

장비의 고장 단계 함수를 이용한 상태 지표 추출

추정호¹ · 박한별¹ · 박연경² · 배혜립^{3*}

¹부산대학교 산업공학과 / ²LIG Nex1 C4ISTAR IPS 연구소 / ³부산대학교 데이터사이언스전문대학원

Health Indicator Construction using the Equipment's Failure Stage Degradation Function

Jung-Ho Choo¹ · Han Byeol Park¹ · Yun Kyung Park² · Hyerim Bae³

¹Major in Industrial Data Science & Engineering, Department of Industrial Engineering, Pusan National University

²C4ISTAR IPS R&D LIG Nex1

³Department of Data Science, Graduate School of Data Science, Pusan National University

The Health Indicator (HI) is used to monitor equipment conditions. Supervised HI extraction methods assume a general degradation pattern, ensuring robustness. However, existing degradation functions are often designed assuming monotonic degradation without reflecting actual equipment characteristics. When the assumed pattern deviates from reality, the extracted HI may suffer from performance loss. This study aims to enhance HI extraction by identifying failure stages and designing degradation functions that better reflect real degradation patterns. A change point detection algorithm was used to identify failure stages, which were then used to construct the degradation function. The proposed method was validated using real-world data from a Weapon System. Compared to conventional linear and exponential degradation functions, the proposed approach improved HI performance by up to 29.13% in terms of Monotonicity. As the proposed degradation function can be applied to various equipment types, it is expected to enhance HI extraction in practical applications.

Keywords: PHM, CBM+, Health Indicator, Degradation Function, Failure Stage Degradation Function

1. 서론

기술과 산업이 급속도로 발전함에 따라 장비 시스템은 갈수록 복잡화되고 있다. 이에 따라 유지 및 정비 비용이 크게 증가할 뿐 아니라, 예기치 못한 고장이 발생할 경우 안전 문제와 생산성 저하가 뒤따를 수 있다. 장비의 예기치 못한 고장을 방지하기 위해서는 장비의 열화를 이해해야 한다. 장비의 열화는 운용에 따른 장비의 피로 혹은 스트레스가 증가하여 발생한다. 이러한 상황에서 예지 및 건강관리(Prognostic Health Management, PHM)가 관심이 높아지고 있다(Zio *et al.*, 2022; Zhou *et al.*, 2022). 이는 장비 상태를 모니터링하여 적시에 예방 정비를 수행하고, 장비 가용성을

극대화하는 정비 방법이다(Kong *et al.*, 2024). 특히 PHM 체계에서 상태 모니터링(Health Indicator, HI)은 장비의 예기치 못한 고장을 미연에 방지하고 효과적인 의사결정을 내리는 핵심 요소로 주목받는다(Chen *et al.*, 2024). 센서 데이터를 통해 장비 상태 변화를 실시간으로 추적함으로써, 고장의 조기 징후를 파악하고, 정비 시점과 범위를 적절하게 결정할 수 있기 때문이다. 이처럼 PHM의 도입은 장비 운용 과정에서 발생할 수 있는 위험 요소를 줄여준다(Zio *et al.*, 2022).

상태 모니터링은 PHM 시스템에서 장비의 상태 변화를 추적하고 고장의 징후를 실시간으로 파악하는 데 핵심적인 역할을 한다(Zhou *et al.*, 2024; Chen *et al.*, 2021; Qin *et al.*, 2023, Yu

이 논문은 2022년 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임(KRIT-CT-22-081, 무기체계 CBM+ 특화연구센터).
* 연락저자 : 배혜립 교수, 46241 부산광역시 금정구 부산대학교63번길 2 (장전동) 제10공학관 10623호, Tel : 051-510-2733, Fax : 051-512-7603,
E-mail : hrbae@pusan.ac.kr

2025년 4월 15일 접수; 2025년 6월 26일 수정본 접수; 2025년 7월 17일 게재 확정.

et al., 2019). HI는 장비의 상태를 수치적으로 표현하며, 이를 통해 장비의 건강 상태를 평가하고 적시에 정비를 수행할 수 있다(Li et al., 2024; Kim et al., 2023). 특히 복합 시스템에서는 개별 구성 요소 간의 상호작용으로 인해 고장이 순차적 혹은 비선형적으로 발생하기 때문에, 기존의 물리 기반 접근만으로는 정확한 고장 단계 구분에 한계가 존재한다(Zhou et al., 2024; Xu et al., 2023; Guo et al., 2018). 장비의 시스템이 복잡해짐에 따라 구성 요소 간의 열화 패턴을 반영하기 위해, 최근에는 HI 추출을 위한 신경망 기반 모델이 많이 사용되고 있다(Zhou et al., 2024; Xu et al., 2023). 신경망은 다양한 센서 데이터를 처리하고, 복잡한 패턴을 학습하는 데 효과적이다. 훈련된 신경망 모델은 장비의 열화 패턴을 학습하였기에 운용 중인 장비의 센서 데이터가 모델에 입력되었을 때 장비의 열화 정도를 파악할 수 있다.

신경망을 이용한 HI 추출은 거리 기반 추출과 열화 가정 함수(Degradation Function, DF)를 이용한 추출로 구분된다(Zhou et al., 2024; Yu et al., 2019; Guo et al., 2018; Bajarunas et al., 2024). 이 중 거리 기반 HI 추출은 학습 데이터와 테스트 데이터 간의 열화 진행 과정에서 명백한 편차가 있다는 가정하에 복원오차를 기반으로 HI를 추출한다(Yu et al., 2019; Bajarunas et al., 2024, Xu et al., 2024). 장비의 운용이 지속됨에 따라, 정상 데이터와 열화 데이터 간의 유사도 및 상관관계는 감소하게 되며, 이러한 차이를 유클리드 거리나 코사인 유사도와 같은 지표를 이용해 HI를 추출할 수 있다(Chen et al., 2024; Xu et al., 2024).

반면, 지도학습 기반 HI 추출은 주어진 데이터를 활용하여 열화 패턴을 학습할 수 있는 DF를 기반으로 한다(Chen et al., 2021; Qin et al., 2023; Li et al., 2024; Zhu et al., 2023). 이 방식은 선형, 비선형, 특정 시점 이후 급격한 감소 등 다양한 형태의 열화 양상을 가정하여 HI를 추출한다. 그러나 실제 장비 시스템이 복잡해짐에 따라 전통적인 고장 패턴과는 상이한 다양한 열화 단계가 나타날 수 있으며, 이러한 특성은 기존 DF가 실제 열화 양상을 정확히 반영하지 못하는 원인이 된다(Li et al., 2024; Zhu et al., 2023; Yan et al., 2022; Duan et al., 2023).

본 논문에서는 장비의 고장 단계를 바탕으로 새로운 DF인 고장 단계 함수(Failure Stage Degradation Function, FSDF)를 제안하였다. 제안된 FSDF는 장비의 센서 데이터와 열화 패턴 간의 연관성을 학습하는 과정에서 사용된다. 기존에 제안되었던 DF와 달리, 제안된 DF는 데이터를 기반으로 고장 단계를 세분화할 수 있다. 세분된 고장 단계로 인해 DF는 실제와 더욱 유사해지며, HI 추출 성능에 기여할 수 있다(Zhou et al., 2024; Li et al., 2024; Zhu et al., 2023, Park et al., 2023).

본 논문의 기여를 정리하면 다음과 같다:

- 1) 장비의 열화 패턴에 알맞은 DF인 FSDF를 제안하였다. 제안된 FSDF는 장비의 열화를 여러 고장 단계로 세분하여 표현할 수 있다.
- 2) FSDF를 사용했을 때 기존에 제안되었던 DF보다 29.13%

성능 개선이 있음을 실험을 통해 검증했다.

본 논문은 다음과 같이 구성되어 있다. 제2장에서는 HI 추출과 관련된 DF 및 고장 단계에 대하여 논의했다. 제3장에서는 제안된 고장 단계 가정 함수의 설계 방법에 대하여 설명하였다. 제4장에서는 제안된 FSDF를 이용한 실험 절차와 기존에 제안되었던 DF를 이용한 HI 추출을 비교 분석했다. 마지막으로 제5장에서는 결론을 맺고자 한다.

