

# 냉동시스템 고장 진단 및 고장유형 분석을 위한 3단계 분류 알고리즘에 관한 연구

이강배<sup>1</sup>, 박성호<sup>2\*</sup>, 이희원<sup>2</sup>, 이승재<sup>2</sup>, 이승현<sup>2</sup>  
<sup>1</sup>동아대학 경영정보학과 교수, <sup>2</sup>동아대학교 경영정보학과 학생

## A study on the 3-step classification algorithm for the diagnosis and classification of refrigeration system failures and their types

Kangbae Lee<sup>1</sup>, Sungho Park<sup>2\*</sup>, Hui-Won Lee<sup>2</sup>, Seung-Jae Lee<sup>2</sup>, Seung-hyun Lee<sup>2</sup>

<sup>1</sup>Professor, Dept. of MIS, Donga University

<sup>2</sup>Student, Dept. of MIS, Donga University

**요약** 산업의 발전으로 도시화로 인해 건물의 규모가 커지면서, 건물의 공기 정화 및 쾌적한 실내 환경을 유지의 필요성 또한 증가하고 있다. 냉동 시스템의 모니터링 기술의 발전으로 건물 내에 발생하는 전력 소모량을 관리할 수 있게 되었다. 특히 상업용 건물에서 발생하는 전력 소모량 중 약 40%가 냉동 시스템에서 일어난다. 따라서 본 연구 냉동시스템 고장진단 알고리즘을 개발하기 위해서 냉동시스템의 구조를 이해하고, 냉동 시스템의 운영과정에서 발생하는 데이터를 수집 분석하여 다양한 유형과 심각도를 가지는 고장 상황을 조기에 신속하게 탐지 분류하고자 하였다. 특히 분류가 어려운 고장 유형들의 분류 정확도를 향상시키기 위하여 3단계 진단 및 분류 알고리즘을 개발하여 제안하였다. 다수의 실험과 초모수 (hyper parameter) 최적화 과정을 거쳐 각 단계에 적합한 분류 모형으로 SVM과 LGBM에 기반 한 모형을 제시하였다. 본 연구에서는 고장에 영향을 미치는 특성을 최대한 보존하면서, 선행연구에서 어려움을 겪었던 냉매 관련 고장을 포함한 모든 고장 유형을 우수한 결과로 도출하였다.

**주제어** : 냉동 공조, 머신러닝, 다중 클래스, 고장진단, 고장유형 분류

**Abstract** As the size of buildings increases due to urbanization due to the development of industry, the need to purify the air and maintain a comfortable indoor environment is also increasing. With the development of monitoring technology for refrigeration systems, it has become possible to manage the amount of electricity consumed in buildings. In particular, refrigeration systems account for about 40% of power consumption in commercial buildings. Therefore, in order to develop the refrigeration system failure diagnosis algorithm in this study, the purpose of this study was to understand the structure of the refrigeration system, collect and analyze data generated during the operation of the refrigeration system, and quickly detect and classify failure situations with various types and severity. In particular, in order to improve the classification accuracy of failure types that are difficult to classify, a three-step diagnosis and classification algorithm was developed and proposed. A model based on SVM and LGBM was presented as a classification model suitable for each stage after a number of experiments and hyper-parameter optimization process. In this study, the characteristics affecting failure were preserved as much as possible, and all failure types, including refrigerant-related failures, which had been difficult in previous studies, were derived with excellent results.

**Key Words** : Refrigeration and air conditioning, Machine learning, Multi-class, Fault diagnosis, Fault type classification

\*This work was partly supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government(MSIT) (No.2020-0-02091, Development and Commercialization of IoT-based refrigerated container real-time monitoring and BigData / AI-based failure predictive service platform to strengthen competitiveness of shipping & logistics company) and Korea Evaluation Institute of Industrial Technology(KEIT) grant funded by the Korea government(MOTIE) (No.2020-0-02091, Development and Commercialization of IoT-based refrigerated container real-time monitoring and BigData / AI-based failure predictive service platform to strengthen competitiveness of shipping & logistics company).

