



오토인코더를 이용한 작업 데이터 정상 여부 판단 알고리즘

김동현 · † 오정석*

주식회사 씨알아이지, *가스안전공사 가스안전연구원
(2021년 9월 10일 접수, 2021년 10월 23일 수정, 2021년 10월 24일 채택)

Algorithm for Determining Whether Work Data is Normal using Autoencoder

Dong-Hyun Kim · † Jeong Seok Oh*

CRIG Corporation, Korea

*Institute of Gas Safety R&D, Korea Gas Safety Corporation, Korea

(Received September 10, 2021; Revised October 23, 2021; Accepted October 24, 2021)

요약

본 연구에서는 오토인코더의 재구성 오류의 임계값을 이용하여 가스 시설에서의 작업이 정상 작업인지 비정상 작업인지를 판단하는 알고리즘을 구축하였다. 이 알고리즘은 정상 작업의 시계열 데이터만으로 오토인코더를 학습하여 최적화된 정상 작업의 재구성 오류의 임계값을 도출한다. 이 알고리즘을 새로운 작업의 시계열 데이터에 적용하여 재구성 오류를 구한 다음 이것을 정상 작업의 재구성 오류 임계값과 비교하여 정상 작업인지 비정상 작업인지를 판별한다. 이 알고리즘을 학습하고 검증하기 위해서 가상의 가스 시설에서의 작업을 규정하고 정상 작업 데이터로만 이루어진 학습 데이터 세트와 정상 작업과 비정상 작업 데이터를 모두 포함한 검증 데이터 세트를 구축하였다.

Abstract - In this study, we established an algorithm to determine whether the work in the gas facility is a normal work or an abnormal work using the threshold of the reconstruction error of the autoencoder. This algorithm do deep learning the autoencoder only with time-series data of a normal work, and derives the optimized threshold of the reconstruction error of the normal work. We applied this algorithm to the time series data of the new work to get the reconstruction error, and then compare it with the reconstruction error threshold of the normal work to determine whether the work is normal work or abnormal work. In order to train and validate this algorithm, we defined the work in a virtual gas facility, and constructed the training data set consisting only of normal work data and the validation data set including both normal work and abnormal work data.

Key words : autoencoder, reconstruction error, time series, deep learning, gas work

I. 서 론

고압가스 시설에는 항상 사고 발생의 위험성이 존재한다. 가스 사고가 발생하면 막대한 피해가 발생하기 때문에 사고 발생 이전에 이를 사전에 감지하고 차단하는 것이 중요하다. 센서 기술의 발전에 따라 각종 가스 시설물에 다양한 센서를 부착하고

이러한 센서 값을 모니터링 하여 특정 센서 값이 미리 설정되어 있는 임계값에 도달하면 위험한 상황으로 인식하고 가스를 차단하거나 시설을 정지하는 등의 기술이 개발되어 있다. 이러한 기술은 보수적인 접근으로써 대형사고 발생을 막는데 효과적이나, 사고 발생이 일어나지 않는 것을 목표로 하는 안전 관리 시스템의 데이터의 특성상 대부분의 센서 값이 정상적이기 때문에 센서 값이 임계값에 도달하지 않은 상황에서는 현재의 상태가 정상적인 상태인지 비정상적인 상태인지 평가하는데

†Corresponding author: jsoh90@gmail.com

Copyright © 2021 by The Korean Institute of Gas

효과적이지 않다.

본 연구에서는 데이터를 기반으로 하는 가스 시설의 위험성 평가를 위하여 가스 시설에서 작업을 진행할 때의 각종 센서 데이터를 이용하여 현재 작업이 정상 작업인지 비정상 작업인지 평가하는 오토인코더를 이용한 딥러닝 알고리즘을 구축하였다. 또한, 가스 시설물의 데이터 특성 상 대부분의 데이터는 정상적인 상태에 대한 데이터라는 특성을 반영할 수 있는 알고리즘을 구축하기 위해 정상 상태의 가상 데이터와 비정상 상태의 가상 데이터를 생성하고 이러한 가상 데이터를 바탕으로 한 알고리즘을 구축하고 성능을 평가하였다.

