



Received: 2026/07/08
Revised: 2026/07/19
Accepted: 2026/08/20
Published: 2026/09/30

***Corresponding Author:**

Joon-Young Jang
Tel: +82-55-907-5390
E-mail: na05jjy@navy.ac.kr

Abstract

본 논문은 병력 감소와 무기체계 첨단화에 대응하여 해군 함정의 가동률을 높이고 정비 인력을 절감하기 위한 ‘지능형 장비상태 감시체계’를 제안한다. 다중 센서 데이터(음향·진동)와 인공지능을 결합하여 탐지·식별·조치·평가의 4단계 프레임워크를 정립하였으며, 특히 비지도학습 기반의 이상 탐지와 RAG 기반 LLM을 활용한 실시간 교범 가이드 제공을 통합하였다. 본 체계는 군 인력 운용의 효율화와 상태기반정비(CBM+) 고도화를 가능케 하며, 향후 전 군으로 확장 적용되어 국방 자산의 신뢰성을 극대화하는 데 기여할 것이다.

This paper proposes an intelligent equipment-condition monitoring system to maximize naval-vessel availability and reduce maintenance personnel amid military downsizing. By integrating multisensor data (acoustic and vibration) with artificial intelligence, this study establishes a four-stage framework comprising detection, identification, action, and evaluation. The system seamlessly combines unsupervised anomaly detection with an LLM and RAG pipeline to deliver real-time, manual-based maintenance guidelines. This approach optimizes military human resources and advances data-driven preventive maintenance (CBM+) with broad applicability across other branches.

Keywords

상태기반정비(Condition-Based Maintenance),
인공지능(Artificial Intelligence),
해군 함정(Naval Vessel),
상태 감시체계(Condition Monitoring System),
상태기반정비 방법론(CBM+ methodology)

해군 함정용 지능형 장비상태 감시체계 구현 방안

Implementation of Intelligent Equipment-Condition Monitoring System for Naval Vessels

장준영*

해군사관학교 기계시스템공학 교관

Joon-Young Jang*

Instructor, Dept. of Mechanical Systems Engineering, Republic of Korea Naval Academy

1. 서론

최근 군의 무기체계는 첨단 기술과 함께 급격히 복잡화·다양화 되고 있어 안정적인 유지보수를 위한 인력 수요가 지속적으로 증가하고 있다[1]. 그러나 인구 절벽으로 인한 급격한 병력 감소는 군 전반의 인력 확보를 어렵게 만들고 있으며, 이를 극복할 병력 절감형 시스템 도입이 시급한 실정이다[2]. 특히 해군 함정은 추진, 발전, 보조 장비 등 수많은 기계장치가 유기적으로 맞물려 운용되므로 주요 장비의 결합은 함정의 작전 수행 능력에 치명적인 공백을 초래한다. 이 때문에 현재 기관부 운용자들은 가혹한 환경 속에서 24시간 계기 감시와 수동 순찰을 수행하고 있으며, 여기에 상당수의 인력이 투입되고 있다[3]. 만약 인공지능(AI) 기반의 감시체계가 이러한 수동형 임무를 대체한다면 승조원의 업무 부하를 줄이는 동시에 데이터 기반의 정밀 장비 관리가 가능해질 것이다.

본 연구는 SF소설 『프로젝트 헤일메리』에서 주인공이 미지의 음성 신호를 녹음한 뒤 ‘푸리에 변환’을 통해 숨겨진 패턴을 해석해내는 장면에서 착안하였다. 이는 물리적 신호를 데이터화하여 정보를 추출하는 현대 신호처리 기술의 핵심 원리와 일치한다[4].

모든 회전 기계장치는 가동 시 그 구조와 부품 상태에 따라 고유한 주파수 특성을 나타낸다[5]. 본 연구에서는 이러한 물리적 신호 특성에 주목하여, 함정 장비의 음향 및 진동 데이터를 활용해 미세 이상 징후를 조기에 포착하고 정비 가이드를 실시간으로 제공하는

4단계(탐지·식별·조치·평가) 분석 프레임워크를 제안하고자 한다.

제안하는 체계는 AI가 정상 상태의 패턴을 비지도 학습한 후, 인간의 청각으로 포착하기 어려운 미세한 비정상 주파수를 감지하여 결함을 식별한다. 본 체계가 도입된다면 순찰 인력을 최소화하여 함정 인력 운영의 효율화를 달성할 수 있으며, 향후 타 군의 주요 무기체제로 확장 적용됨으로써 국방 자산 전반의 상태 기반정비(CBM+) 고도화에 기여할 것으로 기대된다.

2. 정비체계 발전 동향

2.1 상태기반정비(CBM+) 및 건전성 관리(PHM)

정비체계는 고장 후 수리하는 ‘사후 정비’와 정해진 주기에 부품을 바꾸는 ‘정기 예방정비’를 거쳐, 최근에는 실시간 데이터를 기반으로 정비 소요를 도출하는 상태기반정비(CBM: Condition based maintenance)로 진화했다[6,7]. 현대 군사 영역에서는 여기에 인공지능과 빅데이터를 융합하여 과잉 정비를 억제하고 장비 가동률을 높이는 CBM+ 개념으로 발전하였다[8].