\*Corresponding Author : Sungho Park(psh2975@donga.ac.kr)

Received May 6, 2021  
Accepted August 20, 2021

Revised July 10, 2021  
Published August 28, 2021

## 1. 서론

도시화로 인해 건물의 규모가 커지면서, 건물 내의 쾌적한 환경을 위한 건물 공조 및 냉동 시스템의 중요성은 커지고 있다. 건물의 공조 및 냉동 시스템은 건물 내의 공기 순환 및 적정 온도 유지를 통해 쾌적한 실내 환경을 유지하는 기능을 한다[1]. 건물 전체에 대한 공조 및 냉각 시스템의 유지보수는 시간과 비용의 문제를 발생시킨다. 일반적으로 상업용 건물에서 소모하는 전력 소모량 중 냉동 시스템이 약 36%를 차지한다[2]. 건물의 냉동시스템의 성능 저하, 고장 상황 발생은 에너지 낭비를 발생시킨다. 이는 경제적 비용뿐만 아니라, 시간적 측면에서도 많은 비용을 발생시킨다[3]. 냉각 시스템의 고장은 급격한 고장의 발생이 아닌, 성능저하로 나타나게 된다. 고장 상태가 지속되면, 효율성이 10~20%까지 감소된다[4]. 냉각 시스템은 냉동기의 운영을 모니터링을 가능하게 하지만, 냉동기의 경우 현재까지 숙련자들의 경험에 의존하는 경우가 많다. 그 이유는 냉동기를 구성하는 부품이 많지만, 해당 부품에 대한 모든 모니터링이 불가능하기 때문이다. 현재 모니터링 시스템으로는 즉각적인 고장 진단에 어려움이 있는 상황이다. 공조 및 냉동기 시스템의 고장 진단에 대한 연구는 국내외에서 다수 진행되었다. 냉동 시스템 관련 국내 연구는 콜드체인에 관한 연구가 존재한다[5]. 또한 해외 연구에서는 다양한 머신러닝 기법 및 인공지능영향을 활용한 연구가 다수 존재하고 있다.

특히 냉동 시스템 관련 해외 연구는 RP-1043 프로젝트에서 제공하는 데이터를 활용한 연구가 다수 존재하였다. 해당 데이터에 대한 연구는 차원 축소 및 특성공학 방법을 고장 진단 및 분류 성능을 향상하고자 하였다[6].

RP-1043 프로젝트에서는 냉동 시스템의 고장 유형을 7가지로 분류하였다. 다수의 선행 연구에서 고장 유형 분석을 시도하였지만, 냉매 과충전과 냉매 부족이라는 두 가지 고장 유형을 제대로 분류하지 못하는 문제가 발생하였다[1] 일부 연구에서는 이 두 가지 유형을 구분하기 위하여 특성공학 방법을 적용하였다. 냉매관련 진단 성능을 향상 시켰지만, 동시에 다른 고장 유형들의 성능 저하를 발생시켰다[9].

이에 본 연구에서는 심각도 수준을 고려한 모든 고장 유형을 진단할 수 있는 알고리즘을 제안하였다. 특히, 다른 고장 유형 진단 성능을 그대로 유지하면서, 냉매 과충전과 냉매부족이라는 두 가지 고장 유형의 진단 및 분류 성능을 향상 시키는 결과를 도출하였다. 이를 통하여 심각도 수준을 고려하면서, 다양한 고장을 진단할 수 있는

알고리즘을 제시하였다.

본 연구의 구성은 1장 서론, 2장에서 냉동 시스템에 대한 이론적 배경을 설명하고, 3장에서 분석에 사용된 데이터와 데이터 처리 방법을 설명한다. 4장에서는 분석 결과, 5장에서 연구의 결론을 제시한다.

