

## 레이더 체계 운용데이터 기반 냉매 누설 사전 감지 연구

강문식\*, 박연경, 노웅석, 강태호, 조일훈, 전건수  
LIG넥스원 IPS연구소

### Early Detection for Refrigerant Leakage based on Radar System Operation Data

Moon-Sik Kang\*, Yun-Kyung Park, Woong-Seok Noh,  
Tae-Ho Kang, Il-Hoon Cho, Gun-Su Jeon  
Integrated Product Support R&D Lab, LIG Nex1 Co., Ltd

**요약** 정비전략은 고장정비와 예방정비를 넘어서, 장비의 상태를 모니터링하고 센싱데이터를 분석하여 필요한 시점에 필요한 정비만을 수행하는 상태기반정비(Condition-based maintenance, 이하 CBM)로 발전 중이다. CBM의 중요성이 강조됨에 따라 국방 분야에서도 CBM도입을 위한 제도적 개선 및 관련 연구들이 수행되고 있다. 그러나 기존 CBM 관련 연구는 실 운용데이터 획득의 어려움으로 인해 주로 실험실 환경에서의 이루어지고 있어, 실 운용환경에 대한 실증적 연구가 부족하다. 본 논문에서는 전력화되어 운용중인 레이더 체계의 운용 데이터를 활용한 냉매 누설 사전 감지 연구 사례를 제시한다. 냉매 누설 시 송신 신호 증폭을 담당하는 고발열 부품들에 대한 적절한 냉각이 이루어지지 않아 체계 성능 및 신뢰성 저하를 유발할 수 있으나, 이를 사전에 식별할 수 있는 진단 방법이 수립되어 있지 않다. 냉매 누설 사전 감지를 위하여 본 연구에서는 대상 레이더 체계의 냉각장치에 기 설치된 센서로부터 수집되는 데이터 중 냉매 누설과 연관된 데이터 항목을 도메인 지식에 기반하여 선별하였다. 고장이 발생하지 않은 운용초기 데이터로 LSTM(Long Short-Term Memory)-Autoencoder를 학습하였다. 운용초기 이후 정상과 이상이 섞여있는 데이터를 입력하여 냉매 누설 감지 성능을 검증한 결과, 실제 운용 및 정비 간 고장을 탐지한 시점보다 앞서 이상을 감지할 수 있음을 확인하였다.

**Abstract** The maintenance strategy is changing from corrective and preventive maintenance to condition-based maintenance (CBM). CBM is a proactive repair activity based on the health status of a system at any particular time. As the importance of CBM is emphasized, institutional improvement and research are being made for CBM in the defence area. On the other hand, existing research has been conducted in laboratory-scale experiments, so an empirical study on CBM for field environments is insufficient. This paper discusses refrigerant leakage detection of radar systems based on field operation data. Refrigerant leakage leads to insufficient cooling for highly heated components that amplify the transmission signal, but there is no method to detect refrigerant leakage. In this research, the data related to refrigerant leakage were extracted based on domain knowledge. LSTM (Long Short-Term Memory)-Autoencoder was trained on normal operation measurement in the early operation period. The data for the remaining period that comprised both normal and anomaly conditions of the cooling system were input into the trained LSTM-Autoencoder model. The result showed that anomaly data were detected prior to real failure.

**Keywords** : CBM, Radar System, Refrigerant Leakage, Operation Data, Anomaly Detection, LSTM-Autoencoder

이 논문은 2022년 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임.  
(KRIT-CT-22-081, 무기체계 CBM+ 특화연구센터)

\*Corresponding Author : Moon-Sik Kang(LIG Nex1)

email: moonsik.kang@lignex1.com

Received April 3, 2023

Revised May 4, 2023

Accepted June 2, 2023

Published June 30, 2023

## 1. 서론

무기체계의 정비개념은 전투준비태세 강화, 무기체계 가용도 향상, 운용유지비용 절감을 위해 정비기술의 변화와 함께 발전해 왔다. IEEE Standard에 따르면 정비 개념은 고장이 발생한 후 수리 혹은 교체하는 고장정비 (corrective maintenance), 일정 주기 간격으로 점검하는 예방정비(preventive maintenance) 그리고 장비의 상태에 기반하여 정비업무를 수행하는 상태기반정비 (Condition-based maintenance, 이하 CBM)로 구분된다[1]. 미 국방부는 CBM의 개념을 확대하여 광범위한 기술과 행정요소를 포함하는 정비 전략을 CBM+로 정의 하기도 한다[2].

현재까지 일반적으로 무기체계에 적용되는 정비활동은 고장 정비와 예방정비 형태로 수행된다[3]. 고장 정비는 고장으로 인해 장비가 멈추어도 인적·물적 손해가 미미할 때 적용할 수 있으며, 예방 정비는 해군함정과 같이 연속적으로 작동하지 않고 주기적으로 휴지기간을 갖는 무기체계에 적용될 때 효과를 볼 수 있다[4]. 그러나 레이더 무기체계와 같이 24시간 무중단 운영하는 장비에 대해서 고장/예방 정비 적용 시 갑작스러운 고장 발생, 고장 유무와 상관없는 정비 수행 및 수리부속 교환으로 인해 높은 정비 비용과 가용도 저하라는 문제점이 발생한다.

