



선박 추진용 2행정 저속엔진의 고장모드 데이터 개발 및 LSTM 알고리즘을 활용한 특성인자 신뢰성 검증연구

박재철¹ · 권혁찬¹ · 김철환² · 장화섭^{1,†}

(사)한국선급 연구본부 디지털기술원 디지털라이제이션팀¹

넥스트엔지니어링²

The Study of Failure Mode Data Development and Feature Parameter's Reliability Verification Using LSTM Algorithm for 2-Stroke Low Speed Engine for Ship's Propulsion

Jae-Cheul Park¹ · Hyuk-Chan Kwon¹ · Chul-Hwan Kim² · Hwa-Sup Jang^{1,†}

Digitalization Team, Digital Technology Center, R&D Division, Korean Register¹

NEXT Engineering²

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

In the 4th industrial revolution, changes in the technological paradigm have had a direct impact on the maintenance system of ships. The 2-stroke low speed engine system integrates with the core equipment required for propulsive power. The Condition Based Management (CBM) is defined as a technology that predictive maintenance methods in existing calendar-based or running time based maintenance systems by monitoring the condition of machinery and diagnosis/prognosis failures. In this study, we have established a framework for CBM technology development on our own, and are engaged in engineering-based failure analysis, data development and management, data feature analysis and pre-processing, and verified the reliability of failure mode DB using LSTM algorithms. We developed various simulated failure mode scenarios for 2-stroke low speed engine and researched to produce data on onshore basis test_beds. The analysis and pre-processing of normal and abnormal status data acquired through failure mode simulation experiment used various Exploratory Data Analysis (EDA) techniques to feature extract not only data on the performance and efficiency of 2-stroke low speed engine but also key feature data using multivariate statistical analysis. In addition, by developing an LSTM classification algorithm, we tried to verify the reliability of various failure mode data with time-series characteristics.

Keywords : 2-stroke low speed engine(2행정 저속엔진), Condition Based Maintenance(상태 기반 유지관리), Maritime autonomous surface ship(자율운항선박), Failure mode DB(고장모드 데이터베이스), Reliability verification(신뢰성 검증), Exploratory data analysis(탐색적 데이터 분석)

1. 서 론

최근 4차 산업시대에 접어들면서 해운-조선 산업에 기술적 패러다임의 변화는 선박의 유지관리 체계에도 직접적인 영향을 미친다. 특히, 선박의 안정적인 운항성능을 확보하고 기관 고장에 대한 예방 및 운영관리의 효율성 측면에서 상태감시 및 진단/예측 기술의 필요성이 크게 주목받고 있다. 상태 기반 유지관리 기술(Condition Based Maintenance, CBM)은 기존의 Calendar

based 또는 Running time based 정비 체계와 달리 기계장치의 상태를 모니터링하고 고장 현상을 진단 및 예측함으로써 선박의 유지관리 방안을 최적화하는 기술로 정의된다. 이로써 선박 관리의 효율성을 제고시킴과 동시에 실시간 정보분석을 통한 사고를 사전에 방지할 수 있을 것으로 기대할 수 있다. 선박 기관시스템은 일반적으로 선박 운항 안전성과 직접적으로 연계되어있는 추진 엔진 및 발전기 엔진의 구성요소이며 해당 시스템에서 고장이 발생 시 선박 감항성에 영향을 미쳐 심각한 해양 사고로 이어질

수 있다. 이에 따라 CBM 기술을 통한 이상징후 탐지 및 유지관리 계획 등이 사전에 체계적으로 수립되어야 한다. 특히, 선박의 기관시스템은 추진동력 및 전력공급에 필요한 핵심 장비가 집약적으로 시스템화되어 있으므로 엔진 시스템 외에도 연료, 윤활유, 냉각수, 흡/배기 등의 공급 및 배출 시스템을 포함하여 전반적인 관리가 필요하다. 실제 선박에서는 체계적이고 계획적인 유지관리 시스템이 운영되고 있다. 이를 Planned Maintenance System이라 칭하며 일정 운전시간 기준으로 예방적 차원에서 점검 및 수리를 진행하고 고장 발생 시에는 본선에서 선박 운항 손실을 최소화할 수 있도록 즉각적인 대응 태세를 유지하고 있다. 아이러니하게도 이러한 관리체계는 데이터의 취득/관리/분석 과정이 부재하므로 정확한 사고원인의 식별과 이를 예방하기 위한 근본적인 원인 규명에 상당한 어려움이 있다. 그럼에도 불구하고 CBM 시스템의 사전적 고장 진단 및 예측이 가능하기 위해서는 AI 알고리즘의 학습과 검증에 필요한 고품질·고신뢰성의 데이터 확보가 필수적이다.

지금까지 산업 분야의 기계장치에 대한 CBM 기술 연구는 다양하게 이루어지고 있다. Byun and Lee, (2022)의 연구에서는 고장에 대한 이해와 특성인자를 선정하기 위하여 시스템의 건전성을 평가하고 발생할 수 있는 고장모드와 해당 시나리오를 설정하였다. 해당 연구는 CBM 기술의 명확한 목표를 수립하고 구체적인 데이터 취득 시스템의 설계를 가능하게 한다. Cho et al. (2022)의 연구에서는 추진역학에 기반한 고장에 민감하게 반응하는 특성인자 도출목표의 연구로서 실제 실험실 규모의 고장모사 실험을 수행하였다. 해당 연구에서는 다양한 데이터를 수집하고 유의미한 특성인자를 관찰하였으나 취득 데이터의 종류가 제한적이고 데이터 신뢰성 검증은 이루어지지 않았다. 또한, Ugo et al. (2018), Bae (2021) 등의 연구에서는 대상 기계장치의 고장 상황을 시뮬레이션 기반으로 모사하고 해당 모델의 신뢰성을 검증하는 연구를 수행하였다. 다만, 시뮬레이션 결과와 실제 기계 시스템과의 현실적 차이를 보완하기 위한 해석적 기법 개발이 보강되어야 한다. 그 외에도 고장 진단 및 알고리즘 개발에 대한 연구는 다양하게 진행되고 있는데 특히, Chae et al. (2021), Kim (2022) 등은 본 연구와 유사한 내연기관 시스템을 대상으로 하였다. 해당 연구에서는 발전기 엔진 및 차량용 엔진에 대한 고장을 사전에 진단하는 방법을 제안하고 있으며 고장관리 상한선을 설정하거나 엔진고장 초도인지 노하우 기반의 특징적 진단 기준을 제안하였다. 다만, 알고리즘 개발 범위는 고장 여부를 판단하는 것에 국한되어 있으며 실제 선박용 엔진이 아닌 육상용 발전기 및 차량용 엔진을 대상으로 함으로써 해상환경 영향인자를 고려하지 못하는 한계가 존재한다. 이와 달리 Kim et al. (2022), Lee (2021), Hwang et al. (2018) 등의 연구에서는 본 논문과 같이 청정기, 펌프 및 공기압축기를 대상으로 선박용 기관 장치를 직접 활용하여 연구를 수행하였으며 다양한 고장모드에 대한 데이터 베이스 생산 및 시계열 운전 데이터의 이상탐지 모델을 개발하였다. 해당 연구에서는 실제 선박용 기관 장치의 정상운전 및 고장모사 데이터를 직접 생산하고 이를 활용한 고장진단 모델을 개발함으로써 연구 성과의 조선·해양산업에 적용 가능성을 검

증하였다. 다만, 본 연구의 선박용 2행정 추진엔진에 대한 연구와 달리 대상장비의 규모와 중요도 등에 차이를 가진다.