CBM+를 구현하는 핵심 기술인 건전성 예측 및 관리(PHM: Prognostics and health management)는 장비의 고장을 진단(diagnostics)하고 잔존수명(RUL)을 예지(prognostics)하는 기술이다[9,10]. 국방 PHM은 무기체계의 신뢰도와 가용성을 보장하는 필수 요소로 평가받는다[11]. 특히, 함정 추진계통처럼 복잡한 기계 체계에 적용하려면 온도·압력 등의 단순 수치 데이터를 넘어 음향·진동 같은 복합 물리 신호와 기존 정비 교범을 융합한 다각적 분석이 요구된다[12].

2.2 국내외 상태기반정비 적용사례

장비 상태 분석 기술은 단순 모니터링 단계를 넘어, 인공지능을 기반으로 자율적 판단과 의사결정을 수행하는 체계로 진화하고 있다. 본 절에서는 이러한 기술 전환을 선도하는 미국과 한국의 주요 국방 운용 사례를 분석하고 그 성과를 고찰한다.

2.2.1 미국

미 해군은 1990년대부터 함정의 주요 장비에 진동 및 가속도 센서를 설치하여 상태를 진단하고, 정비 요원이 적시에 정비를 수행할 수 있도록 지원하는 통합 상태평가체계(ICAS: Integrated condition assessment system)를 운용해 왔다[13]. 또한, 최근 ICAS 데이터를 통합·관리하기 위한 클라우드 기반의 차세대 플랫폼인 eRM(enterprise remote monitoring)을 구축하여 정비체계를 더욱 고도화하고 있다. eRM은 표준화·디지털화된 군수 데이터 인프라로서, 민간 고도화된 인공지능 알고리즘을 유연하게 수용하고 결합할 수 있는 기반을 제공한다[14]. 이러한 상태 기반 예방정비 시스템의 실질적인 군사적·경제적 효과는 미 정부회계감사원(GAO) 등의 공인 보고서를 통해 입증되었다[15]. 분석에 따르면, 미 해군 H-1 헬기 운용에 CBM+ 체계를 적용하여 5년간 약 1억 달러의 정비 비용을 절감하였다. 미 육군의 경우 CH-47 대대는 2,400만 달러, UH-60 대대는 6년간 2억 1,500만 달러의 정비 예산을 절감하는 성과를 거두었다. 아울러 미 해병대 수륙양용돌격차량(AAV)에 본 정비 체계를 적용한 결과, 고장으로 인한 가동 중단 시간이 32% 감소하고 전체 정비 시간이 69% 단축되는 등 무기체계의 상시 작전 가동률이 비약적으로 향상됨이 확인되었다[16].

2.2.2 대한민국

우리 군은 병력 감소와 무기체계 첨단화에 대응해 인공지능 기반의 국방 혁신을 추진 중이다[17]. 국방부는 2024년 2월 관련 훈령을 개정하여 신규 무기체계 획득 시 CBM+ 적용 검토를 의무화했다[18]. 국내에서는 2009년 기동헬기 수리온(KUH-1)의 상태감시체계(HUMS) 도입을 시작으로, 해군의 광개토-III급 구축함 등 함정 전반으로 대상을 확대하고 있다[19,20]. 또한 방위사업청 주도로 ‘무기체계 CBM+ 특화연구센터’를 개소하는 등 분석체계 고도화를 이끌고 있다[21]. 국내 함정 분야의 대표적 연구로는 국방기술진흥연구소와 한화시스템이 주도한 ‘함정 상태기반정비체계(CBMS)’ 구축 사업이 있다[22]. CBMS는 함정 내 추진 및 발전계통 등 주요 장비로부터 온도, 압력, RPM 등의 물리적 계측 신호를 실시간 수집·통합하여

임계치 모니터링과 고장 진단을 수행하는 국산 함정 CBM+의 표준적 인프라를 정립하는 성과를 거두었다[23]. 그러나 기존 CBMS 체계는 실제 야전 운용 환경에서 다음과 같은 기술적 한계점을 갖는다.

첫째, 주로 접촉식 센서(온도, 압력)에 의존하므로, 베어링의 미세 크랙이나 초기 마모처럼 물리적 징후가 표면화되기 전인 잠복기 단계의 미세 이상을 포착하기 어렵다[24].

둘째, 군의 특성상 고장 데이터 확보가 제한적이므로, 기존의 지도학습(supervised learning) 기반 알고리즘은 라벨 데이터가 없는 미상의 고장이나 복합 결함을 탐지하는 데 취약하다.

셋째, 시스템이 도출하는 결과물이 단순 고장 코드나 경고 알람 표출에 머물러 있어, 숙련도가 낮은 초임 정비 요원이 현장에서 즉각적인 군수·정비 조치를 수행하기 위한 실시간 의사결정 지원 기능이 부족하다[25].

3. 지능형 장비상태 감시체계 관련 기술

본 장에서는 함정 CBM+ 및 PHM 구현을 위한 인공지능 기반 지능형 장비상태 감시체계 관련 기술을 제시한다. 체계는 Fig. 1과 같이 탐지(detection), 식별(identification), 조치(action), 평가(evaluation)의 4단계로 구성되며, 단계별 요구되는 핵심 기술은 다음과 같다.

