



Received: 2024/08/06
Revised: 2024/08/17
Accepted: 2024/09/13
Published: 2024/09/30

***Corresponding Author:**

Mansoo Kim

Future Warfare Integrated Product Support
R&D(Maritime), LIG Nex1
21, Pangyo-ro 255beon-gil, Bundang-gu,
Seongnam-si, Gyeonggi-do, Republic of Korea
Tel: +82-31-326-9415
Fax: +82-31-288-9123
E-mail: mansoo.kim2@lignex1.com

압력, RPM 데이터 및 LSTM을 이용한 디젤엔진의 이상탐지기법 연구

Study on Anomaly Detection in Diesel Engines Using Pressure Data, RPM Data and LSTM

김만수^{1*}, 최영원², 박병호², 박문성², 김진홍³

¹LIG넥스원 미래전장IPS연구소 1팀 수석연구원

²LIG넥스원 미래전장IPS연구소 1팀 선임연구원

³LIG넥스원 미래전장IPS연구소 1팀 연구원

Mansoo Kim^{1*}, Youngwon Choi², Byeongho Bak², Moonsung Park², Jinhong Kim³

¹Chief research engineer, Future Warfare Integrated Product Support R&D (Maritime), LIG Nex1

²Research engineer, Future Warfare Integrated Product Support R&D (Maritime), LIG Nex1

³Research engineer, Future Warfare Integrated Product Support R&D (Maritime), LIG Nex1

Abstract

함정 디젤엔진의 고장을 사전에 탐지하는 것은 함정의 운항 안전을 보장하고 운영유지비용을 최소화하는 중요한 문제이다. 이를 위해 엔진에서 실시간으로 수집되는 각종 압력데이터와 RPM을 모니터링하여 이상을 조기에 감지하는 기술이 필요하다. 본 연구에서는 LSTM을 사용하여 함정의 엔진 고장을 사전에 탐지하는 방법론을 제안한다.

Detecting failures in naval engines in advance is crucial for ensuring the safety of vessel operations and minimizing operational maintenance costs. To achieve this, it is essential to have technologies that can monitor various pressure data and RPM collected in real-time from the engine and detect anomalies early. This study proposes a methodology for predicting engine failures in naval vessels using Long Short-term Memory(LSTM).

Keywords

이상탐지(Anomaly Detection),
장단기 메모리 네트워크(Long Short-term Memory),
상태기반정비(Condition Based Maintenance),
디젤 엔진(Diesel Engine)

1. 서론

함정무기체계 엔진의 신뢰성과 안전성은 함정 운용 준비태세와 효율성에 직접적인 영향을 미치는 중요한 요소이다. 엔진 고장은 예상치 못한 운용 중단을 초래할 수 있으며, 이는 함정의 전투 준비태세를 저하시킬 뿐만 아니라 유지보수 비용을 크게 증가시킨다. 따라서 엔진 고장을 사전에 탐지하는 능력은 함정 운영의 무결성과 비용 효율성을 유지하는 데 있어 핵심적인 요소이다.

전통적으로 엔진 유지보수는 정기 점검과 예방 유지보수 정비정책에 의존해 왔다. 이러한 방법은 많은 문제를 해결할 수 있지만, 예기치 못한 고장을 예측하고 방지하는 데는 한계가 있다. 정기 유지보수는 일반적으로 과거 고장 데이터와 고정된 간격에 기반하여 이루어지기 때문에, 실제 엔진 상태를 정확히 반영하지 못할 수 있다. 이로 인해 불필요한 유지보수로 인한 비용과 불가동 시간이 발생하거나, 고장이 발생하기 전까지 문제를 발견하지 못할 위험이 있다. 이러한 단점을 극복하기 위해 최근에는 센서 기술과 데이

터 분석의 발전에 힘입어 엔진 상태를 실시간으로 모니터링할 수 있는 다양한 연구가 진행되고 있다.

현대 엔진에는 온도, 압력, 진동, 회전 속도 등의 다양한 매개변수를 측정하는 센서가 장착되어 있고 이 센서로부터 수집되는 실시간 데이터는 고장 예측 및 이상 탐지 기법을 적용할 수 있는 기회를 제공한다.

본 연구에서 적용한 장단기 메모리(long short-term memory, LSTM) 네트워크는 시계열 데이터의 기계학습 분석에서 주로 사용되며 순환 신경망(recurrent neural network, RNN)의 일종이다.