II. 가상 데이터 구축

본 연구를 통해 분석하고자 하는 대상은 고압가스 시설에서의 작업이며, 구축한 분석 알고리즘은 작업이 정상 작업인지 비정상 작업인지를 판별하는 알고리즘이다. 이러한 분석 알고리즘을 구축하기 위해서는 작업에 대한 가상 데이터를 구축하였다.

작업에 대한 가상 데이터를 생성하기 위해 다음의 단순화된 가상의 가스 시설을 구성하였다. 이

Table 1. The sensor used to generate the data

	센서 종류	가상 데이터 값	단위
1	측위 센서	작업자 인원수	명
2	산소 농도 센서	작업 구역 산소 농도	%
3	탱크 압력 센서	탱크 내 압력	bar
4	배관 압력 센서	배관 내 압력	bar
5	배관 유량 센서	배관 내 유량	Nm ³ /min
6	탱크 온도 센서	탱크 내 온도	°C
7	밸브 개폐 센서	밸브 개폐 여부	0 or 1

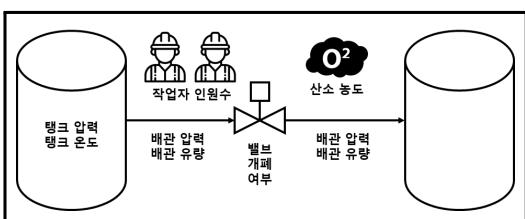


Fig. 1. Schematic of virtual gas facility.

가상의 시설은 밸브를 기준으로 왼쪽의 탱크로부터 왼쪽의 배관을 통해 들어온 가스가 밸브를 지나 오른쪽 배관을 통해 오른쪽 탱크로 이동하는 시설이다. 컴프레서 등의 장치는 단순화를 위해 생략하였다. 이 가상 가스 시설에서 규정된 가상의 작업은 왼쪽 배관을 교체하는 배관 교체 작업으로 규정하였다.

가스 시설로부터 수집이 가능한 가상 데이터는 다음의 7가지 센서 값의 시계열 데이터로 규정하였

Table 2. Work phases of plumbing replacement

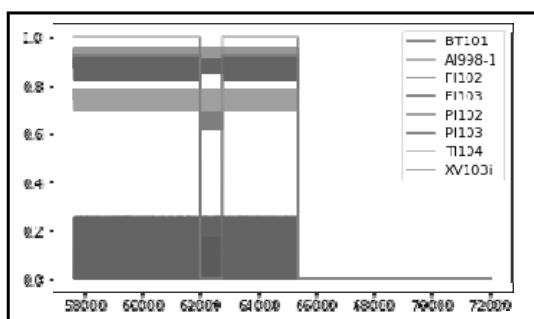
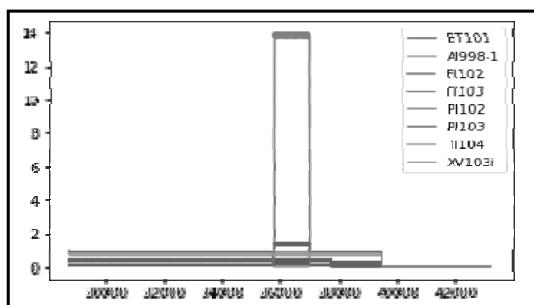
	작업 단계	최소 작업 시간(초)	최대 작업 시간(초)
1	작업자 진입	600	7200
2	시설 중지	600	1200
3	밸브 닫기	600	900
4	가스 배출	60	600
5	환기	60	600
6	배관 교체	600	1200
7	밸브 열기	600	900
8	시설 재시작	600	1200
9	작업자 이탈	600	1800

Table 3. Normal range of sensor data

	가상 데이터 값	정상 범위
1	작업자 인원수	0~6
2	작업 구역 산소 농도	17~22
3	동작중인 시설의 탱크 압력	20~35
4	미동작중인 시설의 탱크 압력	40~55
5	가득 찬 배관 압력	93~105
6	빈 배관 압력	0~15
7	동작중인 시설의 배관 유량	44~55
8	미동작중인 시설의 배관 유량	0~8
9	탱크 온도	15~25