2. 관련 문헌 연구

2.1 HI 추출 방법론

최근에는 비지도 학습 및 지도학습에서는 장비의 열화 특징을 데이터로부터 추출할 수 있는 Encoder-Decoder 구조를 활용한 HI 추출 방식이 연구되고 있다. 데이터 기반 HI 추출 방법론은 비지도학습과 지도학습의 두 가지 방법론으로 구분된다. 비지도학습 방법론은 먼저 장비의 전체 생애주기를 모델에 학습한다. 이후 정상 운전 구간에서 수집된 센서 신호만을 사용해 Encoder-Decoder 모델을 학습시킨다. 학습된 모델에 열화 구간의 데이터를 입력하면, 정상 패턴만 학습된 신경망은 열화 구간 데이터를 완벽하게 재구성하지 못해 재구성 오차가 크게 발생한다. 이를 위해 선행 연구들은 정상 운전 구간의 센서 데이터를 학습한 후, 열화 구간의 데이터를 테스트 데이터로 입력하여 정상 구간과의 복원오차를 계산하였다. 이는 열화가 진행될수록 입력 데이터의 분포가 학습된 정상 구간과 달라지기 때문에, 복원 오차를 열화의 진행 정도로 사용한 것이다. 이렇게 발생한 재구성 오차를 유사성과 상관관계 거리 기반 방식으로 정량화하여 HI를 추출한다. 장비 열화는 일반적으로 시간 의존적인 동적 특성을 가지므로, 이러한 방식은 시계열 데이터를 다루는 데 효과적이다. Yu et al.(2019)은 Bi-LSTM 기반 Encoder-Decoder 모델을 이용하여 시계열 센서 데이터의 특성을 반영한 복원 오차 기반 HI를 제안하였다. 또한 González-Muñiz et al.(2022)은 기존의 입력 벡터 단의 재구성 오차 대신, 잠재 공간(latent vector)에서의 재구성 오차를 이용하여 HI를 추출하는 방법을 제안하였다. Xu et al.(2023)은 Decoder에 Self-Attention 메커니즘을 도입하고, 그 입력으로 Encoder의 은닉층 출력을 사용함으로써 센서 데이터의 품질을 개선하였다.

하지만 비지도학습 기반 HI 추출 방식은 정상 운전 구간의 데이터만 학습하기 때문에, 이 구간에 노이즈나 이상치가 포함되어 있을 경우 이를 정상 패턴으로 학습하게 되어 복원 기준이 높아질 수 있다. 이로 인해 열화 구간과 정상 구간 간의 복원 오차 차이가 줄어들며, 결과적으로 HI의 성능이 저하되는 한계가 존재한다.

지도학습 기반 방법론은 Encoder - Decoder 구조의 병목구

Table 1. Related Works

Author	Methodology		DF	Contribution
	Supervised	Unsupervised		
Yu <i>et al.</i> (2019)		✓	-	Reflect the characteristics of equipment degradation over time
Gonzalez-Muniz <i>et al.</i> (2022)		✓	-	Latent Vector-Based HI Extraction
Yen <i>et al.</i> (2022)		✓	-	Leveraging Elbow Points to Identify Equipment Failure Stages
Xu <i>et al.</i> (2023)		✓	-	Apply the Self-Attention mechanism to the Decoder
Chen <i>et al.</i> (2021)	✓		QDF	Suggest LDF, QDF, and SPDF based on the laws of human aging
Qin <i>et al.</i> (2023)	✓		PDF	Supplementing QDF by setting parameters in the degradation assumption function
Zhu <i>et al.</i> (2023)	✓		SDF	Divide the equipment's lifecycle into four equal parts
Li <i>et al.</i> (2024)	✓		Exponential Function	DF with RMS statistic applied to an exponential function

간(bottleneck)에서 DF를 추가 손실 항 보조적으로 활용하여, 잠재 표현(Latent vector)이 잠재 표현이 DF가 정의한 열화 패턴에 부합하도록 제약함으로써 노이즈에 강건한 HI를 추출할 수 있다. 특히, 장비의 복잡한 작동 환경과 비선형적인 열화 패턴을 반영할 수 있어 HI 추출에서 폭넓게 응용되고 있다(Zhou *et al.*, 2024). 지도학습 기반 HI 추출 방식은 DF를 통해 가상의 HI를 생성하고, 이를 모델의 학습에 보조적으로 활용한다. Chen *et al.*(2021)은 DF(Degradation Function)를 라벨로 적용함으로써, DCAE(Deep Convolutional Auto-Encoder) 모델이 센서 데이터 내 열화와 직접 관련된 패턴만을 학습하고, 불필요한 노이즈 성분의 영향을 억제하여 보다 안정적인 HI를 추출할 수 있음을 보였다. Qin *et al.*(2023)은 HI 추출에서 원시 데이터 뿐만이 아닌 공간적인 특징까지 고려한 시공간 모델을 제안하여 시공간적 관점에서의 열화 패턴을 추출하고자 했다. Li *et al.*(2024)는 고주파수 진동 신호 기반의 장기 시계열 데이터를 대상으로, 기존 DCAE 모델에 Transformer 구조를 결합하여 HI 추출 성능을 향상시켰다. Transformer는 장기 시계열의 시간 의존성을 효과적으로 학습할 수 있기 때문에, 진폭 기반 열화 신호에서 발생하는 복잡한 열화 경향을 보다 정밀하게 반영할 수 있다. 이는 신경망의 특징 추출 능력을 개선하는 것이 HI 성능 개선에 기여함을 의미한다. 또한, 원시 센서 데이터를 RMS(Root Mean Square) 통계량으로 변환하여, 시간 축에 따라 점진적으로 변화하는 열화 양상을 지수 함수 형태의 DF를 구성하였다. 이러한 접근은 기존 선형적 DF보다 실제 열화 경향에 가까운 정답 신호를 제공함으로써, HI 추출의 정확도를 향상시키는 데 목적이 있다.

비지도학습 기반 HI 추출은 학습 데이터와 테스트 데이터 간 열화 양상의 차이로 인해 성능 저하가 발생할 수 있으며, 지도학습 방식은 이러한 문제를 완화하면서도 센서 데이터의 비선형성을 효과적으로 모델링할 수 있다는 강점을 가진다. 다만, DF를 장비의 열화 양상과 다르게 설정한다면, 모델이 실제

열화 패턴을 반영하지 못해 성능 저하가 발생할 수 있다. 따라서 보다 정밀한 HI 추출을 위해서는 장비의 열화 특성을 반영한 적절한 DF의 설계가 필요하다. 단순한 선형 또는 비선형 DF로는 장비의 열화 패턴을 반영하기 어렵다.

본 연구는 기존의 정적 DF 설계 한계를 보완하고자, 고장 단계를 기반으로 동적으로 정의된 FSDF를 제안한다. 제안된 FSDF는 실제 장비의 열화 패턴을 더 정밀하게 반영하여, 고성능의 HI 구축을 가능하게 한다.

2.2 가정 함수에 대한 수학적 배경

지도학습 기반으로 HI를 추출할 때 DF는 장비의 열화 특징과 DF의 연관성을 학습하여 추출된 HI가 단조롭고 시간의 흐름에 따라 감소 및 증가하는 상관성을 보장해준다(Zhou *et al.*, 2024; Chen *et al.*, 2021; Qin *et al.*, 2023). 그러나 장비의 열화 특징을 담고 있지 않는 DF는 센서의 열화 특징과 가정함 간의 연관성을 학습하지 못해 제대로 된 HI 추출을 할 수 없으며, 추출된 HI도 학습 과정 중 정보 손실이 발생하여 장비의 상태를 진단할 수 없다. Chen *et al.*(2021)은 장비에 대한 DF를 인간의 노화 법칙에 영감을 받아, <Figure 1>과 같은 세 가지의 DF를 제안했다.