LSTM 네트워크는 장기적인 정보 유지와 순차 데이터의 패턴 인식에 뛰어나 미래의 사건을 예측하는데 특히 적합하다. 이런 특성을 이용하여 엔진 상태를 모니터링하고 예측하는데 사용할 수 있다. 본 연구에서는 LSTM 네트워크를 활용하여 함정 엔진 고장을 조기에 탐지하는 방법론을 제안한다. 엔진 센서로부터 수집된 실시간 데이터를 활용하여 잠재적 고장을 나타내는 이상 징후를 식별하는 것이 목표이다. 제안된 방법은 LSTM 모델을 사용하여 정상상태의 센서 데이터를 정상 운용 패턴으로 학습시킨 다음, 실시간으로 수집되는 실제 데이터와 LSTM을 통해 예측한 값 사이의 편차를 통해 고장의 징후를 감지하는 개념이다.

이러한 예측 유지보수 시스템을 구현하면 여러 가지 이점을 얻을 수 있다. 우선, 예기치 못한 엔진 고장의 위험을 줄여 함정 운용의 안전성과 신뢰성을 향상시킨다. 또한, 유지보수 일정을 최적화하여 필요할 때만 개입함으로써 운영 비용과 불가동 시간을 줄일 수 있다. 나아가 잠재적 문제를 조기에 발견하여 적시에 교정 조치를 취함으로써 함정 운용에 미치는 영향을 최소화하고 엔진 구성 요소의 수명을 연장할 수 있다.

본 연구를 통해 디젤엔진의 효과적인 이상 탐지 방법을 제안하고 이를 통해 과거 해군 무기체계의 전통적인 유지보수 정책보다 진보된 데이터 기반 접근 방식으로 해군 함대의 운용 준비태세와 비용 효율성을 향상시키는 하나의 방법을 제공하는 것을 목표로 한다.

2. 관련 연구 동향

과거에는 엔진 고장을 예방하기 위해 전통적인 정

기 점검 및 유지보수가 주로 시행되었지만, 고장이 발생하기 전에 문제를 발견하기는 어려웠다. 최근에는 센서 기술의 발전으로 엔진으로부터 다양한 데이터를 수집하고 모니터링하는 것이 가능해지면서, 디젤엔진의 이상 탐지와 고장 분리 기법을 통해 고장을 사전에 예측하는 다양한 연구가 이뤄지고 있다.

Yiannis 등(2018)은 실린더 배기온도, 피스톤 냉각오일 압력값 등을 ANN-SOM(self organizing map)과 유클리드 거리측정법을 사용하여 디젤엔진의 운용 상태를 분류하였다[1].

Chengtao 등(2017)은 엔진의 회전속도와 전력값 등을 SVM(support vector machine)과 rule based data mining을 사용하여 4가지 디젤엔진 고장유형을 분류하였다[2].

Zhixiong 등(2012)은 진동데이터와 오일관련 데이터를 ICA(independent component analysis)와 SFAM(simplified fuzzy ARTMAP)을 사용하여 디젤엔진의 고장을 감지하였다[3].

Yulong 등(2007)은 진동데이터를 Wavelet 변환하고, PSA(principal component analysis) 및 SVM을 사용하여 디젤엔진의 다양한 고장유형을 식별하였다[4].

Venkui 등(2018)은 TFSKICA(time-frequency supervised kernel independent component analysis)와 t-SNE(t-distributed stochastic neighbor embedding)을 사용하여 진동데이터를 시각화함으로써 디젤엔진의 상태를 전시하는 방법을 제안하였다[5].

이상구 등(2022)은 진동데이터를 사용하여 디젤엔진 동력전달계통의 이상에 대한 원인분석 결과를 제시하였다[6].

김성현(2022)은 엔진에서 발생하는 소음데이터에 기계학습을 적용하여 고장을 진단하는 기법을 제안하였다[7].

본 연구에서는 엔진의 충전공기 압력, 제어오일 압력, RPM 센서값과 LSTM 알고리즘을 사용하여 RPM 값을 예측하고 실제 센서값과의 차이를 통해 이상탐지하는 방법을 제안한다.

