



RESEARCH ARTICLE

입력변수 조건에 따른 공조기 고장검출 성능평가

정진화¹ · 채영태^{2*}

¹가천대학교 건축공학과 박사과정, ²가천대학교 건축공학과 조교수

Performance Evaluation of Fault Detection for Building HVAC Systems with Feature Selection Methods

Jeong, Jin-Hwa¹ · Chae, Young-Tae^{2*}

¹PH.D. Candidate, Department of Architectural Engineering, Gachon University, Seongnam, Korea

²Professor, Department of Architectural Engineering, Gachon University, Seongnam, Korea

*Corresponding author: Chae, Young-Tae, Tel: +82-32-750-5299, E-mail: ychae@gachon.ac.kr

ABSTRACT

This study proposes performance improvement methods of fault detection of AHU systems with measurement of variable importance and comparison for three fault models based on ASHRAE 1312-RP experimental dataset. The results show that input variables were determined differently for each of the representative three fault types. The fault detection performance be improved more than 29% compared to base input condition using major input variables which measured importance of system variables. Also, the impact of variables and models be differed for each type of fault. The results of this study contribute to failure protection of HVAC systems and exploration of fault location in advance. It is necessary to verify the generalization performance of the proposed model in actual system conditions.

주요어 : 고장검출, 건물 공조기, 변수중요도, 고장검출 모델, ASHRAE 1312-RP

Keywords: Fault detection, AHU system, Variable importance, Fault detection model, ASHRAE 1312-RP

OPEN ACCESS

Journal of KIAEBS 2023 December, 17(6): 471-481
<https://doi.org/10.22696/jkiaeb.20230040>

pISSN : 1976-6483
eISSN : 2586-0666

Received: December 12, 2023

Revised: December 26, 2023

Accepted: December 27, 2023

© 2023 Korean Institute of Architectural Sustainable Environment and Building Systems.



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

서론

건물에너지는 전세계 에너지의 30% 이상 비중을 차지하고 있으며 그 중 HVAC (Heating, ventilation and air conditioning) 시스템은 상업용 건물에너지의 절반 이상 높은 비율을 보이고 있다(Global Alliance for Building and Construction, 2022). HVAC 시스템은 건물에너지의 주요 요인이자 쾌적한 실내환경 조성을 위해 건물 운영관리에 가장 필요한 요소로 국내 외에 걸쳐 시스템의 효율적인 운영 및 관리를 위해 시스템의 효율 향상, 사전 고장진단 등 다양한 형태의 연구가 이루어지고 있다. 특히, HVAC 시스템의 고장은 에너지 낭비 뿐만 아니라, 실내환경 저하, 건물 운전비용 증가까지 이어질 수 있다.

HVAC 시스템의 복잡성으로 인해 대부분의 고장이 엔지니어의 주관적 판단에 의해 보수

되고 운영되고 있어 최근 보다 효율적인 HVAC 시스템의 고장 검출 및 진단(FDD, fault detection and diagnostics)을 위해 데이터 기반(data driven)의 기계학습모델(machine learning)을 활용한 FDD 연구가 활발히 이루어지고 있다. Jeong et al. (2021)은 에너지 시뮬레이션을 활용한 변풍량(VAV, variable air volume) 시스템을 구축하고 규칙 기반의 물리 모델을 적용하여 VAV 시스템의 주요 고장(온도센서, 외기멤퍼, 환기모드) 검출성능을 검증하였다. 해당 연구에서는 시스템 정상 및 고장 판별을 위해 온도(외기온도, 환기온도, 혼합온도, 토출온도), 뎀퍼개도율 데이터를 통한 각 고장을 검출하였고 사용된 검출모델의 3단계 임계값 설정을 통해 고장 심각도를 산출하였다. Kim (2022)은 환기 설비용 전동기를 대상으로 IoT 센서 설치를 통한 진동 데이터를 수집하여 대상 전동기의 자동 고장진단이 가능한 시분할 CNN-LSTM(convolutional neural network-long short term memory) 모델을 제안하였다. 제안한 모델은 노이즈가 포함된 데이터의 필터링과 CNN 모델 기반의 데이터 특징을 추출을 통해 LSTM 모델에 적용시킴으로써 고장검출 성능 향상에 기여하였다. Gao et al. (2019)은 ASHRAE 1312-RP 데이터셋 및 실제 오피스 건물을 중심으로 3단계 레벨(에너지 벤치마킹, 시스템 제어 성능평가, 데이터 기반 모델링)의 AHU 시스템 FDD 모델을 제안하였다. 특히, 레벨-3 수준(데이터 기반 모델링)에서 적용한 CART(classification and regression tree) 모델은 각 고장별 주요 데이터 예측 및 고장 판별까지 수행하였고 92.8%의 고장 검출 정확도가 산출되었다. Taheri et al. (2021)은 실제 테스트베드 실험 기반의 VAV 시스템의 공조기 정상-고장 데이터를 수집하여 DRNN(deep recurrent neural network) 모델의 은닉층 및 레이어 사이즈 조정, 모델 표준화를 통한 FDD 성능을 비교하였다. 다양한 튜닝 실험을 통해 제안한 모델의 91%의 정확도(F1-score 기준)가 산출되었고 비교한 타모델(random forest: 85%) 대비 높은 검출 성능을 보였다. 앞선 국내외 선행연구로부터 다양한 고장검출 모델을 활용한 FDD 연구가 수행되고 있으나, 대다수 연구는 사용되는 FDD 모델 성능개선에 대해 초점을 두고 있으나, 실제 현장에서 취득되는 데이터 수준 및 고장별 영향도에 따른 모델 비교를 통한 적정 FDD 모델 선정에 대한 연구도 필요하다.