이러한 고장정비와 예방정비의 단점을 보완하기 위해 CBM도입이 강조되고 있다. CBM은 건전성 예측 및 관리(Prognostics and Health Management, 이하 PHM)기술을 기반으로 장비의 상태를 모니터링하고, 장비의 이상감지, 고장진단, 잔여수명 예측을 통해 필요한 시점에 필요한 정비업무 수행을 가능하게 한다. CBM도입 강조에 따라 국방부는 국방전력발전업무훈령 개정 및 총수명주기업무훈령 제정을 통해 CBM/CBM+구현을 위한 제도를 보완하고 있다[5,6]. 또한, CBM+ 특화연구센터 설립을 통해 CBM+기반 기술을 연구하여 CBM+ 데이터 수집체계 및 진단예측 절차를 확립하고자 한다.

무기체계 CBM 적용 및 확대를 위해 학술적인 차원에서 많은 노력이 있다. 그러나 아직까지는 실 운용데이터 획득의 어려움으로 인해 고장 모의실험, 가상데이터 생성, 시뮬레이션 등 실험실 환경 수준에 한정되어있다. Kim 등[7]은 천파 추적레이더 도파관의 결로·결빙 현상 이상감지를 위해 고장 모의실험을 통해 데이터를 수집하고, CNN(Convolution Neural Networks)모델을 활용하여 이상감지를 구현하였다. Koh 등[8]은 함정 통합마

스트에 대해 FMECA(failure mode effect and criticality analysis)를 통해 주요 고장모드를 선정하고, 치명적인 고장인자를 토대로 시뮬레이션을 통해 데이터를 수집한 후 K-NN (k-nearest neighbors)과 가우시안 프로세스 알고리즘을 적용하여 결함진단 및 잔여수명예측을 구현하였다. Hyun 등[9]은 전자전 무기체계 RF모듈에 대해 환경시험을 통해 열화데이터를 수집하고, MATLAB에서 제공하는 모델을 통해 잔여수명예측을 수행하였다. 실험실 환경은 실제 운용 환경에서 발생하는 다양한 외부요인이 반영되지 않기 때문에 고장 유형, 열화 형태 및 추세 등 장비 상태 변화가 실제와 차이가 있을 수 있으나 이에 대한 검증이 어렵다.

본 논문에서는 기 전력화되어 운용중인 레이더 무기체계의 운용데이터를 바탕으로 핵심 구성품에 대한 이상감지를 수행한 사례를 제시한다. 데이터는 본 무기체계에 기 설치된 여러 센서로부터 2년 6개월 동안 수집된 실제 운용데이터를 활용하였다. 해당 기간 동안 일부 구성품에 대해 고장이 발생하였고 이에대한 정비가 이루어졌으나, 고장 건수가 극히 적었다. 고장데이터의 특성을 학습시키기 어려운 점을 고려하여, 운용초기 정상데이터의 학습을 통해 이상감지를 할 수 있는 비지도 학습 기반의 이상감지 방안을 적용하였다. 실제 운용 및 정비 간 고장을 탐지한 시점과 비교하여 본 연구에서 제안한 방안의 사전감지 성능을 평가하였다.

본 논문의 구성은 다음과 같다. 2장은 연구목적인레이더 체계 냉각장치 내 냉매 누설 사전감지 필요성과 이를 구현하기 위해 적용한 알고리즘인 LSTM (Long Short-Term Memory)-Autoencoder에 대해 설명한다. 3장은 수집한 운용데이터를 바탕으로 냉매 누설 감지를 수행한 절차 및 결과를 제시한다. 마지막으로 4장은 결론 및 향후 연구 방향을 제시한다.

## 2. 연구 대상 및 방법

### 2.1 레이더 무기체계 개요 및 CBM 적용 대상

본 연구에서 다루는 레이더는 해상감시 및 저고도 공중표적에 대한 감시와 조기경보를 수행하는 체계이다. 레이더의 기본적인 원리는 안테나를 통해 전파를 방사하고 표적으로부터 반사된 신호를 분석하여 표적에 대한 정보를 탐지한다. 전파를 방사하여 물체에 관련된 각종 정보를 분석하는 레이더는 송신단에서의 높은 출력을 필요로 하며 이를 위해 고출력증폭기가 사용된다[10]. 고출

력증폭기는 많은 전력을 소비하고 높은 열을 방출하는 소자이다. 온도는 송수신 성능 및 송수신 모듈 고장의 주요 인자이므로[10-12], 송신단의 냉각이 적절하게 이루어지지 않는다면 무기체계 가동률 및 전투준비태세 저하로 이어질 수 있다. 본 무기체계에서는 고출력증폭기의 효과적인 냉각을 위해 수냉방식이 사용되며, 회수된 냉각유체는 열교환기에서 냉매를 통해 저온으로 식혀진다.

