



Received: 2022/01/26
Revised: 2022/02/23
Accepted: 2022/03/21
Published: 2022/03/31

***Corresponding Author:**

Sung-Hyun Kim

Naval Technology Team, Korean Register,
36, Myeongji Ocean City 9-ro, Gangseo-gu,
Busan 46762, Republic of Korea

Tel: +82-70-8799-8854

Fax: +82-70-8799-8879

E-mail: kshine@krs.co.kr

소음기반 엔진고장 진단 기계학습 기법 연구

A Study of Machine Learning Technique for Noise-based Engine Fault Diagnosis

김성현*

한국선급 함정기술팀 책임검사원

Sung-Hyun Kim*

Senior Surveyor, Naval Vessel Technology Team, Korean Register

Abstract

본 연구는 소음기반 엔진고장 진단을 위한 기계학습 기법 연구로서 원본 학습데이터를 MFCC 변환 형상으로 대체 적용하는 경우 기계학습 모델 3종에서 고장감별 정확도가 크게 향상되는 것을 고찰하였다. 또한 고장 소음의 패턴추출에 집중할 수 있도록 수리 후 정상소음과 혼합 학습하는 전략이 유효하게 작동함을 확인하였으며, 향후 MFCC 형상변환 과정의 권장 보완을 통해 고장감별의 편향성의 개선과 심층강화 학습과 연계한 후속연구를 제안한다.

As a study of machine learning technique for noise-based engine failure diagnosis, it is considered that the discrimination accuracy was greatly improved in the three machine learning models when the learning data was replaced with the transformed MFCC feature. In addition, it was confirmed that the strategy of mixing learning with normal noise after repair works effectively so that we can focus on the pattern extraction of faulty noise. In the following study, we propose to improve the bias of failure detection through the recommended supplementation of the MFCC feature extraction process, and to couple with deep reinforcement learning.

Keywords

상태기반유지관리(Condition-based Maintenance),
소음기반(Noise-based),
엔진 고장진단 기법(Engine Fault Diagnosis),
기계학습(Machine Learning),
MFCC(Mel Frequency Cepstrum Coefficient),
LR(Logistic Regression),
SVM(Support Vector Machine),
DTC(Decision Tree Classification)

1. 서론

함정 무기체계를 포함한 산업계 전반의 예방정비 분야 기술추세는 통계적 예측방식의 시간기반유지관리 형태에서 점차 전문가 예측방식의 상태기반 유지관리 형태로 변화하고 있다. 이러한 상태기반 유지관리를 위해서는 실제 대상 체계 및 장비의 상태를 감시하고 특징적 고장을 감별 및 진단하고 잔존수명을 예측하는 전문가 수준의 기술접목이 필요하며, 위험도 및 중요도가 높은 대상과 범위를 선별하여 적용하는 것이 필요하다.

함정의 엔진의 경우 종합군수지원계획에 따른 대표적 예방정비 대상으로 부대정비 등을 통해 제조사 권고 주기에 따른 시간기반 유지보수 차원에서 예정된 예비품 등의 교체가 이뤄지고 있다. 하지만 동형 함종이라 할지라도 각 엔진의 상태는 운용해역의 환경과 임무에 따른 운용 방식에 따라 다르기 마련이며 해상 작전 중 엔진 고장인지에 따른 함내 조치의 제한과 자항능력 상실에 따른 2차 확장 사고위험 가능성을 고려할 때 이러한 엔진의 가변적 정비소요에 실질적으로 대응할 수 있는 상태기반의 유지관리 형태로 패러다임 전환이 필요하다고 생각한다.

이에 승조원에게 엔진의 실시간 고장 조기감별 및 후속 의사결정에도움이 될 수 있는 기반연구로서 소음에 기반한 엔진 고장징후 인지에 관한 기법연구를 수행하였다. 다만 함정 엔진의 고장소음자료 획득의 제한성으로 인해 차량용 엔진의 고장소음에 대해 대체 고찰하였다.

2. 본론

2.1 엔진 고장 초도인지 지표 및 프로세스

통상엔진 고장 지표로는 온도, 압력, 유량, 진동 등 다양한 고장 감별인

자가 활용되고 있으나, 본 연구에서는 고장 시 발생하는 특징적 소음에 기반한 고장진단 기법을 제안하며 이는 실제 전문 정비기술자들이 활용하는 다음의 엔진고장 초도 인지 노하우에 착안하고 있다.