<Figure 1>의 (a)는 선형 DF(Linear Degradation Function, LDF)로 장비의 열화가 작동 시점부터 선형 감소의 비율로 감소하는 것이고, (b) DF는 이차 DF(Quadratic Degradation Function, QDF)로 장비의 작동 초기 시점에는 열화 감소율이 낮으나, 시간의 흐름에 따라 성능 저하 속도가 저하 속도가 증가하는 것을 의미한다. 마지막으로 (c)는 장비가 작동하여 특정 시점까지는 장비의 열화가 없다가 특정 시점부터 열화가 발생한다는 단일 지점 DF(Single Point Degradation Function, SPDF)이다. 이 세 가지 DF의 수식은 다음과 같다(Chen *et al.*, 2021).




Figure 1. Degradation Functions by Equipment Degradation Characteristics

$$f(t_i) = -\left(\frac{1}{t_n} * t_i\right) \quad (1)$$

$$f(t_i) = -\left(\frac{1}{t_n^2} * t_i^2\right) \quad (2)$$

$$f(t_i) = \begin{cases} 1 & , t_i \leq t_j \\ \left(\frac{1}{t_j - t_n}\right) * t_j + \left(\frac{t_n}{t_n - t_j}\right) & , t_i > t_j \end{cases} \quad (3)$$

식 (1)의 t_n 은 장비의 전체 수명이며, t_i 는 장비의 현재 시점이다. 식 (3)에 있는 t_j 는 장비의 초기 성능 저하 시점으로 t_j 시점 전까지는 장비의 열화가 발생하지 않음을 의미한다. 이 세 가지 DF는 모두 데이터 학습 과정에서 시간이 지남에 따라 장비의 성능이 지속적으로 감소하도록 한다. 하지만 (a)는 장비의 열화 패턴이 선형적이며, 시간의 흐름에 따라 일정한 성능이 저하되거나 일반적인 장비의 성능 저하 법칙에 위배 된다(Li *et al.*, 2024). (a)의 한계점을 보완하고자 (b)와 같은 2차 함수의 DF가 제안되었다. (b)는 장비의 초기 성능 저하가 완만하다는 점에서 장비의 성능 저하 법칙에 부합한다(Bajarunas *et al.*, 2024). 그러나, 실제 장비 성능이 특정 시점 이후 급격히 저하되는 패턴을 충분히 반영하지 못한다(Bajarunas *et al.*, 2024). 마지막으로(c)는 장비가 특정 시점까지는 정상 성능을 유지하나 그 시점 이후부터 성능이 감소한다는 DF다. 장비의 성능이 특정 시점부터 감소한다는 것은 도메인 영역에 따라 중요하다. 하지만 장비의 열화가 발생하는 특정 시점을 추정한다는 것은 도메인 지식이나, 장비의 센서 데이터의 종류에 따라 달라지며, 이를 특정하는 데 어려움이 있다. 또한, 도메인 지식으로 장비의 성능 저하 시점을 추정한다고 하더라도 그 이후 장비의 성능 저하의 패턴을 선형적으로 감소한다는 한계가 존재한다.

Qin *et al.*(2023)은 2차 함수 기반의 DF가 장비의 특정 시점 이후 급격한 성능 저하 패턴을 반영하는 데 한계가 있어 이를 보완하기 위해 파라미터 DF(Power Degradation Function, PDF)을 제안했다. 이 DF는 앞서 언급한 수식(4)의 차수를 변경하여 기계 성능 저하 과정을 더 유연하게 표현하고 특정 형태 제약을 부과하고자 했다(Qin *et al.*, 2023). Qin *et al.*(2023)이 제안한 파라미터 DF는 다음과 같다:

$$f(t_i) = -\left(\frac{1}{t_n^\alpha} * t_i^\alpha\right) \quad (4)$$

Qin *et al.*(2023)에 의하면 1차 함수 이상의 DF를 사용하면 장비의 초기 성능 저하가 비교적 완만하지만, 시간이 지남에 따라 급격한 성능 저하가 발생한다는 장점이 있으며, 각 장비의 성능 저하 속도에 맞게 α 를 설정할 수 있어 유연한 모델 설정이 가능하다(Qin *et al.*, 2023). 그러나 이러한 DF 역시 QDF와 마찬가지로 급격한 성능 저하 패턴을 완벽하게 반영하지 못하며, 파라미터의 수치에 따라 성능 저하 모델링의 정확도가 달라질 수 있다.

Li *et al.*(2024)은 지도학습 기반 HI 추출에서 실제 데이터를 바탕으로 가정된 함수를 사용하는 것이 장비의 성능 저하 패턴을 더 잘 반영할 수 있다고 했다. 특히, RMS(Root Mean Square) 값을 지수함수에 적용하여 HI를 추출하면 장비의 열화 패턴을 보다 정확하게 추출할 수 있다고 했다(Li *et al.*, 2024). 다만, RMS 통계량을 지수함수에 적용하는 과정에서 지수함수의 파라미터 설정에 따라 정보 손실이 발생할 수 있으며, 장비의 열화가 급격해지는 지점을 반영할 수는 없다.

장비의 열화 패턴은 장비 특성이나 운영 환경에 따라 다르게 나타난다. 그러나, 선행 연구들은 주로 선형 혹은 비선형 형태의 단순한 DF를 설정했다. 실제 열화 패턴과 다른 DF는 모델의 학습 난이도를 올린다. 보다 효과적인 HI 추출을 위해서는 DF가 실제 열화 패턴에 의존하여 설계되어야 한다. 본 연구에서는 장비의 고장 단계를 식별하여 식별된 고장 단계를 고려한 FSDF를 설계하여 장비와 DF를 이용한 HI 추출에서의 학습 난이도를 낮추고 실제 장비의 열화 패턴을 고려한 HI가 추출되도록 했다.

2.3 고장 단계 연구

지도학습 기반의 HI를 추출할 때 DF와 센서 데이터 간의 연관성을 학습하기 위해 DF에 관한 연구 외에 장비의 고장 법칙을 기반으로 한 장비의 고장 단계 연구가 이뤄졌다(Zhu *et al.*, 2023; Yan *et al.*, 2022; Ni *et al.*, 2023; Yan *et al.*, 2023). 장비의 고장 단계란 장비의 작동부터 고장까지 단계를 구분하여 특정 시점부터 장비의 성능 저하가 급격해지는 것을 구분하는 것이며, Yan *et al.*(2022)은 장비의 단계를 총 3단계로 구분했다.

Yan *et al.*(2022)이 제안한 장비의 고장 상태는 Stage I, Stage III, Stage III로 구분되는데, 이 중 Stage I과 Stage III는 Good Condition과 Slow Degradation으로 Nominal Condition에 해당

하고 장비의 성능 저하가 급격하게 진행되지 않은 상태이다. 반면에 StageⅢ은 Accelerated Degradation 단계로 장비의 성능 저하가 급격하게 발생하여 결국에는 고장까지 이르는 단계이다. 각 고장 단계를 구분하는 방법으로는 센서 데이터의 RMS 통계량을 구해서 데이터의 비정상적인 변동 시점(Elbow point) 찾아내는 것이다. 데이터의 Elbow point를 찾아내는 것은 장비의 작동 상태에 따라 그 존재 여부가 달라진다. 또한, 장비의 고장 단계를 3단계로 나누기 위해서는 2개의 Elbow point가 필요한데, 장비의 고장 패턴에 따라 Elbow point의 개수는 달라진다. 즉, 센서 데이터에서 Elbow point를 찾아 고장 단계를 추정하는 방법은 장비의 작동 환경과 고장 패턴에 따라 제한적으로 사용할 수 있다.