본 무기체계의 정비이력을 분석한 결과, 냉각장치에서 빈번한 고장이 발생하였으며, 주된 원인 중 하나로 냉매 압축기에서의 냉매 누설 현상임을 확인하였다. 냉매 누설 시 냉각 효율 저하 및 냉각 유체 온도 상승으로 인해 발열부품의 thermal stress가 증가하고, 냉각 효율 저하에 따른 보상작용으로 냉매압축기와 같은 냉각 관련 구동품목의 과부하가 유발된다.

그러나 본 무기체계는 냉매 누설에 대한 자체고장진단(Built-in Test, 이하 BIT)기능이 없다. 냉각유체 및 냉매 계통 관련 타 BIT(ex. 냉매 압력, 온도)를 통해 유추 혹은 실제 정비를 통해 진단할 수밖에 없다. BIT기능이 있다고 하더라도 고장 발생 후에 장비 상태에 대한 정보를 제공하기 때문에 열화추세파악, 상태 이상 변동 감지, 고장 예측 등 선제적 대응이 불가능하다. 따라서 본 연구에서는 냉각유체 및 냉매 계통의 관련 센싱 데이터와 시계열 데이터 이상감지에 유용한 LSTM-Autoencoder를 활용하여 냉매 누설을 사전에 감지하고 냉각 효율 저하에 따른 연쇄적 고장을 미연에 방지하고자한다.

## 2.2 LSTM-Autoencoder 기반 이상감지

본 연구에서 냉매누설 사전감지를 위해 적용한 알고리즘은 시계열 데이터 이상 감지에 우수한 성능을 나타내는 LSTM-Autoencoder이다. Autoencoder는 정상데이터의 학습을 통해 이상감지 모델을 구축할 수 있다는 장점이 있어 고장 데이터가 정상데이터에 비해 극히 적은 실제 현장에서 취득되는 데이터 적용에 유용하다. 또한, 장비의 노후화 등으로 인해 점진적으로 고장이 진행되는 경우, 데이터 분석 과정에서 시계열 특성을 고려해야한다[13]. LSTM은 순환신경망(Recurrent Neural Network, 이하 RNN)의 일종으로 장기간 과거 정보를 기억할 수 있어 시간의 순서가 중요한 시계열 데이터를 처리하는데 효과적이다. 따라서 시계열 데이터의 효과적인 이상감지를 위해 LSTM과 Autoencoder를 결합한 LSTM -Autoencoder가 널리 활용된다[13-19].

Autoencoder의 기본적인 구조는 아래 Fig. 1과 같이 인코더와 디코더로 구성되며 LSTM-Autoencoder는

Autoencoder의 구조를 LSTM 레이어로 구성한 것이다. 입력된 데이터의 특징을 비지도 방식으로 학습 및 저차원의 잠재 변수로 압축 후 원 입력데이터에 가깝게 복원하는 알고리즘이다. LSTM-Autoencoder는 입력과 출력의 차이를 계산하고 입력과 출력이 동일해지도록 학습을 한다. 차원 축소 과정에서 입력 데이터의 중요한 특징을 학습하게 된다. 따라서 학습되지 않은 임의의 다른 데이터가 입력되었을 때 복원을 제대로 하지 못한다. 이러한 특징을 가지는 LSTM-Autoencoder를 이상감지에 활용시, 정상 데이터만의 학습을 통해 이상감지가 가능하다.




Fig. 1. General architecture of Autoencoder

LSTM-Autoencoder를 활용한 이상감지 절차는 아래 Fig. 2와 같다. 먼저, LSTM-Autoencoder에 정상 데이터를 입력시켜 학습시킨 후 원 데이터와 복원 데이터 간의 오차를 구한다. 이후 정상데이터의 복원 오차 분포를 통해 정상/이상을 판별할 오차의 임계치를 구한다. 학습된 모델에 임의의 데이터를 입력 후 복원하여 복원 오차를 계산한다. 이때 오차가 기 설정한 임계치를 넘어가면 이상, 그렇지 않으면 정상으로 판단한다.