3. LSTM(long short-term memory) 모델

LSTM 알고리즘은 순환 신경망(RNN)의 일종으로,

시계열 데이터나 순차적인 데이터의 장기 의존성(long-term dependencies) 문제를 효과적으로 해결하기 위하여 설계되었다. LSTM은 기본 RNN의 기울기 소멸(vanishing gradient) 문제를 극복하기 위해 개발된 구조로, 주로 장기적인 패턴을 학습하는데 강점을 보인다.

LSTM은 네 개의 주요 구성 요소로 이루어져 있다.

- (1) 입력 게이트: 현재 입력과 이전 은닉 상태를 바탕으로 새로운 정보를 셀 상태에 얼마나 추가할지를 결정
- (2) 망각 게이트: 기존 셀 상태에서 어떤 정보를 버릴지를 결정하여, 장기 의존성 문제 완화
- (3) 출력 게이트: 셀 상태의 정보 중 어떤 것을 출력으로 사용할지 결정
- (4) 셀 상태: 시간에 따라 정보를 유지하거나 업데이트

LSTM은 자연어 처리, 시계열 예측, 음성 인식 등 다양한 분야에서 널리 사용된다. LSTM의 주요 장점은 긴 시퀀스에서도 중요한 정보를 잃지 않고 정보를 효과적으로 기억해 학습할 수 있으며, 단기적인 기억과 장기적인 기억을 적절히 조절할 수 있다는 점이다.

4. 실험 및 결과

4.1 데이터셋

디젤엔진으로부터 수집되는 데이터는 엔진 내부의 다양한 부품 및 구성요소의 상태를 나타내는 중요한 정보로 온도, 압력 등의 데이터를 포함한다. 본 연구에서는 함정의 디젤엔진에서 수집될 수 있는 데이터와 유사한 Engine Datasets를 활용하였다[8]. 이 데이터셋은 열차의 디젤엔진에 대한 센서 데이터로, 본 연구에서는 Table 1에 나타낸 바와 같이 총 15개의 센서를 통해 데이터를 수집하였다. 전체 데이터는 2017년 7월 5일 5시부터 24시까지 약 18시간 동안 수집되었으며, 정확한 고장 발생 시점에 대한 라벨링 정보는 포함되어 있지 않으나 10시경 충전공기(charge air) shortage가 발생한 이력을 제공하고 있다.

Table 1. Composition of diesel engine dataset

Sensor name	Measurement unit	Sampling frequency
Charge air temp	°C	1 Hz
Charge air pressure	psi	
Control oil pressure	psi	
Exhaust temp	°C	
Engine frequency (RPM)	rpm	
Ambient temp	°C	
Fuel pressure	psi	
Fuel temp	°C	
Oil cooler in temp	°C	
Oil cooler out temp	°C	
Cooling water outlet temp	°C	
Cooling water inlet temp	°C	
Cooling water inlet pressure	psi	
Cooling water outlet pressure	psi	
Second stage oil pressure	psi	

이 데이터셋에서 제공하는 상태 모니터링용 주요 센서 데이터의 종류는 온도, 압력, RPM이다. 온도 센서는 엔진의 여러 부분의 온도를 측정하여 과열 등의 문제를 감지할 수 있게 해주며, 압력 센서는 연료 및 공기의 압력을 측정하여 연소 상태를 파악하게 해준다. RPM 센서는 엔진의 회전수를 측정하여 엔진의 작동 상태를 실시간으로 모니터링하는데 사용된다.

디젤엔진의 RPM(engine frequency), 충전공기 압력(charge air pressure) 및 제어오일 압력(control oil pressure) 사이에는 중요한 상호작용이 있으며 각각의 요소는 엔진의 성능과 효율성, 안전성에 영향을 미친다.

- (1) RPM: 엔진 크랭크축이 1분당 회전하는 횟수를 나타낸다. RPM은 엔진의 출력과 직접적으로 관련이 있고 높은 RPM은 더 많은 출력과 빠른 속도를 의미하며, 낮은 RPM은 연료 효율성을 높이고 부하를 줄인다.
- (2) 제어오일 압력: 엔진의 가변 밸브 타이밍 시스

템이나 터보차저 같은 특정 구성 요소를 조절하는 데 사용되는 오일의 압력을 의미한다. 제어오일 압력은 엔진의 성능과 연비를 최적화하고 배출가스를 줄이는 데 중요하며 올바른 제어오일 압력은 밸브 타이밍과 터보차저 작동을 적절히 조절하여 엔진의 효율성을 극대화한다.

