속화재, 가스화재 등이 있다. 화재가 발생했을 경우 소방관서에 발생 장소와 상황 등을 신고하여야 한다.

기존의 화재 경보 시스템의 검출기에는 온도, 연기, 불꽃, 가스, 에어 샘플링 등이 있다[3]. 하지만 단순히 나열된 센서 수치만으로는 실내의 화재 상황을 인식하고 화재 원인을 구분하기에는 어려운 문제가 있었다. 이러한 문제를 해결하기 위해서 화재 상황인식을 통하여 화재 상황을 분류할 수 있는 모델 개발이 필요하다. 기존의 화재 경보 시스템은 화재의 원인까지 구분해 주지 못하고 있다. 본 연구에서는 그래프 형태의 데이터를 처리할 수 있는 GCN 모델을 이용하여 화재 경보 시스템을 개선하는 것을 연구 목적으로 삼는다.

2. 관련 연구

GCN(Graph Convolutional Network)는 그래프 형태의 데이터를 처리할 수 있는 인공지능망 구조이며 그래프를 구성하는 노드(node)와 노드 사이를 연결하는 간선(edge)을 하나로 모아 놓은 구조이다. GCN은 각 노드와 근접한 노드들과의 관계만 본다는 점에서 CNN(Convolutional Neural Network)과 유사하지만, 화학적 성질 예측, 논문 인용 그래프 분석 등 여러 형태의 그래프 문제를 푸는 데 성공적으로 적용되었다[4].

그래프를 행렬로 표현하는 방법에는 크게 인접행렬(adjacency matrix)과 특징행렬(feature matrix) 두 가지가 있다. 먼저 인접행렬이란 그래프의 각 노드를 행렬의 행과 열로 하여 노드 간의 연결 관계를 표현한 것이다. 주어진 그래프를 인접행렬로 나타낸 것은 (그림 1)과 같다.



(그림 1) 그래프와 인접행렬

(그림 1)에서 오른쪽 인접행렬은 각 행과 열이 순서대로 노드를 의미하며, 각 노드가 연결되어 있는지를 정수로 나타낸 행렬로 표기한다. 왼쪽 그래프의 1번 노드의 경우 2, 3번 노드와 연결되어 있으므로 0, 1, 1, 0, 0으로 표시된다. 2번 노드의 경우 1, 3, 4, 5번 노드와 연결되어 1, 0, 1, 1, 1로 표시되고 나머지 3, 4, 5번 노드들도 마찬가지로 연결되어 있는 노드가 정수 1로 오른쪽 인접행렬로 표시된다.

행렬의 크기는 노드가 N개일 때, $N \times N$ 이 된다. (그림 1)에서는 노드가 5개이므로 5×5 행렬이 된다. 노드 1에서 노드 2로의 연결 개수가 행렬(1, 2) 원소의 값이 된다. 무향 단순 그래프의 경우 인접행렬로 표현하면 모든 원소는 0 또는 1의 값을 가지게 되고, 대각 원소는 0의 값을 가진다[5]. 또한, 그래프에서 각 노드의 특징을 행렬로 나타낸 특징행렬은 (그림 2)와 같다.

feature matrix

	feature1	feature2	feature3	feature4	feature5
노드1	1	1	1	0	0
노드2	1	1	1	1	1
노드3	1	1	1	1	1
노드4	0	1	1	1	1
노드5	0	1	1	1	1

(그림 2) 특징행렬

(그림 2)에서 행은 노드 즉, 센서의 수가 되고 열은 센서가 가지는 특징을 의미한다[5]. 특징행렬에서 행은 선정한 특징에 대해 각 노드가 갖는 값을 의미한다. 대각 성분이 0인 인접행렬 A 는 이웃 노드의 특징은 얻을 수 있지만, 해당 노드의 특징은 얻을 수 없게 된다. 이를 보완하기 위해 인접행렬 A 를 $A + I$ 로 변형시킨다. (그림 2)에서 I 는 단위행렬이다. 단위행렬이란 n 차 정방행렬에서 대각원소가 모두 1이고 나머지 원소는 모두 0인 행렬이다[5].

3. 제안 방법

본 논문에서는 아랍에미리트 Zayed University의 Amril Nazir에 의해 2021년 2월 12일 게시된 실내 실험실 화재 데이터셋(이하 화재 데이터셋)을 이용하여 GCN모델을 학습하였다[6-7]. 화재 데이터셋에서 4개의 실험은 전기화재 원인을 사용하여 수행되었고, 2개의 실험은 carton(상자) source를 사용하여 수행되었으며 나머지 2개의 실험은 의류 화재 실험을 통해 수행되었다. 각 실험에서 습도, 온도, MQ139, TVOC, eCO2의 센서 측정값은 화재가 발생했을 때의 처음부터 화재경보가 활성화 및 작동되는 시점까지 기록되었다.

실험에서 사용한 화재 데이터셋은 (그림 3)과 같다. 화재 데이터셋의 각 실험에서 화재를 발생시키는 요인은 3가지인데 전기 가열 장치와 플라스틱층이 있는 종이 상자 재료, 의류 재료이다. 전체 데이터 건수는 11,797건이다.