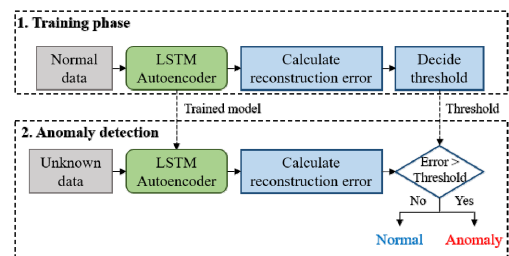


Fig. 2. Process of anomaly detection using LSTM -Autoencoder

## 3. 냉매누설 사전감지

### 3.1 연구 프로세스

본 논문의 연구 프로세스는 아래 Fig. 3과 같다. 첫 번째로는 수집된 센싱 데이터 중 냉매 누설 감지에 활용할 데이터 항목을 도메인 지식에 기반하여 선정하였다. 두 번째로는 센서 신호에는 결함과 관계되는 신호 외에 다양한 신호와 잡음이 혼재되어 있으므로 센서 오류, 외부 환경에 의한 잡음 등 불필요한 정보를 제거하는 데이터 전처리를 진행하였다. 세 번째로 LSTM-Autoencoder 모델에 고장이 발생하지 않은 운용초기 6개월 데이터를 학습시켜 복원오차를 구하고 정상/이상을 판별할 임계치를 설정하였다. 네 번째로는 냉매누설이 발생했던 운용초기 6개월 이후 데이터를 입력하여 복원오차를 구하여 기 설정한 임계치를 넘는 이상데이터를 탐지하였다. 마지막으로, 간헐적으로 감지되는 이상데이터에 대한 민감도를 낮추고, 운용자에게 냉매누설 위험도 정도를 정량적으로 수치화하여 제공하기 위한 후처리 작업을 진행한 후 실제 운용 및 정비 간 식별한 고장일자와 비교하여 사전감지 성능을 검증하였다.




Fig. 3. Research process

### 3.2 데이터 선정 및 데이터 전처리

본 연구에서는 레이더 체계에 기 부착된 센서로부터 2년 6개월 가량의 운용기간 동안 수집된 데이터를 대상으로 분석을 진행하였다. 냉각장치에 대해서는 13개 항목의 센싱 데이터가 수집되며, 이 중 도메인 지식을 바탕으로 냉매 유출의 사전감지에 활용할 데이터 항목으로 6개의 항목을 선정하였다. 선정된 데이터 리스트는 아래 Table 1과 같다.

Table 1. Selected features

No.	Features
1	Temperature of Supplied Fluid
2	Temperature of Retrieved Fluid
3	Temperature of Refrigerants
4	Low Pressure of Refrigerants
5	High Pressure of Refrigerants
6	Current of Refrigerant Compressor

원 신호 데이터는 센서 오류로 인한 비정상적인 수치 및 요동이 크게 존재하기 때문에 노이즈 제거를 위한 전처리를 진행하였다. 또한, 데이터 변수 간 영향성을 동일하게 만들어주기 위해 z-score 정규화를 진행했다.

먼저, 아래 Fig. 4와 같이 정상적인 데이터 수집 환경에서는 발생할 수 없는 0 혹은 음수와 같은 비정상적인 수치를 제거하였다. 또한, 아래 Fig. 5와 같은 냉각 장치의 간헐적 비정상 패턴이 존재한다. 이는 냉각 장치의 고장으로 인한 것이 아닌 간헐적으로 레이더 신호 비방사, 정비비에 따라 냉각 대상 장치가 미작동 및 발열량이 줄어들어 인한 것이므로 제거하였다.

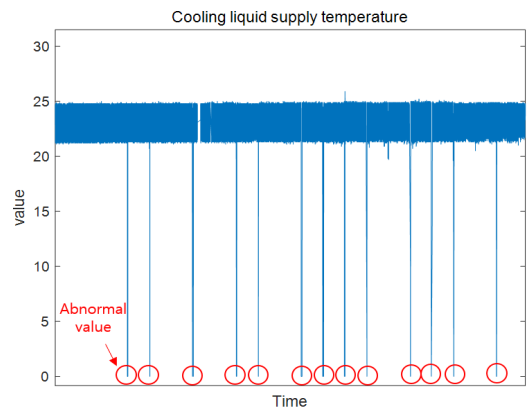


Fig. 4. Abnormal sensing value due to error of the sensor

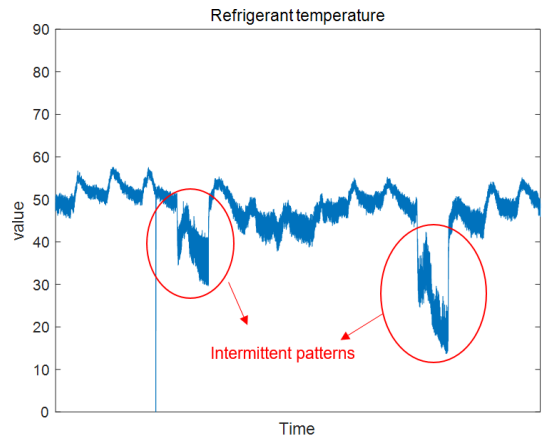


Fig. 5. Intermittently abnormal data patterns due to non operation of cooling target device

이후 노이즈를 줄이기 위해 이동 평균(Moving average) 필터를 적용하였다. 24시간의 평균을 구하고, 1시간씩 스텝을 이동하며 평균을 구하였다. 그 결과, 6개

데이터 변수에 대한 그래프는 아래 Fig. 6과 같다.

