

LSTM-based Fire and Odor Prediction Model for Edge System

Joosang Youn[†] · TaeJin Lee^{**}

ABSTRACT

Recently, various intelligent application services using artificial intelligence are being actively developed. In particular, research on artificial intelligence-based real-time prediction services is being actively conducted in the manufacturing industry, and the demand for artificial intelligence services that can detect and predict fire and odors is very high. However, most of the existing detection and prediction systems do not predict the occurrence of fires and odors, but rather provide detection services after occurrence. This is because AI-based prediction service technology is not applied in existing systems. In addition, fire prediction, odor detection and odor level prediction services are services with ultra-low delay characteristics. Therefore, in order to provide ultra-low-latency prediction service, edge computing technology is combined with artificial intelligence models, so that faster inference results can be applied to the field faster than the cloud is being developed. Therefore, in this paper, we propose an LSTM algorithm-based learning model that can be used for fire prediction and odor detection/prediction, which are most required in the manufacturing industry. In addition, the proposed learning model is designed to be implemented in edge devices, and it is proposed to receive real-time sensor data from the IoT terminal and apply this data to the inference model to predict fire and odor conditions in real time. The proposed model evaluated the prediction accuracy of the learning model through three performance indicators, and the evaluation result showed an average performance of over 90%.

Keywords : Manufacturing Industry, LSTM, Fire Prediction, Odor Level Prediction, Edge Device

엣지 시스템을 위한 LSTM 기반 화재 및 악취 예측 모델

윤 주 상[†] · 이 태 진^{**}

요 약

최근 인공지능을 활용한 다양한 지능형 응용서비스 개발이 활발히 진행 중이다. 특히, 제조 산업 현장에서는 인공지능 기반 실시간 예측서비스 연구가 활발히 진행 중이며 이중 화재 및 악취를 감지·예측할 수 있는 인공지능 서비스에 대한 요구가 매우 높다. 하지만 기존 감지·예측시스템은 화재 및 악취 발생 예측이 아닌 발생 후 감지 서비스가 대부분이다. 이는 인공지능 기반 예측서비스 기술이 적용되어 있지 않기 때문이다. 또한, 화재 예측 및 악취 감지·예측서비스는 초저지연 특성을 가진 서비스이다. 따라서 초저지연 예측서비스를 제공하기 위해 엣지 컴퓨팅 기술이 인공지능 모델과 결합되어 클라우드에 비해 빠른 추론 결과를 현장에 빠르게 적용할 수 있도록 개발 중이다. 따라서 본 논문에서는 제조 산업 현장에서 가장 많이 요구되는 화재 예측 및 악취 감지·예측에 사용할 수 있는 LSTM 알고리즘 기반 학습모델을 제안한다. 또한, 제안하는 학습모델은 엣지 디바이스에 구현이 가능하도록 설계하였으며 사물인터넷 단말로부터 실시간 센서데이터를 수신하고 이 데이터를 추론 모델에 적용하여 화재 및 악취 상태를 실시간으로 예측할 수 있도록 제안한다. 제안된 모델은 3가지 성능 지표를 통해 학습모델의 예측 정확도를 평가하였으며 평가 결과는 평균 90% 이상 성능을 보였다.

키워드 : 제조 공장, LSTM, 화재 예측, 악취 정도 예측, 엣지 디바이스

1. 서 론

최근 인공지능을 활용한 다양한 응용서비스 개발이 활발히

진행 중이다. 특히, 사물인터넷 분야에서는 인공지능 기술을 활용하여 산업 현장에서 실시간 예측서비스를 제공하기 위한 연구가 활발히 진행 중이다[1,2]. 특히, 제조 산업 현장에서는 화재 및 악취를 감지·예측할 수 있는 인공지능 서비스에 대한 요구가 매우 높다[3]. 특히, 화학 성분을 다루는 제조 산업 현장이나 폐기물 처리 및 보관을 수행하는 산업 현장에서는 화재와 악취 관리를 위해 영상 정보를 기반으로 사물인터넷 실시간 현장 감시 시스템이 적용 중이다[3,5,6]. 하지만 기존 감시 시스템은 화재 및 악취 발생 예측이 아닌 발생 후 감

※ 이 논문은 IITP/NIST SW 컴퓨팅산업원천기술개발과제(20200001160012 007)와 2021학년도 동의대학교 교내연구비(202101850001)에 의해 연구되었음.