본 논문에서는 선박 추진용 2행정 저속엔진을 대상으로 다양한 고장모드 시나리오를 직접 구현함으로써 정상 및 고장 상태의 운전 데이터를 생산하고 해당 데이터의 통계적 특성 분석을 통해 각 고장모드 데이터 간의 차별성을 확인하고자 하였다. 또한, Zhengping (2018) and Benkamin (2021) 등의 연구와 같이 시계열 데이터의 신뢰성 검증을 위하여 시간 흐름을 고려한 RNN 기반의 LSTM 알고리즘을 적용하였으며 학습곡선과 고장분류 성능을 살펴봄으로써 고장모사 데이터의 신뢰성을 검증하고자 하였다.

2. 데이터 생산 및 핵심 특성 추출

2.1 고장 모드 및 데이터 생산실험

본 연구에서는 실제 선박용 2행정 저속엔진을 대상으로 직접 고장을 모사하기에 적합한 항목을 선정하고자 고장수목분석(FTA, Fault Tree Analysis)을 수행하였다. 엔진 성능에 영향을 미치는 상위 요인은 연소 상태(Combustion Condition)와 기계 상태(Mechanical condition)로 구분하고 주로 연소 상태에 영향을 미치는 다양한 하위 요인을 상세하게 분석하였다. 이는 상대적으로 기계 상태의 문제는 해당 부품 또는 장치에 국한되어 고장 현상이 제한되는 경향이 크기 때문이다. 앞서 언급한 고장수목분석을 통하여 식별된 여러 고장 모드는 실제 본선의 엔진 운전 중 고장 빈도가 높거나 엔진 성능에 현저한 영향을 미칠 수 있는 대상으로 선정하였다. 또한, 직접 고장 모사가 가능한지의 고장구현 용이성과 엔진에 무리한 손상을 인가하지 않도록 구현범위를 제한하였다. 다만, 본 논문에서는 선정된 여러 고장모사 시나리오 항목 중 엔진 연소상태에 직접적인 영향을 미치는 일부의 고장 모드(총 4가지)에 한하여 고장모사 엔지니어링, 데이터 특성 분석 및 신뢰성 검증 등에 대해 상세히 다루고자 한다.

선박용 2행정 저속엔진에 대한 고장 데이터 생산연구는 고장모사 시나리오를 기반으로 고장 데이터 생산을 위한 모사 엔지니어링이 정확히 구현되어야 한다. 본 실험의 대상인 엔진은 Fig. 1에 나타난 바와 같이 MAN B&W 社의 6S46MC-C7 모델의 2행정 저속엔진으로 7,400 kW의 출력을 내고 이의 부하를 조절할 수 있는 수동력계(Fuchino CFSR 20.0)가 구축되어 있다. 대상 엔진의 사양은 Table 1에 제시하였다. 육상 테스트 벤치에는 실제 엔진 운용에 필요한 연료유 공급장치, 실린더 및 시스템오일 공급장치, 저온/고온(LT/HT) 냉각수 공급장치 및 냉각쿨러, 시동용 고압 공기 공급 시스템 등의 보조기기가 구축되어 있다. 해당 엔진 시스템을 실제 선박 기관시스템의 운용과 유사한 조건에서 수 시간 이상 기동함으로써 각 고장모드에서의 대용량 데이터를 확보하였다. 이처럼 실제 엔진을 기동하여 데이터를 취득하기 위해서는 사전에 구체적인 실험계획의 수립 및 고장 현상을 정확하게 관찰할 수 있는 모니터링 시스템 구축이 수반된다.



Fig. 1 2-Stroke low speed marine engine

Table 1 Specifications of low speed engine and dynamometer
2-Stroke low speed diesel engine(MAN B&W 6S46MC-C7)

Rating output [kW/rpm]	7,400 / 129
No. of Cyl.-bore × stroke [mm]	6-460 × 1,932
Pmax(designed) [bar]	150
Max. fuel consumption [kg/h]	1,393
Firing order	1-5-3-4-2-6-1
Turbocharger type	TPL73B12
Bearing monitoring system	Kongsberg maritime
Hydraulic dynamometer (Fuchino CFSR 20.0)	
Max. power [kW]	22,741 kW @ 200~400 rpm

본 연구에서는 선박용 2행정 저속엔진의 운전상태를 계측하는 알람 모니터링 시스템(AMS, Alarm Monitoring System) 외에 추가적으로 모든 실린더 내부의 압력정보를 모니터링하는 PMI (Performance Measurement Indicator)와 엔진 기동 시의 여러 위치에 대한 가속도계 센서를 활용한 진동 모니터링 시스템 (VMS, Vibration Monitoring System) 등을 구축하였다. AMS에서 취득하는 데이터는 AI(Analog Input)와 DI(Digital Input) 타입의 총 149개 리스트로 구성되며 이는 시리얼 통신으로 수집된다. 그 외, 각 실린더 내 압력, 타코미터(Tachometer), 연료 공급 유량, 라이너 외벽온도, 배기변(Exh. Spindle) 위치, 연료분사 밸브 압력, 크랭크핀 베어링 & 메인베어링 온도 등을 추가적으로 계측하였고 실린더 상부, 터보 차저(Turbo Charger), 엔진 하부 파운데이션 등의 다양한 위치에서 3축 방향의 진동 정보를 취득하였다. 각 모니터링 시스템의 계측주기(sampling rate)는 Table 2에 나타난 바와 같다.

Table 2 Sampling rate of condition monitoring system

Condition monitoring system	Sampling rate [Hz]	Points
Alarm monitoring system	1.0	149
Performance measurement indicator	30 K	6
Vibration monitoring system	16 K ~ 32 K	13

Table 3 Failure mode of 2-Stroke low speed engine

No.	Normal mode	Abbreviation
1	First normal operation	normal1
2	Second normal operation	normal2
No.	Failure mode	Abbreviation
1	Gas leakage at exhaust valve	exhGasLeak
2	Blocked orifice of exhaust valve	exhValveKnock
3	FIV & Fuel pump leakage	fivDamage
4	Nozzle leakage & Low opening pressure at FIV	fuelOilLeak

본 논문에서 다루는 실험 항목은 총 6종으로 정상 실험 2종과 고장 실험 4종으로 구성되며 Table 3에 제시된 바와 같이 정상 실험의 경우 정상 상태에서의 센서 측정값의 범위를 확인하기 위해 2회 실험을 수행하였고 고장 실험의 경우 엔진의 연소상태에 직접적으로 영향을 미칠 수 있는 고장 모드 4종을 구현하였다. 또한 고장모드 데이터의 비교군으로서 정상운전 데이터를 활용하였으며 엔진 운전조건은 동일하다.

Table 3에 제시된 고장모드를 구현하기 위하여 고장 모사 대상 부품을 선정하고 이에 대한 직접적인 손상을 인가하였다. 이후 손상된 부품을 재조립한 후 엔진의 기동을 시작하여 데이터를 취득하는 방식으로 진행하였다. 고장 모사 시 2행정 저속엔진의 운전조건은 추진엔진의 RPM 및 Load의 변화를 고려하여 수립하였다. Fig. 2에 나타난 바와 같이 Load는 무부하(idle), 25%, 50%, 75%, 85% 및 100% 조건을 단계적으로 상향하며 데이터를 취득한다. 엔진 기동 시작부터 전체 데이터를 모두 계측하고 별도로 각 로드 구간별 안정화 유지 시간(stabilizing period)을 최소 20분 이상 지속한 후 해당 구간에서의 안정화 데이터를 5분 이상 계측하였다. 이는 엔진의 Load 또는 RPM이 설정한 조건에 도달하는 경우, 일정 시간(20분 이상) 동안 안정화 상태를 지속함으로써 외부 변화에 따른 데이터 변동성을 줄이고 고장 요인으로 인한 데이터 변화 특성을 확보하고자 하였다.