## 2. 이론적 배경

### 2.1 기계학습

기계학습은 1950년대 다양한 학습기법이 발표되어 이론적으로 활발히 연구되었다. 그러나 이론적인 부분을 뒷받침할 수 있는 다양한 데이터의 존재, 컴퓨팅 파워 부족 등 현실적인 문제로 침체기를 겪었다. 최근 인공지능의 발전과 함께 다양한 기계학습 방법론도 발전하였다. 기계학습은 기존의 통계방법론에서 사용하던, 샘플링 데이터의 한계를 전체 데이터 사용으로 극복할 수 있다. 샘플링 데이터의 한계는 데이터를 샘플링 하는 과정에서 연구자 주관에 개입될 가능성이 높으나, 기계학습을 활용한 분석은 전체 데이터를 사용하기 때문에 샘플링 데이터에 비해 연구의 객관성을 확보할 수 있다[7]. 본 연구에서는 냉동 시스템의 65가지의 특성을 분석하여, 냉동 시스템의 고장을 진단하고 고장 유형을 분류할 수 있는 방법론으로 서포터 벡터 머신(Support Vector Machine; SVM)과 LGBost(Light Gradient Boosting; LGBM)를 사용하였다. SVM은 다양한 커널 방법을 활용하여 다차원의 데이터를 분석할 수 있는 장점이 있다[8]. LGBM은 2016년 MicroSoft가 공개한 프레임워크의 사결정나무 기반 알고리즘으로 속도가 빠르고 메모리를 적게 차지하는 장점이 있다. 많은 특성을 신속한 고장진단을 해야 하는 냉동 시스템 고장진단 및 유형분석에 특성상 SVM과 LGBM 방법론이 적합하여 2가지의 방법론을 3 단계에 걸쳐 순차적으로 사용하였다.

### 2.2 선행연구 검토

G.N LI는 냉각기 결합으로 인한 시스템 에너지 효율을 막기 위해 초기 단계에서 발생하는 결합을 민감하게 진단하기 위해 PCA-R-SVDD 모델을 적용하였고, 모든 고장 유형에 대해 92% 이상의 정확도로 고장유형을 분류하였다[9].

Yalan Wang은 베이시안 네트워크를 적용하여 실용적인 냉동기 고장 탐지 방법을 제안하였고, 제안된 방법은 특성의 분포에 대한 가정을 하지 않았으며, 전문가의

도움없이, 분석된 결과를 통해 매개 변수를 신속하게 결정하였다[10].

Hua Han은 90톤 원심 냉각기에서 고장탐지 모델을 구현하기 위해 교차 검증을 통해 최적화된 LS-SVM 모델을 제안하였고, 4개의 심각도 수준을 통합하여 Traing/Test 데이터 셋을 구분하였다[11].

P.K. Kankar은 다양한 기계학습 알고리즘을 베어링 결함 분류 문제에 적용하여 베어링 고장에 가장 적합한 모델을 구성하였고, 정확도, 민감도, 특이도, 재현율, 정밀도를 평가지표로 사용하여, DNN이 가장 우수한 모형이라는 결과를 도출하였다[12].

Zhuozhen Wang은 딥러닝을 활용하여 CNN를 사용하여 냉각기 시스템을 위한 시계열 시퀀스 기반의 오류 진단 접근법을 제안하였고, 고장 수준 2,3,4에서 정확도가 감소하는 경향을 보였다[13].

X.Liu은 DCNN 기반으로 한 냉각기 오류 진단 및 감지 방법을 제안하였는데, Gradient 문제를 극복하기 위한 방법을 제시하였으며, 정확도에서 높은 성과를 보였다[14].

J.Liu는 연관 기반 분류 및 연관 규칙 마이닝을 기반으로 건물 냉각기 고장 탐지 방법을 제안하여, 연관 규칙 분석을 통해 고장 조치 메커니즘을 분석하였고, 정확도는 90.15%로 나타났다[15].