† 종신회원 : 동의대학교 산업ICT기술공학과 교수

** 정 회 원 : ㈜브로드웨이브 대표이사

Manuscript Received : January 4, 2022

Accepted : January 10, 2022

* Corresponding Author : Joosang Youn(jsyou@deu.ac.kr)

지 서비스가 대부분이다. 이는 기존 시스템이 인공지능 기반 예측서비스 기술이 적용되어 있지 않기 때문이다. 또한, 화재 예측 및 악취 감지·예측서비스는 초저지연 특징을 가진 서비스이다. 따라서 초저지연 예측서비스를 제공하기 위해 엣지 컴퓨팅 기반 인공지능 학습모델 개발이 활발히 진행 중이다 [4]. 엣지 컴퓨팅 기술은 인공지능 기반 예측서비스 제공 시 클라우드에 비해 빠른 추론 결과를 현장에 빠르게 적용할 수 있는 장점이 있다. 또한, 추론에 필요한 데이터를 클라우드로 올리지 않아도 되기 때문에 네트워크 자원 사용률을 감소시킬 수 있는 장점이 있다. 이런 장점으로 인해 대부분은 산업 현장에서는 엣지 기반 인공지능 예측·추론서비스를 개발 및 적용 중이다. 따라서 본 논문에서는 제조 산업 현장에서 가장 많이 요구되는 화재 예측 및 악취 감지·예측에 사용할 수 있는 딥러닝 기반 학습모델을 제안한다. 또한, 제안하는 학습모델은 엣지 다바이스에 구현이 가능하도록 설계하였으며 공용 클라우드와 연계 운영될 수 있도록 개발하였다. 또한, 사물인터넷 단말로부터 실시간 센서데이터를 수신하고 이 데이터를 추론 모델에 적용하여 화재 및 악취 상태를 실시간으로 예측할 수 있도록 하였다.

본 논문은 2장에서 화재 예측 및 악취 감지·예측서비스를 위한 학습모델에 필요한 데이터 수집 및 전처리 과정을 기술하고 3장에서 학습모델 생성과정을 기술한다. 4장에서 모델 평가를 실시하고 5장에서 결론을 맺는다.

2. 데이터 수집 및 전처리

이번 장에서 딥러닝 기반 학습모델 생성을 위한 데이터 수집과 전처리 과정에 대해 기술한다. 화재 예측 모델 및 악취 예측 모델을 생성하는 데 필요한 데이터는 총유기화합물질(TVOC), 암모니아(NH_3), 습도, 연기 농도 데이터이며 화재 예측 모델의 경우 총유기화합물질, 습도, 연기 시계열 데이터가 학습 데이터로 사용되었으며 악취 예측 모델의 경우 총유기화합물질, 암모니아 농도 데이터가 학습 데이터로 사용된다. ML 모델 구성을 위해 현장과 유사한 환경을 만들어서 데이터셋을 확보하였으며 이를 통해 화재, 악취 모델을 개발하였다.

2.1 데이터 수집

데이터 수집은 Fig. 1, 2처럼 산업 현장 중 폐기물 처리장과 유사한 환경을 모델링 하였으며 시설 내부에 엣지 장치를 장착하고 인위적으로 화재 및 악취가 발생하는 상황을 연출하여 시계열 데이터를 수집하였다. 데이터를 수집하기 위해 연출된 상황은 평상시, 화재발생시, 악취발생시 등 3가지 상황을 연출하였다. 평상시는 시설 내부에 어떠한 상황도 연출하지 않고 자연적으로 발생하는 TVOC, NH_3 , 습도, 연기 농도를 약 1시간 30분 수집했고, 화재 발생 시 상황은 시설 내부에 화재를 발생시켜 화재 발생 전후로 약 34분간 관측된 TVOC, 습도, 연기 농도 데이터를 수집하였다. 악취 발생 시 상황은 화재 상황에서 발생한 악취를 포함해 인위적으로