Figure 2. Equipment Degradation Fault Stage

장비의 고장 단계를 기반으로 HI DF를 제안한 연구는 Zhu *et al.*(2023)의 연구이다. Zhu *et al.*(2023)은 기존 Yan *et al.*(2019)가 나누는 3단계 고장 단계를 Health stage, Weak fault stage, Serious fault stage와 Failure stage 4단계로 확장하고 장비의 생애주기를 균등하게 4등분하여 각 단계의 HI 수치를 100, 95, 85, 50, 0으로 설정했다. <Figure 2>에서 볼 수 있듯이 장비의 고장 단계를 세분화하면, 복잡한 열화 패턴을 고려할 수 있다. Zhu *et al.*(2023)이 제안한 세분화 DF(Segmented Degradation Function)은 기존 선형 DF보다 적은 Loss로 센서 데이터와의 학습이 가능했다. 이는 장비의 고장 단계를 고려한 DF로 HI를 추출하는 것이 효과적임을 입증했다. 하지만 Zhu *et al.*(2023)은 장비의 고장 단계를 식별하지는 않았다. 학습 라벨 설계 시, 고장 단계 구간에 기반하여 DF를 정의하고 각 구간별로 상이한 라벨 값을 부여한 DF를 사용할 것을 제안한다.

3. 제안 방법론

본 논문의 HI 추출 프로세스는 <Figure 3>과 같으며, 제안하는 방법론은 크게 두 가지로 구성된다. 먼저 장비의 고장 단계를 식별하는 방법에 대해 설명한다. 두 번째로 본 논문에서 제안한 FSDF 설계에 대해 설명한다. 이 과정에서 사용되는 주요 수학적 기호는 <Table 2>에 정리되어 있다.

Table 2. Nomenclature

Notration	Description
y_t	Measurements from sensor data t
x	Time index of collected sensor data
T	Total data length of collected sensors
τ_i	When a changepoint changes the failure stage
K	Number of failure stages detected
$C(\cdot)$	Specific failure stage intervals $[\tau_{i-1}, \tau_i]$
λ	Penalty values to control the number of failure steps
ϕ_i	Initial values for specific failure stages
a_i, b_i	Start and end points within a failure phase
L_i	Length of a specific failure phase
$\sigma(z_i)$	Sigmoid functions
z_i	Relative position of at each failure stage with $\frac{t - \tau_{i-1}}{\tau_i - \tau_{i-1}}$
$HI(x)$	HI at a specific time x
X^i	Multiple sensor data from a single instrument
x_i^i	The i -th value of the sensor data
$H(t_n)$	HI value at time t_n
$H_T(t_n)$	Average trend of HI
$H_R(t_n)$	Residuals of HI
$dH_T(t_n)$	Average trend difference in HI
\bar{H}	Average of HI
ξ	Normalization factor for exponential reduction
$Loss_{DF}$	Loss of potential backers and DFs
$Loss_{recon}$	Loss of input data and reconstruction data
DF_i	Index of Degradation Function used for learning
Z_i	Index of Encoder Decoder latent vector




Figure 3. Failure Stage Degradation Function HI Construction Process

3.1 고장 단계 함수

본 절에서는 장비의 고장 단계를 데이터 기반으로 식별하고, 이를 활용한 고장 단계 함수(Failure Stage Degradation Function, FSDF) 설계 방법을 설명한다. 기존 연구에서는 고장 단계를 수동으로 설정하거나 사전 정의된 기준에 따라 구분하였지만, 본 연구는 변화점 탐지 기반 접근을 통해 실제 센서 데이터에서 고장 단계를 자동으로 식별하고, 이를 기반으로 고장 단계별 DF를 구성하는 절차를 제안한다.

고장 단계를 자동으로 식별하기 위한 변화점 탐지(change point detection) 기법으로는 Binary Segmentation, Bottom-up, Dynamic Programming(DP), KernelCPD 등의 방법이 사용되어 왔다.

Binary Segmentation은 시계열을 반복적으로 이분 분할하여 탐지하는 방식이지만, 초기 분할 조건에 민감하며 인접한 변화점을 탐지하지 못하거나 과도하게 분할하는 한계가 있다(Cho *et al.*, 2016). Bottom-up 방식은 초기 구간을 세분화하고 병합하는 방식으로 연산은 빠르지만, 복잡한 열화 패턴에서는 병합 기준이 불안정해 탐지 정확도가 낮다(Samaneh *et al.*, 2016). DP는 탐지 정확도는 높지만 시간 복잡도가 $O(n^2)$ 로 매우 커서 대규모 시계열에는 비효율적이다. Kernel CPD는 커널 기반 탐지를 통해 비선형 변화를 포착할 수 있지만, 커널 설정에 민감하고 계산 비용이 높다(Samaneh *et al.*, 2016).

PELT(Pruned Exact Linear Time)는 비용 함수 기반의 전역 최적 분할을 수행하면서도, pruning 전략을 통해 연산량을 줄여 선형 시간 복잡도 $O(n)$ 를 달성할 수 있다. 또한, 다수의 변화점을 자동으로 탐지할 수 있으며, 복잡한 패턴의 센서 신호에서도 변화 시점을 안정적으로 식별할 수 있다는 장점이 있다(Killick *et al.*, 2021). 복잡한 센서 패턴에서도 변화 시점을 안정적으로 식별할 수 있어, 고장 단계의 경계 시점을 정밀하게 추정하려고 본 연구에서 사용하였다.

구체적인 절차는 다음과 같다: 먼저, Savitzky - Golay 필터를 적용하여 센서 데이터를 스무딩하고, Min - Max Scaling을 통해 데이터를 0~1 범위로 정규화하였다(Shi *et al.*, 2021). 이후, 정규화된 시계열 데이터에 대해 PELT 알고리즘을 적용하여 변화점을 탐지하고, 탐지된 시점을 고장 단계의 경계로 정의하였다. PELT는 사용자가 설정한 패널티 항(penalty term)을 기반으로 각 구간의 비용 함수(RBF)를 최소화하면서 변화점을 탐색하며, 이를 통해 고장 단계를 자동으로 식별하고, 이후 단계별로 DF를 구성한다. PELT의 수식은 식 (5)에 제시되어 있다(Killick *et al.*, 2012).

$$\min_{K, \{\tau_i\}} \left[\sum_{i=1}^K C(y_{t_{\tau_{i-1}+1} : \tau_i}) + \lambda \cdot K \right], 0 = \tau_0 < \tau_1 < \dots < \tau_K = T \quad (5)$$

수식 (5)의 $C(y_{t_{\tau_{i-1}+1} : \tau_i})$ 는 각 고장 단계에서의 모델 비용을 나타내며, λ 는 패널티로 고장 단계의 개수 K 가 증가할 때 발생하는 추가 비용을 조정하는 역할을 한다.

현실 세계에서 고장 단계에 따른 장비의 HI 지수를 아는 것은

어렵다. 그렇기에 고장 단계 DF를 만들 때 식별된 고장 단계의 수치를 알 수 없어 FSDF를 설정하기는 어렵다. 하지만, DF의 시작점과 끝 지점을 1과 0으로 설정할 수 있기에 시그모이드 함수를 사용하면 고장 단계 DF를 사용할 수 있다. 이는 고장 단계가 진행됨에 따라 시스템 성능이 점진적으로 열화됨을 감소 형태로 표현하는 방식이다. 즉, 각 고장 단계 사이를 시그모이드 함수로 이어주면 장비의 고장 단계에 근사한 형태의 DF를 설정할 수 있다. 시그모이드 함수는 다음과 같이 정의할 수 있다:

$$\sigma(z_i) = \frac{1}{1 + e^{-z_i}} \quad (6)$$

변화점 τ_i 가 발견되면 구간 $[\tau_{i-1}, \tau_i]$ 마다 시그모이드 함수를 적용한다. 단계별 고장 단계를 연결한 수식은 수식 (7)과 같다.

$$HI(x) = \begin{cases} \phi, & \text{if } L_i \leq 0 \\ b_i, & \text{if } L_i = 0 \\ a_i + (b_i - a_i)(\sigma(\alpha(2z_i - 1)) - \sigma(-\alpha)), & \text{if } L_i > 2 \text{ and } x \in [\tau_{i-1}, \tau_i] \end{cases} \quad (7)$$

이로써 각 고장 단계별 FSDF가 완성되며, 이는 모델이 장비의 실시간 상태 변화를 학습하는 데 사용된다.