2.2 데이터 특성추출 및 신뢰성 검증 기법

본 연구에서는 실제 선박용 2행정 저속엔진을 대상으로 고장




Fig. 2 Running plan of 2-Stroke low speed engine

모드 모사 실험을 통해 대용량의 정상운전 및 고장 모사 운전 데이터를 확보하였다. 해당 데이터를 실시간으로 취득할 때, 분석에 활용할 수 있도록 각종 데이터 형식의 변환, 가속도 데이터의 FFT(Fast Fourier Transform) 연산, 주요 특징 추출 및 데이터 용량 축소 등 다양한 전처리 과정이 수반된다. 특히, 기존 선박 환경에서 사용되는 AMS 데이터(sampling rate: 1Hz)와 달리 PMI 데이터(sampling rate: 30kHz) 및 VMS 데이터(sampling rate: 16~32kHz)의 경우에는 데이터를 로드하고 처리하는데 상당한 컴퓨팅 파워와 시간이 소요되므로 해당 Raw 데이터를 활용한 실시간 성능진단은 현실적으로 불가능에 가깝다. 또한 육상의 선박 관리 측면에서 의사결정을 위한 CBM 데이터의 취득 및 알고리즘 개선 등 운영관리 최적화를 위해서 네트워크 통신을 이용한 육/해상 간의 데이터 교류가 필수적이다. 즉, 선박에서 취득된 상태 정보를 제한된 해상 네트워크 가용성을 고려하여 육상으로 전송하고자 할 때 고장 현상을 최대한 반영해 줄 수 있는 필수적이고 중요한 정보를 추출(또는 재생성)하여 전체 용량을 축소하는 데이터 전처리 과정이 필요하다. 이를 위하여 취득된 고장모드 데이터에 대한 특징 추출기법을 자체적으로 개발함으로써 PMI와 VMS의 계측 데이터를 AMS 데이터와 동일한 계측주기인 1Hz로 특성을 추출하였다.

엔진 운전 시에 PMI를 통해 계측된 압력 데이터는 개별 실린더의 크랭크 각도별 압력 데이터를 나타내는 압력 선도(pressure vs. crank angle curve)를 실시간으로 도식화할 수 있다. 해당 압력 선도의 각 구간별 특성인자 6종을 도출하는 수식을 개발하였으며 이는 Table 4에 제시한 바와 같다. 압력 선도의 1) 최대폭 발압력, 2) 폭발압력면적, 3) 연료분사와 Pmax 시점의 Crank 각도 차이, 4) 연료분사와 Pmax 시점의 압력 차이, 5) 연료분사와 Pmax 시점의 기울기, 6) Pmax에서 BDC (Bottom Dead Center) 간 압력선도의 곡률 등이다. 해당 특성인자를 추출하는 수식을 통해 전처리 코드에서 30kHz의 실린더 내부압력 데이터를 1Hz 주기로 특성 추출하여 데이터 프레임을 다시 생성한다. 이처럼 대용량의 데이터에서 특성추출을 통한 용량 축소는 데이터 핸들링이 용이하고 연산속도를 증대시킴과 동시에 알고리즘의 성능을 개선하는 효과를 가져올 수 있다.

Table 4 Feature parameters of each Cyl. pressure data (PMI)

No.	Feature parameter	Description
1	Pmax	$\frac{1}{N} \sum_{i=1}^N P_i$ (N : number of samples in the range of $\pm 1^\circ$ at Pmax angle)
2	PI_comb	$\int_{TDC-180^\circ}^{TDC+180^\circ} P d\theta$ (Compression-Expansion area of crank angle-pressure graph)
3	$\Delta\theta_{injection, to Pmax}$	$ \theta_{P=Pmax} - \theta_{P=P_{fuelinjection}} $
4	$\Delta P_{injection, to Pmax}$	$ P_{max} - P_{fuelinjection} $
5	Slope	$\Delta P_{injection to Pmax} / \Delta\theta_{injection to Pmax}$
6	Curv_nearEVO	Curvature of P _{max} to BDC

Table 5는 VMS를 통해 계측된 진동 데이터의 시간 영역 및 주파수 영역 내 다양한 특성인자를 나타낸 것이다. 진동 데이터에서 추출한 특성인자는 1) 진동 신호의 최대값(MAX), 2) 분산 제곱근(standard deviation), 3) 에너지 값(RMS), 4) RMS 값 대비 피크값(crest factor) 등의 시간영역 특성인자와 5) 진동신호 주파수의 중앙성분(frequency center), 6) 주파수의 variance 값(root variance frequency) 등의 주파수 영역 인자이며 이를 1Hz 주기로 추출하여 통계분석 및 고장 진단 알고리즘의 입력값으로 활용하였다.

상기 특성인자 12종에 대하여 기본적인 통계수치를 도출하여 비교·분석함으로써 데이터가 가지는 특성을 우선 검토하였다. 또한 LSTM(Long Short-Term Memory) 알고리즘을 활용하여 데이터의 차별성과 신뢰성을 검토하고자 하였다. RNN(Recurrent Neural Network) 계열의 LSTM 알고리즘은 시계열 자료처리에 특화되어 있다. 기존의 RNN은 정보와 정보 사이의 거리가 멀면 초기 가중치(weight) 값이 유지되지 않아 학습 능력이 저하되는 가중치 소실 문제(gradient vanishing problem)가 발생한다. Table 6에 제시된 바와 같이 LSTM 알고리즘은 반복 모듈을 가지고 있으며 4개의 상호작용하는 gate layer로 구성되어 있다. 이는 neural network 모듈을 반복시키는 체인과 같은 형태로 cell state에 흐르는 정보를 제어하는 gate layer의 각 기능이 핵심 사항이다. LSTM의 구조는 과거의 정보를 잊기 위한 forget gate (f_t), 이전 상태와 입력데이터를 다음 상태에 전달하는 input gate(i_t), i_t 와 f_t 를 다음 상태의 정보를 업데이트하는 cell state 그리고 이전 상태와 입력값, f_t 를 고려한 출력값을 다음 상태에 전달하는 output gate로 구성되어 있다.





본 논문에서는 선박용 2행정 저속엔진을 활용하여 고장모드 시나리오를 직접 구현함으로써 4종 이상의 고장모드 데이터를 생산하였다. 생산된 데이터를 대상으로 자체적으로 개발한 수식

Table 5 Feature parameters of vibration data (VMS)

No.	Domain	Feature parameter	Description
1	Time	Maximum	Largest value of the function, either within a given range
2		Standard deviation	$\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
3		Root mean square	$\sqrt{\frac{1}{n} (x_1^2 + x_2^2 + \dots + x_n^2)}$
4		Crest factor	$\frac{ x_{peak} }{x_s}$
5	Frequency	Frequency center	$\frac{\int f \times s(f) df}{\int s(f) df}$
6		Root variance frequency	$\left[\frac{\int (f - FC)^2 \times s(f) df}{\int s(f) df} \right]^{\frac{1}{2}}$

$$s(f) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} dt$$

Table 6 Structure of gate layer & equations of LSTM

Gate	Structure	Equation
Forget		$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$
Input		$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$ $\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$
Cell state		$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$
Output		$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$ $h_t = o_t * \tanh(C_t)$

σ : activation function, W_f : weight of f_t , h_t : new output
 x_t : current input, b : bias, W_o : weight of o_t

기반의 12가지 feature 데이터를 통해 통계분석 및 LSTM 기법을 적용한 차별성 및 신뢰성을 식별·검증하는 연구를 수행하였다.