이에 본 연구에서는 ASHRAE 1312-RP 데이터셋 기반의 공조기 입력변수 중요도를 평가하고 변수 조건에 따른 고장검출 모델 성능비교를 통해 대표 고장별 적정 고장검출 모델의 선정방안을 제안하고자 한다.

공조기 고장검출 방안

ASHRAE 1312-RP 데이터셋

미국냉동공조학회(ASHRAE, American Society of Heating, Refrigerating and Air-Conditioning Engineers)는 2012년 ASHRAE-1312 ‘Tools for Evaluating Fault Detection and Diagnostic Methods for Air-Handling Units’ 프로젝트를 통해 변풍량(VAV, Variable air volume) 시스템을 대상으로 31가지 고장현상(하절기 기준) 실험 데이터셋(ASHRAE 1312-RP)을 구현하였다. ASHRAE 1312-RP는 29가지 데이터 항목과 절기별 특정기간동안 발생하는 31가지 항

목의 고장(센서고장-12가지, 요소고장-19가지)을 구현하고 모든 고장은 하루 24시간 중 주간 시간(오전 6시- 오후 6시)동안 1분별 간격으로 구성되어 있다. 해당 VAV 시스템은 Figure 1 과 같이 냉난방 코일, 급기/환기팬, 그리고 혼합덤퍼로 이루어져 있으며 실제 현장에서 수행 되기 어려운 고장 실험을 통해 데이터를 취득하여 시스템 정상 및 고장에 대한 뚜렷한 변수특 성이 나타난다. 본 연구에서는 하절기 기간(총 32일)을 중심으로 공조기 부위별 16가지 시스 템 고장(Table 1) 및 19가지 데이터 항목(Table 2)으로 재구성된 데이터셋을 기반으로 주요 고장현상에 대한 변수 중요도 평가 및 입력변수의 영향도에 따른 모델 성능비교를 통해 적정 FDD 방법을 선정하였으며 성능평가를 위한 데이터 구성은 Table 3과 같다.

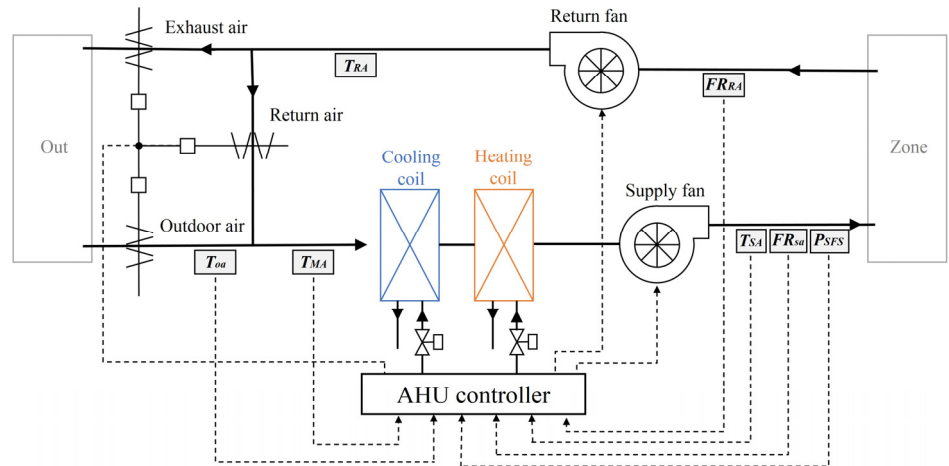


Figure 1. Schematic of target VAV systems (Wen and Li, 2012)