학습데이터는 운용 초기 6개월의 데이터로, 테스트 데이터는 운용 초기 6개월 이후의 데이터로 구분하였다. 학습시킬 운용 초기 6개월의 정상 데이터에 대해 z-score 정규화를 진행했다. 6개월 이후 데이터는 정상 데이터 정규화 시 사용된 파라미터로 동일하게 z-score 정규화를 진행했다.

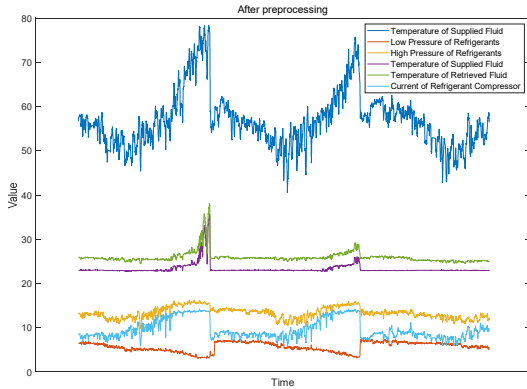


Fig. 6. Graph of the selected data after preprocessing

Sequence는 아래 Fig. 7과 같이 24개의 데이터로 1개의 sequence를 구성하였으며, 1개의 데이터씩 스텝을 옮겨가며 순차적으로 sequence를 구성하였다. 총 20495개의 sequence 중 운용 초기 6개월에 해당하는 4040개는 학습에 활용하였고, 나머지 16455개는 테스트에 활용하였다.




Fig. 7. Datasets handling method

### 3.3 LSTM-Autoencoder 기반 이상감지

본 연구에서 LSTM-Autoencoder는 MATLAB을 통해 구현하였다. 활성화 함수는 Relu, 미니배치사이즈는 500, 에포크는 200으로 설정했다. 운용 초기 6개월 데이터로 구성된 정상 데이터 셋을 학습시켰고, 복원된 데이터와 원 데이터 간의 오차는 MAE(Mean Absolute Error)로 계산하였다. 정상 sequence 4040개의 복원오차에 대한 히스토그램은 아래 Fig. 8과 같다. 정상데이터 복원오차의 최대치를 정상/이상 판별할 임계치로 설정했다.

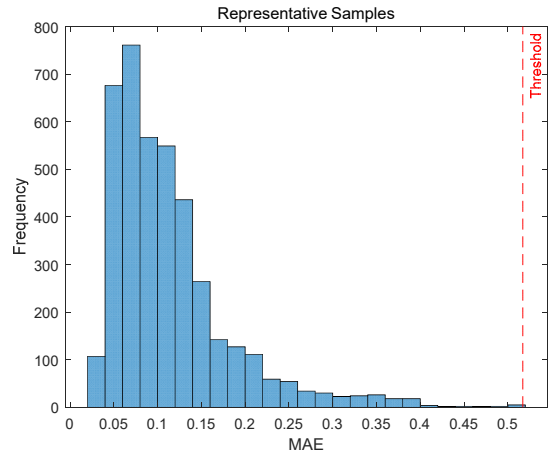


Fig. 8. Histogram of the reconstruction error of normal data

정상데이터로 학습된 LSTM-Autoencoder모델에 초기 운용 6개월 이후 데이터를 입력하고 복원오차를 구하여 이상데이터를 감지하였다. 이상감지 결과는 아래 Fig. 9와 같다. 학습시킨 운용 초기 6개월을 포함한 초기 데이터는 정상으로 분류되었다. 첫 번째 냉매 누설 고장 건에 대하여 실제 운용 및 정비 간 고장을 식별한 시점(1<sup>st</sup> failure)보다 앞선 시점부터 이상(1<sup>st</sup> Anomaly)으로 감지되었다. 정비(1<sup>st</sup> Maintenance) 직후 데이터의 복원 오차가 줄어들며 정상으로 분류되었다. 두 번째 냉매 누설 고장 건에 대해서도 운용 및 정비 간 고장(2<sup>nd</sup> Failure)을 식별한 시점보다 앞서서 이상(2<sup>nd</sup> Anomaly)을 감지하였으며, 정비(2<sup>nd</sup> Maintenance) 이후 복원오차가 줄어들어 정상으로 분류되었다.