3. 고장 모드 구현기법 및 데이터 분석

3.1 Failure mode 1. Gas Leakage at Exhaust Valve

Fig. 3에 나타난 바와 같이 선박 2행정 저속엔진의 각 실린더 커버에 설치된 배기밸브(exhaust valve)는 개폐를 통해 배기가스가 리시버로 전달되는데 배기밸브 하부에 설치된 bottom piece와 spindle은 서로 metal contact을 통해 기밀을 유지한다. 즉, 배기밸브 시트면의 건전성은 배기가스의 기밀능력과 밀접한 관계가 있다. 만일, 배기밸브 시트면이 손상되면 배기밸브가 닫혔을 때 완벽히 기밀된 상태로 폐워된 연소실을 구성하지 못하게 되므로 연소실의 압축 및 폭발과정에서 연소실 내부가스가 원치




Fig. 3 Cross-section of exhaust valve

않는 시점에 누설이 되고 이로 인해 연소실 내부 압력의 변화 및 연소가스 온도의 변화가 관찰될 것으로 예상된다.

Fig. 4는 배기밸브 손상을 구현하기 위하여 실제 bottom piece의 시트면에 leakage groove를 가공한 사진을 나타낸 것이다. leakage groove는 폭 10mm, 깊이 1mm의 크기로 bottom piece의 총 4곳(Exh. & Cam & Fore & Aft side)에 가공하여 누설을 유발하도록 하였다. 해당 고장 모드에서 주요한 변동이 관찰될 수 있는 센서 항목은 PMI 센서, Exh. gas temp. 센서 등으로 정상 상태와 고장 모드에서의 정량적인 데이터 경향 차이는 Table 7에 나타난 바와 같다.

Table 7은 Gas leak at exhaust valve 고장모드의 주요 관찰 파라미터에 대한 정상과 비정상 상태에서의 Load 별 계측값을 비교한 것이다. Pmax의 경우 연소실 내부가 배기밸브의 시트면의 불완전한 기밀로 인해 완벽히 폐워된 공간을 구성하지 못하므로 예상대로 Abnormal Fluctuation(이하, AF)이 Normal Error Range Avg.(이하, NERA) 영역보다 음의 방향으로 벗어나는 경향을 보인다. PLcomb 또한 같은 이유로 AF가 NERA 영역보다 음의 방향으로 벗어나는 경향을 보인다. Exh. Gas Out Temp.의 경우 AF는 NERA 영역보다 양의 방향으로 벗어나는 경향을 보이는데 이는 완전 연소되지 않은 연소가스가 연소 중에 새어나와 연소실 외부의 온도센서 근처에서 연소가 이루어짐에 따라 배기





Fig. 4 Failure mode engineering of Exh. valve leakage

Table 7 Comparison of mean value difference for exhGasLeak mode

Failure mode : Gas leak at exhaust valve (Mean value)										
Condition	In process of load-up					In process of load-down				
	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	76.7	101.9	133.1	142.3	153.4	75.8	102.0	133.1	142.2	153.4
Normal2	76.2	102.9	131.4	144.1	153.2	76.1	103.0	134.0	144.3	153.2

P M I	Pmax - exhGasLeak_Cylinder 4					Pmax - exhGasLeak_Cylinder 4				
	Percent					Percent				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
	-1.31	-2.15	-1.66	-1.96	-1.04	-1.05	-2.34	-1.72	-1.89	-1.04

Table 7 Continued



* Normal Mean Value Average(NMVA) = Nor.1 Mean & Nor.2 Mean의 평균값
 * Abnormal Fluctuation(AF) = (Abn. Mean Value - NMVA) / NMVA * 100
 * Normal Error Range(NER) = |Nor.1 Mean - Nor.2 Mean| / NMVA * 100
 * Normal Error Range Average(NERA) = (NER25 + NER50 + NER75 + NER85 + NER100) / 5

가스의 온도가 상승하는 것으로 판단된다. 그럼에도 불구하고 단 변량의 사후 데이터 변화양상으로만 해당 고장모드를 정확하게 진단하기에는 어려움이 따르므로 AI 기반 고장분류 알고리즘의 검증이 요구된다.

3.2 Failure mode 2.

Blocked orifice of exhaust valve

Fig. 5는 배기밸브의 미개방 혹은 개방지연에 따른 배기밸브 노킹(knocking) 현상을 구현하기 위하여 orifice 기능불량 모사 방법을 나타낸 것이다. 배기밸브의 작동은 액추에이터(actuator)에서 캠(cam)에 의해 만들어진 오일의 압력에 의해 이루어진다. 오일내 기포는 orifice의 흡을 통해서 계속해서 제거되며 만일, 흡이 폐색되면 기포가 배출되지 않아 배기밸브 spindle과 bottom piece가 부딪히는 knocking 현상이 발생하게 된다. 해당 고장모드는 배기밸브 knocking 현상의 주원인인 orifice 폐색을 모사하




Fig. 5 Failure mode engineering of blocked orifice of Exh. valve

기 위하여 기존의 orifice를 취외한 후 blind steel plate를 넣고 다시 orifice를 체결하는 방식으로 구현하였다.

Table 8은 blocked orifice of exhaust valve 고장 모드의 주요 관찰 파라미터에 대한 정상과 비정상 상태에서의 load 별 계측값을 비교한 것이다. 해당 고장 모드는 엔진 운전 컨디션으로 고장 현상이 나타나기보다는 노킹현상으로 인한 물리적 진동이 주로 발생하므로 VMS 데이터를 주요 관찰 파라미터로 선정하였다. 시간 영역의 MAX와 주파수 영역의 frequency center의 경우 AF가 NERA 영역보다 수평 진동에서는 음의 방향으로, 수직 진동에서는 양의 방향으로 벗어나는 경향을 보인다. 이는 노킹 현상이 일어날 때 수직 진동이 강해지면서 상대적으로 수평 진동이 약해지는 것으로 사료된다. Root Variance Frequency의 경우

Table 8 Comparison of mean value difference for exh-ValveKnock mode




Table 8 Continued

Failure mode : Blocked orifice of exhaust valve (Mean value)										
Load	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	5949	5462	5407	5397	5377	5126	4822	4968	5031	5055
Normal2	5876	5527	5427	5386	5361	5194	4825	4865	4863	4533

Load	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	1868	1971	1983	1959	1984	2218	2341	2387	2387	2432
Normal2	1952	2050	2061	2030	2050	2479	2548	2550	2535	2673

Load	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	1868	1971	1983	1959	1984	2218	2341	2387	2387	2432
Normal2	1952	2050	2061	2030	2050	2479	2548	2550	2535	2673

* Normal Mean Value Average(NMVA) = Nor.1 Mean & Nor.2 Mean의 평균값
 * Abnormal Fluctuation(AF) = (Abn. Mean Value - NMVA) / NMVA * 100
 * Normal Error Range(NER) = |Nor.1 Mean - Nor.2 Mean| / NMVA * 100
 * Normal Error Range Average(NERA) = (NER25 + NER50 + NER75 + NER85 + NER100) / 5

로드가 증가하면서 수평 및 수직 진동 모두 AF가 NERA 영역보다 음의 방향으로 벗어나는 경향을 보이는데 로드 높아질수록 노킹 현상이 일어날 때의 진동이 커지면서 주파수 영역에서의 이상치가 증대되는 것으로 판단된다. 이 또한 단변량의 사후 데이터 변화양상을 독립적으로 활용하여 고장 진단하는 것은 정확도가 높지 못하므로 SI 기반 고장 분류 알고리즘을 활용한 검증이 필요하다.