Table 1. Summary of fault types in VAV systems based on ASHRAE 1312-RP project

	Fault type	Abbreviation
OA damper	OA damper stuck (fully closed)	O AFC
	OA damper leak (45% open)	OA45
	OA damper leak (55% open)	OA55
Cooling coil	Cooling coil valve stuck (15% open)	CC15
	Cooling coil valve stuck (65% open)	CC65
	Cooling coil valve stuck (fully closed)	CCFC
	Cooling coil valve stuck (fully open)	CCFO
	Cooling coil valve control unstable	CCCU
	Cooling coil valve reverse action	CCRA
Heating coil	Heating coil valve leaking (0.4 GPM)	HC0.4
	Heating coil valve leaking (1.0 GPM)	HC1.0
	Heating coil valve leaking (2.0 GPM)	HC2.0
Return fan	Return fan completer fault	RFCF
	Return fan fixed speed (30%)	RFFS
AHU duct	AHU duct leaking after supply fan	ADLA
	AHU duct leaking before supply fan	ADLB

Table 2. Data description of VAV systems in AHSRAE 1312-RP project

		Data description	Abbreviation
1	Valve position	Cooling coil valve position (%)	VP_{CC}
2		EA damper position (%open)	DP_{EA}
3	Damper position	RA damper position (%open)	DP_{RA}
4		OA damper position (%open)	DP_{OA}
5		Supply fan power (W)	FP_{SF}
6	Fan power	Return fan power (W)	FP_{RF}
7		Supply air flow rate (CFM)	FR_{SA}
8	Air flow rate	Return air flow rate (CFM)	FR_{RA}
9		Outdoor air flow rate (CFM)	FR_{OA}
10		Supply air temperature (F)	T_{SA}
11	Air temperature	Mixing air temperature (F)	T_{MA}
12		Return air temperature (F)	T_{RA}
13		Outdoor air temperature (F)	T_{OA}
14	Discharge air temperature	Cooling coil discharge air temperature (F)	DT_{CC}
15		Supply fan static pressure (in.wg)	P_{SFS}
16	Pressure	Supply fan differential pressure (in.wg)	P_{SFD}
17		Return fan differential pressure (in.wg)	P_{RFD}
18		Supply fan speed (%)	FS_{SF}
19	Fan speed	Return fan speed (%)	FS_{RF}

Table 3. Data divisions of fault dataset of VAV systems

		Data size	Day condition	Note
Measurement of variable importance	Test	22,656	Normal (16 days) + 16 fault (1 fault / 1 day)	excluded on time
Model compare with input conditions	Train	22,656	Normal (16 days) + 16 fault (1 fault / 1 day)	excluded on time
	Test	204	Normal (16 days) + 1 fault (1 day)	Only on time

FDD 모델 개요

본 연구에서는 공조기 고장검출 성능평가를 위해 패턴인식(pattern recognition) 기반의 1 가지 black-box 모델(ANN-artificial neural network) 및 2가지 white-box 모델(DT- decision tree, ES - ensemble)을 활용하였다. ANN 모델은 크게 입력층, 은닉층, 결과가 산출되는 출력층으로 구성되어 입력되는 변수 간의 관계를 각 층간의 가중치 기반의 학습을 통해 고장 검출 정확도를 높일 수 있는 모델 구조적 특징을 지니고 있다. 본 FDD 평가를 위해 입력층의 노드는 입력변수의 수와 동일하게 설정하였고 사전 테스트를 통해 학습회수는 안정적인 성능을 확보할 수 있도록 최대 1,000번으로 설정하였다. 의사결정나무(DT) 모델의 경우 크게 입력

데이터 노드(root node), 분류노드(decision node), 결과값 출력노드(terminal node)로 구성되어 입력되는 데이터에 대해 나무 형태의 분류규칙을 통해 순차적으로 분류해 나감으로써 최적값에 수렴하는 특성이 있다. 특히, 본 연구에서는 학습과정을 직관적으로 분석가능한 DT 모델을 통해 변수 중요도(variable importance)를 측정하였다. 마지막으로 앙상블(ES) 모델은 DT 모델을 기반으로 여러 모델(bagging, boosting)을 결합하여 구성되는 모델로 본 연구에서는 출력값을 여러번 샘플링하여 모델을 학습하는 bagging 기법을 활용하였다. DT, ES 모델의 경우 노드 수를 입력되는 데이터 수만큼 설정하여 과대학습(overfitting)을 방지할 수 있도록 설정하였다. 각기 학습구조가 다른 위 3가지 모델 기반의 대표 3개 고장현상별 검출 성능비교를 통해 적정 FDD 모델을 선정하였다.