3.1 탐지(Detection): 비지도 학습 기반 이상징후 탐지

함정 기관실의 복합 소음과 고온·고습 환경에서 데이터 왜곡을 막고 진단 신뢰성을 높이려면 다중 센서 체계가 필수적이다. 본 체계의 탐지 단계에 적용되는 핵심 센서는 다음과 같다.

① MEMS(Micro Electro-Mechanical Systems): 반도체 공정 기술을 적용한 MEMS 마이크로폰(Fig. 2)은 초소형·저전력 구동이 가능하며, 기계적 가동 부위가 없어 외부 충격과 진동에 대한 내구성이 우수하다. 높은 경제성을 바탕으로 함정 내 격실과 주요 장비 주변에 고밀도·광범위하게 배치함으로써, 함정 전반의 음향 감시 네트워크를 구축하는 데 유리하다.

② 가속도계(Accelerometer): 장비 표면에 직접 부착되어 기계적 진동을 물리적으로 측정하는 센서




Fig. 1. Analysis framework and core technologies




Fig. 2. MEMS microphone




Fig. 3. Non-invasive ultrasonic sensor for acoustic signal acquisition

이다. 주변 소음의 간섭을 받지 않고 구조 진동을 파악할 수 있으므로, 추진축이나 베어링 하우징 등 핵심 회전체에 부착하여 음향 데이터와의 교차 검증을 통해 진단의 정확도를 향상시킨다.

③ 초음파 센서(Ultrasonic Sensor): 인간 가청 영

역(20 Hz~20 kHz)을 초과하는 고주파수 신호를 감지한다. 베어링의 미세 크랙이나 초기 마모 징후는 주로 초음파 대역(24 kHz~50 kHz)에서 가장 먼저 응력과 형태로 나타나는 특성이 있다[26,27]. 따라서 Fig. 3와 같이 핵심 장비의 마찰부 및 구동부에 부착되어 고장 잠복기 단계의 징후를 조기에 포착할 수 있다.

가혹한 배경 소음이 공존하는 함정 기관실 환경에서 고장 징후를 정밀하게 감지하려면, 수집된 신호에서 유의미한 특징만 추출하는 전처리 기술이 필수적이다[28]. 단순히 시간 도메인에서의 진폭 변화만 보는 시계열 데이터 분석을 넘어, 시간-주파수의 상관관계를 분석할 수 있는 형태로 변환해야 한다.




Fig. 4. Comparison of raw vibration signal and converted spectrogram for anomaly detection

기존 푸리에 변환(FFT)은 특정 주파수 성분이 ‘어느 시점’에 발생했는지 알 수 없는 한계가 있다. 이를 극복하기 위해 신호를 짧은 단위로 분할하여 변환하는 단시간 푸리에 변환(STFT)을 활용한다. STFT 결과값을 에너지 강도(dB)에 따라 시각화한 것이 스펙트로그램(spectrogram)이다. Fig. 4는 MATLAB을 통해 장비 가동 중 정상적인 부하 증가 상태(50 Hz~150 Hz)에 배경 잡음을 추가하고, 1.2초 지점에 순간적인 충격 신호(결함 모사)를 반영하여 분석한 결과이다. 상단의 시계열 데이터에서 1.2초 지점의 충격 시점은 명확히 표출하지만, 결함 충격음의 주파수 대역 분포를 파악하기는 어렵다. 반면, 하단의 스펙

트로그램은 시간-주파수 축을 기준으로 에너지 밀도를 시각화한다. 스펙트로그램 하단의 완만한 우상향 직선은 장비의 부하 증가에 따라 주파수가 선형적으로 상승하는 정상 작동 상태를 뚜렷하게 보여준다. 그러나 고장이 발생한 1.2초 지점에서 저주파부터 고주파 대역까지 수직으로 길게 뻗은 밝은 에너지 형태가 관찰되는데, 이는 광대역 결함 충격 에너지가 순간적으로 방출되었음을 정밀하게 나타낸다. 이처럼 스펙트로그램은 소리 신호를 시간-주파수 특징이 보존된 이미지 형태로 변환하므로, 이미지 패턴 인식에 탁월한 인공지능 알고리즘인 합성곱 신경망(CNN)의 입력 데이터셋으로 쓰기에 적합하다[29,30].




Fig. 5. Structure of autoencoder for unsupervised anomaly detection

실제 군 함정 환경은 보안 문제로 인해 결함 및 고장 데이터를 대량으로 확보하기 어렵다. 이러한 데이터의 희소성은 사전에 분류된 고장 라벨을 요구하는 지도학습 기반 모델 구축의 주요 제한 사항이다. 따라서 탐지 단계에서는 정상 상태의 데이터만을 활용해 학습한 뒤 입력 신호가 정상 범주에서 벗어나는 이상치를 식별하는 비지도학습 방식을 채택한다. 대표적인 비지도학습 모델인 오토인코더(autoencoder)는 Fig. 5와 같이 입력 데이터를 핵심 특징인 잠재변수(latent variable)로 압축하는 인코더(encoder)와 이를 다시 원래 형태로 복원하는 디코더(decoder)로 구성된다[31].