냉동기 시스템 고장진단 및 유형 분석관련 연구는 RP-1043 프로젝트 데이터를 활용한 연구가 다수 수행되었다. RP-1043 데이터는 65개의 특성이 존재하며, 고장 유형 7가지에 따라 심각도가 4단계로 구성되어 있어, 전체 데이터를 활용했을 때 특정 고장 유형에 대한 성능 지표가 급격하게 감소하는 것을 확인하였다. 다수의 선형연구에서 특정 고장유형의 성능지표 감소를 해결하기 위해 차원 축소 방법과 심각도를 다르게 분류하였다. 본 연구에서는 냉동기 시스템에서 발생한 65개의 특성을 모두 사용하였고, 고장 심각도 4단계를 모두 반영하여 분석을 진행하였으며, 고장진단과 고장 유형분석을 진행하였다.

### 3. 분석자료 및 분석 방법

#### 3.1 자료설명

본 연구에 사용된 데이터는 미국 ASHRAE 프로젝트 RP-1043에서 제공받은 것이다. ASHRAE 프로젝트 RP-1043에 사용된 냉각기는 2패스 쉘 및 튜브 증발기가 장착되었으며, 사용된 냉매는 R134a를 사용하였다. 전체 데이터에는 정상, 응축기 고장, 냉매 과충전, 오일

과충전, 응축기 유량 감소, 응축기 냉각수 감소, 냉매 비응축, 증발기 냉수 감소, 냉매 누출 상황으로 총 8가지 상황으로 분류 되어있으며, 각 고장 유형은 4단계의 심각도로 Table 1에서 확인할 수 있다.

Table 1. Data description

no	Data	Type	Explanation
1	normal normal1 normal2	normal data	Normal State Data
2	cf6 cf12 cf20 cf30 cf45	Condenser Fouling	Refrigerant tube is blocked by 6% to 45%
3	ro10 ro20 ro30 ro40	Refrigerant Overcharge	Refrigerant is 10% to 40% overcharged
4	eo14 eo32 eo50 eo68	Excess Oil	Oil is 14% to 68% overfilled
5	fwc10 fwc20 fwc30 fwc40	Flow Rate of Condenser Water	Reduced condenser coolant by 10% to 40%
6	nc1 nc2 nc3 nc5	Non-Condensable in refrigerant	The degree to which the refrigerant is non-condensed as 1% to 5% of nitrogen in the refrigerant tube is generated
7	fwe10 fwe20 fwe30 fwe40	Flow Rate of Evaporator Water	Evaporator cold water reduced by 10% to 40%
8	r110 r120 r130 r140	Refrigerant Leak	Refrigerant charge is 10% ~ 40% insufficient

Table 2. Feature Description

no	variable	Full name	unit
1	Time	Real time counter	second
2	TWE_set	Chilled water setpoint—control variable	°F
3	TEI	Temperature of Evaporator Water In	°F
4	TWEI		
16	Cooling Tons	Calculated City Water Cooling Rate	Tons Tons
17	Shared Cond Tons	Calculated Shared HX Heat Transfer (only valid with no water bypass)	
...	...	....	....
64	FWH	Calculated Hot Water Flow Rate	GPM
65	FWB	Calculated Condenser Water Bypass Flow Rate	GPM

수집된 데이터는 총 65개의 특성으로 구성되어 있으며, 데이터 수집 주기는 10초이다. 각 고장 유형과 심각도마다 5,191개의 행으로 구성되어 있다.

### 3.2 데이터 탐색분석

냉동기 데이터에 포함된 포함된 65개의 특성의 분포를 확인하기 위해 Boxplot 분석을 진행하였고, 정상상태 데이터에 포함된 65개의 특성의 분포를 확인하였다. 데이터 분포는 각 특성별로 다른 분포를 가지고 있는 것을 확인하였다. 다른 단위와 분포를 가진 데이터를 기계 학습에 학습시키면 학습시간 및 학습 결과에 영향을 미치기 때문에, 본 연구에서는 정규화 및 표준화를 진행하였다.