고장검출 성능지표

본 연구에서는 공조기의 정상 및 고장으로 이루어진 범주형 결과값을 분류성능을 산출하기 위하여 혼동행렬(confusion matrix) 기반의 정밀도(precision), 재현율(recall), 가중조화평균(F1-score)을 활용하였다. 혼동행렬은 Figure 2와 같이 실제 정상-고장값과 각 FDD 모델 값을 나타낼 수 있으며 precision, recall, F1-score 계산을 위한 기초지표이다.

		Actual values	
		Positive	Negative
Predicted values	Positive	True positive (TP)	False positive (FP)
	Negative	False negative (FN)	True negative (TN)

Precision
 Recall

Figure 2. Confusion matrix

Precision 및 recall은 각 모델의 고장 분류성능에 초점을 둔 지표로 precision은 모델이 고장으로 분류한 것 중에 실제값에서 고장으로 검출된 비율을 나타낸 것이며 recall의 경우 모델이 분류한 모든 데이터 중 실제값에서 고장으로 검출된 비율을 의미한다. 각 모델별 전체적인 정상-고장 판별성능을 산출하기 위한 지표로 accuracy 및 F1 score 중 본 연구에서는 Table 3과 같이 구성된 데이터의 정상-고장 데이터 불균형 비율을 보정하여 결과 산출이 가능한 F1 score를 활용하였다. 위 3개 지표를 활용하여 입력변수 조건별 고장현상에 따른 각 모델의 FDD 성능을 비교하였다.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1Score = \frac{recall \times precision}{recall + precision} \quad (3)$$

연구결과 및 분석

공조기 고장현상별 변수중요도 평가

공조기 고장현상 검출을 위한 변수 선정은 사용되는 데이터의 양과 질을 적절히 조절하고 소요시간을 줄이는 등 고장검출 성능향상을 위해 중요한 과정이다(Singh et al., 2022). 본 연구에서는 DT 모델을 기반으로 16가지 고장 중 대표 3가지 고장(OAFC, RFFS, CCVS)을 대상으로 입력변수의 중요도를 평가하고 고장별 변수중요도에 따른 고장검출 모델 성능을 비교하였다. Figure 3은 대표 3가지 고장현상에 대한 변수별 중요도로 각 고장현상별 19가지 변수 중 영향도가 높은 주요한 변수 항목만을 나타냈다.

외기덤퍼 완전막힘(OAFC) 고장의 경우 외기덤퍼가 완전막힘으로써 Figure 4의 (a)와 같이 유입되는 외기유량(FR_{OA})이 발생하지 않고 그에 따라 환기유량(FR_{RA}) 및 급기팬의 차압(P_{SFD})이 정상일 대비 일평균 각 7.62%, 16.79% 수준 증가하였다. 환기팬 30% 속도고정(RFFS) 고장일 경우 유입되는 유량에 대해 효율적으로 순환되지 않음으로써 Figure 4의 (b)와 같이 혼합온도(T_{MA}) 증가와 고장시 일부구간(9-11시, 13-14시)에서 잔류공기에 의해 급기팬 차압(P_{SFD}), 냉방코일의 밸브 개도율 및 토출온도(VP_{CC} , DT_{CC})의 현상이 나타났다. 마지막으로 냉방코일 밸브고착(CCVS) 고장에서는 앞선 OAFC, RFFS 고장 대비 보다 다양한 변수에서 영향도가 나타났고 Figure 4의 (c)와 같이 급기온도(T_{SA}), 냉방토출온도(DT_{CC})를 효율적으로 제어하지 못하며 특히, 급기팬의 회전속도(FS_{SF}) 증가와 냉방코일에서의 효율저하로 인해 환기유량(FR_{RA})이 정상일 대비 44%의 큰 폭으로 증가하였다.

앞선 대표 3가지 공조기 고장현상별 DT 기반의 변수중요도 분석결과를 기반으로 각 고장별 영향도 순으로 입력변수 조건을 Table 4와 같이 5가지 case (base, case 1-4)로 구성하였으며 구성된 case별 3가지 주요고장에 대해 모델별 고장검출 성능비교를 통해 적정 입력변수 수준 및 모델을 선정하였다.