- (3) 충전공기 압력: 터보차저에 의해 엔진에 공급되는 공기의 압력을 나타낸다. 충전공기 압력은 엔진으로 유입되는 공기의 양을 증가시켜 연소 효율성을 높이고 출력을 증가시킨다. 적절한 충전공기 압력은 연소 과정에서 더 많은 산소를 공급하여 연료를 완전히 연소시킬 수 있게 한다.

RPM이 증가하면 터보차저가 더 빠르게 회전하여 충전공기 압력이 상승하고 높은 RPM에서 더 많은 공기를 압축하여 엔진에 공급함으로써, 출력이 증가하고 성능이 향상된다. 낮은 RPM에서는 충전공기 압력이 낮아져 출력이 감소한다. RPM의 변화에 따라 제어오일 압력도 변하는데, 높은 RPM에서는 더 높은 제어오일 압력이 필요할 수 있으며, 이는 밸브 타이밍과 터보차저를 조절하여 최적의 성능을 유지하는 데 기여한다.

제어오일 압력의 적절한 조절은 엔진이 다양한 RPM 범위에서 효율적으로 작동하도록 한다. 제어

오일 압력은 충전 공기 압력에도 영향을 미친다. 예를 들어, 가변 밸브 타이밍 시스템은 제어오일 압력을 통해 밸브 타이밍을 조절하여 엔진의 흡기 효율성을 최적화할 수 있다. 이 세 가지 요소는 상호의존적이며, 엔진의 성능과 효율성을 최적화하기 위해 조화롭게 작동해야 한다. 본 논문에서는 엔진의 상태를 평가하기 위해 이들 변수를 실시간으로 모니터링하는 방법에 대하여 연구하였다.

4.2. 방법 및 절차

본 연구는 파이썬을 사용하여 수행하였으며, 단계별 분석절차는 Table 2와 같다.

4.2.1 데이터 전처리

앞의 Table 1에서 센서 데이터 중 의미있는 센서 데이터 5종에 대한 약 150초간의 그래프는 Fig. 1과 같다. RPM, 충전공기 압력 및 제어오일 압력은 상호 즉각적인 영향을 받으며 변화하는 것을 확인할 수 있으며, 충전공기 온도와 배기 온도는 엔진의 동작과 연동하여 변화하지만 상대적으로 지연되어 발생하는 것을 알 수 있다. 따라서 본 연구에서는 상호 즉각적인 영향을 받는 RPM, 충전공기 압력 및 제어오일 압력을 주요 특성(feature)으로 선택하여 분석을 수행하였다.

Table 2. The process of the proposed model

Process		Description
Data pre-processing	Feature selection	Selection of Key Features
	Standardization	Standardization of data through Min-Max Scaling
	Time series data construction	Construct time series data with a fixed window size for training the prediction model and distinguish between training and validation datasets
LSTM model	Model architecture	Design an LSTM model consisting of an input layer, LSTM hidden layers, and an output layer. The LSTM hidden layers process the sequence data to predict future RPM values at the output layer
	Model training	Divide the collected data into training and validation datasets to train the model
Anomaly detection	Calculate the difference between predicted and actual values	Use the trained LSTM model to predict RPM values in real-time and compare the predicted values with the actual values
	Set error threshold	Classify as an anomaly if the prediction error exceeds a certain threshold
	Anomaly warning	Issue a real-time warning if an anomaly is detected

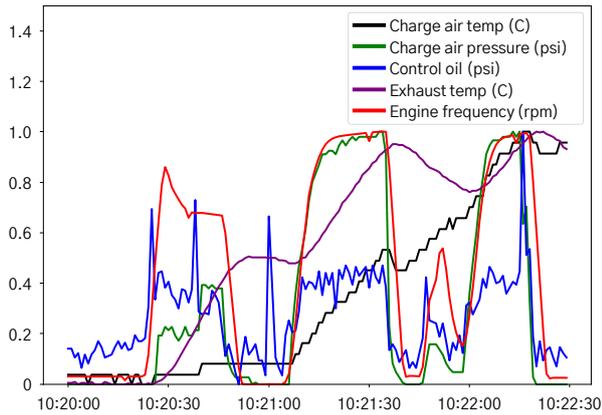


Fig. 1. Five diesel engine sensor data for 150 seconds

RPM, 충전공기 압력 및 제어오일 압력에 대한 전체 데이터 기간의 데이터는 Fig. 2와 같다.