Fig. 1. Boxplot Analysis

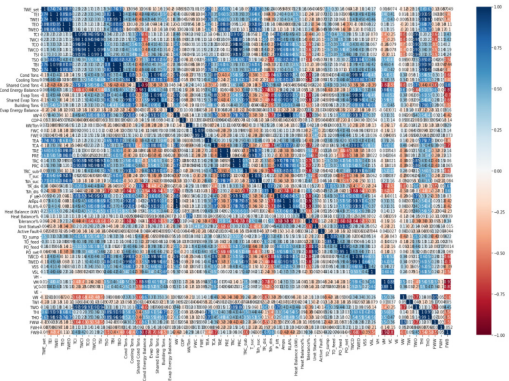


Fig. 2. Correlation Analysis

### 3.3 분석 프로세스

본 연구에서는 Fig. 3과 같이 3단계에 걸쳐 고장여부 진단, 고장유형 1차 분류, 고장 유형 2차 분류를 수행하는 알고리즘을 개발하였다. 1단계 고장여부진단에서는

고장 유형을 고려하지 않은 정상과 고장클래스만을 분류하는 모델을 개발하여 사용하였다. 기존의 연구에서는 7가지 고장유형을 한번에 분류하고자 하였지만, 냉매 과충전/과부족 데이터를 분석한 결과 두 고장 유형 간의 유의한 차이를 구분하기 어려움이 있었다. 본 연구에서는 냉매 관련 고장을 보다 정확하게 분류하기 위해서 2단계에서는 고장 유형 7가지 중 냉매관련 고장 유형 2가지를 통합하여, 6개의 고장 유형 클래스에 대한 분류 모형을 개발하여 사용하였다. 2단계 분류결과 냉매 관련 고장으로 판단된 것에 대하여 냉매 과충전과 냉매 부족 두 가지 클래스를 분류하는 모델을 3단계에 개발하여 적용하였다.

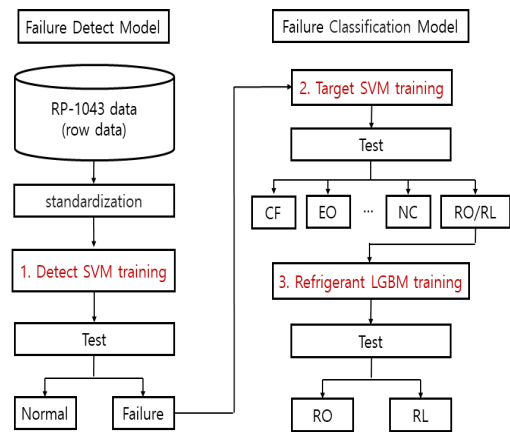


Fig. 3. 3-Class FD Model

각 단계에서 최상의 결과를 나타내는 모델 개발을 시도하였고 다수의 실험과 초모수(hyperparameter) 최적화를 거쳐 비교한 결과 1, 2 단계에서는 SVM 방법을 3단계에서는 LGBM 방법을 선택하게 되었다.

1단계에서는 정상/비정상 상황을 분류할 수 있는 다차원 분류 모델인 RBF SVM 모형을 활용하였다. 65개의 다양한 특성을 분류하기 위해서는 다차원 분류모델이 가장 적합하였다. 2단계에서는 선행연구에서 전체 고장 유형 중 냉매 부족/과충전을 구분하지 못하는 문제를 해결하기 위해, 냉매 부족/과충전 문제를 하나로 통합하였고, 분류 문제에 강점을 보인 SVM 모형을 통해 각 고장유형을 분류하였다. 3단계 냉매 관련 고장 유형을 구분하는 모델에서는 약 분류기를 조합하는 부스팅 기법을 활용한 LGBM 모형을 활용하여 기존의 선행연구에서 문제를 보였던 냉매 부족/과충전 고장 유형을 분류하였다.