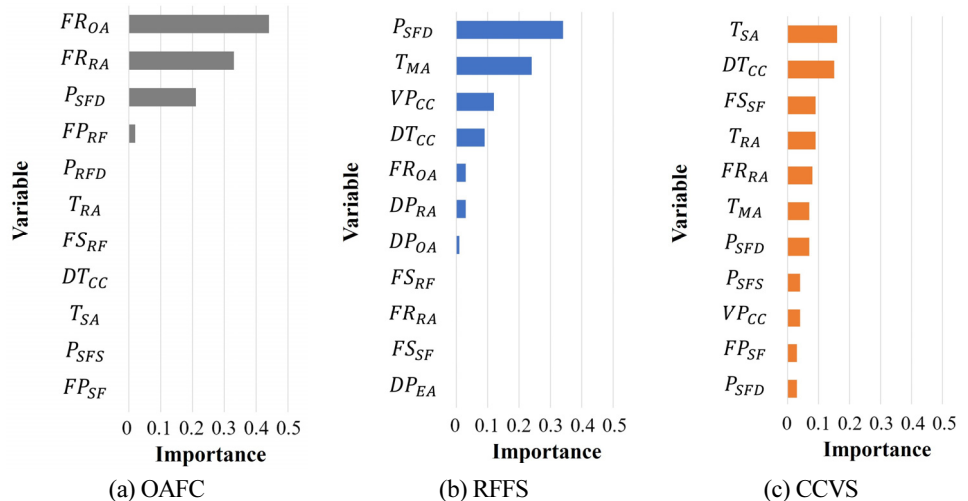


Figure 3. Measurement of variable importance of three fault types using decision tree

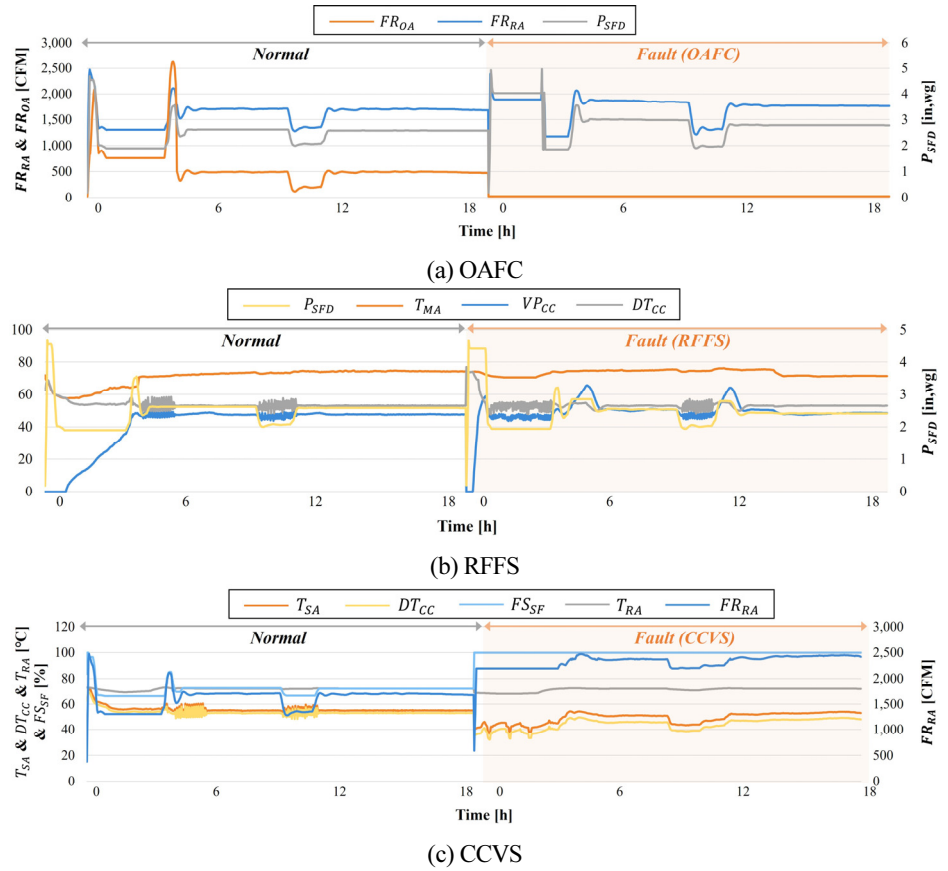


Figure 4. Measurement of variable importance of three fault types using decision tree