Table 4. Criteria values used for data normalization

	가상 데이터 값	정규화 기준값
1	작업자 인원수	4
2	작업 구역 산소 농도	20
3	동작중인 시설의 탱크 압력	33
4	미동작중인 시설의 탱크 압력	53
5	가득 찬 배관 압력	104
6	빈 배관 압력	13
7	동작중인 시설의 배관 유량	53
8	미동작중인 시설의 배관 유량	6
9	탱크 온도	23

**Fig. 2.** Schematic of one of the normal data.**Fig. 3.** Schematic of one of the anomaly data.

으며 압력의 경우 밸브 왼쪽 탱크와 밸브 왼쪽 배관에 대한 압력 값을 수집하고 유량의 경우 밸브

좌우의 배관에 대한 유량 값을 수집하는 것으로 규정하고 데이터를 구축하였다.

배관 교체 작업은 순차적으로 다음의 작업 단계에 따라 이루어지며 각 작업 단계는 최소 작업 시간과 최대 작업 시간을 가지도록 규정하였다.

작업 단계별로 센서 데이터의 정상 범위는 다음의 범위로 설정하였다.

이와 같은 데이터에 대한 규정에 따라 가상 데이터를 구축하였다. 분석 알고리즘 최적화에 대한 성능 향상을 위해 구축된 데이터를 정규화 하였다. 정규화에 사용한 기준 값은 다음과 같다.

구축된 데이터는 시계열 데이터로 개별적으로 생성된 배관 작업 데이터는 데이터마다 시간이 서로 다르다. 각 작업 단계의 최대 작업 시간에 따라 총 작업 시간의 최댓값은 15600초이고, 개별적인 작업 데이터 중 이것보다 시간이 짧은 데이터는 분석 알고리즘에 동일한 데이터를 입력하기 위해 데이터가 없는 뒷부분은 모든 데이터를 0으로 채웠다. 개별적인 배관 교체 작업 데이터는 다음처럼 도식화할 수 있다.

III. 딥러닝 모델의 선정

3.1. 오토인코더

오토인코더는 입력 데이터를 가장 잘 설명할 수 있는 코드(Code)로 요약 또는 압축한 다음 이 코드로부터 데이터를 복원하는 인공신경망이다. 오토인코더는 레이블이 없는 학습 데이터를 사용하기 때문에 비지도 학습(Unsupervised Learning)으로 생각할 수 있으나, 정확하게는 원본 데이터를 레이블로 사용하기 때문에 자기 지도 학습(Self-Supervised Learning)에 해당한다. 일반적으로 코드는 입력보다 훨씬 낮은 차원을 가지도록 신경망을 구성하므로 차원 축소에 유용하게 사용된다.

오토인코더는 입력 데이터를 잠재 공간 표현(latent-space representation)인 코드로 바꾸는 인코더(Encoder)와 코드를 출력 데이터로 바꾸는 디코더(Decoder)로 구성된다. 인코더와 디코더는 동일한 구조의 네트워크를 역순으로 배치하여 사용하는 것이 일반적이다.

오토인코더는 입력 데이터를 요약 또는 압축한 다음 입력 데이터와 동일한 출력으로 재구성하도록 학습하는 네트워크이지만 인공신경망의 특성상 손실이 발생한다. 이러한 손실을 오토인코더의 재구성 오류로 규정할 수 있다. 데이터의 종류에 따라 이러한 재구성 오류를 어떻게 규정할 수 있는지가 달라진다. 수치형 데이터의 경우 원본 데이터와

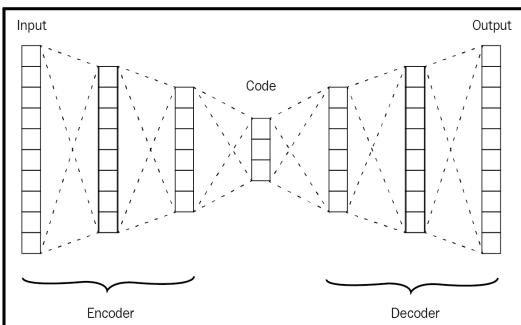


Fig. 4. Architecture of autoencoder.