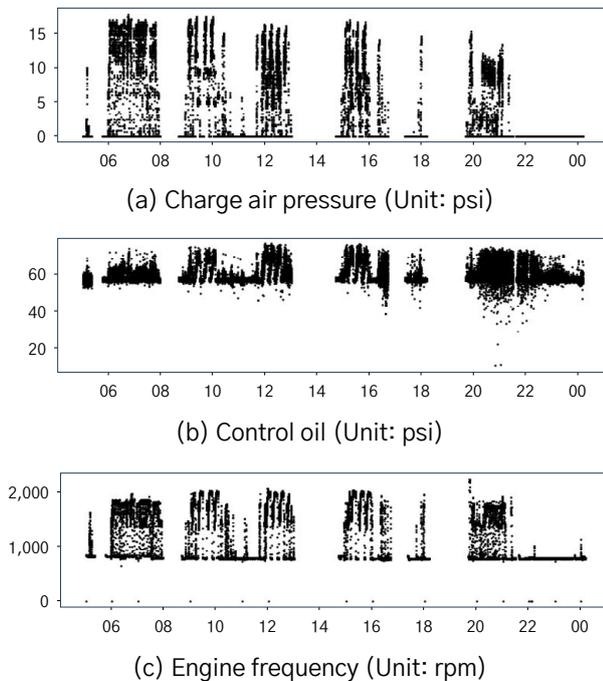


Fig. 2. Three diesel engine sensor data for 18 hours

다음으로 선별된 데이터에 대해서 sklearn 라이브러리의 Min-Max scaler를 통해 모든 데이터를 [0, 1] 범위로 정규화한다. 그 다음 LSTM 알고리즘을 적용하여 과거 10초간의 RPM, 충전공기 압력 및 제어오일 압력을 통해 RPM을 예측하기 위해 정규화된 데이터를 LSTM의 입력 형태인 (10,3) 구조로 구성한다. 이는 10개의 시퀀스 길이와 3개의 특성을 의미한다. 이후 전체 데이터를 학습용(11시간), 검증용(2시간), 예측용(5시간) 데이터셋으로 구분하였다.

4.2.2 LSTM 모델 구축

LSTM 모델은 tensorflow를 사용하여 구현하였으며 LSTM 층은 50개 유닛으로 구분하였고, 활성화 함수로는 ReLU(rectified linear unit)를 적용하였다. 입력 형태는 (10, 3)이고 하나의 dense 층을 추가하여 최종 출력을 RPM 값으로 설정하였다.

모델 학습을 위해 손실 함수로는 평균 제곱 오차(mean squared error, MSE)를 사용하였으며, 최적화 알고리즘으로는 Adam(adaptive moment estimation)을 사용하였다.

4.3 시험 결과

학습 과정에서 손실함수의 변화는 Fig. 3와 같다.

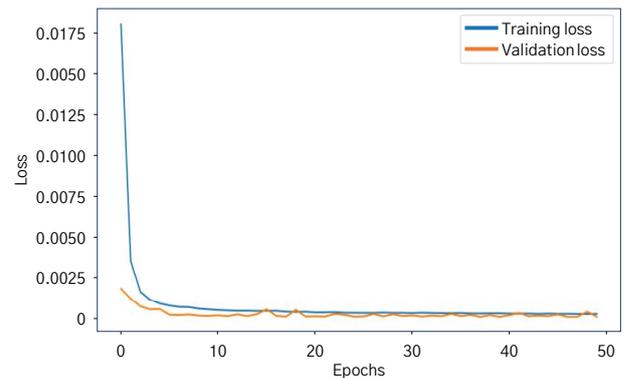


Fig. 3. Training and validation loss over Epochs

LSTM 모델의 예측 성능을 평가한 결과 평균제곱오차(MSE)는 0.00056으로 나타났다.

Fig. 4는 7시부터 11시까지의 충전공기 압력, 제어오일 압력 및 RPM를 나타낸 그래프이고, Fig. 5는 같은 시간대의 RPM 실제값과 예측값을 비교한 그래프이다. Fig. 4에서 보이는 바와 같이 각 센서 데이터 자체로는 특이사항이 없어 보이지만, Fig. 5에 나타난 LSTM을 통한 RPM 예측값에서는 10시경에 예측값이 일반적인 RPM 값의 범위를 크게 벗어난 것을 확인할 수 있다. 이는 과거 10초간의 충전공기압력과 제어오일 압력 및 RPM 값의 패턴이 학습된 기간과는 상이한 패턴이 있었고 그 결과로 LSTM을 통한 RPM 예측값 정상상태와는 다른 값으로 나타난 것으로 보이며, 이 결과는 datasets에 명시된 충전 공기(charge air) shortage가 발생한 시점과 일치한다.