Fig. 1. Odor Test Environment



Fig. 2. Fire Test Environment

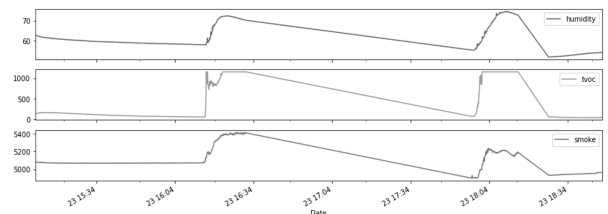


Fig. 3. Time-series Data in the Event of a Fire

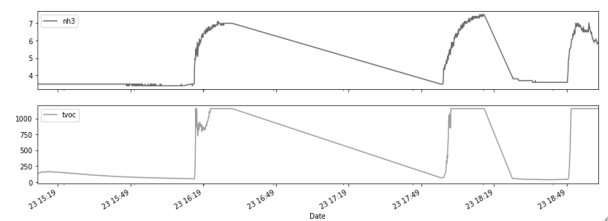


Fig. 4. Time-series Data in the Event of a Odor

NH_3 용액을 분출하는 상황을 연출한 뒤 전후 약 46분간 TVOC, NH_3 데이터를 수집하였다.

2.2 데이터 전처리

1차로 수집된 데이터는 화재 예측용 1,000개, 악취 예측용 1,100개이며 Fig. 3, 4처럼 시계열 그래프로 나타났다. Fig. 3, 4에서 보여지는 것처럼 급격하게 농도가 증가한 부분이 화재 및 악취를 발생시켰을 때 농도 변화로 해당 상황에 따라 실제로 물질들의 농도가 변화하는 것을 확인할 수 있다. 하지만, 농도를 측정하는 센서의 측정 주기와 민감도 문제로 농도가 급격하게 변화할 때 농도 값이 일정하게 측정되지 못하는 문제점이 발생할 때도 있다. 이런 문제를 해결하기 위해

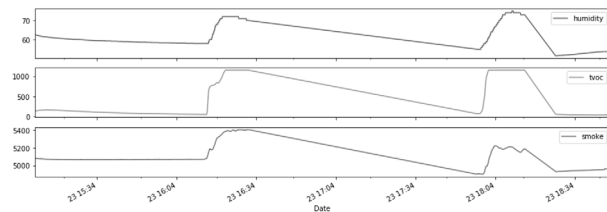


Fig. 5. Time-series Data of Fire Occurrence Situation Applying Smoothing Technique

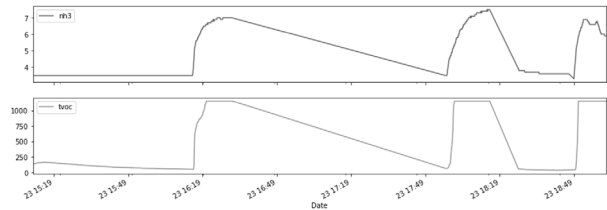


Fig. 6. Time-series Data of Odor Occurrence Situation Applying Smoothing Technique

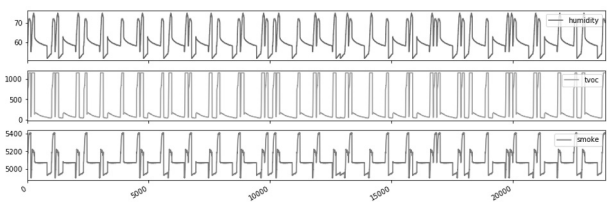


Fig. 7. Amplified Learning Data of Odor Occurrence Situations

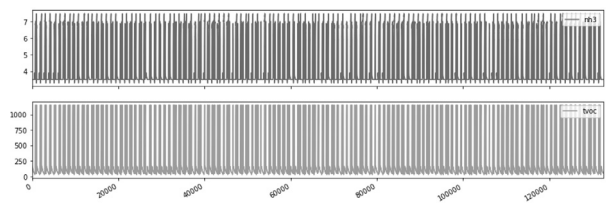


Fig. 8. Amplified Learning Data of Fire Occurrence Situations

데이터 스무딩 기법을 통해 수집된 데이터의 노이즈를 제거하고 일정한 값을 보이도록 했다. 수정된 데이터의 시계열 그래프는 Fig. 5, 6과 같다. 예측을 위한 추론 모델을 만들기 위해서는 많은 양의 학습데이터를 통한 학습모델을 만들어야 한다. 따라서 본 논문에서는 수정된 데이터를 이용하여 데이터를 증식하는 과정을 수행하였다. 데이터 증식 과정은 평상시 발생하는 물질들의 농도 값과 화재 발생 시 농도 변화 값, 악취 발생 시 농도 변화 값을 각각 하나의 상태로 정의하고, 각 상태 간의 조합을 통해 생성했다. 그 결과 화재 예측 모델을 위한 학습 데이터는 30,000개, 악취 예측 모델을 위한 학습 데이터는 150,000개가 생성되었으며 이를 학습 데이터로 활용하였다. 증폭된 학습 데이터는 Fig. 7, 8과 같다.