모델의 학습은 정상 스펙트로그램의 입력 데이터와 복원된 출력데이터 사이의 차이인 재구성 오차(reconstruction error)를 최소화하는 것을 목적으로 진행된다. 정상신호가 입력되면 인코더가 장비 고유의 주파수 패턴만을 잠재변수로 추출하고 디코더가 이를 완벽히 복원하므로 재구성 오차가 최소화된다.

반면, 베어링의 미세 크랙 등 결함 신호가 입력되면 오토인코더는 학습 과정에서 경험하지 못한 주파수 패턴이므로 복원 능력이 저하되어 출력 스펙트로그램에 큰 왜곡이 발생한다. 결과적으로 재구성 오차가 급격히 증가하며, 본 체계는 이 오차값이 사전에 설정한 임계치를 초과하는 시점에 이상 징후로 판정하게 된다[32]. 이러한 비지도학습 메커니즘은 사전에 데이터의 부족으로 인해 분류되지 않은 미상의 고장이 라도 조기에 포착할 수 있는 기술적 기반이 된다.

3.2. 식별(Identification): 지도학습 기반 결함 분류

탐지 단계가 이상 징후를 선제적으로 포착하는 과정이라면, 식별 단계는 감지된 신호를 분석하여 구체적인 고장 부위와 결함 유형을 판별하는 과정이다. 스펙트로그램 전처리를 거친 시간-주파수 이미지는 이미지 특징 추출에 탁월한 합성곱 신경망(CNN)의 최적 입력값이다. CNN 모델은 베어링 손상, 기어 마모, 추진축 정렬 불량 등 각 결함이 가지는 고유의 주파수 에너지 분포 패턴을 학습한다. 최종 출력층에서 결함 유형별 확률값을 도출하여 가장 유력한 결함 원인과 부위를 식별하며, 모델의 신뢰도 기준을 만족하지 못하는 신호는 ‘미분류 고장’으로 분류하여 전문가의 정밀 진단을 유도할 수 있다. 결함 데이터의 부족이라는 군 특성상의 한계는 지속적인 운용으로 축적된 데이터, 육상 시험 설비의 모사 데이터, 제작사 기술 자료, 최근 주목받는 디지털 트윈 기술 등을 다양한 기술을 연계하여 극복할 수 있다.

이와 함께, 국방 데이터의 불균형 문제를 해결하기 위해 전이학습(transfer learning)을 활용할 수 있다. 데이터가 풍부한 영역에서 사전 학습된 모델을 유사한 목적의 새로운 분야에 재사용하는 전이학습은, 군 장비 고장 신호처럼 학습 데이터 확보가 어려운 환경에서 매우 효과적이다[33]. 예를 들어 대규모 사물 이미지셋으로 선, 면, 색 등의 특징 추출 능력이 검증된 사전 학습 모델(ResNet 등)에 소량의 함정 고장 스펙트로그램을 추가 학습(fine-tuning)시키면, 모델은 장비의 결함 특성을 매우 신속하고 정확하게 습득한다. 결과적으로 전이학습은 부족한 데이터 한계를 극복하고 야전 환경에서 즉시 활용 가능한 수준의 분류 성능을 보장하는 핵심적 기술이 될 수 있다.

3.3 조치(Action): RAG기반 지능형 의사결정 지원

조치 단계는 식별된 결함 정보를 바탕으로 현장 정비 요원이 즉각적이고 정확한 후속 조치를 취할 수 있도록 가이드를 제공하는 단계이다. 본 단계에서는 거대언어모델(LLM)에 검색 증강 생성(RAG: Retrieval-augmented generation) 기술을 융합하여, 단순한 고장 코드 표시를 넘어 기술 교범에 근거한 실시간 맞춤형 의사결정 지원체계를 구현한다[34,35]. 이를 통해 초임 승조원 및 비숙련 요원이라도 표준화된 정비 품질을 발휘할 수 있도록 보장한다. 이러한 체계를 구축하려면 대상 함정의 기술 교범, 과거 정비 이력, 부품 도면 등을 고차원 수치 데이터로 변환한 ‘벡터 데이터베이스(vector DB)’ 구축이 선행되어야 한다[36]. 벡터 DB는 단어와 문맥 간의 의미적 유사성을 계산하는 데 특화되어 있어, 사용자가 정제된 군사 전문 키워드를 입력하지 않고 일상적인 자연어로 질의 하더라도 의도를 정확히 파악하여 수천 페이지에 달하는 교범과 관련 정비 지침을 실시간으로 찾아낸다.

특히, 생성형 AI의 고질적인 한계인 환각 현상(hallucination)은 정확성이 필수적인 군 정비 분야에서 치명적인 오류를 유발할 수 있다. RAG 기술은 LLM이 답변을 생성하기 전, 사용자 질의와 가장 유사한 검증된 기술 교범 텍스트를 벡터 DB에서 선제적으로 검색한다. 이후 추출된 공식 문서를 LLM의 프롬프트에 주입하여 답변을 생성하도록 제약함으로써 결과물의 신뢰성을 보장한다. 예를 들어, 식별 단계에서 ‘발전기 베어링 손상’이 확인되면 시스템은 벡터 DB에서 해당 장비의 분해·조립 절차와 유의사항을 실시간 검색한다. 이어 확인된 내용을 LLM으로 처리하여 “베어링의 윤활유 오염 상태를 점검하고, 함정 기술교범 제4장 제12절의 절차에 따라 정비를 수행하십시오”와 같은 정밀한 가이드를 현장 요원에게 즉각 하달한다.