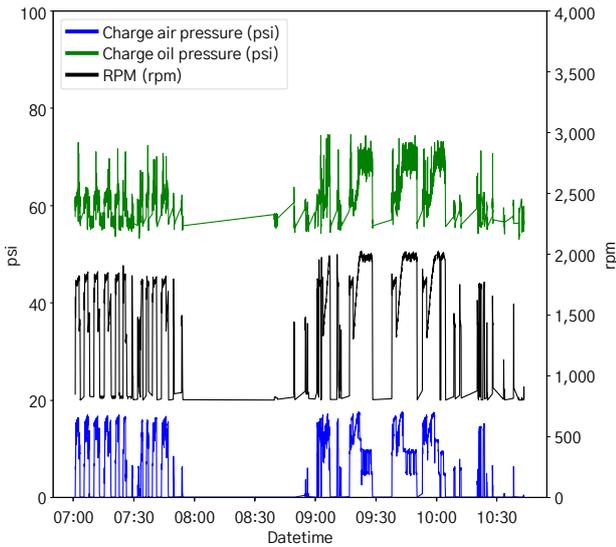


Fig. 4. Charge air pressure, control oil pressure and RPM from 7 AM to 11 AM

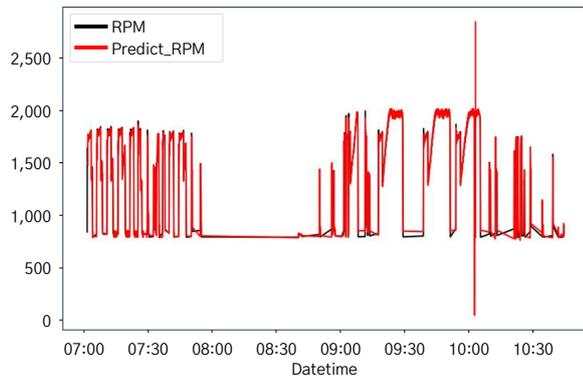


Fig. 5. Actual vs predicted RPM from 7 AM to 11 AM

4.3.1 이상상태 탐지

앞의 결과를 토대로 Fig. 6의 절차를 따라서 LSTM을 통한 RPM의 예측과 실제 값의 차이를 계산하여 디젤엔진의 이상탐지를 수행한다.

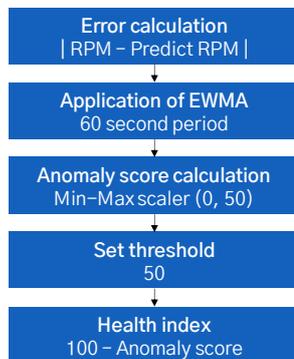


Fig. 6. Anomaly detection process

본 연구에서는 RPM 예측값과 실제값 간 차이의 절대값을 구하고, 단기 변동에 의한 오탐지 최소화 및 추세 파악을 위하여 앞에서 구한 절대값에 대하여 60초 동안의 EWMA(exponential weighted moving average)를 적용하여 급작스런 변동을 최소화 하였다. 또한 학습데이터 기간 동안을 정상상태로 가정하고 이 기간 동안의 EWMA 적용 결과값을 최소-최대값(0, 50)으로 하는 min-max scaler를 적용하여 표준화하여 이상치 점수(anomaly score)를 계산한다.

이상탐지의 기준이 되는 임계치는 실장비에 적용하여 수집한 더 많은 데이터를 토대로 판단할 필요가 있으나 본 연구에서는 50을 기준으로 하였다. 실제 장비에 대한 모니터링 화면 구성 시, 경우에 따라 이상치 점수가 아닌 장비 장비상태지수(health index)를 나타낼 때에는 ‘100-이상치 점수’로 제시할 수도 있다. Fig. 7은 7시부터 11시까지의 이상치 점수를 나타내고 Fig. 8은 장비상태지수를 표현하는 예시 이미지이다. 장비상태지수는 50보다 큰 경우 정상(normal), 50보다 작은 경우 이상(abnormal)로 구분하였다.