Table 4. Data description of AHU systems in AHSRAE 1312-RP project

Data Base	OAFc				RFFS				CCVS			
	Case 1	Case 2	Case 3	Case 4	Case 1	Case 2	Case 3	Case 4	Case 1	Case 2	Case 3	Case 4
VP_{CC}	●				●	●	●		●	●		
DP_{EA}	●								●			
DP_{RA}	●				●	●			●			
DP_{OA}	●				●				●			
FP_{SF}	●								●	●		
FP_{RF}	●	●										
FR_{SA}	●								●			
FR_{RA}	●	●	●	●					●	●	●	
FR_{OA}	●	●	●		●							
T_{SA}	●								●	●	●	●
T_{MA}	●				●	●	●	●	●	●	●	
T_{RA}	●								●	●	●	
T_{OA}	●								●			
DT_{CC}	●				●	●			●	●	●	●
P_{SFS}	●								●	●		
P_{SFD}	●	●			●	●	●	●	●	●	●	
P_{RFD}	●								●	●		
FS_{SF}	●								●	●	●	
FS_{RF}	●											

입력변수 조건별 고장검출 성능비교

앞선, 공조기 고장현상별 변수중요도 평가결과를 기반으로 입력변수를 구성하여 검출모델별 고장검출 성능을 비교하였다. Figure 5는 입력변수 조건(Table 4)에 따른 대표 3개 고장현상별 각 모델의 고장검출 성능(precision, recall, F1 score)을 나타낸 것이다. OADS (Figure 5의 (a))고장의 경우 최적 case의 F1 score 기준 case 2 - DT (0.818) > base - ES (0.526) > case 1 - ANN (0.513) 순의 정상-고장 판별 성능 순을 보였다. 그 중 DT 모델(case 2)은 모든 모델 및 case에서 최적 고장검출 성능을 보였으며 특히, recall 성능은 0.900(타 모델 동일 case 평균 recall - 0.322)으로 base에서 사용되는 19가지 변수항목 대비 불필요한 변수제거를 통해 유량 요소(FR_{RA} , FR_{OA}), 공급팬차압(P_{SFD})인 주요 3가지 항목만으로 높은 OADS 고장 검출정확도를 확보할 수 있었다. 하지만, 환기팬의 유량(FR_{RA})만을 적용한 case 4에서 F1 score 기준 0.302 (case 2 - 0.578)로 모델 영향 대비 사용되는 변수 영향도가 높은 것을 알 수 있었다. RFFS (Figure 5의 (b))고장에서는 Table 5와 같이 모델별 F1 score 기준 ES (0.550) > DT (0.520) > ANN (0.123)이고 입력변수 조건만 다른 각 case는 0.248-0.578 수준으로 분포되어 있어 입력변수 조건 대비 FDD 모델종류의 영향도가 높았다. 그 중 ES 모델의 경우 주요 5가지 변수항목(VP_{CC} , DP_{RA} , T_{MA} , DT_{CC} , P_{SFD})을 사용한 case 2에서 recall, F1 score가 각 0.818, 0.783으로 RFFS 고장 검출 정확도뿐만 아니라 정상-고장 판별 성능도 우수하였다. CCVS (Figure 5의 (c))고장에서는 모델이 고장으로 분류한 데이터 중 실제 고장으로 검출한 성능