3.4 평가(Evaluation): 빅데이터 기반 장비수명 예측

평가 단계는 정비 조치 결과를 검증하고, 장비 생애 주기 전반의 데이터를 축적하여 미래 고장을 예측하는 최종 단계이다. 센서 수집 신호, 인공지능 분석 결과, 현장 정비 이력을 통합하여 장비별 빅데이터를 구축한다. 정비 후 측정값을 바탕으로 탐지·식별 알고

리즘의 정확도를 검증하며, 판정 오류 발생 시 이를 피드백 루프(feedback loop)를 통해 재학습 데이터로 활용함으로써 시스템을 지속적으로 고도화한다.

나아가 축적된 빅데이터를 바탕으로 장비 성능의 변화를 추적하여 고장 전까지의 남은 시간인 잔존수명(RUL: Remaining useful life)을 예측한다. 이는 단기적 상태 진단을 넘어 복잡한 환경 요인 간의 상관관계를 파악하고 미래 결함 시점을 추정하는 과정이며, 이를 위해 회귀 모델(regression model)을 활용한다[37].




Fig. 6. Equipment RUL estimation based on the performance degradation regression model

Fig. 6는 회귀 모델을 적용하여 온도·진동·소음 등의 환경 변수를 반영한 장비 성능 점수(0~100)와 가동 시간의 관계를 도출한 결과이다. 그래프의 파란색 점들은 과거부터 현재까지 측정된 가상의 장비 성능치 점수이며, 빨간색 곡선은 회귀 모델이 이 점들의 추세를 분석하여 도출한 미래 예측선이다. 본 예시에서는 가동 후 약 150일이 경과하는 시점에 장비 성능 점수가 정비·수리 권고 임계치인 20% 이하로 저하될 것으로 예측된다. 이 20%의 임계치는 기계 상태 감시 및 예측에 관한 국제 표준(ISO 13381-1)과 국방 상태기반정비 가이드라인의 안전 기준(safety margin)을 반영한 설계 기준점이다[38]. 즉, 장비의 기능 상실(0%) 전 정비 안전 여유를 확보하기 위한 임계값이다.

결과적으로 이러한 RUL 예측 정보는 정비 요원과 지휘관에게 최적의 정비·교체 주기를 선제적으로 제시한다. 이를 통해 과도 정비로 인한 예산 낭비를 막고, 장비 고장에 따른 함정의 작전 공백을 원천 차단

하여 운용 효율성을 극대화한다.

4. 지능형 장비상태 감시체계 구성

본 연구에서 제안하는 지능형 장비상태 감시체계는 Fig. 7과 같이 크게 세 가지 하부 시스템으로 구성된다.




Fig. 7. Overall architecture and configuration of the intelligent equipment condition monitoring system

4.1 센서

센서는 본 감시체계의 시작점으로서, 함정 주요 장비의 물리적인 상태 변화를 디지털 신호로 변환하여 인공지능 알고리즘에 전달하는 역할을 수행한다. 해군 함정의 기관실 및 보기실은 고온·고습하고 강한 진동과 복합 배경 소음이 상존하는 가혹한 환경이므로, 여기에 적용되는 센서는 높은 내구성과 안정성을 갖추어야 한다. 구체적으로는 외부 충격에 견딜 수 있는 견고한 하우징 설계와 함께 습기 및 분진으로부터 내부 회로를 보호할 수 있는 방수·방진 등급 확보가 필수적이다. 또한 엔진 및 터빈 주변의 고열 환경에서도 감도 저하 없이 안정적으로 데이터를 수집할 수 있는 내열 신뢰성이 요구된다.

이와 함께 센서가 결함 징후를 정밀하게 포착하기 위해서는 광대역 주파수 측정 능력이 수반되어야 한

다. 기계 결함은 유형에 따라 고유한 주파수 대역에서 발생하므로, 인간의 가청 영역(20 Hz~20 kHz)을 넘어 초기 고장 징후가 최초로 발현되는 초음파 영역(20 kHz 이상)까지 계측할 수 있어야 한다. 이를 통해 주로 초음파 대역에서 나타나는 베어링의 미세 마찰음이나 기밀 누설 등을 고장 잠복기 단계에서 조기에 탐지할 수 있다.

최종적으로는 음향을 수집하는 비접촉식 센서뿐만 아니라, 장비 표면에 직접 부착하는 접촉식 진동 센서를 복합 배치하여 물리적 신호의 다각화를 이루어야 한다. 기계의 실제 구조 진동 데이터와 주위 음향 데이터를 동시에 확보하여 상호 보완적으로 융합 분석함으로써, 장비의 이상 유무를 한층 더 정확하고 종합적으로 판단할 수 있는 공학적 기반을 마련한다.