3.2 HI 추출 절차

FSDF를 이용한 HI 추출 절차는 앞서 언급한 <Figure 3>과 같다.

- 1) 장비의 작동 특성을 분석하기 위해서는 하나 이상의 생애 주기(Run to Failure, RtF) 단위의 원시 센서 데이터를 확보해야 한다. 이 데이터는 압력, 온도, 진폭 등 다양한 물리량으로 구성되며, 각 RtF를 기준으로 정렬된 시계열 형태의 다변량 센서 데이터로 구성된다.
- 2) 이후 장비에서 다양한 열화 패턴 특징을 확보하기 위해 Time Domain Feature로 변환한다. 본 논문에서 사용한 Time Domain Feature는 <Table 3>과 같다:

Table 3. Time Domain Feature

Notation	Description
Mean	$\frac{1}{n} \sum_{i=1}^n x_i$
Standard Deviation	$\sqrt{\frac{1}{n} \sum_{i=1}^n x_i - \mu}$
Median	$\begin{cases} x_{(\frac{n+1}{2})}, & \text{if } n \text{ is odd} \\ \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2}, & \text{if } n \text{ is even} \end{cases}$
Peak	$\max x(i) $
Root Mean Squares (RMS)	$\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
Root Amplitude	$\frac{1}{n} \sqrt{\sum_{i=1}^n x_i }$
Root Sum of Squares	$\sqrt{\sum_{i=1}^n x_i^2}$

센서 데이터는 정해진 주기로 수집된다. 초로 수집되는 센서 데이터의 경우 그 Raw Data의 양이나 노이즈로 인하여 데이터 분석에 있어 어려우며, 의사결정에 적절하지 않은 주기이다. 적절한 의사결정을 위해 초로 수집되는 데이터를 시간 단위로 구성했으며, 이 과정에서 데이터의 통계량을 구해 여러 특징을 파악할 수 있다. <Table 3>의 수식들은 데이터의 노이즈를 줄이고 데이터의 변동성을 파악할 수 있는 시간 통계량이다.

- 3) 앞서 제안한 CPD를 사용하여 장비의 고장 단계를 식별한다. 장비의 고장 단계는 $X_t^i = \{x_t^i \mid \tau_{j-1} + 1 \leq t \leq \tau_j\}$, $j=1, 2, \dots, k$ 가 된다. 즉, 하나의 RtF에서 고장 단계는 다음의 수식처럼 표현된다:

$$X^i = \begin{cases} X_1^i = [x_{\tau_1+1}^i, \dots, x_{\tau_1}^i]^T, & \text{Stage 1} \\ X_2^i = [x_{\tau_2+1}^i, \dots, x_{\tau_2}^i]^T, & \text{Stage 2} \\ \vdots \\ X_K^i = [x_{\tau_{K-1}+1}^i, \dots, x_{\tau_K}^i]^T, & \text{Stage } K \end{cases} \quad (8)$$

식 (8)은 τ 에 의해 구분된 장비 하나의 RtF에서 고장 단계이다. 첫 고장 단계는 $\tau_1=0$ 부터 τ_1 이며, 두 번째 단계는 τ_1 부터 τ_2 이고, 마지막 단계는 τ_{k-1} 부터 $\tau_k=t$ 로 구분된다.

본 논문에서는 초 단위로 수집된 센서 데이터를 시간 단위로 변환한 후, 장비의 고장 단계를 효과적으로 식별하기 위해 다양한 시계열 통계량 중 Root Mean Square(RMS)는 고장 단계 식별에 사용된 주요 feature로 선정했다. RMS는 센서 데이터의 제공 평균의 제공근을 계산함으로써 신호의 에너지와 변

동성을 반영하는 지표이며, 물리적 변화가 중요한 시스템에서 상태를 정량적으로 표현하는 데 유용하다. 특히, RMS는 제공 기반 계산으로 항상 양수 값을 유지하며, 센서의 전체적인 크기와 에너지 수준을 안정적으로 나타낼 수 있어, 장비의 점진적 열화 과정을 모니터링하는 데 효과적이다. 실제 선행 연구들에서도 RMS는 신뢰성 있는 고장 지표로 활용되어 왔으며, HI 추출 또는 지수 기반 DF 모델의 입력으로 사용되었다(Chen et al., 2021; Li et al., 2024). 본 연구에서는 RMS 값을 기반으로 Savitzky - Golay 필터를 결합하여 고장 단계를 식별하였으며, 필터의 파라미터는 시퀀스 길이 50, 다항식 차수 3으로 설정하였다.

이전 단계를 통해 식별된 고장 단계를 바탕으로 고장 단계별 열화 정도를 함수 형태로 정의하여 HI 추출 DF를 설계한다. 각 고장 단계마다 시그모이드 함수를 적용하여 각 고장 단계를 정의한다. 본 논문에서 사용한 시그모이드 함수의 값은 2로 설정하여 각 고장 단계를 부드럽게 연결하여 장비의 센서 데이터와 FSDF 간의 연관성을 학습할 수 있게 했다.

본 논문에서는 고장 단계 DF로 HI를 추출할 때 사용한 모델은 <Figure 5>에 있는 기본 Auto-Encoder이다. Auto-Encoder는 입력 데이터를 효율적으로 압축하고 특징을 학습함으로써 장비의 열화 상태를 표현하는 데 적합한 모델이다. Auto-Encoder에서 HI 추출을 하기 위해 센서 데이터와 DF의 학습은 아래 수식 (9)와 같이 이뤄진다.

$$Loss = w_1 * \frac{1}{N} \sum_{i=1}^N \|Z_i - DF_i\|^2 + w_2 * \frac{1}{N} \sum_{i=1}^N \|X - \hat{X}\|^2 \quad (9)$$




Figure 4. Auto-Encoders for HI Construction

Auto-Encoder에 장비의 센서 데이터가 입력되면, 차원 축소를 거쳐 1차원의 Z (Latent Vector)에서 DF와의 손실을 계산하며, 센서 데이터가 DF와의 연관성을 학습할 수 있도록 한다. 이후 장비의 센서 데이터와 DF에 과도하게 적합되는 현상을 방지하기 위해 재구성 손실을 추가적인 로스항에 추가하여 학습한다. 이를 통해 고장 단계별 HI를 효과적으로 생성하고 분석할 수 있으며, Chen *et al.*(2019), Zhu *et al.*(2023), Duan *et al.*(2023), Qin *et al.*(2023) 등 다양한 연구에서 모델에 집중하여 HI를 추출한 것과 다르게 DF를 통한 HI 추출의 성능을 파악했다.

4. 실험 결과

4.1 적용 대상

본 연구에서 사용한 데이터는 실제 대한민국 국군에서 운용 중인 무기체계의 하부 장비로부터 수집된 것이다. 무기체계는 여러 하부 장비로 구성된 복합적인 시스템으로, 그 구조가 복잡하고 센서 데이터는 비선형적인 특성을 지닌다. 이러한 특성으로 인해 하부 장비의 센서만을 이용하여 HI(Health Indicator)를 추출할 경우, 장비의 성능 저하 패턴을 온전히 반영하기 어렵다. <Figure 5>는 본 연구에서 사용된 장비의 센서

데이터를 시계열로 시각화한 것으로, 검은색 수직선은 실제 정비 일자를 나타내며, 이는 고장 시점을 의미한다. 냉매 온도, 냉매 공급 온도, 냉매 회수 온도, 냉매 저압 압력, 냉매 고압 압력 등의 센서 데이터를 통해 각 변수별로 장비의 열화 패턴이 나타나는 것을 확인할 수 있다. 본 연구에서는 고장 시점을 기준으로 RtF를 정의하여, 세 개의 운용 사례(KWS-001, KWS-002, KWS-003)를 실험에 사용하였다.