3.3 Failure mode 3.

Fuel Injection Valve (FIV) & fuel pump leakage

Fig. 6은 fuel injection system의 fuel injection valve 및 fuel pump의 고장모드 엔지니어링을 구현한 것이다. FIV 내부의 non-return valve는 엔진 정지 중 FIV 내부에 연료를 순환시켜




Fig. 6 Failure mode engineering of FIV & fuel pump leakage

Table 9 Open & close pressure setting value of non-return valve







Diagram	Setting value	
	opening pressure	26 bar
	closing pressure	15 bar

주기 위해 설치되어 있다. Table 9에 제시된 바와 같이 연료펌프 토출압력이 대략 15bar가 될 때까지는 non-return valve가 개방되어 연료가 순환하고 그 이상으로 압력이 상승 시에는 닫혀 연료 순환을 제어한다. 이는 엔진 정지 중 FIV 내부에 HFO(Heavy Fuel Oil)와 같은 고점도 연료가 응고되어 엔진 기동이 불가능한 상태를 방지하기 위해서이다. 해당 고장모드의 목적은 non-return valve 및 fuel pump에서 leakage가 발생하여 실제 연료유 분사량이 저하되었을 때 엔진 성능의 변화를 관찰하기 위함이다.

Fuel pump는 barrel과 plunger의 조합으로 연료분사에 필요한 압력을 형성하는데 연료유의 이물질 또는 낮은 황 함유량 및 점도의 영향으로 barrel과 plunger 사이 미찰면 마모가 발생할 수 있으며, 마모 발생 시 clearance의 증가로 누유가 일어나게 된다. 아울러, 실제 연료 분사량 또한 감소할 수 있다. 본 연구에서는 상기 현상을 구현하기 위하여 fuel pump의 suction valve 내부 시트면에 홈을 가공하여 누유가 발생하도록 하였다.

Table 10은 FIV & fuel pump leakage 고장 모드의 주요 관찰 파라미터에 대한 정상과 비정상 상태에서의 Load 및 실린더별 계측값을 비교한 것이다. 해당 고장모드는 앞서 소개한 바와 같이 2가지의 고장구현 기법을 고안하여 Cyl. 1은 FIV의 non-

Table 10 Comparison of mean value difference for fivDamage mode

Failure mode : FIV & fuel pump leakage (Mean value)											
Condition		Cyl.1 FIV internal leakage					Cyl.4 Fuel pump internal Leakage				
Load		Mean value per load					Mean value per load				
		25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1		77.4	101.9	135.9	146.9	159.0	76.7	101.9	133.1	142.3	153.4
Normal2		77.3	102.5	134.8	149.4	158.4	76.2	102.9	131.4	144.1	153.2
P MI	Pmax										
		Mean value per load					Mean value per load				
Load		25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1		3640	5520	8105	8737	9804	3611	5470	7577	8240	9279
Normal2		3640	5557	8153	8902	9982	3596	5516	7495	8385	9441
P MI	PI_comb										
		Mean value per load					Mean value per load				
Load		25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1		290	325	334	338	363	279	316	323	330	352
Normal2		284	314	328	336	364	274	309	322	332	354
AMS	Exh gas out temp.										
		Mean value per load					Mean value per load				
Load		25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1		290	325	334	338	363	279	316	323	330	352
Normal2		284	314	328	336	364	274	309	322	332	354

* Normal Mean Value Average (NMVA) = Nor.1 Mean & Nor.2 Mean의 평균값
 * Abnormal Fluctuation (AF) = (Abn. Mean Value - NMVA) / NMVA * 100
 * Normal Error Range (NER) = |Nor.1 Mean - Nor.2 Mean| / NMVA * 100
 * Normal Error Range Average(NERA) = (NER25 + NER50 + NER75 + NER85 + NER100) / 5

return valve leakage, Cyl. 4는 fuel pump의 suction valve 내부 시트면 leakage를 각각 구현하였다. 해당 고장모사 실험을 통해서 각기 다른 고장원인으로 동일한 연료분사량 저하 현상을 구현하여 데이터 변동의 양상과 차이를 관찰할 수 있다. 해당 고장 모드에서 Pmax와 PI_comb는 Cyl. 1의 FIV, Cyl. 4의 Fuel pump 고장이 동일하게 AF가 NERA 영역에서 음의 방향으로 벗어나는 경향을 보인다. 그 이유는 예상대로 연료 분사량이 정상 모드와 비교하여 감소하였기 때문이라고 보여진다. 다만, 엔진 로드가 점점 상승할수록 NERA 영역에서 벗어난 정도가 비교적 적어지는 것을 관찰할 수 있다. Exh Gas Out Temp.는 Cyl. 4의 Fuel pump 고장의 경우 AF가 NERA 영역에서 음의 방향으로 확실하게 벗어난 것을 확인할 수 있는 반면에 Cyl. 1의 FIV 고장의 경우 AF가 다소 불규칙하게 NERA 영역에서 아래 위로 움직이는 것이 관찰된다. 이는 FIV의 내부 누설은 엔진의 낮은 로드보다는 높은 로드에서 확실히 일어나는 반면에 Fuel pump의 내부 누설은 FIV와는 달리 엔진 로드 전구간에서 연료 분사량이 정상 상태에 비하여 감소되고 있다고 판단된다.

3.4 Failure mode 4.

Nozzle leakage & low opening pressure at FIV

Table 11에 나타낸 바와 같이 2행정 저속엔진은 직분사 디젤 엔진으로 fuel pump에서 형성된 고압의 연료유를 FIV 노즐 끝단의 작은 홀을 통해 무화된 상태로 분사한다. 실린더 내 연소상태는 FIV의 무화성능과 밀접한 관계가 있으며 무화성능의 저하는 불완전 연소를 일으키게 한다. 건전한 무화성능을 보장하기 위해서는 올바른 opening pressure setting이 중요하므로 FIV 밸브 내부의 spring이 특정 압력 이상에서 연료유를 분사하여야 한다.

다음의 Fig. 7에 나타낸 바와 같이 fuel pump의 특성상 연료 분사 압력은 최종 분사 압력까지 아날로그 식으로 증가하게 되며 최소한의 필요한 무화성능을 얻을 수 있도록 opening pressure 이상에서 실질적인 연료분사가 이루어지게 셋팅되어 있다.

Fig. 8은 FIV의 구조와 노즐의 형상을 나타낸 것으로 일반적인 엔진 운전 중 과도한 열부하 또는 연료유의 이물질로 인하여 노즐 홀이 확공되는 문제가 운전 중 발생하게 된다. 본 연구에서는 동일한 고장모드인 연료 분사압력 저하 현상을 2가지 고장구현 기법을 선정하여 Cyl. 1과 Cyl. 4에 각각 구현하였다. 엔진의 각 실린더에는 FIV가 fore side와 after side에 설치되어 있

Table 11 Specification of fuel injection valve

Type		5125853-3×105			
Opening pressure		350 + 30 bar			
Spec.	Hole No.	1	2	3	4
	Dia. of hole [mm]	1.05	1.05	1.05	1.05
	Vertical angle	29	19	14	12
	Horizontal angle	-4	10	28	46




Fig. 7 Diagram of fuel injection pressure and range




Fig. 8 FIV structure and shape of nozzle




Fig. 9 Failure mode engineering of fuel oil leakage

으며 본 실험에서는 Cyl. 1 fore side에 위치한 FIV를 Fig. 9(a)에 나타난 바와 같이 nozzle cut-off shaft의 표시부분에 scratch를 만들어 leakage를 모사하였다. 두 번째 고장모사 기법은 Fig. 9(b)에 나타난 바와 같이 Cyl. 4에 대해 fore 및 after side FIV의 thrust spindle 자체를 기존 치수 6.85mm에서 5.04mm로 줄이고

Table 12 Comparison of fuel injection pressure setting

No. of Cyl.		Cyl. 1		Cyl. 4	
FIV Position		Fore side	After side	Fore side	After side
Nor.	Opening pressure	346 bar	338 bar	330 bar	323 bar
Abn.		Unmeasurable	376bar	150 bar	170 bar
Nor.	Leakage	No	No	No	No
Abn.		Leak over 20 bar	No	No	No

샤프트 측 R 가공 및 모서리 45° 모따기를 하여 최종 opening pressure를 170bar로 세팅하였다. 이로써 각 실린더 FIV의 opening pressure를 Table 12와 같이 분사되도록 고장 모사를 구현하였다. 해당 고장모드에서 주요 관찰 파라미터는 실린더 연소실 압력(Pmax, Pcom 등), Exh. gas out temp., fuel index, Cyl. liner wall temp., Jacket cooling water outlet temp., Piston cooling oil outlet temp. 등으로 앞서 3.3의 Fuel Injection Valve (FIV) & fuel pump leakage 고장모드와 유사한 파라미터가 연관성이 높을 것으로 예상되었다. 다만, 연료유 무화 불량 또는 50% 이하의 낮은 부하에서의 연소실 불완전 연소에 미치는 영향에 대한 차이를 확인할 수 있었다.