4.2 분석 및 판단 알고리즘

분석 및 판단 알고리즘은 센서가 수집한 방대한 데이터로부터 복잡한 신호 속 이상 징후를 탐지·해석하는 시스템의 ‘두뇌’ 역할을 하는 부분이다. 본 알고리즘이 효과적으로 구동하기 위한 첫 번째 요구조건은 음원 분리기술의 적용이다. 함정 기관실의 복합 배경 소음 속에서 특정 장비의 신호만을 깨끗하게 걸러내기 위해, 시스템 개발 단계에서 개별 장비의 정상 구동음을 인위적으로 혼합한 복합 소음을 입력하고 원래의 개별 음원을 복원하도록 인공지능을 사전 학습시킨다. 이렇게 훈련된 모델은 실시간으로 유입되는 전체 소음 속에서 주변 장비의 간섭을 배제하고 특정 대상 장비 고유의 주파수 성분만을 분리하여 미세한 소리 변화를 정확히 추적할 수 있다.

둘째로, 오토인코더와 CNN 등 심층 신경망 기반의 실시간 데이터 분석 및 이상 식별 능력이 요구된다. 정상 상태 데이터의 주파수 및 진동 분포 특성을 미리 학습한 인공지능 모델은, 실시간 센서 신호가 통계적으로 허용된 안전 기준치와 정형화된 패턴을 벗어나는 즉시 이를 이상 징후로 판별하고 시스템에 경고를 전파해야 한다.

마지막으로, 함정의 가변적인 운용 부하를 고려한 모델 구축과 부품 단위의 정밀한 진단 능력이 수반되어야 한다. 함정 장비는 기동 속도나 전력 소모량 등 운용 부하에 따라 발생하는 음향·진동 특성이 완전히 달라지므로, 인공지능이 정상적인 부하 변동을 고장

으로 오인하지 않도록 저부하부터 고부하까지 다양한 영역의 데이터를 학습해야 한다. 나아가 단순한 장비 수준의 이상 탐지를 넘어 베어링 손상이나 축 정렬 불량 등 특정 부품의 결함 패턴을 함께 학습함으로써, 이상 발생 시 고장 부위와 원인을 확률적 수치로 제시하여 정비 요원이 조치 우선순위를 신속하게 결정할 수 있도록 지원해야 한다.

4.3 전시장치

전시장치는 인공지능 알고리즘이 도출한 분석 결과를 운용자가 직관적으로 인지하고 후속 조치를 신속하게 결정할 수 있도록 시각화하는 시스템이다. 전시장치는 소음과 고온 등 환경적 간섭이 심한 기관실 내부를 배제하고, 집중도 유지가 용이한 중앙조종실이나 함교에 배치된다. 또한 함정 내 개별 구동 장비별로 독립된 모니터를 두는 대신 하나의 통합 전시장치 스크린으로 일원화하여 추진기관, 발전기, 보기류 등 함 내 주요 자산의 상태를 전체적으로 파악할 수 있는 효율적인 감시 환경을 구축한다.




Fig. 8. User interface configuration of the integrated display system (AI assisted image)

Fig. 8은 이러한 설계를 반영한 통합 전시장치의 인터페이스 구성 예시이다. 화면은 긴박한 작전 상황 속에서도 운용 당직자가 신속한 의사결정을 내릴 수 있도록 직관적으로 집약되어 있다. 세부 인터페이스 구조를 살펴보면, 먼저 화면 좌측에는 대상 장비의 실시간 주파수 특성 그래프와 실시간 스펙트로그램 이미지가 전시되어 고주파 대역의 이상 주파수 검출 등 알고리즘 판단의 물리적 근거를 검증할 수 있도록 지원한다.

화면 중앙의 결함 식별 및 분석 영역에서는 대상 장

비의 3D 도면과 함께 이상이 식별된 구체적인 부품 위치(예: 2번 베어링)를 붉은색 색상으로 강조하여 전시한다. 동시에 모델이 추정한 결함 원인(이물질 또는 윤활 부족)과 식별 신뢰도를 확률적 수치로 명시하여 신속한 상황 판단을 유도한다. 화면 우측의 조치 및 정비 영역은 현장 정비의 실효성을 보장하기 위한 정보들로 구성된다. 알고리즘의 진단 결과와 RAG를 연계하여 운용 부하 하강 및 센서 재확인 등 기술 교범 기반의 초동 조치 절차를 나열한다. 그 하단에는 회귀 모델을 통해 연산된 해당 부품의 잔존수명(RUL) 지표가 전시되며, 현장 정비 위치 지도를 동시 전시하여 구체적인 작업 구역을 안내한다. 결과적으로 본 전시장치는 장비상태부터 정비 가이드까지 안내하여 비숙련 당직자라도 정비 공백 없이 정확하고 최적화된 표준 초동 조치를 수행할 수 있는 운용 기반을 마련한다.