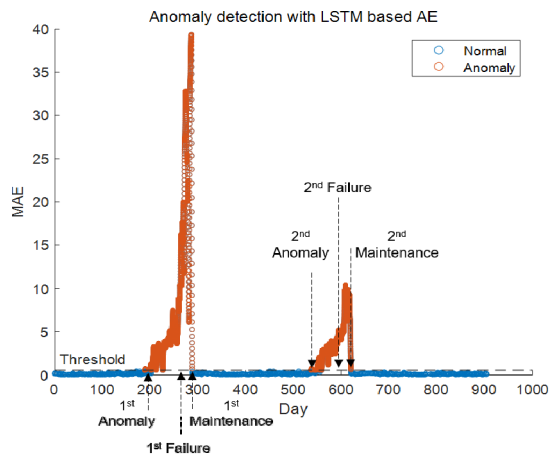


Fig. 9. Anomaly detection results

### 3.4 후처리(냉매 누설 위험도 수치화)

냉매 누설 사전 감지 가능성을 확인하였으나, 아래 Fig. 10과 같이 이상이 감지되기 시작하는 초반에는 정상으로 복구되었다가 다시 이상으로 감지되는 경우가 있다. 이후 정비 수행 전까지는 연속적으로 이상으로 감지된다. 이는 냉매 누설 초기에는 누설 정도가 미미하여 임계치의 근접한 이상 sequence가 간헐적으로 발생하다가, 점진적으로 누설이 진행되며 정상 sequence의 특성과는 확연히 다른 이상 sequence가 발생하는 것으로 보여진다. 간헐적 이상 알람은 운용자에게 혼란을 야기할 수 있으며, 냉매 누설로 판단할만한 충분한 정보가 축적될 시간이 필요하다

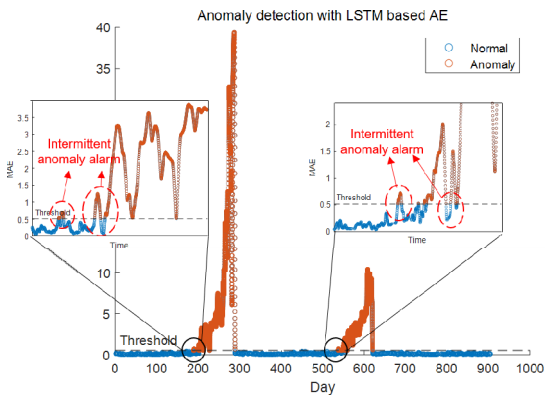


Fig. 10. Intermittent anomaly detection cases

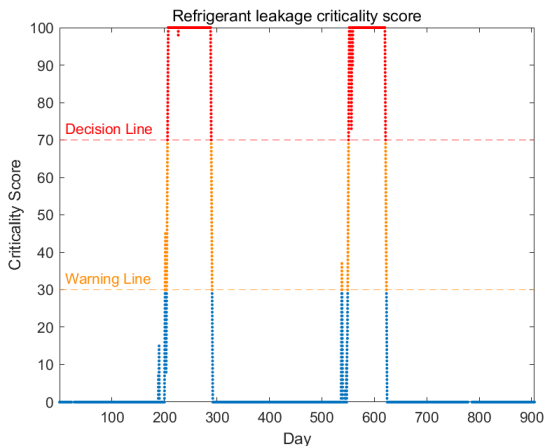


Fig. 11. Refrigerant leakage criticality scoring results

본 논문에서는 운용자의 판단을 서포트하기 위해 냉매 누설 위험도 정도를 수치화하였다. 스코어를 최소0부터 최대100 범위로 정하였고, 실시간으로 들어오는 sequence

데이터가 정상으로 분류될 경우 -1, 이상으로 분류될 경우 1점을 부여하여 장비 상태를 표시한다. 냉매 누설 위험도가 30을 넘어갈 경우 냉매 누설을 '경고'하고, 70을 넘어갈 경우 냉매 누설로 '판단'한다. 냉매 누설 위험도 수치화 결과는 위 Fig. 11과 같다. 현재 점수에 따라 위험도 정도를 파악할 수 있으며, 70점(Decision line) 기준 간헐적 이상신호에 의한 혼란은 배제 되었다.

### 3.5 냉매 누설 사전 감지 결과 종합

LSTM-Autoencoder 및 위험도 수치화에 따른 냉매 누설 사전 감지 성능은 아래 Table 2와 같다. Table 2는 두 건의 냉매 누설에 대하여 실제 운용 및 정비 간 고장을 탐지한 시점(Real), 냉매 누설 위험도 수치화에 따른 '경고(Warning)' 및 '판단(Decision)' 시점을 보여준다. 두 건의 냉매 누설에 대하여 실제 운용 및 정비 간 고장을 탐지한 시점 대비 약 45일, 67일 선형하여 냉매 누설을 경고하였으며, 약 40일, 54일 선형하여 냉매 누설을 판단하였다. 즉, 본 연구에서 제안한 방법을 통해 최소 40일 앞서 냉매 누설에 대한 사전 감지를 할 수 있음을 알 수 있다.

Table 2. Time to detect refrigerant leakage

Category		Time to detect 1 <sup>st</sup> leakage (Day)	Time to detect 2 <sup>nd</sup> leakage (Day)
Real		246.8	605.5
Criticality	Warning	201.2	538.0
	Decision	206.0	551.0

## 4. 결론

본 연구에서는 기 전력화되어 운용중인 레이더 체계의 실 운용 데이터를 활용하여 무기체계 CBM 적용을 위한 실증적 연구를 수행하였다. 장기간 수집된 운용데이터에 LSTM-Autoencoder를 적용하여 이상 데이터를 감지하였으며, 운용자의 판단을 서포트하기 위하여 냉매 누설 위험도를 수치화하여 정보 제공하는 방식을 제안하였다. 그 결과 실제 운용 및 정비 간 냉매 누설을 탐지한 시점 대비 약 40일 앞서 감지할 수 있음을 확인하며, 본 연구에서 제안한 방식의 냉매 누설 사전 감지 성능을 검증하였다.

