

# 딥 러닝과 설명가능 인공지능을 이용한 VOCs 저감설비 이상 분석

서민지<sup>1</sup>, 김명호<sup>2</sup>

<sup>1</sup>승실대학교 AI융합연구원 연구원

<sup>2</sup>승실대학교 소프트웨어학부 교수

[porito2@soongsil.ac.kr](mailto:porito2@soongsil.ac.kr), [kmh@ssu.ac.kr](mailto:kmh@ssu.ac.kr)

## Analysis for Anomalies in VOCs Reduction Facilities using Deep Learning and XAI

Min-Ji Seo<sup>1</sup>, Myung-Ho Kim<sup>2</sup>

<sup>1</sup>AI Convergence Research Institute, Soongsil University

<sup>2</sup>Dept. of Software, Soongsil University

### 요 약

4차 산업혁명의 발달로 스마트공장 기술이 발달하면서, 딥 러닝을 활용한 공정 과정에서 나타나는 이상을 탐지하는 기술이 활발히 연구되고 있다. 하지만 공정 과정에서 발생하는 휘발성유기화합물(VOCs) 저감 설비에서 발생하는 이상을 탐지하기 위한 연구는 적극적으로 진행되고 있지 않다. 따라서 본 논문에서는 딥 러닝 기술을 이용하여 VOCs 저감설비에서 발생하는 이상을 탐지하고, 설명가능 인공지능(XAI)을 활용하여 이상에 큰 영향을 미치는 주요 설비를 특정하여 이상 발생 시 관리자가 용이하게 설비들을 관리할 수 있도록 하였다.

### 1. 서론

이상 탐지는 정상적인 상황에서 예측되거나 기대되지 않았던 데이터 패턴을 찾아 찾는 문제를 의미한다. 이상 탐지는 다양한 분야에 적용되어 왔으며, 최근에는 스마트공장 기술의 발달로 인해 산업 현장에서 실시간으로 수집되는 데이터의 양이 기하급수적으로 늘어남에 따라, 딥 러닝을 활용한 시계열 데이터 기반의 이상 탐지 모델에 대한 연구가 활발히 진행되고 있다[1]. 산업 분야에서는 수집되는 이상 데이터가 정상 데이터에 비해 현저히 부족하기 때문에, 이상 탐지 모델은 지도 학습보다는 비지도 학습 기반 모델이 주로 연구되고 있다.

그러나 휘발성 유기화합물(VOCs) 저감 설비에 대한 이상 탐지 모델은 연구된 바가 거의 없는 실정이다. 현재 Environmental, social, governance(ESG)에 대한 관심이 높아지면서, VOCs 저감에 대한 중요성에 대한 관심은 높아지고 있다. 그러나 저감 설비의 이상 탐지에 대한 연구는 적극적으로 진행되지 않고 있어 이에 대한 연구가 필요하다.

이러한 배경에서 본 논문에서는 VOCs 저감설비에서 수집한 데이터를 활용하여 이상 탐지 여부를 확인하고, 이상에 영향을 미치는 요인을 확인하였다. Anomaly-transformer[2] 모델을 통해 설비의 이상

을 확인하였으며, 이상에 영향을 미치는 요인은 설명가능 인공지능(XAI) 모델 중 Shapley Additive explanations (SHAP)[3]를 이용하여 확인하였다.

본 논문의 구성은 다음과 같다. 2장에서는 연구되고 있는 시계열 데이터 기반 이상 탐지 모델과 XAI 방법론을 설명한다. 3장에서는 딥 러닝 모델을 활용하여 VOCs 저감설비의 이상을 탐지하며, 4장에서는 XAI 방법론을 적용하여 이상에 큰 영향을 미치는 주요 설비들을 특정한다. 마지막 5장에서는 결론을 내리며 향후 과제에 대하여 논의한다.

### 2. 관련 연구

#### 2.1 시계열 데이터 기반 이상 탐지

4차 산업혁명의 발달로 공정 과정이 스마트화되면서, 실시간으로 수집되는 대용량의 시계열 데이터 이상을 탐지하기 위한 딥러닝 기반 이상탐지 모델 연구가 적극적으로 진행되고 있다. 이상 탐지를 위한 딥러닝 모델 중에서는 오토인코더(Autoencoder), Generative Adversarial Network(GAN) 모델을 활용한 재구성(Reconstruction) 기반 모델[4, 5]이 주로 연구되고 있다. 최근에는 자연어처리에서 높은 성능을 보인 트랜스포머(Transformer) 모델이 시계열 데이터 처리에 높은 성능을 보이면서, 재구성 기반 모

델에 트랜스포머 모델의 self-attention 기법을 활용한 이상 탐지 모델이 연구되고 있다. 본 논문에서는 재구축기반 모델과 self-attention 기법을 모두 활용하여 우수한 성능으로 공정 설비 데이터의 이상을 탐지하는 Anomaly-transformer 모델을 활용하였다.