5. 결론 및 향후 과제

본 연구에서는 해군 함정 핵심 장비의 상태를 실시간으로 감시하고 결함을 예방하기 위해, 복합 음향·진동 데이터와 인공지능 기술을 융합한 지능형 장비상태 감시체계 프레임워크를 제안하였다. 인구 절벽에 따른 병력 감소와 무기체계 첨단화라는 급격한 국방 환경 변화 속에서, 본 연구가 제시한 체계는 군수 및 작전 운용 측면에서 다음과 같은 의의와 기대효과를 가진다. 첫째, 단순 반복적인 확인 및 상시 계기 모니터링 임무를 자동화함으로써 국방 인력 운용의 효율성을 극대화하고 병력 부족 문제에 능동적으로 대응할 수 있다. 고온·고소음의 가혹한 기관실 환경에 정비 대원들을 상시 노출시키지 않고 안전한 원격 감시 환경을 조성하는 한편, 한정된 소수 정예 인력을 고난도 수리나 긴급 대응 등 핵심 임무에 집중 배치하여 병력 절감형 함정 운용 체계 구현에 기여한다. 둘째, 가청 영역을 초과하는 초기 잠복기 단계의 미세 크랙이나 마모 징후를 초음파 및 주파수 파형 분석으로 조기 포착하여 상태기반정비(CBM+)를 실현한다. 이는 부품 파손에 따른 예기치 못한 작전 공백과 대규모 장비 손상을 최소화하여, 사후 정비 중심에서 선제적 예방정비 체계로의 전환을 이끌고 정비 등 군수 예산 절감에 기여한다. 셋째, RAG 기반 기술교범 조치 권고를 통해 숙련·비숙련 정비 요원의 편차 최소

화를 달성하며, 장비 개조가 필요 없는 비침습적 복합 센서 설계를 채택하여 전차, 장갑차, 항공기 등 육·공군 기계 장비 전반으로의 높은 범용적 확장성을 보장한다.

본 체계의 실효성 있는 야전 배치 및 안정적 정착을 위한 향후 연구 과제는 다음과 같다. 먼저 교전 상황이나 통신 불가 등 함정 운용의 고유한 특수성을 고려하여, 외부 서버나 육상 데이터 센터에 의존하지 않고 함 내에서 독자적으로 알고리즘 구동과 추론이 가능한 엣지 컴퓨팅(edge AI) 기술의 도입이 필수적이다. 이와 함께 민감한 국방 데이터 자산을 보호하기 위한 군사 보안 체계 및 독립 망 구축이 선행되어야 한다. 두 번째로는 인공지능 모델의 판단 신뢰성을 한층 더 고도화하기 위해, 실제 장비를 가상 공간에 동기화하는 디지털 트윈 기술과의 융합 연구가 요구된다. 최종적으로는 이러한 기술적 고도화와 더불어 데이터 기반의 자동화된 의사결정을 신뢰하고 수용할 수 있는 군 내부의 제도적 기준 수립과 선진 정비 문화로의 인식 전환이 뒷받침되어야 할 것이다.

본 연구에서 제안한 인공지능 기반 지능형 장비상태 감시체계가 인력 부족의 한계를 극복하고, 미래 첨단 과학기술 강군으로 도약하는 데 실질적인 기반이 되기를 기대한다.

참고문헌

- [1] 한국국방연구원, 국방 환경 변화에 따른 무기체계 유지보수 인력 최적화 방안, KIDA 연구보고서, 2024.
- [2] 통계청, 인구절벽에 따른 군 병력 자원 수급 전망 보고서, 2023.
- [3] 해군기술연구소, 함정 기관실 승조원 근무 환경 및 직무 피로도 조사 분석, 해군기술연구소 기술보고서, 2023.
- [4] Alan V. Oppenheim & Ronald W. Schaffer, Discrete-Time Signal Processing (3rd ed.), Pearson, 2010.
- [5] Robert Bond Randall, Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications, John Wiley & Sons, 2021.
- [6] R. Keith Mobley, An Introduction to Predictive Maintenance, Elsevier, 2002.
- [7] 한국PHM학회, 상태기반정비(CBM+) 가이드북 및 산업 적용 표준, 2023.
- [8] 방위사업청, 데이터 기반의 국방 무기체계 CBM+ 발전 방향, 방위사업청 정책연구보고서, 2023.
- [9] Michael Pecht, Prognostics and Health Management of Electronics, John Wiley & Sons, 2008.
- [10] 윤병동, 황태완, 조수호, 이동기, 나규민, '인공지능을 이용한 공학시스템 상태진단 및 예지,' 기계저널, 제57권 제3호, 2017, pp.

38-41.

[11] 국방기술품질원, 국방 PHM 기술 동향 및 군수 혁신 연계 방안, 국방기술품질원 조사분석보고서, 2024.

[12] Youngdoo Choi, Mingyu Jeon, Dongjin Kim, & Sera Kim, 'A Study on the Elemental System Analysis for Applying Condition-Based Maintenance to Naval Ship Propulsion Systems,' *Journal of the KNST*, VOL. 8, NO. 4, 2025, pp. 908-915.

[13] Naval Surface Warfare Center (NSWC), Integrated Condition Assessment System (ICAS) Fleet Operational Evaluation Report, NSWC Technical Report, 2018.

[14] US Navy, Enterprise Remote Monitoring (eRM) Architecture Design and Cloud Migration Strategy, Naval Sea Systems Command (NAVSEA), 2021.

[15] Government Accountability Office (GAO), Military Readiness: Opportunities Exist to Improve Option and Cost Efficiency Through Predictive Maintenance, GAO-23-10524, 2023.

[16] Department of Defense (DoD), Condition Based Maintenance Plus (CBM+) Guidebook, US Department of Defense, 2022.

[17] 국방부, 국방운영 효율화를 위한 AI 기반 군수혁신 마스터플랜, 국방부 정책서, 2024.