재구성된 데이터의 값의 차이를 구할 수 있다. 이 경우 두 값의 차이의 절대 값, 차이의 제곱 또는 차이의 제곱근 등을 재구성 오류로 규정할 수 있다. 여러 개의 수치형 데이터 샘플로 이루어진 데이터의 경우 각 샘플의 재구성 오류에 대한 평균으로 해당 데이터의 재구성 오류를 규정할 수 있다. 일반적으로 각 샘플의 원본 데이터와 재구성 데이터의 차이의 절대 값들의 평균인 MAE(Mean Absolute Error), 차이의 제곱 값들의 평균인 MSE(Mean Squared Error), 차이의 제곱근 값들의 평균 RMSE(Root Mean Squared Error) 등을 사용하여 이러한 데이터의 재구성 오류를 규정한다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |S_r^i - S^i| \quad (1)$$

n 개의 샘플로 이루어진 데이터의 i 번째 샘플의 원본 데이터 값을 S^i , 재구성한 데이터의 i 번째 샘플 값을 S_r^i 라고 하면, 원본 데이터의 샘플과 재구성 데이터의 샘플의 차이 값의 절대 값의 평균인 MAE(Mean Absolute Error)는 샘플간의 차이의 절대 값을 모두 더한 다음 평균을 낸 값이다.

범주형 데이터의 경우는 원본 데이터와 재구성된 데이터가 같은 범주인지 다른 범주인지를 재구성 오류로 규정할 수 있다. 그리고 여러 개의 범주형 데이터 샘플이 모여서 하나의 데이터를 이를 경우 일반적으로 Precision, Recall, Accuracy 등을 사용하여 이러한 데이터의 재구성 오류를 규정한다.

본 연구에서는 수치형 데이터를 사용하며, 시계열 데이터는 여러 개의 수치형 데이터 샘플로 이루어진 데이터이다. 그러므로 각 수치형 데이터 샘플의 원본 데이터와 재구성 데이터의 차이의 절대 값들의 평균인 MAE를 재구성 오류로 사용하였다.

3.2. 기존 연구와의 차이점

많은 연구에서 사용하는 분류기는 정상 데이터와 비정상 데이터 및 레이블을 사전에 분류기에 학습하여 미지의 데이터가 정상 데이터에 속하는지 비정상 데이터에 속하는지 예측해야 하는 지도학습의 기술이다. 이러한 기술을 사용하기 위해서는 레이블이 있는 비정상 데이터를 사전에 충분히 확보해야 하지만 실제 가스 시설 또는 작업의 비정상 데이터는 현장에서 획득하는 것이 거의 불가능하다. 또한, 지도학습의 분류기는 새로운 유형의 비정상 데이터를 비정상 데이터로 예측할 수 없는 문제점을 가지고 있다. 반면 오토인코더를 활용한 모델은 기존의 기술과는 달리 레이블이 필요 없고 정상 데이터만을 이용한 학습을 통해 정상 데이터의 재구성 오류의 분포를 확보할 수 있다. 정상 데이터의 재구성 오류 분포에서 통계적 기법을 이용하여 정상 데이터의 재구성 오류의 임계값(Threshold)을 설정하고 임의의 데이터를 동일한 학습 모델을 통해 재구성 오류가 임계값 이하이면 정상 데이터로 판단하고 임계값을 벗어나면 비정상 데이터로 판단한다. 이 임계값을 이용하여 정상 데이터와 비정상 데이터를 직관적으로 시각화 하는 것이 가능하며, 새로운 유형의 비정상 데이터 또한 이러한 모델을 사용해 감지가 가능하다.

IV. 학습 및 결과

4.1. 오토인코더 모델 구조

본 연구에서는 Tensorflow 인공지능 라이브러리의 상위 수준 API이인 Keras를 사용하여 오토인코더 딥러닝 인공신경망을 구성하였다. 인코더(Encoder)와 디코더(Decoder)는 15600초 길이로 고정된 시계열 데이터를 1차원 이미지로 보고 각 센서 데이터를 하나의 채널로 인식하는 1차원 합성곱 신경망(CNN: Convolutional Neural Networks)을 사용하였다.