	Humidity	Temperature	MQ139	TVOC	eCO2	label
0	59.6	24.9	363	8849	22325	2
1	39.2	22.1	72	135	442	0
2	59.5	24.9	378	10019	23634	2
3	63.5	24.1	138	496	567	0
4	61.0	21.9	82	5	400	0
...
11792	61.6	21.7	81	8	404	0
11793	39.9	21.7	133	564	1956	0
11794	66.1	20.9	99	164	525	0
11795	62.8	24.0	119	201	400	0
11796	62.8	23.8	117	209	486	0

11797 rows × 6 columns


(그림 3) 화재 데이터셋

본 연구에서 화재가 발생했을 때 여러 가지 센서들의 상황을 학습하기 위하여 상자, 의류, 전기 등의 원인으로 구성된 화재 데이터셋을 4가지 상황으로 레이블링하였다. 예를 들어 의류 재료의 화재일 때는 MQ139, TVOC, eCO2 센서의 측정값이 화재 발생 알람 OFF일 때 보다 높게 나타났으며 평균 324ppm, 7,794 $\mu\text{g}/\text{m}^3$, 18,848ppm이었다. 또한 상자 화재 실험은 MQ139, TVOC, eCO2 센서들의 측정값은 평균 238ppm, 2,864 $\mu\text{g}/\text{m}^3$, 6,639ppm이었다. 이러한 센서 노드의 특성을 그래프 형태로 나타내어 GCN 모델로 학습하였다.


상자 재료 화재 실험의 화재 발생 알람이 ON(화재 발생 검출) 상태일 때 데이터 건수는 144건이며 레이블을 '1'로 입력하였고, 의류 재료의 화재 발생 알람이 ON 상태일 때 1,595건의 데이터는 '2'로 입력하였다. 전기 가열 장치에 의한 화재 발생 알람이 ON 상태일 때는 135건이고 '3'으로 입력하였다. 마지막으로 모든 종류의 실험에서 화재 발생 알람이 OFF 상태일 때는 9,923건이며 label을 '0'으로 입력하였다. 각각의 상황별 데이터셋을 시각화한 그림은 (그림 4), (그림 5), (그림 6), (그림 7)과 같다.




(그림 4) 화재 발생 알람 OFF



(그림 5) 상자 재료 화재 알람 ON



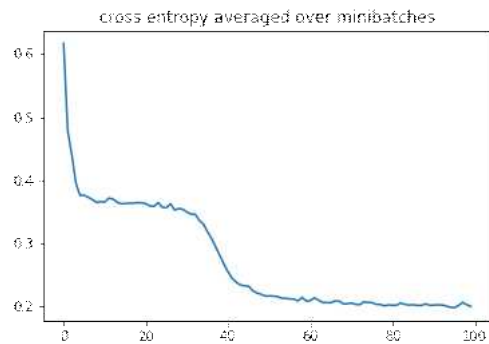
(그림 6) 의류 재료 화재 알람 ON



(그림 7) 전기 화재 발생 알람 ON

4. 실험 결과 및 평가

레이블링 처리된 화재 데이터셋을 이용하여 GCN 모델을 100 epochs 학습한 결과는 (그림 8)과 같다.



(그림 8) GCN 모델 학습 손실을 그래프

(그림 8)에서 x 축은 epoch 횟수이고 y 축은 예측값 loss rate를 나타낸다. 예측값 loss rate가 0에 수렴하고 있는 것을 확인할 수 있다. 손실값을 구하는 cross entropy 손실함수 수식은 식(1)과 같다[8].

$$\text{loss}(x, \text{class}) = -\log\left(\frac{\exp(x[\text{class}])}{\sum_j \exp(x[j])}\right) = -x[\text{class}] + \log\left(\sum_j \exp(x[j])\right) \quad (1)$$

수식(1)은 softmax와 log 처리 및 cross entropy loss 연산의 조합이다.

5. 결론 및 향후 연구

본 논문에서는 기존의 화재 경보 시스템에서 구분해 주지 못하는 화재의 원인을 구분하기 위해 특정한 화재 원인으로 레이블링 된 화재 데이터셋을 이용하여 GCN 모델을 학습하였다. 상자 화재, 의류 화재, 전기 화재, 화재 미발생 이렇게 4가지 레이블링 된 데이터를 7 대 3 비율로 GCN 모델 학습에는 70%를 사용하고 평가에는 30%를 사용한 실험 결과 정확도는 93.44%이다.

93.44%의 의미는 화재 원인을 상자 화재, 의류 화재, 전기 화재, 화재 미발생으로 구분했을 때 화재 원인이 무엇인지 얼마나 정확하게 분류할 수 있는지를 의미한다. 기존 연구에서는 화재의 원인을 구분할 수 없었지만 GCN 모델을 이용하여 화재의 원인을 구분할 수 있음을 증명하였다.

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구 결과로 수행되었음 (IITP-2023-2020-0-01789)

참고문헌

[1] 국가 화재 정보 시스템, “화재 현황분석”, Available: <https://nfds.go.kr>, (accessed Mar. 07, 2023).
 [2] 채 진, “화재예방에 영향을 미치는 요인에 관한 연구”, 한국화재소방학회 논문지, Vol. 34, No. 3, pp. 100-109, 2020.
 [3] James Sinopoli, “건축가, 건축주, 시공사를 위한 스마트 빌딩 시스템”, 도서출판 씨아이알, 2014.
 [4] 이민우, 김양훈, 정교민, “문장 레벨 그래프 회신 신경망을 통한 텍스트 분류”, 한국정보과학회, Vol. 25, No. 8, pp. 397-401, 2019.
 [5] 손진곤, “이산수학”, 한국방송통신대학교출판문화원, 2013.

[6] A. Nazir, et al. “Early fire detection: a new indoor laboratory dataset and data distribution analysis.” Fire Vol. 5, No. 1, 2022.

[7] N. Amril, “Indoor Laboratory Fire Dataset,” (2021년) Available: <https://www.kaggle.com/datasets/saurabhshahane/indoor-laboratory-fire-dataset>, (accessed Feb. 2023).

[8] 김형준, “다중분류를 위한 대표적인 손실함수, torch.nn.CrossEntropyLoss”, Available: <http://www.gisdeveloper.co.kr/?p=8668>, (accessed Apr. 30, 2023).