[18] 국방부, 국방전력발전업무훈령(국방부훈령 제2866호, 2024년 2월 2일 개정), 대한민국 국방부, 2024.

[19] 한국항공우주산업(KAI), 수리온(KUH-1) 헬기 HUMS 데이터 분석을 통한 구성품 수명 예측 성과 보고서, KAI 기술논문집, 2020.

[20] 해군기술연구소, 광개토-III급 구축함 ICAS 운용 데이터를 통한 선제적 정비 효과 검증, 해군기술보고서, 2022.

[21] 국방기술진흥연구소(KRIT), 무기체계 CBM+ 특화연구센터 연구 성과 요약서, 2025.

[22] 김주영, '한화시스템, CBMS 국산화... '수출 주력품목으로 자리 잡을 것', 연합뉴스TV, 2025.01.24.

<https://www.yonhapnewstv.co.kr/news/AKR20250124095146136> (accessed 2026.07.01.)

[23] 한화시스템, 함정 상태기반정비체계(CBMS) 핵심 기술 개발 및 해군 전력화 방안, 방위산업부품장비대전 발표논문집, 2023.

[24] Jae-Soon Shim, Hyeong-Min Lee, & Chan-Yeong Park, 'Design of CBM Algorithm for Naval On-Board Equipment,' *Journal of the Korean Society of Industry Convergence*, VOL. 27, NO. 5, 2024, pp. 1243-1251.

[25] Jae-Soon Shim, Chan-Yeong Park, Hun-Seok Lee, & Jin-Seok Oh, 'Design of Regression Model for Abnormal Diagnosis of Naval Propulsion System,' *Journal of the Korea Institute of Information and Communication Engineering*, VOL. 27, NO. 8, 2023, pp. 941-950.

[26] Sang-Guk Lee, Sun-Ki Lee, Do-Hwan Lee, & Sung-Keun Park, 'A Study on Damage Evaluation of Bearings for Rotating Machinery in Power Plant Using Ultrasonic Wave,' *Transactions of the KSME A*, VOL. 32, NO. 7, 2008, pp.

583-589.

[27] Hyunseok Choi, Junu Oh, & Hong Seok Kim, 'Early Detection of Bearing Failure Used in Power Plant Based on Ultrasound,' in proceedings of KSME Annual Meeting 2022, November 2022, pp. 2725-2726.

[28] Dong-Hyun Kim, Seung-Eon Yoo, Byung-Jun Lee, Kyung-Tae Kim, & Hee-Yong Youn, 'Data Preprocessing for Efficient Machine Learning,' in proceedings of the Korean Society of Computer and Information Winter Conference, VOL. 27, NO. 1, January 2019, pp. 49-50.

[29] Kyung-Won Kang & Kyeong-Min Lee, 'CNN-Based Automatic Machine Fault Diagnosis Method Using Spectrogram Images,' *The Journal of Korea Institute of Convergence Signal Processing*, VOL. 21, NO. 3, 2020, pp. 121-126.

[30] Youngjun Kim & Seok-pil Lee, 'An Abnormalities Detection Model of a Machine Using Spectrogram,' *The Transactions of the Korean Institute of Electrical Engineers*, VOL. 71, NO. 9, 2022, pp. 1274-1279.

[31] Hyo Jin Lee & Yoonsuh Jung, 'Comparison of Deep Learning-Based Autoencoders for Recommender Systems,' *The Korean Journal of Applied Statistics*, VOL. 34, NO. 3, 2021, pp. 329-345.

[32] Junwoo Jung, Daesik Kim, & Jaemin Baek, 'Detection of Combustion Instability of Gas Turbine Combustor Using Convolutional Autoencoder Model,' *Journal of the Korean Society of Combustion*, VOL. 28, NO. 3, 2023, pp. 11-19.

[33] Jong Pil Yun, Min Su Kim, Gyogwon Koo, & Woosang Shin, 'Fault Diagnosis and Analysis Based on Transfer Learning and Vibration Signals,' *IEMEK Journal of Embedded Systems and Applications*, VOL. 14, NO. 6, 2019, pp. 287-294.

[34] Yeo Chan Yoon & Soo Kyun Kim, 'Trends and Prospects of Retrieval-Augmented Generation (RAG) for Generative AI,' *The Journal of Korean Association of Computer Education*, VOL. 28, NO. 2, 2025, pp. 69-80.

[35] Cheonsu Jeong, 'Generative AI Service Implementation Using LLM Application Architecture: Based on RAG Model and LangChain Framework,' *Journal of Intelligence and Information Systems*, VOL. 29, NO. 4, 2023, pp. 129-164.

[36] Yun-Jin Jang, Sung-Gwan Seo, Gi-Seung Lee, & HoiJin Yoon, 'Development of a Long-Term Memory-Based Chatbot System Using Vector Database,' *Journal of Artificial Intelligence Convergence Technology*, VOL. 4, NO. 4, 2024, pp. 125-130.

[37] 이종구, '다중회귀분석방법을 이용한 디바이스 수명예측에 관한 연구,' 광운대학교 대학원 석사학위논문, 1996.

[38] International Organization for Standardization, Condition Monitoring and Diagnostics of Machines — Prognostics — Part 1: General Guidelines, ISO 13381-1:2015, 2015.