

머신러닝 기반 실내 냉방기의 냉매누설 검출 방법

우영주*, 김유민**, 안소현*, 고서영*,
Nguyen Thi Phuong Hang*, 신춘성***, 정희용*, **

*전남대학교 인공지능융합학과

**전남대학교 소프트웨어공학과

***전남대학교 문화전문대학원

218860@jnu.ac.kr, culyumin33@gmail.com, 217558@jnu.ac.kr, 217927@jnu.ac.kr,
208258@jnu.ac.kr, cshin@jnu.ac.kr, h.jeong@jnu.ac.kr

AutoML-based Refrigerant Leakage Detection of Air-Conditioning System

Yeoungju Woo*, Yumin Kim**, Sohyun Ahn*, Seoyeong Ko*, Hang Thi
Phuong Nguyen*, Choonsung Shin***, Hieyong Jeong*, **

*Dept. of Artificial Intelligence Convergence, Chonnam National University

**Dept. of Software Engineering, Chonnam National University

***Graduate School of Culture, Chonnam National University

요 약

해마다 실내 냉방기 냉매누설 문제가 고질적으로 반복되며 소비자들의 피해도 커져가고 있다. 특히 제조사와 설치 업체가 다른 경우 냉매 누설의 원인이 제품인지, 설치하자인지 책임소재를 두고 갈등을 빚는 경우가 빈번하다. 이에 더 이상 소비자들의 피해를 막기 위해 냉매누설 검출 방안 마련이 필요해 보인다. 본 연구에서는 실내 냉방기 설치 후 냉매누설 검출을 위한 별도의 하드웨어 장치 추가 없이 냉방기의 운영을 위해 설치된 센서들의 값을 이용하여 냉매누설의 유무를 판단할 수 있는 방안을 제안하는 것을 목적으로 한다. 데이터 분석을 위하여 제조사의 제품 출하 전 현장 테스트 단계에서 측정된 온도값, 전류값, 습도값을 취합하여 데이터 셋을 구축하였다. 이때 자동화된 머신러닝(AutoML)을 이용하여 데이터의 80%를 훈련 데이터로 20%를 테스트 데이터로 사용하여 냉매량 80%는 1, 그 이하는 0으로 훈련시켰다. 구축한 데이터 셋을 이용하여 훈련시킨 결과 99% 정확도로 냉매누설 검출을 분별할 수 있었다. 또한 냉매누설과 관련성이 높은 중요 특징 4개를 추출할 수 있었다. 본 연구를 통하여 별도의 하드웨어 장치 추가 없이 소프트웨어적인 접근 방법으로 문제를 해결할 수 있는 feasibility를 확인할 수 있었다.

1. 서론

각 가정에 실내 냉방기를 사용하여 쾌적한 실내 환경 조성에 대한 요구가 증가하고 있다 [1], [2]. 하지만 매년 냉방기 냉매 누설 문제가 고질적으로 반복되면서 소비자들의 불만도 함께 증가하고 있다. 제조사와 설치업체가 다른 경우 냉매 누설의 원인이 제품인지, 설치하자인지 책임소재를 두고 갈등을 빚는 경우가 빈번히 발생하고 있다. 설치한지 오래 안 된 냉방기에서 냉매가 누설되어 정신적 금전적 피해를 호소하는 소비자 불만 목소리가 해마다 들끓고 있다. 실내 냉방기 냉매는 순환형 가스로 통상 10년가량 충전 없이 사용할 수 있지만, 거의 매년 냉매가 누설돼 많게는 수 십만원의 비용을 지불하고 가스를 재충전 한다는 것이다.

냉동사이클에서 냉매누설은 냉동기에 치명적인 고장을 발생시키게 된다. 기존 냉매누설 검사 방법으로

1) 헬라이트 토치검사법, 2) 전자식 누설탐지기 검사법, 3) 질소가압 비누물검사가 있다 [3]. 1)과 2)는 전문적인 지식과 경험이 요구된다. 3)은 전문적인 지식이 없더라도 가능하지만, 누설 부분이 소비자의 손에 닿지 않는 부분에서 발생하였다면 발견하기 어렵다.

이에 본 연구에서는 전문적인 지식과 경험이 없는 소비자라도 실내 냉방기 설치 후 냉매누설 검출 유무를 확인할 수 있는 방법을 제안하는 것을 목적으로 하였다. 실내 냉방기 설치 후 냉매누설 검출을 위한 별도의 하드웨어 장치 추가 없이 냉방기의 운영을 위해 설치된 센서들의 값을 이용하여 냉매누설의 유무를 판단할 수 있는 방안을 제안하고 그 유효성을 확인해 보았다.