Table 13은 nozzle leakage & low opening pressure at FIV 고장 모드의 주요 관찰 파라미터에 대한 정상과 비정상 상태에서의 Load 및 실린더별 계측값을 비교한 것이다. Pmax의 경우는 불완전 연소됨에 따라 소폭 상승할 것으로 예상하였으나 Cyl. 1의 Nozzle 고장은 대체적으로 AF가 NERA 영역에서 음의 방향으로 벗어나는 경향을 보였고(50% 로드 제외) Cyl. 4의 FIV 고장은 AF가 NERA 영역에서 양의 방향, 음의 방향 또는 정상 범위에 속하는 등 불규칙한 상태가 관찰되었다. 이로 인해 연료유 분사 시 무화 성능에 좀 더 직접적인 영향을 주는 고장은 Cyl. 1의 Nozzle 고장으로 판단된다. Pl_comb는 Cyl. 1의 Nozzle 고장의 경우, AF가 NERA 영역에서 음의 방향으로 벗어나는 경향을 나타내고 Cyl. 4의 FIV 고장은 AF가 NERA 영역에서 양의 방향으로 벗어나는 경향을 나타낸다. 그 이유는 Cyl. 1 Nozzle 고장의 경우는 20bar 이상부터 연료유의 누유가 시작되므로 실제 분사 시점에서 분사되는 연료유의 총량이 적어지는 현상이 일어나는 것으로 판단된다. Cyl. 4 FIV 고장의 경우는 Cyl. 1과는 달리 연료 분사 시 무화불량으로 인해 소폭 상승하는 것으로 나타나지만 엔진 로드가 상승하면서 AF가 정상 범위로 다시 들어오는 것을 확인할 수 있다. Exh Gas Out Temp.는 Cyl. 1 Nozzle 고장과 Cyl. 4 FIV 고장이 정반대의 양상을 나타내는데 이는 앞서 같은 이유인 Cyl. 1은 연료유가 누유되므로 분사 시 무화되는 연료유가 부족하여 배기가스 온도가 감소하며 Cyl. 4는 분사되는 연료유 양은 충분하지만 분사 시 무화상태가 불량하여 불완전 연소가 일어남에 따라 배기가스 온도가 상승하는 것으로 판단된다. 다만 두 경우 모두 엔진 로드가 상승하면서 그 양상은 완화되는 현상이 관찰되었다.

Table 13 Comparison of mean value difference for fuelOilLeak mode

Failure mode : Nozzle leakage & Low opening pressure at FIV
(Mean value)

Condition	Cyl.1 Nozzle external leakage					Cyl.4 Low opening pressure of FIV				
Load	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	77.4	101.9	135.9	146.9	159.0	76.7	101.9	133.1	142.3	153.4
Normal2	77.3	102.5	134.8	149.4	158.4	76.2	102.9	131.4	144.1	153.2
P MI	Pmax - fuelOilLeak_Cylinder 1					Pmax - fuelOilLeak_Cylinder 4				
P Comb	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	3640	5520	8105	8737	9804	3611	5470	7577	8240	9279
Normal2	3640	5557	8153	8902	9982	3596	5516	7495	8385	9441
P Comb	Pcomb - fuelOilLeak_Cylinder 1					Pcomb - fuelOilLeak_Cylinder 4				
AMS	Mean value per load					Mean value per load				
	25%	50%	75%	85%	100%	25%	50%	75%	85%	100%
Normal1	290	325	334	338	363	279	316	323	330	352
Normal2	284	314	328	336	364	274	309	322	332	354
AMS	ExhGas - fuelOilLeak_Cylinder 1					ExhGas - fuelOilLeak_Cylinder 4				

※ Normal Mean Value Average (NMVA) = Nor.1 Mean & Nor.2 Mean의 평균값
 ※ Abnormal Fluctuation (AF) = (Abn. Mean Value - NMVA) / NMVA * 100
 ※ Normal Error Range (NER) = |Nor.1 Mean - Nor.2 Mean| / NMVA * 100
 ※ Normal Error Range Average (NERA) = (NER25 + NER50 + NER75 + NER85 + NER100) / 5

이처럼 본 연구에서 구현된 4종의 고장모드 데이터에 대한 통계분석 결과, 독립적 단별량 변수에 한해 뚜렷한 경향을 보이고 기존 엔지니어링 지식과 유사하였다. 그러나 시계열적인 다변량 데이터 간의 유기적인 상관성 및 추세가 반영된 데이터 차별성은 AI 알고리즘을 활용한 검증이 요구된다.

4. 데이터 신뢰성 평가


4.1 특성인자 데이터 비교 및 t 검증

상태 모니터링 시스템은 PMI 및 VMS로 계속된 데이터의 계속 주기는 각각 50kHz, 16~32kHz로 상당한 양의 데이터를 취득할 수 있다. 해당 데이터를 상기 Table 5에 제시된 바와 같이 엔지니어링 지식에 기반한 특성을 추출하여 1Hz 주기로 축소하여 데이터 핸들링을 용이하게 하고 분석/처리 시간을 단축시키고자 하였다. 이러한 데이터 특성인자 추출은 raw data로부터 고장모드와 연관된 유용한 정보를 취득하거나 재생성함으로써 효율적인 분석이 가능하게 하는 기술이다. 그러나 여기서 중요한 사항은 필요한 정보의 손실을 최소화하여 차원을 축소하되 데이터의 완결성은 유지하여야 한다는 것이다.


본 연구에서는 실린더 내 연소 시의 크랭크 각도별 압력 데이터를 나타내는 압력 선도(pressure vs. crank angle curve)와 진동 원신호의 time domain과 FFT 변환 데이터의 frequency domain 기반 추출 데이터 등 총 12가지의 특성인자에 대한 고장모드 별 통계적 차이가 있는지 유의성(statistical significance)을 확인하고자 하였다.

Fig. 10은 PMI의 특성인자를 각 고장모드 별 mean value를 비교한 것이다. 각 특성인자는 원신호의 단위 및 범위의 차이를 줄이고 다차원 값들의 비교분석이 용이하도록 Scikit-Learn의 StandardScaler를 적용하였다. StandardScaler는 데이터의 평균과 표준편차를 사용하는데 평균을 제거하고 데이터를 단위 분산으로 조정한다. 또한, 이상치를 사전에 제거하여 데이터의 확산에 영향이 발생하지 않도록 하였다. Fig. 10(a)와 (b)는 Cyl. 1와 Cyl. 4의 PMI 특성인자의 표준편차와 t-test 유의확률(p-value) 값을 비교한 것이다. Fig. 9(a)와 (b)에 제시된 바와 같이 각 고장모드와 정상 데이터 간 표준화된 가우시안(Gaussian) 정규분포의 평균과 분산의 차이를 관찰할 수 있다. 개별 고장모드에서 각 특성인자의 분산 경향 또한, Cyl. 1번과 Cyl. 4번 모두에서 다름을 확인할 수 있다. Fig. 10(c)를 살펴보면 표준오차와 표본평균 사이의 비율에 따른 t 값의 귀무가설을 기각할 수 있는 (p-value < 0.05) 각 고장모드의 PMI 특성인자는 소수에 국한된다. 모든 조건을 비교한 All failure mode(정상 및 고장모드 총 5가지 label)에서는 Slope와 $\Delta P_{injec. to Pmax}$, exhGasLeak과 정상모드에서는 Curv_nearEVO 특성인자가 귀무가설을 수용하는 것을 확인할 수 있다.