마지막으로 모델 학습 과정에서 입력된 물질 간의 크기 차이가 큰 경우 상대적으로 크기가 작은 물질은 가중치 값이 낮게 할당돼 모델의 출력에 영향력을 잃게 되는 일이 발생할 가

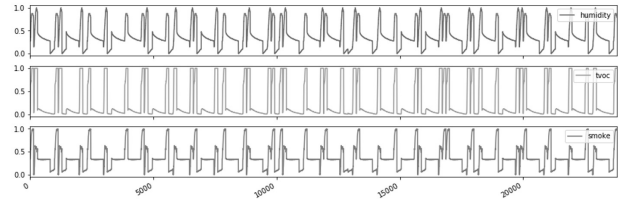


Fig. 9. Amplified Learning Data of Odor Occurrence Situations after Normalization




Fig. 10. Amplified Learning Data of Fire Occurrence Situations after Normalization

능성이 존재한다. 이를 해결하는 방법으로 데이터 정규화 과정을 수행했다. 정규화를 수행한 결과는 각 물질 별로 0과 1사이의 실수값을 반환하게 되며 Equation (1)를 통해 정규화를 수행한다.

$$y_{new} = \frac{y - y_{min}}{y_{max} - y_{min}} \quad (1)$$

정규화를 통해 최종적으로 생성된 물질별 시계열 그래프는 Fig. 9, 10과 그림과 같다. 그림에서 알 수 있듯이 정규화 이전과 이후 그래프의 형태는 차이가 없으면 단순히 y축의 값이 0과 1사이의 실수값으로 나타내어진 것을 확인할 수 있다.

3. 학습모델 생성

이번 장에서 화재 예측 및 악취 예측을 위한 학습모델 생성과정을 기술한다. 화재 예측 모델의 경우 입력 시점으로부터 과거 3분 동안 수집된 TVOC, 습도, 연기의 농도 데이터를 입력으로 사용해 향후 1분 및 3분 후의 연기 농도를 예측한다. 악취 예측 모델의 경우도 마찬가지로 현재를 기준으로 과거 3분 동안 수집된 데이터를 입력으로 사용하여 입력에 사용되는 데이터는 TVOC와 NH₃ 데이터이고 향후 1분 및 3분 후의 NH₃ 농도 값을 예측하는 것을 목표로 한다.

3.1 학습 및 검증 데이터 분리

데이터 전처리 과정을 통해 생성된 데이터셋 중 화재 예측 모델을 위한 데이터셋과 악취 예측을 위한 데이터셋 모두 전체 데이터 중 약 90%를 학습 데이터용으로 할당하고, 나머지 10% 데이터는 모델 학습 후 성능 평가를 위한 검증 데이터로

분리했다. 이후 학습 데이터와 검증 데이터 모두 모델이 요구하는 입력 형태 (총 입력 개수, 입력당 길이(시간), 물질 수)로 변환하는 과정을 거쳤으며 이렇게 생성된 데이터셋을 배치(batch)하였다.

이후 위 과정을 통해 생성된 학습 데이터는 모델 학습 과정에서 과적합(over fitting)을 방지하기 위함과 동시에 최적의 학습 횟수를 반영하는 방법으로 미니-배치(mini-batch)를 생성했다. 미니-배치는 학습 데이터의 총 입력 개수를 동등한 크기로 분리해 또 다른 배치를 생성하는 것으로 화재 예측 모델을 위한 학습 데이터는 총 입력 개수를 255개 단위로 나눠 83개의 미니 배치를 생성했고, 악취 예측 모델을 위한 학습 데이터는 513개 단위로 나눠 232개의 미니 배치를 생성하여 학습 데이터로 활용하였다.