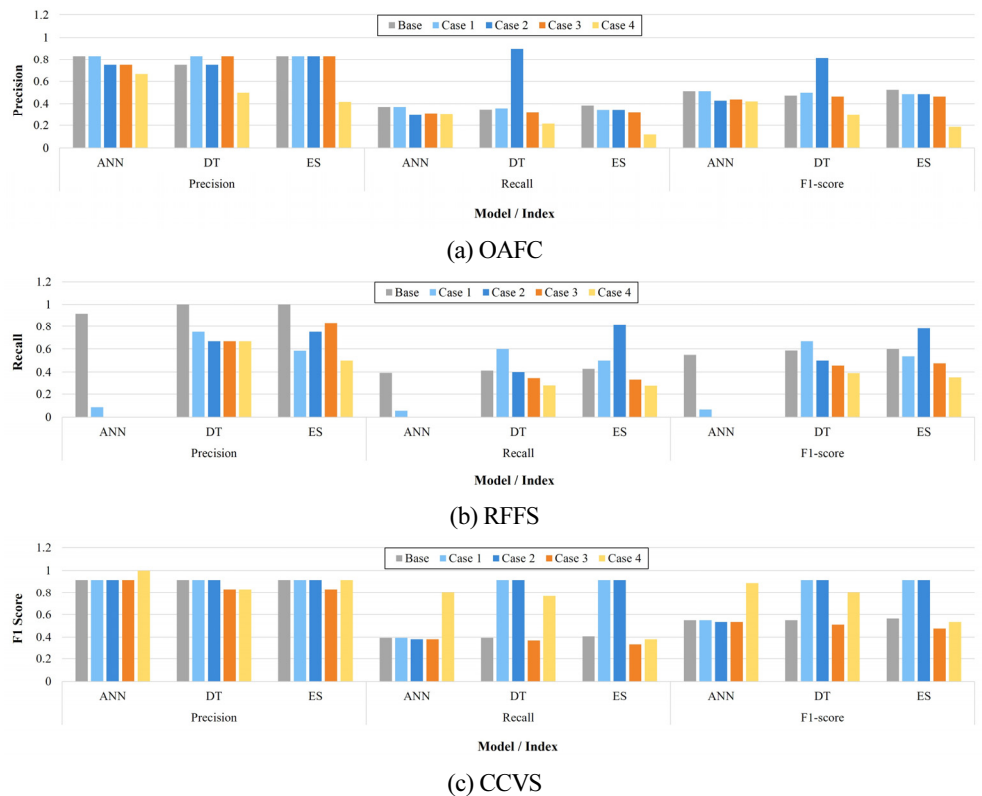


Figure 5. Precision, recall, and F1 score of each fault detection with different input conditions in VAV systems

(precision)이 모든 모델 및 case에서 0.833-1.000으로 유사한 검출성능을 보였다. 하지만, recall, F1 score의 경우 특정 case에서 가장 높은 검출성능을 확인할 수 있었다(case 2의 ES 모델로부터 각각 0.917). 특히, case 3 (case 2로부터 VP_{CC} , FP_{SF} , P_{SFS} , P_{RFD} 제외)에서 case 2 대비 급격히 낮아진 성능을 보였으며(F1 score 기준 0.476) 이를 미루어보아 CCVS 고장은 Table 5와 같이 사용되는 모델 대비 입력되는 변수 조건이 고장검출 성능에 더 많은 영향을 미쳤다.

Table 6은 공조기 각 고장현상별 최적 모델조건 및 검출성능을 나타낸 것이다. 위 주요 3가지 고장현상별 입력변수 조건에 따른 모델 성능비교를 통해 고장별 입력변수 및 모델 영향도를 파악할 수 있었다. 모든 고장유형에서 case 2 및 분류계열의 FDD 모델(DT, ES)의 고장 검출 정확도가 높았으며 모든 고장에서 평균 0.878의 검출정확도(recall 기준)와 0.839 수준(F1 score)의 정상-고장 판별성능이 산출되었다.

Table 5. Performance of fault detection of three models with different input conditions

		Bsae	Case 1	Case 2	Case 3	Case 4	Mean	
Precision	O AFC	ANN	0.833	0.833	0.750	0.750	0.667	0.767
		DT	0.750	0.833	0.750	0.833	0.500	0.733
		ES	0.833	0.833	0.833	0.833	0.417	0.750
		Mean	0.806	0.833	0.778	0.806	0.528	-
	R FFS	ANN	0.917	0.083	0.000	0.000	0.000	0.200
		DT	1.000	0.750	0.667	0.667	0.667	0.750
		ES	1.000	0.583	0.750	0.833	0.500	0.733
		Mean	0.972	0.472	0.472	0.500	0.389	-
	C C V S	ANN	0.917	0.917	0.917	0.917	1.000	0.933
		DT	0.917	0.915	0.917	0.833	0.833	0.883
		ES	0.917	0.916	0.917	0.833	0.917	0.900
		Mean	0.917	0.916	0.917	0.861	0.917	-
Recall	O AFC	ANN	0.369	0.370	0.300	0.310	0.308	0.332
		DT	0.346	0.357	0.900	0.323	0.214	0.428
		ES	0.385	0.345	0.345	0.323	0.119	0.303
		Mean	0.367	0.357	0.515	0.319	0.214	-
	R FFS	ANN	0.393	0.053	0.000	0.000	0.000	0.089
		DT	0.414	0.600	0.400	0.348	0.276	0.407
		ES	0.429	0.500	0.818	0.333	0.273	0.471
		Mean	0.412	0.384	0.406	0.227	0.183	-
	C C V S	ANN	0.393	0.393	0.379	0.379	0.800	0.469
		DT	0.393	0.917	0.917	0.370	0.769	0.673
		ES	0.407	0.914	0.917	0.333	0.379	0.591
		Mean	0.398	0.741	0.738	0.361	0.650	-
O AFC	ANN	0.512	0.513	0.429	0.439	0.421	0.463	
	DT	0.474	0.500	0.818	0.465	0.300	0.511	
	ES	0.526	0.488	0.488	0.465	0.185	0.430	
	Mean	0.504	0.500	0.578	0.456	0.302	-	
F1 score	R FFS	ANN	0.550	0.065	0.000	0.000	0.000	0.123
		DT	0.585	0.667	0.500	0.457	0.390	0.520
		ES	0.600	0.538	0.783	0.476	0.353	0.550
		Mean	0.578	0.423	0.428	0.311	0.248	-
C C V S	ANN	0.550	0.550	0.537	0.537	0.889	0.612	
	DT	0.550	0.916	0.916	0.513	0.800	0.739	
	ES	0.564	0.914	0.917	0.476	0.537	0.682	
	Mean	0.555	0.793	0.790	0.509	0.742	-	