실제 엔진이 고장난 경우 정비 전문가들은 곧바로 엔진 완전분해 정비를 수행하진 않는다. 대신 엔진상태를 선행 점검하여 대상 정비범위와 목표를 조금씩 넓혀 가는 방법을 통상 채택한다. 여기에는 정비 전문가들의 여러 가지 노하우들이 활용되는데, 그중 대표적인 방법 중 하나로서 “엔진 고장 패턴소음의 청음훈련” 노하우를 들 수 있다. 이는 고장감별을 위해 선행 확인된 유사한 고장별 패턴소음을 반복적으로 청음훈련하여 숙달하고, 후속 입고 확인된 실제 엔진의 고장 소음과 비교해 특징적 고장을 경험적으로 감별하는 방법이다. 일부 전문가들은 사례별 패턴소음을 다양한 사회 관계망을 통해 공개하고 있으며, 일반 정비기술자들에게 청음 숙달과 실무활용을 권장하고 있다. 이러한 청음훈련 노하우는 본 논문이 목표로 하는 엔진 고장 초도 인지목적에 부합되며, 특히 일련의 프로세스가 전형적인 인공지능 기술(기계학습 기법) 접목이 가능한 형태로 평가되었다.

2.2 대표적 엔진 고장소음

대표적 차량용 엔진과 관계된 소음은 다음 7가지로 정의하였다. 간단히 정의하면 먼저 태핏, 캠 로브, 캠 캐리어의 마모 유격소음은 공통적으로 캠축의 회전과 관계된 소음으로 규정간극이 일시적 또는 영구적 결손에 의해 기계적 마찰 소음을 동반한다. 통상 타이밍 체인 장력조절, 윤회계통 관리의 문제로 발생될 수 있으며 그 중 캠로브 마모 유격소음은 흡배기 밸브의 작동거리가 영구적으로 짧아져서 배기행정에서 잔여배기가 흡기로 역류하는 흡기 맥동파 소음이 동반되는 특징이 있다. 상기 유격소음을 방지할 경우 점차 연소효율의 저하와 엔진 실화현상 등이 동반될 수 있다.

정화조절밸브(PCSV) 노후화 소음은 태핏소음과 매우 유사한 마찰음을 내며, 내장된 밸브 시트부 및 스프링의 노후화 등으로 인해 개폐오작동을 동반한다. 캐니스터에 포집된 탄화수소를 흡기계통으로 환류하지 못하여 대기 오염과 엔진의 흡기량 제어의 문제로 인해 연소효율이 떨어지는 문제가 동반된다.

댐퍼 풀리 파손 이탈소음은 크랭크축의 회전관성을 완충해주는 고무재질의 완충재가 경화, 박리 등의 형태로 파

괴되어 내·외륜이 탈락되어 발생되며 풀리와 연결구동되는 외부장치(발전기, 에어컨, 냉각수펌프 등)의 기능저하와 외륜 이탈로 인한 체인커버 소손 및 2차 사고의 위험이 동반될 수 있다.

인젝터 와서 파손 누설소음은 연소실 직분사 방식의 인젝터의 경우 실린더 상부 연결구에 밀봉을 위해 삽입된 구리재질의 와셔가 열변형, 단조마모 등으로 인해 파손되어 실린더 내부 연소 혼합물이 누설되면서 발생하는 소음으로 전자제어를 통한 보상연소로 인해 블로우-바이 가스 생성이 가속화되며 해당 가스가 순환되어 흡기측 오염과 막힘 등의 문제를 야기할 수 있다.

크랭크축 메탈 베어링 파손 유격소음은 유막결손 등에 의한 메탈 베어링의 박리, 압축 등으로 인한 규정간극 초과 운전에서 피스톤의 승강되면서 유격부에 발생하는 타격에 의한 소음으로 커벡팅 로드의 힘이나 절손 등 엔진 수명의 단축과 확장 사고의 원인이 될 수 있다.

2.3 데이터 전처리 접근전략

상기 살펴본 7가지 엔진 대표적 고장소음의 주파수분석을 통해 유의 주파수 대역을 확인한 결과 고장별로 다양한 대역별 분포가 확인되었다. 따라서 전처리 단계에서 수집 고장음원의 입력신호를 대역별로 필터링하는 방법은 고장분류 코드별로 입력 고장신호를 재연산해야 하는 소요가 동반되므로, 대신 입력 형상자체를 캡스트랄 형태인 MFCC 형상으로 변환 처리하는 방법을 채택하였다. 이러한 MFCC 방법은 스펙트럼 정보의 주파수별 변동량으로 그 스케일로 증폭 변환한 로그 파워 스펙트럼을 인간의 청력에 상응한 멜-주파수 대역으로 리스케일링한 주기 함수로 변환한 후 이를 다시 포락선과 고조파 성분으로 분리하는 이산코사인변환을 수행한 새로운 형상맵 형태이다.