고장의 이상 징후를 파악함으로써 미리 수리부속조달,

정비계획수립 등 적합한 정비대책을 통해 장치의 치명적 손상, 관련 장치의 연쇄 고장, 가용도 저하 등을 예방하고, 전투준비대세 강화에 본 연구가 기여할 것으로 기대한다. 본 연구 사례는 기 전력화된 타 무기체계에 CBM 적용 측면에서도 의미를 갖는다. 기 전력화된 대다수의 무기체계는 개발 단계부터 CBM을 고려하여 센서, 센싱 데이터 선정 등이 이루어지지 않았기 때문에 CBM 적용이 어려울 수 있다. 본 연구에서 수행한 CBM 적용 절차 및 이상감지 방법을 활용하여, 유사 문제를 갖는 다양한 무기체계 가용도 향상에 기여할 것으로 기대한다.

향후 연구로는 정상데이터 범위를 설정하는 방법에 대한 연구를 할 필요가 있다. 본 연구에서는 장기간 운용데이터를 먼저 수집하고, 고장이 발생하지 않았던 운용 초기 6개월을 정상 범위로 설정하였다. 그러나 실시간으로 데이터가 순차적으로 수집되는 실제 운용환경을 고려하였을 때, 모델을 구축하기 위해 어느 기간까지 수집된 데이터를 학습에 활용할지 결정이 어려울 수 있다. 지속적으로 축적되는 데이터에 따라 주기적으로 모델을 재학습 및 업데이트하는 알고리즘을 개발하는 등의 방안을 모색할 필요가 있다. 또한, 한정된 고장 사례를 본 연구에서는 다루었으므로 무기체계의 CBM 적용 및 확대를 위해서는 지속적으로 데이터 및 고장 사례를 수집하여 연구 범위를 확장해나갈 필요가 있다.

## References

- [1] IEEE Reliability Society, IEEE Standard Framework for Prognostics and Health Management of Electronic Systems.
- [2] B. C. Shin, J. W. Hur, "A Study of Sensor Reasoning for the Diesel engine TurbochargerCBM+ Application in the Early Design Stage", *Journal of the Korea Academia-Industrial cooperation Society*, pp.121-126, 2022.  
DOI: <https://doi.org/10.5762/KAIS.2022.23.7.121>
- [3] M. J. Son, Y. G. Kim, A Study on the Reflection of Condition-Based Maintenance Requirement in the Defense Specification, *Journal of the Korean Society for Quality Management*, Vol.49, No.3, pp.269-279, 2021.  
DOI: <https://dx.doi.org/10.7469/JKSQM.2021.49.3.269>
- [4] D. H. Kim, S. W. Kang, J. H. Lee, K. M. Nam, S. H. Seong, H. J. Lee, "A Study on Applicability of Predictive Maintenance and Vibration Data Analysis by Fast Fourier Transform into Major Equipment of Submarine", *Journal of the KNST*, Vol.4, No.1, pp.014-021, 2021.  
DOI: <https://doi.org/10.31818/JKNST.2021.03.4.1.14>
- [5] Ministry of National Defence, "Directive on defence force development", pp.12-82, 2022.
- [6] Ministry of National Defence, "Directive on total life cycle management", pp.18-19, 2023.
- [7] Y. G. Kim, M. J. Son, S. C. Noh, S. J. Kim, "A Study on Prevention of Condensation and Freezing in Radar Waveguide using Condition Based Maintenance", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.23, No.7, pp.229-239, 2022.  
DOI: <https://doi.org/10.5762/KAIS.2022.23.7.229>
- [8] H. J. Koh, J. H. Lee, Y. E. Ra, M. S. Kang, Y. M. Yoo, D. I. Kwon, J. S. Lee, "Degradation Analysis, Fault Diagnosis and Remaining Life Prediction of Integrated Mast and Transmitter Receiver Module", *Korean Journal of Computational Design and Engineering*, Vol.25, No.2, pp.192-204, 2020.  
DOI: <https://doi.org/10.7315/CDE.2020.192>
- [9] D. K. Hyun, S. H. Kim, Y. H. Lee, H. W. Lee, S. H. Lee, K. S. Kwon, B. J. Moon, "A Study of PHM Technology Application to an Electronic Weapon System", *Journal of applied reliability*, Vol.20, No.3, pp.246-253, 2020.  
DOI: <https://doi.org/10.33162/JAR.2020.09.20.3.246>
- [10] S. M. Hwang, C. H. Kim, K. H. Lee, "HALT of High Power Amplifier Module Used in Radar", *Journal of applied reliability*, Vol.14, No.2, pp.97-102, 2014.
- [11] A. J. Wileman, S. Perinpanayagam, "Failure mechanisms of radar and RF systems", *International Through-life Engineering Services Conference*, Vol.11, pp.56-61, 2013.  
DOI: <https://doi.org/10.1016/j.procir.2013.07.063>
- [12] G. Wenjun, S. Bin, Z. Yuanzhu, "Fault Prognosis of Transmit-receive Modules for Active Phased Array radar", *2021 Global Reliability and Prognostics and Health Management*, Nanjing, pp.1-6, 2021.  
DOI: <https://doi.org/10.1109/PHM-Nanjing52125.2021.9612938>
- [13] M. J. Oh, E. S. Choi, K. W. Roh, J. S. Kim, W. S. Cho, "A Study on the Design of Supervised and Unsupervised Learning Models for Fault and Anomaly Detection in Manufacturing Facilities", *The Korea Journal of BigData*, Vol.6, No.1, pp.23-35, 2021.  
DOI: <https://doi.org/10.36498/KBIGDT.2021.6.1.23>
- [14] O. I. Provotar, Y. M. Lindar, M. M. Veres, "Unsupervised Anomaly Detection in Time Series Using LSTM-Based Autoencoders", *2019 IEEE International Conference on Advanced Trends in Information Theory(ATIT)*, pp.513-517, 2019.  
DOI: <https://doi.org/10.1109/ATIT49449.2019.9030505>
- [15] J. G. Lee, D. H. Kim, "Case Study on Fault Diagnosis of Radiator Using LSTM Autoencoder", *The Journal of KINGComputing*, Vol.16, No.6, pp.17-25, 2020.
- [16] J. Y. Lee, K. Y. Lee, "An Anomalous Sequence Detection Method Based on An Extended LSTM