3.2 학습모델 정의

화재 예측 모델과 악취 예측 모델 모두 LSTM 알고리즘 [7]을 사용하였다. 모델은 입력을 위한 입력층, 연산이 수행되는 은닉층, 그리고 예측 결과를 나타내는 출력층으로 이뤄진다. 입력층은 단순히 학습 데이터 샘플을 입력받고 다음층에 해당 값들을 넘겨주는 역할만 하며, 별도의 연산은 수행하지 않는다. 은닉층은 입력층으로부터 전달받은 값들의 연산이 수행되는 곳으로 해당 연산은 LSTM 알고리즘의 수식을 통해 수행되고 화재 예측 모델의 은닉층에는 32개의 LSTM 셀이 배치되며 악취 예측 모델은 그보다 적은 16개의 LSTM 셀이 배치되도록 설정하였다. 출력층은 은닉층의 연산결과를 전달받아 최종적으로 예측 결과를 나타내게 된다. 이를 위해 출력층은 은닉층으로부터 전달받은 값을 활성화 함수 층인 시그모이드 층의 연산을 통해 0과 1 사이의 실수값을 반환하게 된다. 예측 모델로 사용된 모델 구조는 Fig. 11, 12와 같다. 모델 학습 과정은 입력층, 은닉층, 출력층을 순서대로 거치는 순전파 과정을 통해 입력에 대한 예측을 수행한 후 오차 함수(loss function)를 통해 예측값과 실제값의 오차를 계산하고, 이를 입력층까지 역으로 흘려보내는 오차 역전파법을 수행하면서 연결된 층 간의 가중치 값을 업데이트해 모델이 최적의 결과를 도출할 수 있도록 하였다. 이 과정에서 오차 역전파는 학습 데이터셋의 미니배치 크기만큼 반복한 이후 수행되며, 전체 미니배치의 수만큼 해당 과정을 반복했을 때 1-epoch를 수행했다고 한다. 또한 모델은 위와 같은 학습 과정을 수행하기 위해 예측값과 실제값의 오차를 계산하는 오차 함수를 MAE(Mean Absolute Error)로 정의하고, 오차 역전파시 최적화 알고리즘을 사용한다.

4. 모델 성능 평가

모델 생성 이후 예측 성능을 평가하기 위해 이전에 생성한 검증 데이터를 모델의 입력으로 사용해 예측을 진행하고, 평가 지표에 예측값과 실제값을 입력해 해당 지표의 결과값을 기반으로 모델의 예측 성능을 평가한다.

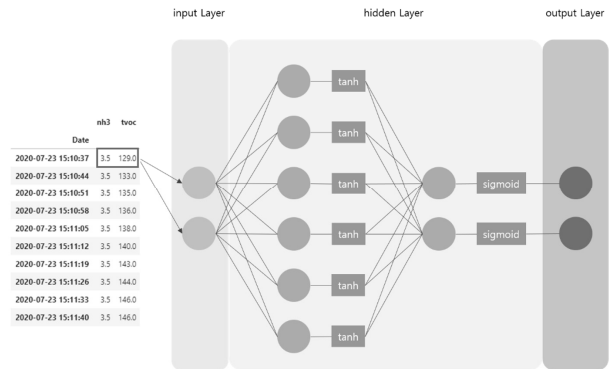


Fig. 11. Structure of Odor Prediction Learning Model

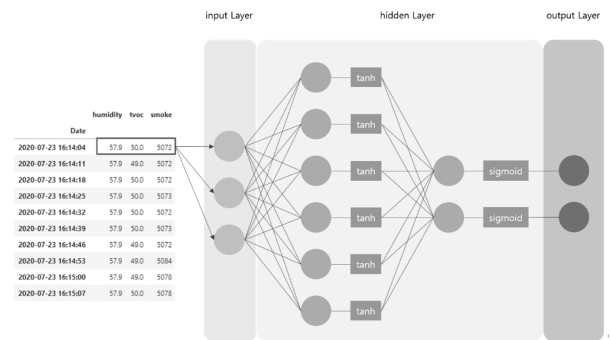


Fig. 12. Structure of Fire Prediction Learning Model

4.1 모델 성능 평가 방법

모델의 예측 결과는 정규화된 값으로 도출된다. 정확한 비교를 위해서는 예측 결과값을 원본 데이터와 같은 형태로 다시 되돌리는 과정이 필요하며, 해당 과정은 아래 Equation (2)처럼 정규화 수식의 역산을 통해 수행된다.