### 3.4 성능지표 선정

본 연구의 데이터는 정상과 고장 데이터가 혼재되어있다. 이 경우 정확도 하나의 성능지표를 사용할 경우 편향된 결과가 나타날 수 있다. 따라서 데이터와 연구의 특성을 고려하여, 본 연구에서는 Precision, Recall, F1-Score를 모두 고려해서 사용하였다.

Table 3. Performance indicators

index	formula	explanation
accuracy	$(TP+TN)/(TP+TN+FP+FN)$	
precision	$TP/(TP+FP)$	
recall	$TP/(TP+FN)$	
F1-score		Precision, recall harmonic mean

## 4. 분석결과

### 4.1 단계1: 고장(이상) 유무 진단 Detect SVM

1단계 SVM 고장 유무 진단의 결과는 전체 데이터 중를 활용한 결과 Accuracy는 99.72%로 정상과 비정상 상황을 정확하게 분류하였다.

Table 4. Diagnosis of faults (abnormalities) SVM model results

	precision	recall	f1-score
normal	0.99	0.98	0.98
abnormal	1.00	1.00	1.00

### 4.2 단계 2: 고장 유형 분류 Target SVM

고장 유형을 분류하는 Accuracy는 99.52로 총 6가지 비정상 상황을 정확하게 분류하였다.

Table 5. 2-Class Target SVM model results

	precision	recall	f1-score
nomal	0.99	0.98	0.98
Ef	1.00	1.00	1.00
ro + rl	0.99	1.00	0.99
Eo	1.00	0.99	1.00
Fwc	1.00	1.00	1.00
Nc	1.00	1.00	1.00
fwe	1.00	1.00	1.00

2단계에서 분류 대상은 정상 상황 및 6가지 고장 유형을 포함하여 총 7가지의 클래스로 분류된다. Target SVM 모형은 Precision, Recall, F1-Score가 모두 98% 이상으로 고장유형을 분류하였다. 선행연구에서는 냉매 부족/과충전 문제를 분류하는데 어려움을 보였던 반면 본 연구에서는 전체 고장유형을 분류에서 뛰어난 성능을 보였다.

### 4.3 단계 3: Refrigerant LGBM

단계 3은 냉매 과충전(ro)과 냉매 부족(rl)을 분류 진단하는 과정으로 Accuracy는 94.4%로 분류하였다.

Table 6. ro, rl Analysis Result

	precision	recall	f1-score
(ro)	0.92	0.97	0.95
(rl)	0.97	0.92	0.94

냉매 고장을 분류한 결과는 Table 6의 결과와 같이 Precision과 Recall, F1-Score가 92%이상으로 나타났다.

### 4.4 최종 결과 정리

Table 7은 기존의 선행연구 모델과 본 연구가 제안하는 방법인 3단계 모델을 비교한 것이다. 본 연구에서 제안한 3단계 고장 진단 및 유형 분류 모델은 선행 연구들과 비교하여 Accuracy, Precision, Recall, F1 Score 등 모든 면에서 우수하였다. 본 연구에서 제시하는 3단계 분류 모델은 모든 특성을 유지하면서도, 모든 고장 유형 분류에 우수한 성능 결과를 보였다.

Table 7. Final Result

Variable	Exp	Prior Research Model	3-step classification algorithm
Cause of failure		detect Acc : 0.9947 target Acc : 0.8623	detect Acc : 0.9972 target Acc : 0.9952 refrigerant Acc: 0.9440
1(Normal)	nomal	precision : 0.9829	precision : 0.9899
2(Condenser failure)	cf	precision : 0.9764	precision : 0.9973
3(Refrigerant overcharge)	ro	<b>precision : 0.4626</b>	<b>precision : 0.9147</b>
4(Oil overfill)	eo	precision : 0.9929	precision : 0.9973

5(Reduced condenser flow)	fwc	precision : 0.9990	precision : 1.0
6(Refrigerant non-condensing)	nc	precision : 0.9985	precision : 0.9998
7(Reduced evaporator flow)	fwe	precision : 1.0000	precision : 1.0
8(Refrigerant leak)	rl	<b>precision : 0.4778</b>	<b>precision : 0.9552</b>