따라서 장비의 성능 저하와 고장 패턴을 정확히 분석하기 위해서는 개별 하부 장비와 연관된 다양한 센서 정보를 통합하여 데이터셋을 구축하고, 이를 바탕으로 HI를 추출하는 접근이 필요하다. 이러한 방식은 장비 상태를 보다 신뢰성 있게 예측하고, 효과적인 유지보수 전략을 수립하는 데 기여할 수 있다. 더불어, 복잡하고 비선형적인 열화 과정을 정량적으로 모델링하는 데도 효과적이다. HI를 추출하기 위해서는 장비의 생애주기 데이터를 학습하여 모니터링하려는 데이터를 모델에 입력해야 한다. 모니터링하고자 하는 데이터 이전 생애주기 데이터를 학습하여 모니터링 장비의 데이터를 신경망으로 훈련해야 현재 장비의 상태를 파악할 수 있다. 본 연구에서는 무기체계의 HI 추출은 선행 생애주기 RtF1을 학습해서 이후의 생애주기인 RtF2와 RtF3를 테스트한다.

HI는 단조롭고, 시간과의 선형성을 가지며, 견고해야 한다. HI




Figure 5. Weapon System Sensing Data

의 성능을 평가하기 위해서는 두 가지의 방법이 있다. 하나는 추출한 HI에 다항식 피팅 방법을 적용하여 평가하는 방식이 있다. 다른 하나는 추출된 HI를 이용하는 방법이다. 다항식 피팅 방법을 사용하는 방식은 추출된 HI를 평균 추세와 잔차로 구성된다. 다항식 피팅 수식은 다음과 같다(Chen *et al.*, 2021):

$$H(t_n) = H_T(t_n) + H_R(t_n) \quad (10)$$

수식 (10)의 $H(t_n)$ 은 시점의 HI값을 의미하고, $H_T(t_n)$ 은 평균 추세와 $H_R(t_n)$ 은 잔차를 의미한다. 본 연구에서는 추출된 HI의 성능을 종합적으로 평가하기 위해 기존 선행 연구(Chen *et al.*, 2019; Qin *et al.*, 2023)에서 널리 채택된 세 가지 지표인 Monotonicity(Mon), Correlation(Cor), Robustness(Rob), Composite Index(CI)를 사용했으며 수식은 아래와 같다(Chen *et al.*, 2019; Qin *et al.*, 2023):

$$Mon(H) = \frac{1}{3} \left(\frac{|\sum_{j=1}^J S(dH_T(t_j))|}{J-1} + \frac{|\sum_{j=1}^J S(dH_T(t_{j+2}) - H_T(t_j))|}{J-2} + \frac{|\sum_{j=1}^J S(dH_T(t_{j+3}) - H_T(t_j))|}{J-3} \right) \quad (11)$$

$$Cor(H, T) = \frac{1}{3} \left(\frac{\sum_{j=1}^J (H(t_j) - \bar{H})(t_j - \bar{t})}{\sqrt{\sum_{j=1}^J (H(t_j) - \bar{H})^2 \sum_{j=1}^J (t_j - \bar{t})^2}} \right) \quad (12)$$

$$Rob(H) = \exp\left(-\frac{\xi}{J} \sum_j \left| \frac{H_R(t_k)}{\max(H_T) - \min(H_T)} \right| \right) \quad (13)$$

$$CI = 0.4 * Mon + 0.3 * Cor + 0.3 * Rob \quad (14)$$

수식 (11)은 HI가 열화 진행에 따라 지속적으로 감소하는지를 측정함으로써, HI의 단조성(Monotonicity)을 평가한다. 수식 (12)는 HI와 시간 간의 선형 관계를 기반으로, 시간 경과에 따라 HI가 얼마나 일관된 감소 추세를 가지는지를 나타내는 상관성(Correlation)을 측정한다. 한편, 수식 (13)은 HI의 강건성(Robustness)을 평가하는 지표로서, 추출된 HI가 센서 노이즈나 외란에 의해 얼마나 영향을 받는지를 정량적으로 판단한다. 따라서 이와 같은 평가지표는 HI의 성능을 단조성, 선형성, 노이즈 민감도 측면에서 다각도로 평가할 수 있도록 설계되었으며, 이를 바탕으로 최종적으로 종합 성능 지표인 CI(Composite Index)를 계산하여 HI의 전반적인 품질을 정량

적으로 비교 평가할 수 있다.

앞서 언급했듯이, 지도학습 방식으로 HI를 추출할 때 센서 데이터와 DF 간의 연관성을 학습하게 된다. 훈련 과정 중 센서 데이터와 DF 간의 손실은 센서 데이터와 DF 간의 연관성이 잘 나타내고 있는지를 확인할 수 있다(Zhu *et al.*, 2023). 본 논문에서는 수식 (9)의 훈련 과정 중에서 손실을 평가지표로 활용하여, 장비의 열화 패턴을 반영한 DF가 센서 데이터와의 낮은 손실로 학습되는지를 확인했다.

4.2 HI 추출 성능 평가

실험 결과는 다음 순서로 제공된다: 1) 식별된 FSDF와 기존 DF를 시각적으로 비교한다. 2) 추출한 HI의 성능을 정량적으로 비교한다. 3) 추출한 HI의 성능을 시각적으로 비교한다.

본 연구에서 제안하는 방법론으로 HI를 추출하기 위해서는 Train 데이터의 고장 단계를 식별하고 이를 기반으로 FSDF를 설계해야 한다. 본 연구에서는 데이터의 스케일 문제를 완화하기 위해 자연로그를 취했다. 센서 데이터는 비선형적인 증가 또는 감소 패턴을 보이며, 이러한 비선형적 특성은 분석 및 고장 단계 구분에서 복잡성을 초래한다. 자연로그를 취함으로써 데이터의 변동성을 줄이고자 했다.

본 연구에서는 장비의 고장 단계를 식별하기 위해 온도 데이터를 핵심 feature로 선정하였다. 이는 무기체계 하부 장비의 작동 특성상, 온도 변화가 장비의 물리적 열화 및 이상 작동과 직접적으로 연결되기 때문이다. 또한, 다수의 센서가 온도의 변화에 민감하게 반응하며, 온도는 다른 센서들의 반응 특성을 결정짓는 근본 요인 중 하나로 작용한다. 따라서 본 연구에서는 온도를 기준으로 고장 진행 단계를 정의하였으며, 이는 고장 패턴의 명확한 구분과 FSDF(Failure Stage Degradation Function) 설계의 기반이 된다. <Figure 6>은 학습 데이터의 고장 단계를 식별한 결과이다. <Figure 6>의 빨간색 점선은 장비의 열화 구간과 고장 단계를 나타낸다. 식별된 고장 단계는 FSDF를 설계하기 위한 기초 데이터로 활용되며, 장비의 성능 저하 및 고장 진행의 단계를 의미한다. 이 과정에서 고장 단계는 기존의 방식보다 더욱 직관적으로 열화 과정을 반영할 수 있다.

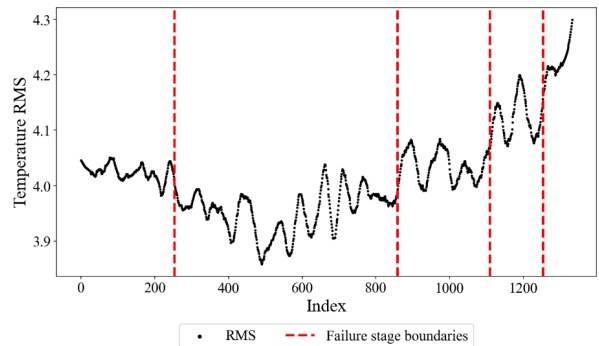


Figure 6. Failure Stage Identification

<Figure 7>은 본 연구에서 제안한 FSDF와 기존 DF를 학습 데이터에 적용한 결과이다. LDF의 경우 초기부터 일정한 기울기로 성능이 단조롭게 감소하지만, 실제 장비의 열화 특성은 더 복잡하여 이를 충분히 반영하지 못할 수 있다. QDF 특정 구간에서는 실제 열화 경향과 유사하게 보일 수 있지만, 전 구간에 걸쳐서는 복합적인 열화 요소를 모두 반영하기에 한계가 있다. SDF는 장비의 생애주기를 4등분하고 해당하는 시점의 HI값을 고정하여 DF를 생성한다. 이와 같은 가정은 실제 장비의 열화 패턴을 고려하지 않았다는 한계가 있다.