model_id	auc	logloss	aucpr	mean_per_class_error	rmse	mse	training_time_ms	predict_time_per_row_ms	algo
DeepLearning_grid_1_AutoML_20210714_054656_model_1	0.996714	0.224386	0.996292	0.0322581	0.184884	0.0341823	4001	0.097197	DeepLearning
StackedEnsemble_AllModels_AutoML_20210714_054656	0.99552	0.15749	0.99495	0.0334528	0.187444	0.0351353	226	0.195312	StackedEnsemble
StackedEnsemble_BestOfffamily_AutoML_20210714_054656	0.994922	0.0896818	0.994709	0.0253883	0.154249	0.0237927	429	0.13087	StackedEnsemble
DeepLearning_1_AutoML_20210714_054656	0.994325	0.0976143	0.993492	0.026583	0.161353	0.0260347	120	0.057075	DeepLearning
XRT_1_AutoML_20210714_054656	0.994176	0.112732	0.993578	0.0427121	0.186052	0.0346154	268	0.067068	DRF
DRF_1_AutoML_20210714_054656	0.992832	0.116325	0.992157	0.0415173	0.189994	0.0360977	181	0.065601	DRF
GBM_2_AutoML_20210714_054656	0.992234	0.157759	0.991184	0.0403226	0.222679	0.0495861	1108	0.137249	GBM
GBM_4_AutoML_20210714_054656	0.991338	0.167683	0.990152	0.0415173	0.227599	0.0518013	761	0.109299	GBM
GBM_3_AutoML_20210714_054656	0.990741	0.163464	0.990201	0.0415173	0.227655	0.0518266	669	0.092203	GBM
GBM_grid_1_AutoML_20210714_054656_model_1	0.989247	0.18899	0.988165	0.0507766	0.235283	0.0553579	1410	0.100305	GBM
GBM_1_AutoML_20210714_054656	0.984767	0.209309	0.985716	0.0507766	0.238869	0.0570584	890	0.085517	GBM
GLM_1_AutoML_20210714_054656	0.97491	0.184153	0.973815	0.106033	0.246071	0.060551	549	0.049381	GLM

(그림 1) 자동화된 머신러닝(AutoML)을 이용하여 데이터를 학습시킨 결과.

2. 자동화된 머신러닝

피쳐 엔지니어링은 원천데이터로부터 피쳐를 이해하고 개선하여 구성함으로써 피쳐링된 데이터셋을 구성하는 과정이다. 머신러닝 알고리즘의 예측 정확도를 높이기 위해 필수적으로 요구되지만 도메인 전문가의 역량이 집중적으로 투자돼야 한다. 자동화된 머신러닝은 피쳐 엔지니어링과 모델 학습과 운영 등 머신러닝 프로세스의 전 과정을 지원하여 별도의 인공지능 관련 전문적인 경험과 지식 없이도 다양한 머신러닝 알고리즘을 분석해 사용자 목적에 맞는 최적의 모델을 선정할 수 있도록 제공해 준다. 따라서 도메인 지식을 가지고 있지만 인공지능 알고리즘과 코딩에 어려움을 겪고 있는 분들에게 적합한 도구라고 여겨진다.


3. 실험 결과

제품 출하 전 현장 테스트 과정에서 수집한 데이터를 이용하여 데이터 셋을 구축하여 AutoML을 이용하여 분석하였다. 데이터 전처리 과정에서 결측 데이터가 많은 행과 열은 삭제하여 총 (행 x 열 = 139 x 75) 크기의 데이터 셋을 구축하였고 80%는 훈련에 20%는 테스트에 사용하였다. 냉매량 80% 이상은 1로 그 이하는 0으로 분류할 수 있도록 훈련시켰다.

그림 1은 AutoML로 훈련시킨 모델과 그 결과를 보여주고 있다. 총 12개의 모델을 이용하여 데이터를 학습시킨 후 accuracy, loss 등 훈련 성능을 보여주는 결과가 동시에 얻을 수 있는 것을 알 수 있다. 주어진 데이터 셋에서는 Deep_Learning_Grid_1 모델이 가장 좋은 성능을 보였고, 99% 정확도로 냉매누설의 유무를 분별할 수 있었다.

그림 2는 본 훈련 결과에 중요한 영향을 미친 요소를 보여주고 있다. 4~5개의 특성이 주어진 결과에 큰 영향을 미친 것을 알 수 있다.

본 실험 결과를 통하여 시스템의 모니터링에 사용



(그림 2) 특성 중요 요인 추출.

되는 센서값을 이용하여 냉매누설 검출이 가능하다는 것을 간단히 확인해 볼 수 있었다.

4. 결론

본 연구에서는 별도의 하드웨어 장치의 추가 없이 실내 냉방기의 원활한 운영을 위해 기 설치된 센서값들을 이용하여 냉매누설을 검출할 수 있는지 이진분류로 확인해 본 결과, 높은 정확도로 분류가 가능하다는 것을 알게 되었다.

사사

이 논문은 2021년도 전남대학교 SW중심대학 산학협력프로젝트와 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(2021R111A305521011)의 연구비 지원을 받아 수행되었고, 현장 테스트 데이터는 (주)오텍캐리어로부터 제공받았음.

참고문헌

- [1] 한도영, 정남철, “신경망무고장모델과 이중퍼지 규칙을 사용한 냉방기 고장진단 알고리즘”, 설비공학논문집, 18(10), 791-799, 2006.
- [2] 이승현, “멀티형 냉방기의 냉매누설 검출과 위치 추적에 관한 연구”, 국민대학교 대학원 기계공학석사학위 논문, 2003.
- [3] 김인술, “김인술의 알기 쉬운 냉동공조이야기23”, 냉동공조저널, 기술정보, 연재, 2021 (<https://www.hvacri.co.kr/news/articleView.html?idxno=10135>).