### 2.2 설명가능 인공지능

인공지능 기반의 이상 탐지의 성능이 향상되면서, 인공지능 모델이 결과를 도출하는 과정을 분석하고자 하는 연구가 진행되고 있다. 모델이 도출한 결과뿐만 아니라 모델이 해당 결과를 판단하게 된 원인이 되는 특징 변수들을 판단하는 것 또한 중요하기 때문에, 모델이 내린 결정과 그 작동 원리를 사람이 이해하기 위한 XAI에 대한 연구가 다양한 분야에서 적극적으로 진행되고 있다. 현재 XAI 방법론으로 Local Interpretable Model-Agnostic Explanations(LIME)[6], SHAP 등이 연구되었다.

SHAP는 게임 이론을 기반으로 모델의 결과 도출에 대한 각 특징의 영향도를 설명하기 위해, 여러 특징들의 조합을 구성하고 그 중에 각 특징의 유무에 대한 결과를 분석한 SHAP value를 계산한다. SHAP은 타 기법에 비해 모델 전체에 대해 일관성 있는 설명을 제공할 수 있어 본 논문에서는 공정 이상시 이상에 영향을 주는 설비를 측정하기 위해 SHAP를 활용하였다.

### 3. Anomaly-transformer 기반 설비 이상탐지

본 논문에서는 VOCs 저감 설비의 이상을 탐지하기 위해 Anomaly-transformer 모델을 활용하였다. Anomaly-transformer는 두 패러다임으로 구성된다. 첫 번째로, self-attention 기법을 활용하여 전반적으로 나타나는 데이터들의 상관성을 학습하였다. 두 번째로, 가우시안 커널을 활용하여 인접한 시간에서 나타나는 데이터들의 상관성을 학습하고자 하였다. 특히, 미니맥스 전략(Minimax Strategy)을 활용하여 self-attention 기법에서 주변 구간의 데이터 정보를 더 학습할 수 있도록 하였으며, 가우시안 커널을 통해 전반적인 구간에서 나타나는 데이터 특징을 더 잘 학습할 수 있도록 하였다.

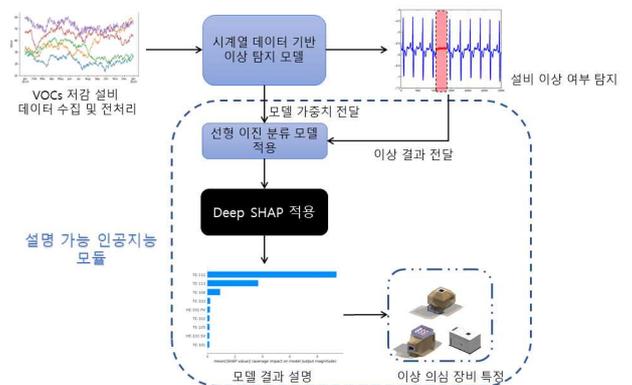
본 논문에서는 Anomaly-transformer 모델을 이용하여 VOCs 저감 설비에서 수집한 데이터를 기반으로 실험을 진행하였다. 모델의 학습은 정상 상황 날짜의 데이터를 사용하였으며, 모델의 테스트는 이상 상황이 포함된 날짜의 데이터를 사용하였다. 또

한 실험에 사용할 데이터의 종류는 24개로, VOCs 저감설비를 구성하는 장비들의 온도, 압력, 장비 구동 속도, 온도 설정 수치 등을 포함한다. 실증 데이터의 학습 데이터는 41,832개이며, 테스트 데이터는 52,897개의 데이터를 가진다. 데이터는 슬라이딩 윈도우 기법을 활용하여 시계열 데이터를 분할하였으며, 이 때 분할된 윈도우의 크기는 100, 데이터 배치 크기는 50으로 설정하였다. 또한 학습의 옵티마이저(Optimizer)는 Adam을 활용하였으며, 실증 데이터 테스트에서 모델의 하이퍼파라미터(Hyperparameter)는 Anomaly-Transformer과 동일하게 설정하였다. 또한 이상 탐지의 성능은 정밀도(Precision), 재현율(Recall), F1 점수를 사용하여 평가하였다.

실험 결과, VOCs 저감 설비 데이터의 이상 탐지 정밀도는 85%, 재현율은 96%, F1 점수는 90%의 성능을 보이며, 공정의 이상 여부를 높은 성능으로 발견하는 것을 확인하였다.