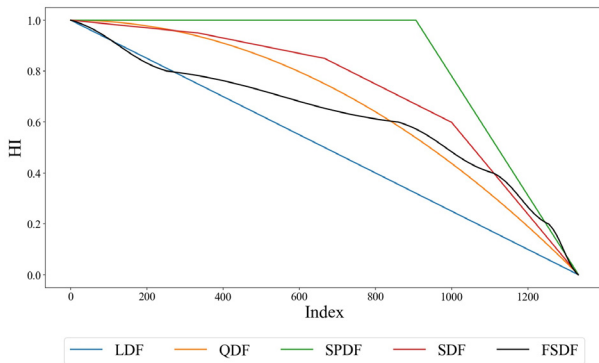


Figure 7. Application of Different DF

제안된 FSDF는 기존 DF와 달리, 시간의 흐름에 따라 일정한 기울기로 감소하는 형태가 아닌 장비의 고장 단계 특성을 반영하여 유동적으로 감소하는 특징을 갖는다. 무기체계는 단계에 따라 유동적인 감소 패턴을 가지므로, 제안하는 DF가 이러한 패턴을 반영할 수 있다.

<Table 4>는 기존에 제안되었던 HI 추출에 사용된 DF들과 본 논문에서 제안하는 FSDF를 사용한 HI 추출 결과를 요약한 것이다. DF의 비교를 위해 LDF, QDF, SPDF, 그리고 SDF를 사용하였다. 실험의 무결성을 위하여 모든 모델을 통일하였다. 실험 결과, KWS-002 Subset에서 CI를 기준으로 SPDF가 가장 낮은 HI 추출 성능을 보여주었다. 이는 <Figure 6>에서 볼 수 있듯이, SPDF의 가정이 장비의 열화가 특정 시점부터 발생한

다는 가정으로 다른 DF들의 가정과 달랐기 때문이다. 그 외 LDF, QDF, SDF, FSDF는 장비의 성능이 작동과 동시에 감소한다는 공통된 가정을 한다. 이에 따라 시간에 따른 감소 패턴을 가진다. 다만, LDF, QDF, SDF는 DF 설계에 있어 장비의 열화 패턴을 고려하지 않았기에, Mon의 수치가 FSDF에 비해 높지 않다. FSDF는 QDF에 비해 Mon을 기준으로 29.13% 성능 향상을 기록하였다. Cor 또한 개선되어 시간의 흐름에 따라 성능이 감소하는 장비의 성능 저하 범칙을 견고하게 했다. HI 종합 성능 지표인 CI에서는 QDF에 비해 14.14%의 성능 개선을 보여주었다. Loss 또한 15%의 성능 향상을 기록하면서 센서 데이터와 DF의 학습 난이도를 낮추었다.

KWS-003의 실험 결과에서 SPDF는 Mon에서 가장 낮은 수치를 기록하였는데, 이는 SPDF가 특정 지점까지 장비의 열화가 발생하지 않는다는 가정 때문인 것으로 판단된다. FSDF는 비교군 DF보다 Mon에서 25.84% 성능 개선이 있었는데, 이는 FSDF의 열화 패턴이 실제와 더욱 유사하였기에, 강건한 HI가 추출된 것으로 판단된다. 종합지수 CI에서 또한 10.55%의 성능 향상을 기록했으며, Loss에서도 16.25%의 개선을 보여 FSDF가 실제 열화와 유사한 가정을 한 것으로 판단할 수 있다.

<Figure 8>과 <Figure 9>는 기존 연구와 본 논문의 HI 추출 결과를 시각적으로 비교한 것이다. <Figure 8>의 (a)-(e)는 각각 LDF, QDF, SPDF, SDF, 그리고 FSDF를 비교한 것이다. (a)-(d)에서 추출한 HI는 공통적으로 높은 폭의 파동을 보여주었다. 이는 장비의 상태를 모니터링함에 있어 일관적이지 않은 정보를 주게 된다. 반면, FSDF는 파동의 폭이 적으며, 시간과의 상관성을 유지하고 장비의 성능 저하 범칙에 위배되지 않는 열화 패턴을 보여준다.

KWS-003의 HI 추출을 시각화한 <Figure 9>에서도 제안하는 DF와 센서 데이터의 연관성이 기존 DF보다 우수하게 학습된 것을 확인할 수 있다. 특히 SPDF로 KWS-003의 HI를 추출한 경우 FPT 가정이 실제 열화 패턴과 맞지 않아, 열화 패턴이 없는 HI가 추출되었다. 이는 HI를 추출할 때 실제와 유사한 열화 가정이 필요함을 의미한다. FSDF로 추출한 HI는 다른 DF

Table 4. Performance of Constructed HI

Subset	DF	Metric				
		Mon	Cor	Rob	CI	Loss
KWS-002	LDF	0.4996	0.8895	0.8015	0.7071	0.0083
	QDF	0.6474	0.8666	0.8123	0.7626	0.0082
	SPDF	0.2350	0.6095	0.8638	0.5359	0.0115
	SDF	0.6057	0.8018	0.8197	0.7287	0.0080
	FSDF	0.8360	0.9219	0.8649	0.8704	0.0068
KWS-003	LDF	0.6338	0.9169	0.9223	0.8049	0.0080
	QDF	0.7081	0.8860	0.9209	0.8250	0.0081
	SPDF	0.0619	0.2704	0.9581	0.3931	0.0115
	SDF	0.5551	0.7895	0.9312	0.7380	0.0081
	FSDF	0.8911	0.9225	0.9295	0.9120	0.0067

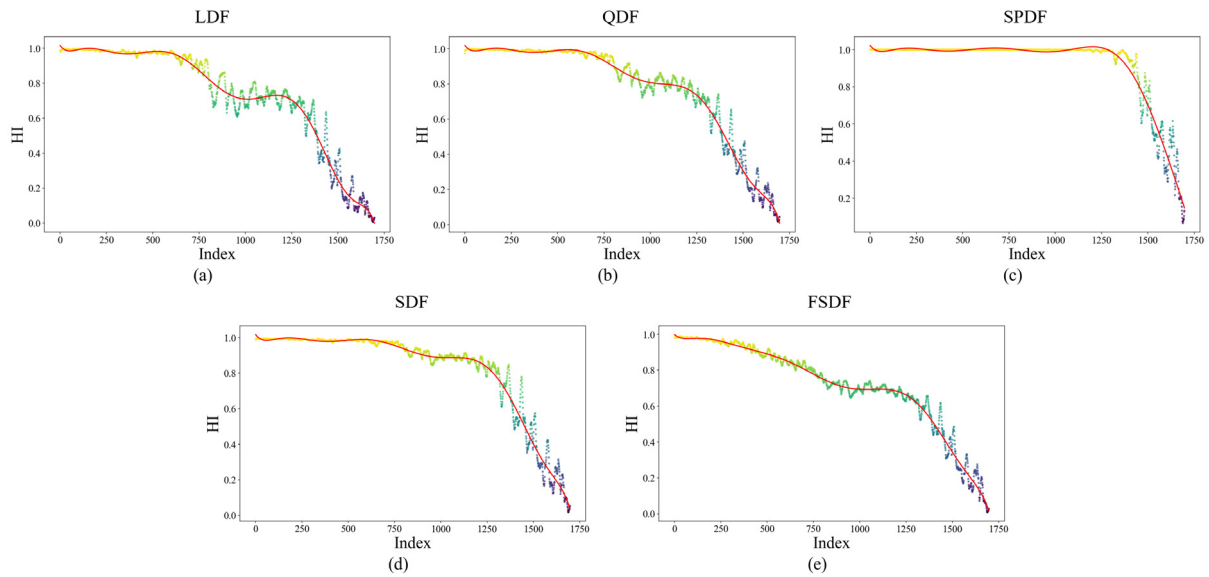


Figure 8. KWS-002 HI Curves with Different Degradation Functions (a) LDF, (b) QDF, (c) SPDF, (d) SDF, (e) FSDF