## 5. 결론

본 연구에서는 냉동기 시스템 운영에서 발생하는 모든 데이터를 최대한 반영하여 고장 진단 및 고장 유형을 분석하였다. 냉동 시스템의 고장 또는 고장징후 발생 시 이를 신속하게 진단하고 고장의 유형을 파악하는 것은 냉동 시스템의 가용성 (Availability) 향상에 중요하다. 조기에 진단하고 정확하게 고장유형 및 원인을 파악함으로써 심각한 수준의 고장을 미연에 방지하고 발생한 고장에 대한 조치도 신속하게 할 수 있기 때문이다. 정확한 냉동기 고장 탐지 및 고장 유형 분석에 대해 SVM 모형과 LGM 모형을 활용한 3 단계 모형을 적용하였다. 기존의 연구에서 제시하는 방법에서는 특성 공학적 방법을 활용하는 연구가 다수 존재했지만, 본 연구에서는 복잡한 냉동기 시스템의 특성을 모두 반영한 고장탐지 및 유형 분석 모형을 구성하였다. 기존의 냉매에 대한 고장 분류에 대한 어려움을 본 연구에서 제안한 3단계 모형을 활용하여 크게 개선하였다. 본 연구는 건물 냉동 시스템과 유사한 냉동 시스템이나, 기계 결함에 발생하는 데이터를 가공, 처리할 수 있는 프로세스를 제시하고, 고장 탐지 및 고장 유형을 분석할 수 있는 기초연구가 될 수 있을 것으로 기대한다.

## REFERENCES

- [1] B. Jin, D. Li, S. Srinivasan & S. K. Ng. (2019). Detecting and Diagnosing Incipient Building Faults Using Uncertainty Information from Deep Neural Networks. *2019 IEEE International Conference on Prognostics and Health Management (ICPHM), 2019*. DOI : 10.1109/ICPHM.2019.8819438
- [2] Y. Xia, Q. Ding, Z. Li & A. Jiang. (2021). Fault detection for centrifugal chillers using a Kernel Entropy Component Analysis (KECA) method. *Journal of Building Simulation, 14(1)*, 53-61
- [3] Q. Jiehui, Z. Hanyuan, Z. Guiqing & H. Hao. (2021). Incipient fault detection of chiller based on improved CVA. *5th International Workshop on Advances in Energy Science and Environment Engineering (AESEE 2021), 257(1)*, 1-5. DOI : 10.1051/e3sconf/202125701062
- [4] G. N. Li, Y. P. Hu, Q. J. Mao, C. H. Zhou & L. Z. Jiao. (2019). A deep neural network based fault diagnosis method for centrifugal chillers. *2019 IOP Conference Series: Earth and Environmental Science*, (pp. 1-6), Poland. DOI : 10.1088/1755-1315/238/1/012047
- [5] Y. S. Moon, S. J. Park, J. W. Jung, H. R. Cho & J. J. Kim. (2017). Temperature Control Algorithm for Reefer Container. *Journal of the Korea Institute of Information and Communication Engineering, 21(12)*, 2080-2386. DOI : 10.6109/jkiice.2017.21.12.2380
- [6] Z. Wang, Y. Dong, W. Liu & Z. Ma. (2020). A Novel Fault Diagnosis Approach for Chillers Based on 1-D Convolutional Neural Network and Gated Recurrent Unit. *Journal of Sensors, 20(9)*, 1-20. DOI : 10.3390/s20092458
- [7] K. Lee, S. Park, S. Sung & D. Park. (2019). A Study on the Prediction of CNC Tool Wear Using Machine Learning Technique. *Journal of the Korea Convergence Society, 10(10)*, 15-21. DOI : 10.15207/JKCS.2019.10.11.015
- [8] A. Beghi, L. Cecchinato, C. Corazzol, M. Rampazzo, F. Simmini & G. A. Susto. (2014). A One-Class SVM Based Tool for Machine Learning Novelty Detection in HVAC Chiller Systems. *IFAC Proceedings Volumes, 47(3)*, 1953-1958. DOI : 10.3182/20140824-6-ZA-1003.02382
- [9] G. Li, Y. Huab, H. Chen, L. Shen, H. Li, M. Hu, J. Liu & Kaizheng Sun. (2016). An improved fault detection method for incipient centrifugal chiller faults using the PCA-R-SVDD algorithm. *Journal of Energy and Buildings, 116(15)*, 104-113. DOI : 10.1016/j.enbuild.2015.12.045
- [10] Y. Wang, Z. Wang, S. He & Z. Wang. (2019). A practical chiller fault diagnosis method based on discrete Bayesian network. *Une méthode pratique de diagnostic des anomalies du refroidisseur basée sur un réseau bayésien discret. Journal of International Journal of Refrigeration, 102*, 159-167. DOI : 10.1016/j.ijrefrig.2019.03.008
- [11] H. Han, X. Cui, Y. Fan & H. Qing. (2019). Least squares support vector machine (LS-SVM)-based chiller fault diagnosis using fault indicative features. *Journal of Applied Thermal Engineering, 154*, 540-547. DOI : 10.1016/j.applthermaleng.2019.03.111
- [12] P. K. Kankar, S. C. Sharma & S. P. Harsha. (2019). Fault diagnosis of ball bearings using machine learning methods. *Journal of Expert Systems with*