Fig. 11은 Cyl. 1에 설치된 Ch. 1(horizontal Dir.) & Ch. 2(vertical Dir.) VMS의 특성인자에 대한 표준편차와 t-test 유의




(a) Comparison of std for PMI feature data (Cyl. 1)




(a) Comparison of std for VMS feature data (Cyl. 1)



(b) Comparison of std for PMI feature data (Cyl. 4)




(b) Comparison of std for VMS feature data (Cyl. 2)



(c) Comparison of p-value (t-test)

Fig. 10 Comparison of PMI data for each failure mode



(c) Comparison of p-value (t-test) for VMS feature data

Fig. 11 Comparison of VMS data for each failure mode

확률(p 값, p -value) 값을 비교한 것이다. Fig. 11(a)와 (b)의 진동 특성인자 표준편차의 경향을 살펴보면, ch. 1_rvf 인자가 fivDamage vs. normal, fuelOilLeak vs. normal에서 유사하고 ch. 2_ch 및 ch. 2_rvf 인자는 exhGasLeak vs. normal, fuelOilLeak vs. normal에서 유사한 경향을 나타내고 있다. 이는 Fig. 11(c)의 t-test에서도 해당 특성인자만 귀무가설을 수용하는 결과를 확인할 수 있다. 본 연구에서 개발한 특성인자 추출 데이터는 통계분석 시에 각 고장모드에서 유사한 경향을 보이지만, t-test 결과에서는 대부분의 특성인자가 두 집단 또는 다중

집단 간의 평균 차이가 유의미하여 귀무가설을 수용하는 것을 확인할 수 있다. 따라서 데이터의 완결성을 유지함은 물론 고장 진단 알고리즘의 효율성과 정확성을 높이기 적합한 것으로 판단된다.

4.2 LSTM 기반 고장 데이터 신뢰성 평가

본 절에서는 고장 모사 실험을 통해 생산하고 특징 추출 과정을 거친 데이터를 대상으로 LSTM 알고리즘을 활용하여 고장별




Fig. 12 Multivariate time series data input & training data split




Fig. 13 Sliding window method

로 구분되는 고유한 특징을 내재하고 있는지 실험하였다. 본 모델링 실험은 분류 알고리즘을 개발하기 위한 실험이 아니므로 하이퍼파라미터의 파인튜닝을 하지 않고 적용 대상 데이터(AMS, PMI, VMS)의 학습 조건은 동일하게 적용했다.

Fig. 12는 센서의 다변량 시계열 데이터를 Train Set과 Test Set으로 분할하여 모델의 Input Data로 활용하는 것을 시각화하였다. 이때 Input 시계열 데이터의 시간적 속성을 맥락적으로 보존하기 위해 데이터를 랜덤하게 섞으면서 분할하지 않고 시간상으로 과거의 데이터를 Train Set, 미래의 데이터를 Test Set으로 하는 Time Series Split을 적용하였다. Fig. 13은 Window Sliding 기법에 대해 도식화한 것이며 이는 모델에 단위 시간당 한 시점의 데이터가 아니라 설정한 구간의 데이터를 입력하기 위해 적용한 기법이다. 기관 고장의 데이터는 특정 시점에 순간적으로 특징이 나타나는 고장도 있지만 시간의 흐름에 따라 서서히 특징이 나타나는 고장도 존재한다. 따라서 Point-anomaly와 Context-anomaly를 함께 고려하는 데는 Window Sliding 기법을 적용하는 것이 효과적일 것으로 판단하였다. Table 14는 LSTM 모델 학습 실험에 사용된 데이터와 모델의 기본적인 정보를 나타낸다. 입력 데이터 정보를 보면 AMS, PMI, VMS, All(AMS & PMI & VMS)의 데이터의 크기와 차원을 제시하였고 모델 정보에는 실험에 사용된 모델의 구조와 그에 따른 총 파라미터를 기술하였다. 하이퍼 파라미터 정보는 별도의 파인튜닝 과정을 통해서 설정한 값은 아니며 일반적으로 많이 사용하거나 임의 설정을 통해서 정했으며 모든 실험에 동일하게 적용하였다.

앞서 Table 3을 참고하면 LSTM 모델 학습에 사용된 데이터의 클래스는 4종의 고장모드를 4 Class로 2종의 정상 데이터를 1 Class로 취합하여 총 5 Class로 라벨링 하였다. Fig. 14의 AMS

Table 14 Input data and model information

Input data dimension					
Type	Row [s]		Column (Feature)		
	Train	Test			
AMS	64,057	16,054	149		
PMI	64,031	16,048	36		
VMS	63,797	15,987	78		
All	63,793	15,986	263		

Model Summary					
Layer (type)	Output shape	Parameter			
		AMS	PMI	VMS	All
LSTM	(None,5,512)	1,355,776	1,124,352	1,210,368	1,589,248
LSTM	(None,256)	787,456	787,456	787,456	787,456
Dense	(None,128)	32,896	32,896	32,896	32,896
Dense	(None,64)	8,256	8,256	8,256	8,256
Dense	(None,32)	2,080	2,080	2,080	2,080
Dense	(None,5)	165	165	165	165
Total parameters		2,186,629	1,955,208	2,041,221	2,420,101
Trainable parameters		2,186,629	1,955,208	2,041,221	2,420,101

Hyper-Parameter	
Option	Value
Train-test ratio	8 : 2
Scaler type	StandardScaler
Window Size	5
Step	1
Epoch	50
Batch size	200
Loss function	categorical-crossentropy
Optimizer	adam
Activation function	softmax

Train Set 학습곡선을 보면 학습 초기 Epoch에서 Train Loss가 순간적으로 상승하기는 하지만 전체적으로 Train Loss와 Validation Loss가 큰 차이 없이 동일하게 0에 가깝게 떨어지는 경향을 보이므로 데이터 패턴 자체는 학습이 잘되는 것으로 판단된다. AMS Test Set의 추론 결과로 Confusion Matrix를 도출하면 정밀도 99.6%, 재현성 99.6% 수준이며 클래스 별로는 exhGasLeak 고장의 정확도가 97.9%로 다른 고장에 비해 분류 성능이 조금 낮게 나타났다. 이는 exhGasLeak 고장을 일부 ExhValveKnock 고장으로 분류되는 현상을 보이므로 AMS 데이터만으로는 고장별 데이터 특성 구분에 한계가 있다.

Fig. 15의 PMI Train Set 학습곡선을 보면 Train Loss의 경우 완만한 곡선을 그리면서 Loss가 낮아지지만, Validation Loss의 경우 어느 시점부터 위아래로 요동치며 Train Loss와 간격이 벌어지는 것을 관찰할 수 있다. 이는 데이터 학습은 비교적 잘 되고 있으나 하이퍼파라미터 튜닝을 통해서 Train Loss와 Validation Loss를 줄이는 방법을 찾아야 할 것으로 사료된다. PMI Test Set의 추론 결과로 Confusion Matrix를 살펴보면 정밀도 93.9%, 재현성 93.9% 수준이며 normal이 90.9%로 일부를 exhGasLeak과 exhValveKnock으로 분류되었으며 exhGasLeak과 exhValveKnock은 각각 98.1%와 83.7%로 일부를 normal로 분




Fig. 14 AMS train set learning and test set inference result




Fig. 15 PMI train set learning and test set inference result

류하여 전체 성능이 비교적 낮게 측정되었다. 이는 PMI 센서의 경우 각 Cylinder 별로 No. 1~6까지 설치가 되어 있고 각 고장 실험에서도 정상상태인 Cylinder는 존재하고 있었으므로 모델이 판단하는데 혼동이 생긴 것으로 판단된다. 추후 연구에서는 PMI 데이터만을 적용할 때는 리벨링 기준을 개별 Cylinder로 설정하여 분석하면 고장 진단 알고리즘의 성능을 개선시킬 수 있을 것으로 사료된다.