최적화 과정은 학습에 사용한 1000건의 가상의 정상 데이터의 재구성 오류인 MAE을 최소로 하는 방향으로 진행하였다. 이를 통해 정상 데이터의 특징을 가장 잘 추출하고 이 모델을 통해 압축하고 복원한 정상 데이터가 최대한 원본 데이터에 가깝게 복원되는 딥러닝 모델을 구축할 수 있다.

모델의 검증을 위해 각 센서 데이터인 작업자 인원수, 산소 농도, 유량, 압력, 온도, 밸브 개폐 여부 등 6개 센서 데이터 종류 각각에 대해 각 작업 단계별로 비정상 범위에 있는 데이터를 오류 데이터로써 추가한 1000건의 시계열 데이터를 생성하였다. 이 오류 데이터 6000건과 새로 생성한 정상 데이터

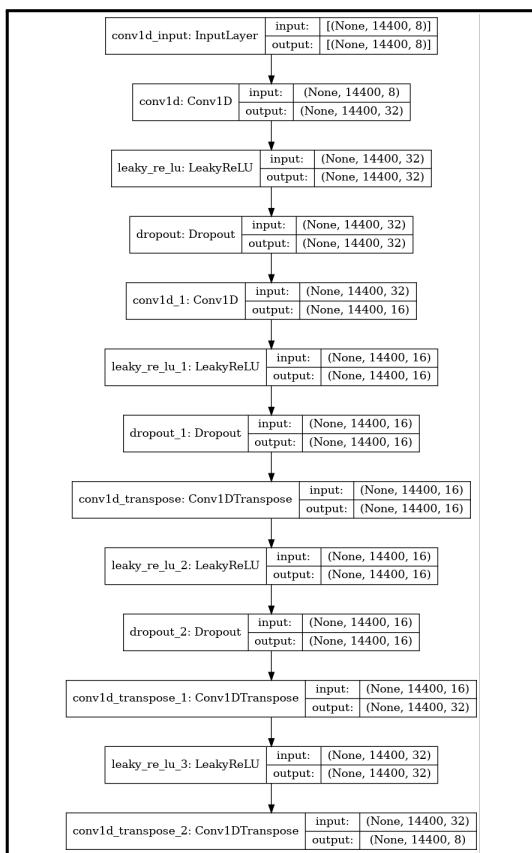


Fig. 5. Autoencoder layer structure.

1000건을 합한 7000건의 데이터를 검증 데이터로 사용하여 모델을 검증하였다. Activation Function으로 ReLU와 Leaky ReLU를 사용하여 성능을 비교하였으며 과적합(Overfitting)을 방지하기 위해 인코더와 디코더의 각 레이어 뒤에 Dropout을 추가하였다. 이 외에 Epoch 변경 등으로 최적화를 수행하였다. 최적화 결과 1000건의 학습용 작업 데이터들의 MAE에 대한 다음과 같은 분포를 얻었다. 이러한 분포로부터 정상 데이터의 MAE의 임계값(Threshold)을 얻을 수 있다. 통계적으로 MAE 분포의 평균과 표준 편차 등을 이용하여 정상 데이터로 볼 수 있는 MAE의 값의 임계값을 구할 수 있으나, 정상 데이터의 범위를 가장 넓게 판단하도록 MAE의 최댓값(약 0.104)을 임계값으로 사용하였다.

최적화된 인공지능 모델을 이용하여 새롭게 생성한 임의의 입력 작업 데이터에 대해 정상 데이터 여부 판정을 진행하였다. 인공지능 모델의 학습 과정은 시간이 소요되지만, 학습이 완료된 인공지능

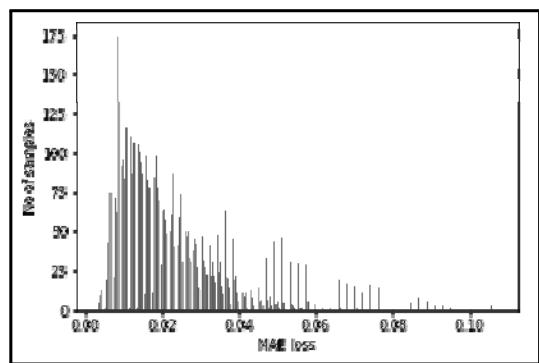


Fig. 6. MAE distribution of the optimized model.