*Applications*, 38, 1876-1886.  
DOI : 10.1016/j.eswa.2010.07.119

- [13] Z. Wang, Y. Dong, W. Liu & Z. Ma. (2020). A Novel Fault Diagnosis Approach for Chillers Based on 1-D Convolutional Neural Network and Gated Recurrent Unit. *Journal of Sensors*, 20(9), 1-20.  
DOI : 10.3390/s20092458
- [14] X. Liu, Y. Li, X. Liu & J. Shen. (2018). Fault diagnosis of chillers using very deep convolutional network. *Chinese Automation Congress*, (pp 1274- 1279), China.  
DOI : 10.1109/CAC.2018.8623749
- [15] J. Liu, D. Shi, G. Li, Y. Xie, K. Li, B. Liu & Z. Ru. (2020). Data-driven and association rule mining-based fault diagnosis and action mechanism analysis for building chillers. *Journal of Energy and Buildings*, 216, 1-16.  
DOI : 10.1016/j.enbuild.2020.109957

**이 강 배(Kangbae Lee)** [정회원]



- 1991년 3월 ~ 1995년 8월 : 한국과학기술원 산업공학(박사)
- 2001년 3월 ~ 2004년 8월 : 부산 가톨릭대학교 경영정보학과 교수
- 2008년 2월 ~ 현재 : 동아대학교 경영정보학과 교수
- 관심분야 : 머신러닝, 딥러닝

· E-Mail : kanglee@dau.ac.kr

**박 성 호(Sungho Park)** [정회원]



- 2017년 2월 : 동아대학교(학사)
- 2019년 2월 : 동아대학교(석사)
- 2019년 2월 ~ 현재 : 동아대학교 경영정보학과 박사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : psh2975@donga.ac.kr

**이 희 원(Hui-Won Lee)** [학생회원]



- 2021년 2월 : 동아대학교 경영정보학과(학사)
- 2021년 3월 ~ 현재 : 동아대학교 경영정보학과 석사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : 1718317@donga.ac.kr

**이 승 현(Seung-hyun Lee)** [학생회원]



- 2021년 2월 : 동아대학교 경영정보학과(학사)
- 2021년 3월 ~ 현재 : 동아대학교 경영정보학과 석사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : hyunwow1263@naver.com

**이 승 재(Seung-jae Lee)** [학생회원]



- 2021년 2월 : 동아대학교 경영정보학과(학사)
- 2021년 3월 ~ 현재 : 동아대학교 경영정보학과 석사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : sschoi2427@naver.com