Fig. 16의 VMS Train Set 학습곡선을 보면 Train Loss와 Validation Loss 모두 Epoch 초기에 급격하게 낮아져 동일하게 낮은 수준을 유지하다가 학습이 종료되는 것을 관찰할 수 있다. 이는 데이터 자체가 클래스별로 구별이 잘되고 학습이 상당히 잘 되었다고 볼 수 있다. VMS Test Set의 추론 결과로 Confusion Matrix를 보면 정밀도 99.9%, 재현성 99.9% 수준이며 개별 클래스를 확인했을 때 전체 성능에 비해 특별히 분류 정확도가 낮게 관찰되는 클래스는 확인이 되지 않는다.

Fig. 17의 All Data Train Set 학습곡선을 보면 Train Loss와 Validation Loss 모두 Epoch 초기에 잠시 상승을 그렸다가 다시 지속해 낮아져서 동일하게 낮은 수준을 유지하다가 학습이 종료되는 것을 관찰할 수 있다. 이는 3가지 타입의 데이터(AMS, PMI, VMS)를 함께 사용하여 학습시킴으로써 앞서 개별 데이터 학습 시에 관찰되었던 특성 중에 학습이 잘되지 않던 특성들은 대부분 보완이 된 것으로 보인다. All Data Test Set의 추론 결과로 Confusion Matrix를 보면 정밀도 99.9%, 재현성 99.9% 수준




Fig. 16 VMS train set learning and test set inference result




Fig. 17 All data train set learning and test set inference result

이며 개별 클래스를 확인했을 때 전체 성능에 비해 특별히 분류 정확도가 낮게 관찰되는 클래스는 확인이 되지 않는다.

5. 결 론

본 논문에서는 선박 2행정 저속엔진을 대상으로 고장 진단 및 예측 알고리즘에 필요한 데이터를 생산하였고 이를 위한 4종의 고장모사 시나리오 및 엔지니어링 구현방법을 개발하였다. 선박용 엔진을 대상으로 직접 고장을 모사하고 기동하여 고장모드 데이터를 취득하였으며 개발된 데이터에 대한 다양한 통계분석 및 딥러닝 모델을 활용한 데이터 신뢰성을 검토하였다. 이로써 다음과 같은 결론을 도출하고자 한다.

4종의 고장모드 모사 시나리오와 고장원인을 구현하기 위한 엔지니어링 기법은 적절한 것으로 판단된다. 선박 대형엔진을 완전히 shut-down 될 정도의 무리한 운영은 현실적으로 불가능하기 때문에 기관 공학의 이론과 경험에 기반하여 데이터의 차별성이 확보될 수 있는 적정 수준의 스트레스 레벨을 결정해야 한다. 본 연구에서는 고장 실험을 통해 생산한 고장 모사 데이터를 대상으로 다양한 통계분석 및 LSTM 알고리즘 분류성능을 확인함으로써 고장 모사 기법의 적정성을 확인할 수 있었다. 또한 데이터 처리의 효율성과 알고리즘 연산의 정확성을 향상하기 위해서는 적정 수준의 데이터 축소가 필요하고 이때 필요한 정보의 손

실은 최소화하면서 차원을 축소하되 완결성은 유지하여야 한다. 앞서 설명한 바와 같이 PMI 및 VMS의 취득 데이터에서 총 12종의 특성인자를 추출하였으며 이를 알고리즘 학습에 활용하여 건전한 학습곡선과 99% 이상의 우수한 분류성능을 확인할 수 있었다. 결과적으로 고장 모사 실험을 통해 생산한 각 고장모드 원본 데이터와 특성인자 추출기법에 대한 정확도와 신뢰성을 검증하였다. 이를 기반으로 특성인자의 변화양상과 상대적 경향을 분석하여 각 고장모드 별 특성인자를 제안하고자 하며 실제 운항선박에서도 유사한 진단성능이 확보될 수 있는 알고리즘 최적화에 대한 추가적인 연구가 필요하다. 향후 연구에서는 실 해역 운항선을 대상으로 실시간 데이터 취득 및 알고리즘 추론 성능 확보, 운영 최적화 기술 개발 순으로 단계적인 연구를 추진해 나갈 예정이다.

후 기

본 연구는 2020년도 산업통상자원부 및 산업기술평가관리원 연구비 지원으로 수행된 '자율운항선박 기술개발사업(20011164, 자율운항선박 핵심 기관시스템 상태 모니터링 및 고장예측 진단 기술 개발)'의 연구결과입니다.

References

- Bae, J.H., 2021. Fault detection of aircraft turbofan engine system using a fault detection filter. *Institute of Korean Electrical and Electronics Engineers*, 25(2), pp.330-336.
- Benkamin, L., Timo, M., Hannes, V., Nasser, J. and Michael, W., 2021. A survey on long short-term memory networks for time series prediction, 14th CIRP 99, pp.650-655.
- Byun, S.I. and Lee, D.I., 2022. Health monitoring for autonomous underwater vehicles using fault tree analysis. *Journal of Institute of Control, Robotics and Systems*, 28(5), pp. 398-405.
- Chae, S.G., Kim, G.R., Bae, B.Y. and Bae, S.J., 2021. Failure diagnosis and prediction for a thermal power plant generator using fastICA. *Journal of Applied Reliability*, 21(4), pp.341-351.
- Cho, H.J., Choi, H.S., Kim, H.J., Nam, K.S., Ryu, J.D. and Ha, K. N., 2022. Feature selection for unmanned surface vehicle fault diagnosis research and experimental verification. *Journal of Institute of Control, Robotics and Systems*, 28(6), pp.542-550.
- Hwang, S.Y., Heo, J.Y., Hong, K.T. and Lee, J.H., 2018. Time series data analysis and fault diagnosis of plant process equipment using statistical machine learning method. *Korean Journal of Computational Design and Engineering*, 23(3), pp. 193-201.

- Kim, S.H., 2022. A study of machine learning technique for noise-based engine fault diagnosis. *Journal of the KNST*, 5(1), pp.16–19.
- Kim, J.Y., Lee, T.H., Lee, S.H., Lee, J.J., Shin, D.M., Lee, W.K. and Kim, Y.J., 2022. A study on the development of a failure simulation database for condition based maintenance of marine engine system auxiliary equipment. *Journal of the Society of Naval Architects of Korea*, 59(4), pp.200–206.
- Kim, S.I., Noh, Y.J., Kang, Y.J., Park, S.H. and Ahn, B.H., 2021. Fault classification model based on time domain feature extraction vibration data. *Journal of the Computational Structural Engineering Institute of Korea*, 34(1), pp.25–33.
- Lee, J.H., 2021. Experimental study on application of an anomaly detection algorithm electric current datasets generated from marine air compressor with time-series features. *Journal of the Korean Society of Marine Environment & Safety*, 27(1), pp.127–134.
- Ugo, C., Carlo, C. and Raphael, Z., 2018. Marine gas turbine monitoring and diagnostics by simulation and pattern recognition. *International Journal of Naval Architecture and Ocean Engineering*, 10, pp.617–628.
- Zhengping, C., Sanjay, P., Cho, K.H., David, S. and Yan, L., 2018. Recurrent neural networks for multivariate time series with missing values, *Scientific Reports*, 8:6085.