MFCC 형상은 원본 입력정보를 특징적 대역 분리가 용이한 로그정보의 합성 조합으로 재정돈해 주기 때문에 그 자체로서 기계학습을 위한 패턴인지가 용이한 입력형상으로 활용할 수 있다고 판단하였다. 이때 MFCC 추출형상은 지정된 해상력(지정 대역폭 및 시간간격)에 따라 배열된 2차원 행렬구조를 갖는 스펙트럼 이미지맵 형태로 변환되므로 후행 학습을 위한 패턴추출을 위해 입력신호가 변환 후 불필요 격자가 발생되지 않는 수준에 맞춘 최대한의 해상력으로 통일 변환 적용하였다. 또한 기계학습에 필요한 다양한 고장신호인 학습데이터 준비가 제한되는 관례로 고장패턴의 구분에 집중할 수 있도록 엔진 고장소음

7종과 함께 고장수리 후 정상소음 5종을 입력정보로 혼합 학습 전략을 함께 접목하였다.

고장 소음데이터의 준비는 전문 정비기술자들이 사회 관계망에 공개한 영상에서 추출하여 활용하였으며, 해당 고장이 확정적으로 판정된 엔진의 공회전 상태를 기준으로 고장소음이 마이크에 수음된 시간구간에 대해 선택적으로 샘플링 하여 170개 학습데이터를 준비하였다. 최종 평가를 위해서는 학습데이터와 독립된 데이터 12개를 별도 추가 준비하였다. 관련 데이터 준비 현황과 절차는 다음 Table 1 및 Fig. 1과 같다.

Table 1. Data preparation status

Fault code	Car type	Train data	
[0]	Tappet	A/B	41
[1]	PCSV	B	11
[2]	C.LOB	C	9
[3]	C.CAR	D	17
[4]	D.PUL	D	39
[5]	INJ.WA	E	9
[6]	METAL	C	9
[7]	[0]FIX	A	19
[8]	[1]FIX	B	3
-	-	-	-
[9]	[3]FIX	D	3
[10]	[4]FIX	D	7
[11]	[5]FIX	E	3
-	-	-	-

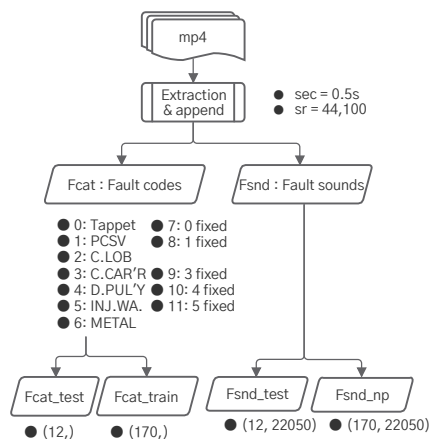


Fig. 1. Data preparation flow chart

2.4 기계학습 3종 수행 결과 비교 및 고찰

앞서 준비한 데이터 원본은 음압의 최대진폭에 해당되

는 정보로서 샘플 추출한 시간영역의 1차원 데이터 구조를 갖는다. 이를 정규화한 데이터를 학습데이터로 그대로 사용하는 경우와 앞서 제안한 MFCC 입력형상으로 변환한 경우의 성능 비교를 위하여 다음 대표적 기계학습 기법인 선형 로지스틱 회귀, 서포트 벡터 머신, 의사결정트리에 적용한 감별 정확도의 결과를 비교하였고 그 결과는 Table 2와 같다. 이 과정에서 MFCC 변환을 위한 후처리 과정은 다음 Fig. 2와 같으며, MFCC 입력형상 비교 예시는 Fig. 3와 같다.

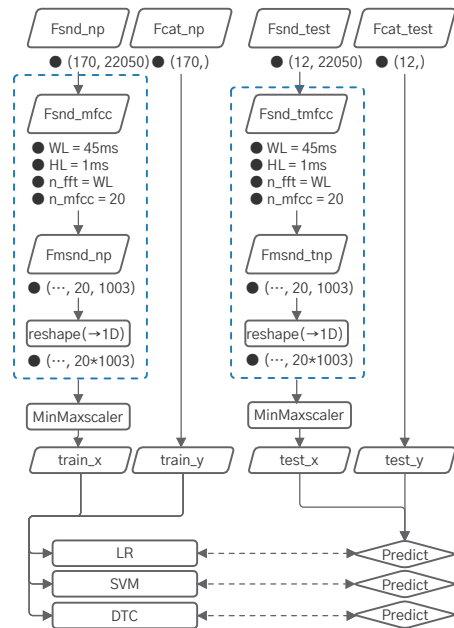


Fig. 2. Machine learning flow chart




Fig. 3. Feature comparison of code case [5] and [11]