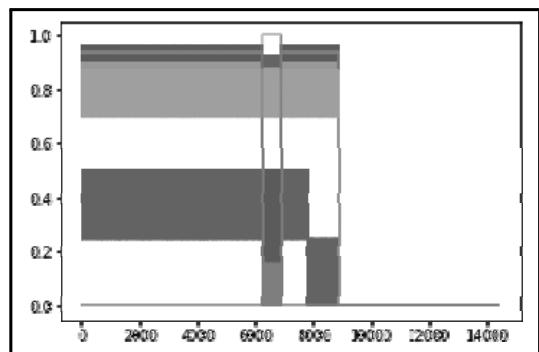


Fig. 7. An example of test data.

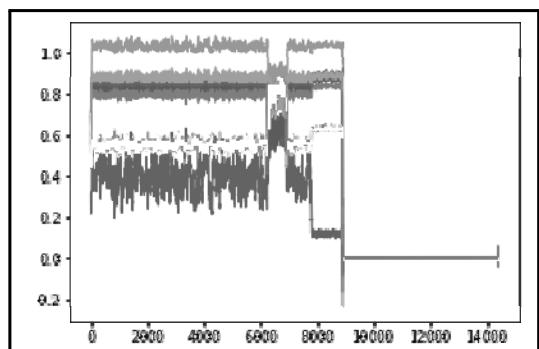


Fig. 8. Reconstruction data of the test data.

모델을 새로운 입력 작업 데이터에 적용하여 입력 데이터의 정상 데이터 여부 판정을 하는 과정은 실시간으로 진행이 가능하였다.

학습된 인공지능 모델을 새로운 작업 데이터에 적용하면 재구성된 작업 데이터가 만들어지며, 입

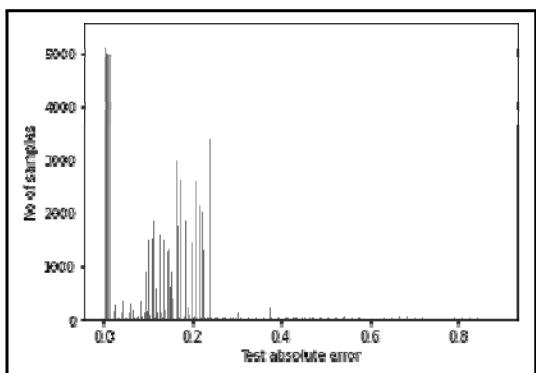


Fig. 9. Distribution of reconstruction errors for each sample of the test data.

력한 작업 데이터와 재구성된 작업 데이터의 각 샘플의 재구성 오류를 구할 수 있고, 이 각 샘플의 재구성 오류로부터 입력한 작업 데이터와 재구성된 작업 데이터 간의 MAE를 구할 수 있다. 이렇게 도출한 MAE 값을 정상 데이터의 MAE 임계값과 비교하여 작으면 정상 데이터이고, 크면 비정상 데이터로 판정한다.

예시의 테스트 작업 데이터의 MAE는 약 0.14로 계산되었다. 이 값은 정상 작업 데이터의 MAE의 최댓값인 임계값 0.104보다 크기 때문에 이 작업 데이터는 비정상 데이터로 판정할 수 있다.

테스트 작업 데이터의 MAE를 구성하는 각 샘플의 재구성 오류의 분포를 보면 다수의 샘플에서 임계값(0.104) 이상의 재구성 오류를 보인다. 이러한 시각화를 통해서도 이 데이터가 정상에서 벗어난 데이터인 것을 확인 할 수 있다.