$$y = y \times (y_{max} - y_{min}) + y_{min} \tag{2}$$

이후 성능평가 지표 IOA(index of agreement), MAE, MAPE(Mean Absolute Percentage Error)를 사용해 예측값과 실제값의 비교를 수행하게 되며 해당 수식들의 정의는 아래 Equation (3)~(5)와 같다.

$$IOA = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \tag{3}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \tag{4}$$

$$MAPE = 100 \times \frac{\sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right|}{n} \tag{5}$$

IOA는 예측 값과 실제 값의 시계열 유사성을 평가하기 위한 것으로 그 결과 값은 0과 1사이의 실수 값을 반환하게 되

Table 1. Experimental Results

	Prediction Time	IOA	MAE	MAPE
Fire Prediction Model	1 minute later	0.966	10.377	0.207
	3 minute later	0.906	24.221	0.485
Odor Prediction Model	1 minute later	0.970	0.157	3.512
	3 minute later	0.924	0.347	7.313

고, 1에 가까울수록 두 값 사이의 시계열 유사성이 높다고 판단할 수 있다. MAE는 각 샘플들의 예측값과 실제 값의 절대 오차를 계산한 후 이를 전체 샘플에 대한 평균을 나타낸 것으로 MAE의 결과값은 예측값이 실제 값과 비교했을 때 어느 정도의 차이를 보이는지 확인할 수 있다. MAPE는 단순히 MAE를 백분율로 나타낸 것으로 결과값은 모델의 예측 결과가 실제 값과 비교했을 때 몇 퍼센트의 오차가 발생하는지 확인할 수 있고, 모델의 예측 정확도를 나타낼 수 있다.

4.2 모델 성능 평가 결과

모델에 검증데이터를 입력하여 얻어진 예측값과, 모델이 예측하는 실제 값을 앞서 정의한 평가 지표를 통해 계산한 결과는 Table 1, Fig.13, Fig 14와 같다.

화재 예측 모델에서 IOA 값은 1분, 3분 후의 예측 모두 0.9 이상 정확도를 나타냈으며 모델의 예측값이 실제값과 시계열 유사성이 높다는 것으로 판단할 수 있다. 또한, MAE와 MAPE를 통해 예측된 예측값과 실제값의 오차가 평균적으로 약 0.2%, 0.4% 정도 발생하며, 오차의 정도는 각각 10ppm, 24ppm이 발생한다고 해석할 수 있다.

악취 예측 모델 또한 IOA 값이 1분, 3분 후의 예측 모두 0.9 이상으로 높게 나타나 예측값과 실제값 간의 시계열 유사성이 높다고 판단할 수 있다. 그리고 예측 시간별로 평균 0.1ppm, 0.3ppm 정도의 오차가 발생하지만, MAPE는 3.5%, 7.3%를 나타내 실질적으로 화재 예측 모델보다 오차 발생의 정도가 더욱 높게 나타났음을 알 수 있다.

5. 결 론

본 논문에서는 제조산업현장 내 저장 시설의 화재 및 악취를 사전에 감지하고 대처할 수 있는 인공지능 예측 모델을 제안하였다. 이 모델은 엣지 디바이스 내 설치되어 시설 내부에 연결된 네트워크를 통해 데이터를 수집하고 실시간 예측 결과를 알리는 지능형 사물인터넷 서비스 모델로 활용 가능하도록 설계되었다. 또한, 시계열 예측에 높은 정확도를 높이기 위해 최근에 시계열 예측 성능이 우수한 LSTM 알고리즘을 기반으로 학습모델을 생성하였다. 생성된 모델은 화재 예측