Autoencoder", *The Journal of Society for e-Business Studies*, Vol.16, No.1, pp.127-140, 2021.

DOI: <https://doi.org/10.7838/jsebs.2021.26.1.127>

- [17] J. Y. Kang, C. S. Kim, J. W. Kang, J. H. Gwak, "Anomaly Detection of the Brake Operating Unit on Metro Vehicles Using a One-Class LSTM Autoencoder", *Appl. Sci.*, 11, 9290, 2021.  
DOI: <https://doi.org/10.3390/app11199290>
- [18] I. Mitiche, T. McGrail, P. Boreham, A. Nesbitt, G. Morison, "Data-Driven Anomaly Detection in High-Voltage Transformer Bushings with LSTM Auto-Encoder", *Sensors*, 21, 7426, 2021.  
DOI: <https://doi.org/10.3390/s21217426>
- [19] Bampoula, X.; Siaterlis, G.; Nikolakis, N.; Alexopoulos, K. A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders. *Sensors* 2021, 21, 972.  
DOI: <https://doi.org/10.3390/s21030972>

#### 강 문 식(Moon-Sik Kang)

[정회원]



- 2019년 8월 : 성균관대학교 기계공학부 (공학학사)
- 2022년 2월 : 성균관대학교 산업공학과 (공학석사)
- 2022년 4월 ~ 현재 : LIG 넥스원 IPS 연구소

<관심분야>

신뢰성공학, CBM, IPS

#### 박 연 경(Yun-Kyung Park)

[정회원]



- 2006년 8월 : 고려대학교 산업공학과 (공학학사)
- 2019년 8월 : 고려대학교 소프트웨어 공학과 (공학석사)
- 2006년 7월 ~ 현재 : LIG 넥스원 IPS 연구소

<관심분야>

Machine Learning, IPS

#### 노 응 석(Woong-Seok Roh)

[정회원]



- 2002년 2월 : 서강대학교 컴퓨터공학과 (공학학사)
- 2020년 2월 : 고려대학교 빅데이터융합학과 (공학석사)
- 2002년 4월 ~ 현재 : LIG 넥스원 IPS 연구소

<관심분야>

Machine Learning, IPS

#### 강 태 호(Tae-Ho Kang)

[정회원]



- 1989년 2월 : 원광대학교 전자공학과 (공학학사)
- 2013년 1월 : 국방대학교 산업관리학과 (경영석사)
- 2011년 6월 ~ 현재 : LIG 넥스원 IPS 연구소

<관심분야>

국방/과학, 신뢰성분야, IPS

#### 조 일 훈(Hoon Cho)

[정회원]



- 2011년 2월 : 고려대학교 산업시스템정보공학과 (공학학사)
- 2013년 2월 : 한국과학기술원 산업 및 시스템공학과 (공학석사)
- 2013년 3월 ~ 현재 : LIG 넥스원 IPS 연구소

<관심분야>

정보경영, 정보통신, IPS



전 건 수(Gun-Su Jeon)

[정회원]



- 2023년 2월 : 성균관대학교 바이오테크놀로지학과 (공학학사)
- 2023년 1월 ~ 현재 : LIG 넥스원 IPS 연구소

〈관심분야〉

Machine Learning, IPS