Table 2. Accuracy comparison according to input feature

Machine learning	Peak input in time domain		MFCC in quefrequency domain
	train ≠ test	train = test	train ≠ test
LR	0/12	12/12	12/12
SVM	0/12	12/12	12/12
DTC	3/12	3/12	8/12

상기 Table 2의 비교 결과와 같이 데이터 원본의 시간 영역의 피크를 입력형상으로 활용한 기계학습은 학습데이터와 독립된 평가데이터 12종에 대해서 감별 정확도가 매우 낮다. 대신 학습데이터에 종속된 평가데이터로 감별할 경우 기계학습 2종의 정확도가 개선되는 것을 볼 수 있는데, 이는 학습 데이터에 대한 감별만 성공한 것으로서 비학습 데이터에 대한 감별은 실패한 것이다. 따라서 시간 영역의 피크 입력형상은 기계학습을 통한 고장소음 패턴 추출에 부적합하다.

반면 MFCC 형상으로 변환 후 기계학습 수행 결과, 학습데이터와 독립된 평가데이터에 대해서도 감별 정확도가 기계학습 3종에서 모두 개선되는 것을 볼 수 있다. 그 중 기계학습 기법 2종(로지스틱 회귀와 서포트 벡터 머신 기법)은 12종 고장에 대해 정확한 감별 성능이 확인된 것으로 본 연구에서 목표하고 있는 기계학습을 통한 엔진고장 진단에 보다 적합한 입력형태로 평가할 수 있었다.

3. 결론

본 연구는 차량, 선박 등의 주요 부품인 엔진의 상태기반 유지관리를 위한 방법으로 특징적 고장소음에 기반을 둔 진단 기법 적용을 제안하고 있다. 특히 일반 운용요원들의 정비전문성 수준의 한계를 정비전문가들의 엔진 고장 초도인지 노하우에 착안하여 기계학습 모사 과정을 통해 효과적으로 극복할 수 있을 것으로 판단하고 있다. 이를 위한 기반연구로서 본 연구는 기계학습을 위한 입력형상을 원본 입력데이터의 형상과 비교해 MFCC로 변환하여 기계학습에 접목하는 경우의 고장감별 정확도 개선결과를 비교 확인하였다. 또한 고장소음의 데이터 확보의 한계로 인한 보조적인 접근 전략으로서 정상데이터를 혼합

한 학습방법을 함께 접목하여 기계학습 시 고장소음의 패턴학습에 보다 집중할 수 있도록 유도할 수 있었다.

다만 MFCC 형상추출 과정에서 최종 의사결정시 운용요원과 감각적 동질감을 줄 수 있는 장점을 고려해 인간의 청감과 유사하도록 멜 주파수로 리스케일링하는 과정을 포함하는데, 향후 고장코드 추가 시 고장소음이 존재하는 주파수 대역에 따라 고장패턴 인식의 편향문제가 발생할 수 있는 잠재 가능성이 있다. 따라서 멜 주파수 변환을 제외한 캡스트럼 변환 방식으로 개선 적용하는 것을 권장 제안한다. 또한 이미지맵 형태의 입력형상의 특징을 극대화하기 위해 본 기반연구를 토대로 향후 엔진 운용 환경별 범용적용이 가능하도록 이미지분야 패턴추출층을 능동적으로 구성할 수 있는 심층강화학습 모델로서 합성곱인공 신경망 등의 기법과 후속 접목 연구가 수행될 수 있을 것으로 기대한다.

참고문헌

- [1] He X, Xu S. Artificial neural networks[J]. Process Neural Networks: Theory and Applications, 2010:20-42
- [2] McFee, Brian et al. "Librosa: Audio and music signal analysis in python." In Proceedings of the 14th python in science conference, pp. 18-25. 2015.
- [3] Scikit-learn: Machine Learning in Python, Pedregosa et al., JMLR 12, pp. 2825-2830, 2011.
- [4] Y. S. Wang, Q. H. Ma, Q. Zhu, L. Zhao, "An intelligent approach for engine fault diagnosis based on hibert-huang transform and support vector machine," Applied Acoustics, Vol. 75, pp. 1-9, 2014.
- [5] Dai W, Ji W. A mapreduce implementation of C4. 5 decision tree algorithm[J]. International journal of database theory and application, 2014, 7(1): 49-60