Table 6. Results of optimal case with different fault types

Model	Model conditions	Performance index (optimal (base))		
		Precision	Recall	F1-score
O AFC	DT Case 2 ($FR_{RA}, FR_{OA}, P_{SFD}$)	0.750 (0.750)	0.900 (0.346)	0.818 (0.474)
RFFS	ES Case 2 ($VP_{CC}, DP_{RA}, T_{MA}, DT_{CC}, P_{SFD}$)	0.750 (1.000)	0.818 (0.429)	0.783 (0.600)
CCVS	ES Case 2 ($VP_{CC}, FP_{SF}, FR_{RA}, T_{SA}, T_{MA}, T_{RA}$)	0.917 (0.917)	0.917 (0.407)	0.917 (0.564)

결론

본 연구에서는 ASHRAE 1312-RP 데이터셋 기반의 공조기 입력변수 중요도를 평가하고 변수 조건에 따른 고장검출 모델 성능비교를 통해 3가지 고장현상별 적정 고장검출 방법을 제안하였다. 주요 3가지 고장현상(외기덤퍼고장, 환기팬속도고정, 냉방코일고착)별 시스템의 변수 중요도 평가를 통해 각 고장에 대한 영향도를 정량적으로 산출할 수 있었고 입력변수 및 FDD 모델별 고장검출 성능 비교를 통해 각 고장현상에 대한 변수 및 모델의 영향도를 파악할 수 있었다. 기존 19가지 변수 항목 대비 3가지 고장현상에서 평균 12가지 항목의 불필요한 변수 제거 및 적정 모델 선정을 통해 기존 base 대비 29% 이상의 고장 검출 정확도 향상이 가능하였으며 이를 통해 공조기의 각 고장현상에 따라 변수 또는 모델 영향도의 정량적 산출이 가능하였다.

향후, 보다 다양한 공조기 고장현상에 대한 변수중요도 평가와 이에 따른 모델 비교가 이루어질 필요가 있으며 실험데이터셋 이외 실제 건물의 다양한 공조기 유형에 대해서 제안한 FDD 방법의 일반화 성능을 검증할 예정이다.

후기

본 연구는 산업통상자원부(MOTIE)와 한국에너지평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No.20212020800120).

References

1. Jeong, C.H., Kim, C.H., Kim, W.H. (2021). The Development of a Rule-Based Fault Detection and Diagnostic System to Use for the Economizing of HVAC Systems. Korean Journal of Air-Conditioning and Refrigeration Engineering, 33(5), 244-253.
2. Kim, M.K. (2022). Anomaly Diagnosis of Rotational Machinery Using Time-Series Vibration Data Based on Time-Distributed CNN-LSTM. Journal of Multimedia Information System, 25(11), 1547-1556.

3. Singh, V., Mathur, J., Bhatia, A. (2022). A comprehensive review: Fault detection, diagnostics, prognostics, and fault modeling in HVAC systems. *International Journal of Refrigeration*, 144, 283-295.
4. Taheri, S., Ahmadi, A., Mohammadi-Ivatloo, B., Asadi, S. (2021). Fault detection diagnostic for HVAC systems via deep learning algorithms. *Energy and Buildings*, 250, 111275.
5. Gao, T., Boguslawski, B., Marié, S., Béguery, P., Thebault, S., Lecoecue, S. (2019). Data mining and data-driven modelling for Air Handling Unit fault detection. In *E3S Web of Conferences*, 111, 05009, EDP Sciences.
6. Global Alliance for Building and Construction. (2022). *Global Status Report for Buildings and Construction*, 325.
7. Wen, J., Li, S. (2012). RP-1312 -- Tools for Evaluating Fault Detection and Diagnostic Methods for Air-Handling Units. ASHRAE, Tech. Rep.