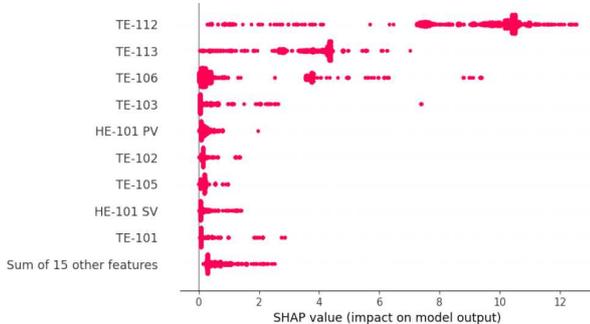
### 4. SHAP을 활용한 이상 영향 주요 설비 판별

VOCs 저감 설비에서의 이상 탐지가 완료되면, SHAP을 적용하여 이상에 가장 영향을 미치는 요인들을 판별한다. 일반적으로 SHAP은 기본적으로 하나의 값으로 모델의 결과 값이 명확해야 한다는 제한 사항이 있어, 재구축 기반 모델은 직접적으로 SHAP을 적용하기 어렵다는 문제점을 가진다. 따라서 제조에서의 이상 탐지 모델을 설명하기 위해 기존 훈련된 모델의 가중치를 전달하여, 사전 학습된 가중치에 이진 분류 모델을 위한 다층 퍼셉트론(MLP)레이어를 하나 추가하였다. 이 때, 본 논문에서는 SHAP 중에서도 딥 러닝 모델을 설명하기 위해 고안된 DeepSHAP을 이용하여 재구축 모델을 설명하였다. 전체적인 구성도는 그림 1과 같다.



(그림 1) 딥 러닝과 XAI를 이용한 VOCs 저감설비 이상 분석 시스템 구성도

Anomaly-transformer에서 이상이 발견된 타임 윈도우를 선별하여 DeepSHAP으로 설명한 결과는 그림 2와 같다. 그림 2는 설비의 이상에 영향을 주는 정도를 높은 순으로 정렬하여 나타낸 것이다.



(그림 2) XAI로 분석한 센서별 이상 기여율

DeepSHAP으로 모델의 결과를 분석한 결과, TE-112와 TE-113, TE-106 센서가 데이터의 이상에 전반적으로 높은 기여율을 보이는 것으로 보인다. TE로 시작하는 센서들은 온도 센서를 의미하며, TE-112는 VOCs 물질을 분해 공기에 탈착시키는 탈착팬의 입력부의 온도를, TE-113은 시스템에서 배출하는 폐열을 회수하기 위한 냉각부의 온도를 의미한다. TE-106은 VOCs를 정화하기 위한 촉매산화설비의 온도를 의미한다. 이로 미루어 봤을 때, VOCs 저감설비에서 이상이 생길 경우 탈착팬의 온도가 큰 가장 큰 영향을 주었으며, 탈착팬은 시스템 작동 구조상 냉각부와 촉매산화설비와 유기적으로 연결되어 있기 때문에, 연쇄적으로 이들의 온도 또한 저감설비 공정의 이상에 영향을 미치는 것을 확인할 수 있었다.

## 5. 결론

본 논문에서는 공정 과정에서 나타나는 VOCs 저감설비에서 나타나는 이상의 중요 영향 변수를 분석하기 위해 XAI 기법을 활용하여 데이터 특징의 기여도를 계산하였다. 먼저 딥 러닝 기반 이상탐지 모델인 Anomaly-transformer 모델을 이용하여 이상이 탐지되는 구간을 탐색하였으며, XAI 기법 중에서 딥 러닝 모델 설명에 높은 성능을 보이는 DeepSHAP 기법을 적용하여 딥 러닝 모델의 예측 결과를 설명하도록 하였다. XAI 기법을 적용한 결과, 저감설비의 이상에는 VOCs 물질을 분해 공기에 탈착시키는 탈착팬이 큰 영향을 미치는 것을 판단할 수 있었다. 본 논문의 분석 결과를 통해 관리자가 공정 이

상 탐지 시 관리해야 할 주요 설비를 용이하게 찾을 수 있을 것으로 기대한다. 향후 연구에서는 XAI 기법을 통해 찾아낸 이상의 중요 요인이 되는 설비들을 자동적으로 용이하게 관리할 수 있는 추가적인 연구를 수행할 계획이다.

## Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(No. 2022202090003C)

## 참고문헌

- [1] Cook, A. A., Göksel M., and Zhong F., "Anomaly detection for IoT time-series data: A survey," *IEEE Internet of Things Journal*, vol. 7, no. 7, pp. 6481-6494, 2019.
- [2] Xu, J., Wu, H., Wang, J. and Long, M., "Anomaly transformer: Time series anomaly detection with association discrepancy," *arXiv preprint arXiv:2110.02642*, 2021.
- [3] Lundberg, S. M., and S. I. Lee., "A unified approach to interpreting model predictions," *Advances in neural information processing systems* 30, USA, 2017.
- [4] Zhou, B., Liu, S., Hooi, B., Cheng, X. and Ye, J., "BeatGAN: Anomalous Rhythm Detection using Adversarially Generated Time Series," In *IJCAI, China*, 2019, vol. 2019, pp. 4433-4439.
- [5] Audibert, J., Michiardi, P., Guyard, F., Marti, S., and Zuluaga, M. A., "Usad: Unsupervised anomaly detection on multivariate time series," In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, USA*, 2020, pp. 3395-3404.
- [6] Ribeiro, M. T., Singh, S. and Guestrin, C., "Why should i trust you? Explaining the predictions of any classifier," In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, USA*, 2016, pp. 1135-1144.