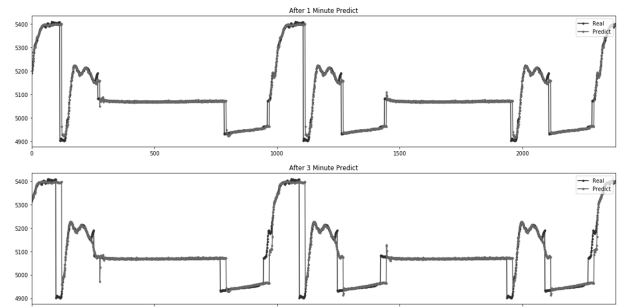


Fig. 13. Performance of Fire Prediction Model

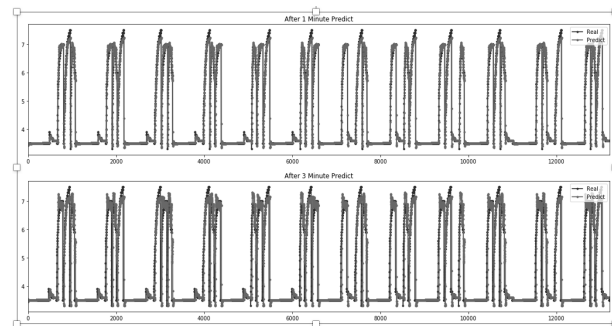


Fig. 14. Performance of Odor Prediction Model

모델과 악취 예측 모델이며 두 모델 모두 현재 기준 과거 3분 데이터를 입력으로 사용하여 향후 1분, 3분 후의 특정 물질에 대한 농도 값을 예측하도록 했다. 여기서 화재 예측 모델은 TVOC, 습도, 연기 농도 데이터를 입력으로 사용해 연기 농도 데이터를 예측하도록 했고, 악취 예측 모델은 TVOC와 NH₃ 농도 데이터를 입력으로 사용해 NH₃의 그 결과 두 모델 모두 예측 결과값이 실제 값과 굉장히 유사한 시계열 특성을 보였고, 모델의 평균 예측 정확도 또한 90% 이상을 보였다. 하지만 예측하는 시점이 입력 시점으로부터 멀어질수록 예측 정확도가 떨어지는 것을 확인할 수 있었는데, 이는 모델에 입력되는 시계열의 길이에 따라 편차가 발생하는 것으로 추측된다. 또한, 원본 데이터값을 정규화하고 정규화된 값으로 도출된 모델의 출력을 다시 원본 데이터의 형태와 같게 만드는 모든 연산 과정에서 일부 데이터 손실이 발생해 모델 학습 과정에 온전한 데이터를 반영할 수 없었다는 점은 한계점으로 남아있다.

References

[1] M. Nakıp and C. Güzeliş, "Development of a multi-sensor fire detector based on machine learning models," in *2019 Innovations in Intelligent Systems and Applications Conference (ASYU)*, pp.1-6, Oct. 2019.

[2] L. Wu, L. Chen, and X. Hao, "Multi-sensor data fusion algorithm for indoor fire early warning based on BP neural network," *Information*, Vol.12, No.2, pp.59, Jan. 2021.

- [3] A. Sharma, P. K. Singh, and Y. Kumar, "An integrated fire detection system using IoT and image processing technique for smart cities," *Sustainable Cities and Society*, Vol.61, Art. No.102332, Oct. 2020.
- [4] Y. Mao, C. You, J. Zhang, K. Huang, and K B. Letaief, "A survey on mobile edge computing: The communication perspective," *IEEE Communications Surveys Tutorials*, Vol.19, No.4, pp.2322-2358, 2017.
- [5] R. Chanonsirivorakul and N. Nimsuk, "A study of relationship between sensor response and odor perception in human," in *International Electrical Engineering Congress (iEECON)*, pp.1-4, Mar. 2018.
- [6] D. Wu, D. Luo, K. Wong, and K. Hung "POP-CNN: Predicting odor pleasantness with convolutional neural network," *IEEE Sensors Journal*, Vol.19, No.23, pp.11337-11345, 2019.
- [7] Z. Xu, Y. Guo, and J. H. Saleh, "Advances toward the next generation fire detection: Deep LSTM variational auto-encoder for improved sensitivity and reliability," *IEEE Access*, Vol.9, pp.30636-30653, 2021.



윤 주 상

<https://orcid.org/0000-0001-9952-9649>

e-mail : jsyoun@deu.ac.kr

2001년 고려대학교 전기전자전파공학과 (학사)

2003년 고려대학교 전기전자전파공학과 (석사)

2008년 고려대학교 전기전자전파공학과(박사)

2008년 ~ 현 재 동의대학교 산업ICT기술공학과 교수

관심분야 : AI, IoT, Edge computing, Mobile network



이 태 진

<https://orcid.org/0000-0001-6649-9076>

e-mail : LTJ@Broadwave.co.kr

1992년 서울시립대학교 전자공학과(학사)

1994년 서울시립대학교 디지털통신(석사)

2008년 ~ 현 재 (주)브로드웨이브 대표이사

관심분야 : Wireless Sensor