V. 결 론

본 연구에서는 가상의 가스 시설에서의 배관 교체 작업을 상정하고 이 시설과 작업에 대한 데이터의 특징을 규정하였다. 이 규정에 따라 작업 단계 별로 정상 데이터만으로 이루어진 1000건의 학습용 작업 데이터와 작업 단계별로 정상 데이터와 함께 6가지 센서에 대한 비정상 데이터가 포함된 7000 건의 검증용 작업 데이터를 생성하였다. 오토인코더를 기반으로 하는 인공지능 모델을 설계하고 정상 작업 데이터만으로 이루어진 학습용 데이터를 이용하여 정상 작업 데이터의 MAE가 최소화되도록 하여 모델을 최적화 하였다. 도출된 최적화 모델은 정상 작업 데이터만의 특징으로 데이터를 압축하고 재구성하여 원본 데이터에 가장 가까운 정상 테

이터를 복원하는 것에만 최적화되었기 때문에, 정상 작업 데이터는 특정 임계값 이하의 작은 재구성 오류로 데이터를 재구성하지만, 비정상 작업 데이터는 특정 임계값 이하의 작은 재구성 오류로는 데이터 재구성을 하지 못한다. 이러한 모델의 재구성 오류 특성을 이용하여 미지의 작업 데이터의 정상 비정상 여부를 판정하는 알고리즘을 구축하였다.

기존의 대다수의 비정상 데이터 감지 연구는 지도학습을 기반으로 하고 있다. 하지만, 지도학습은 학습에 사용할 정상 데이터와 비정상 데이터를 확보하고 레이블링을 해야 하는 한계가 있다. 특히, 가스 안전 분야에서는 비정상 데이터를 확보하는 것이 매우 힘들기 때문에 지도학습을 기반으로 하는 연구는 한계를 가질 수밖에 없다. 그에 반해, 본 연구에서 제안한 자기 지도 학습 기반의 알고리즘은 실제 작업 환경에서 수집이 가능한 데이터가 정상 데이터만 있을 경우에도 이 정상 데이터만을 이용하여 정상 데이터와 비정상 데이터를 구분할 수 있는 장점이 있다. 이러한 모델은 기존의 지도학습 알고리즘의 수행을 보완하는 용도로 사용하면 비정상 데이터 감지 알고리즘의 성능 향상에 기여할 수 있을 것으로 예상한다. 기존의 알고리즘으로 구분할 수 없었던 비정상 작업 데이터를 구분하고 비정상 데이터에 대한 레이블을 추가하여 지도 학습에 활용하거나, 비정상 작업 데이터의 특성에 대한 추가적인 연구를 하는데 도움을 줄 수 있을 것으로 기대한다.

본 연구의 향후에는 가스 시설의 작업 데이터의 정상 비정상 판정 알고리즘을 이용하여 기존의 가스 안전 관리 기법과 접목할 수 있는 방법에 대한 연구를 진행할 수 있을 것으로 예상한다.

감사의 글

본 연구는 중소벤처기업부의 규제자유특구혁신 사업육성 지원에 의한 연구임 (과제번호 : P0011362, 과제명 : 누출검지 고도화 및 산업용 IoT기반 스마트 차단제어 장치 개발 및 실증)

REFERENCES

- [1] Md. Rezaul Karim, Ahmed Menshawy, *Deep Learning By Example*, O'Reilly, (2018)
- [2] J. An and S. Cho., *Variational autoencoder based anomaly detection using reconstruction probability*, (2015)
- [3] Y. LeCun and C. Cortes, *MNIST handwritten*

- digit database*, (2010)
- [4] B. Zong, Q. Song, M. R. Min, W. Cheng, C. Lumezanu, D. Cho, and H. Chen., *Deep autoencoding gaussian mixture model for unsupervised anomaly detection*. In *International Conference on Learning Representations*, (2018)
- [5] V. Nair and G. E. Hinton., *Rectified linear units improve restricted boltzmann machines*. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, 807-814, (2010)
- [6] D. P. Kingma and J. Ba. Adam, *A method for stochastic optimization*. In *International Conference on Learning Representations*, (2015)