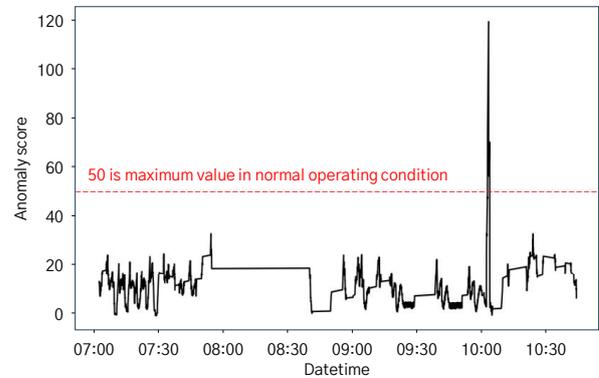
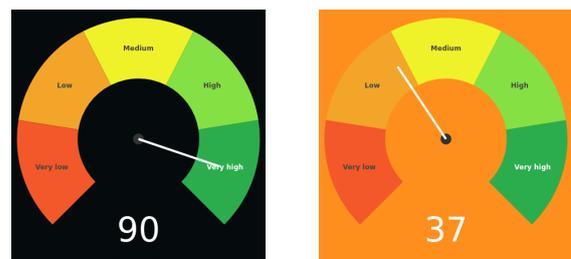


Fig. 7. Anomaly score for diesel engine from 7 AM to 11 AM



(a) Normal

(b) Abnormal

Fig. 8. Example of health index diagram of diesel engine

5. 결론

본 논문에서는 디젤엔진의 온도, 압력, RPM 데이터를 이용하여 LSTM 모델을 통해 미래의 RPM 값을 예측하고, 예측값과 실제값의 차이를 이용해 이상 상태를 탐지하는 방법을 제안하였다. 제안된 알고리즘은 실시간 모니터링 시스템에 적용되어 디젤엔진의 신뢰성을 높이고, 조기에 문제를 발견하여 예방적인 유지보수가 가능하도록 정비정책을 수립하는데 도움이 될 수 있다. 앞으로 실제 함정에서 운용 중인 디젤엔진을 대상으로 센서 데이터와 고장이력에 기반한 연구를 통해 알고리즘의 적합성을 검증하고 정확성을 향상시킬 필요가 있다.

참고문헌

- [1] Raptodimos, Y., Lazakis, I., Using Artificial Neural Network-self-organising Map for Data Clustering of Marine Engine Condition Monitoring Applications, *Ships Offshore Structures.*, 13(6), 649–656, 2018
- [2] Cai, C., Weng, X. & Zhang, C., A Novel Approach for

Marine Diesel Engine Fault Diagnosis, *Cluster Computing*, 20, 1691–1702, 2017

[3] Li, Z., Yan, X., Guo, Z. et al. A New Intelligent Fusion Method of Multi-Dimensional Sensors and Its Application to Tribo-System Fault Diagnosis of Marine Diesel Engines, *Tribology Letters*, 47, 1–15, 2012

[4] Y. Zhan, Z. Shi and M. Liu, The Application of Support Vector Machines (SVM) to Fault Diagnosis of Marine Main Engine Cylinder Cover, *IECON 2007 – 33rd Annual Conference of the IEEE Industrial Electronics Society*, 3018–3022, 2007

[5] Wenkui Xi, Zhixiong Li, Zhe Tian, Zhihe Duan, A Feature Extraction and Visualization Method for Fault Detection of Marine Diesel Engines, *Measurement*, 116, 429–437, 2018

[6] Sang Gu Lee, Sung Woong Kim, Jae Young Lee, Hyeon Ju Jeong, Dong Hun Kang, A Cause Analysis Study on the Abnormal Vibration Characteristics of Diesel Engine Power Transmission System, *Journal of the KNST*, 5(1), 76–83, 2022

[7] Sung-Hyun Kim, A Study of Machine Learning Technique for Noise-based Engine Fault Diagnosis, *Journal of the KNST*, 5(1), 16–19, 2022

[8] Namoano Bernadin, Starr Andrew, Emmanouilidis Christos, Ruiz Carcel Cristobal, *Engines Datasets*, Cranfield Online Research Data (CORD), 2020, Dataset. <https://doi.org/10.17862/cranfield.rd.12378053>