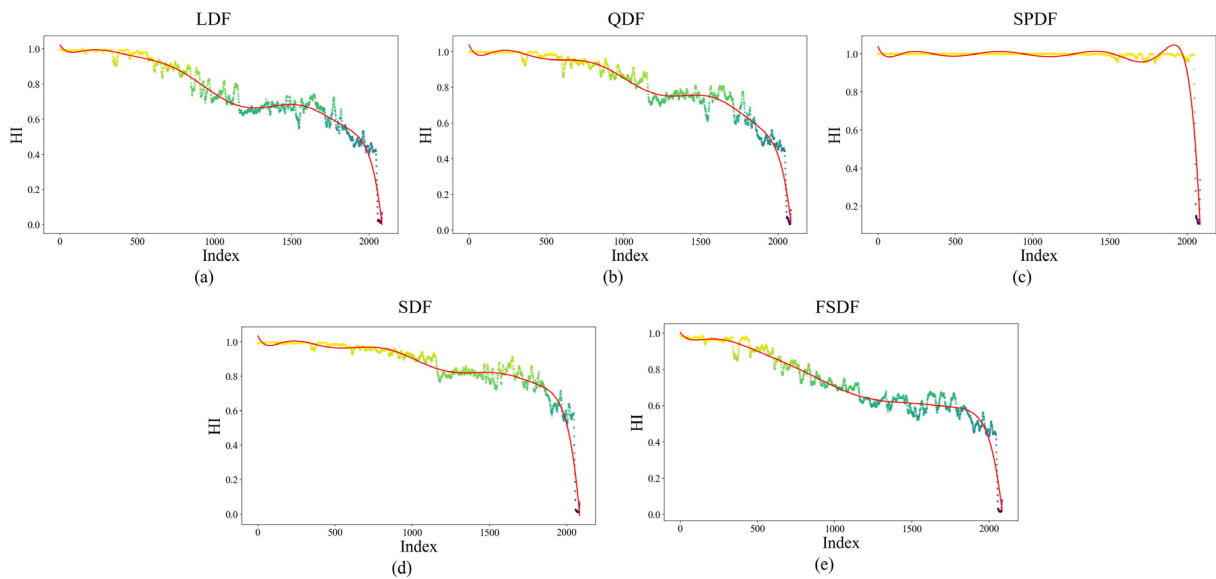


Figure 9. KWS-003 HI Curves with Different Degradation Functions (a) LDF, (b) QDF, (c) SPDF, (d) SDF, (e) FSDF

로 추출한 HI보다 강건하다. HI 추출에 있어 여러 고장 단계로 세분화한 FSDF의 우수함을 입증한다.

5. 결론

본 논문에서는 새로운 DF인 FSDF를 설계하는 것을 목표로 하였다. 기존 선행 연구들은 장비의 DF를 선형 혹은 2차 함수, 그리고 단순 통계량을 기반으로 가정하고 있다. 그러나, 실제 장비는 더욱 비선형적이고 복잡한 열화 패턴을 보인다. 실제 장비의 열화와 다른 가정은 모델의 학습을 어렵게 하고, HI 추출 성능을 저하 시키는 원인이 될 수 있다. 본 연구

에서 제안된 FSDF는 변화점 탐지 알고리즘을 사용하여 장비의 고장 단계를 식별하고, 식별된 고장 단계를 기반으로 DF를 설계했다. FSDF는 이전 선행 연구에서 제안된 DF에 비해 실제 열화 패턴에 가깝기에 현장에서 센서 데이터와의 안정적인 학습을 통해 안정적인 장비 모니터링을 할 수 있을 것이다.

제안하는 방법론의 성능을 검증하기 위해 실제 현장에서 수집된 무기체계 데이터를 사용하였다. 공정한 비교를 위해 HI 추출 모델을 고정하여 DF를 다르게 구성하여 실험하였다. 실험 결과, 제안하는 FSDF를 사용했을 때 가장 우수한 HI 추출 성능을 보여주었다. 특히, 추출한 HI가 가장 우수한 강건성을 보여주었으며 이는 실제 현장에서 안정적인 모니터링에 기여

할 수 있을 것으로 보인다.

학습 방식, 장비의 다양한 운영 환경, 학습 데이터와 테스트 데이터의 분포 차이와 같은 요인에 따라 고장 단계 DF의 성능은 달라질 수 있다. 본 논문에서는 무기체계의 운영 조건에 적합한 DF를 제안하였지만, 더 복잡한 시스템이나 다중 운영 조건이 존재하는 환경에서는 제안된 방법론이 제한될 수 있다. 또한, 본 연구는 모델 구조 자체를 변경하지 않고 DF 설계를 통해 HI 성능을 개선하는 접근을 하였다. 향후 연구에서는 고장 단계를 잠재 공간(latent space)과 연계하거나, 단계별 구조적 변형이 가능한 모델로 확장함으로써 모델 아키텍처 차원에서 고장 정보를 통합할 수 있는 방향을 고려할 계획이다. 또한 다양한 운영 조건과 장비 유형에 대응 가능한 유연하고 일반화 가능한 DF 설계 방식에 대한 연구를 지속하고자 한다.

참고문헌

- Aminikhanghahi, S. and Cook, D. J. (2017), A survey of methods for time series change point detection, *Knowledge and Information Systems*, **51**(2), 339-367.
- Bajarunas, K., Baptista, M. L., Goebel, K., and Chao, M. A. (2024), Health index estimation through integration of general knowledge with unsupervised learning, *Reliability Engineering & System Safety*, **251**, 110352.
- Chen, D., Qin, Y., Wang, Y., and Zhou, J. (2021), Health indicator construction by quadratic function-based deep convolutional auto-encoder and its application into bearing RUL prediction, *ISA transactions*, **114**, 44-56.
- Chen, H., Lin, J., Yang, H., and Xu, G. (2024), Measurement Capability Evaluation of Acoustic Emission Sensors in IIoT System for PHM, *IEEE Internet of Things Journal*.
- Cho, H. and Fryzlewicz, P. (2015), Multiple-change-point detection for high dimensional time series via sparsified binary segmentation, *Journal of the Royal Statistical Society Series B: Statistical Methodology*, **77**(2), 475-507.
- Ding, W., Li, J., Mao, W., Meng, Z., and Shen, Z. (2023), Rolling bearing remaining useful life prediction based on dilated causal convolutional DenseNet and an exponential model, *Reliability Engineering & System Safety*, **232**, 109072.
- Duan, Y., Cao, X., Zhao, J., Li, M., and Yang, X. (2023), A Spatio-temporal Fusion Autoencoder-based Health Indicator Automatic Construction Method for Rotating Machinery Considering Vibration Signal Expression, *IEEE Sensors Journal*.
- González-Muñiz, A., Diaz, I., Cuadrado, A. A., and García-Pérez, D. (2022), Health indicator for machine condition monitoring built in the latent space of a deep autoencoder, *Reliability Engineering & System Safety*, **224**, 108482.
- Guo, L., Lei, Y., Li, N., Yan, T., and Li, N. (2018), Machinery health indicator construction based on convolutional neural networks considering trend burr, *Neurocomputing*, **292**, 142-150.
- Killick, R., Fearnhead, P., and Eckley, I. A. (2012), Optimal detection of changepoints with a linear computational cost, *Journal of the American Statistical Association*, **107**(500), 1590-1598.
- Kim, M., Park, H., Park, M., Kwon, J., Kim, D., Bae, H., and Park, Y. (2023), Data-driven degradation trend construction method for RUL prediction, *ICCC 2023*, 43-44.
- Kong, F., Li, Y., Li, C., and Liu, S. (2024, May), A Review of PHM Research on Weapons and Mechanical Equipment. In *2024 Prognostics and System Health Management Conference (PHM)*, IEEE, 90-93.
- Li, M., Wei, T., Zhou, S., Duan, Y., Pan, N., and Cao, X. (2024), A health indicator construction method for coal mine rotating machinery based on transformer autoencoder and exponential function constraint, *IEEE Sensors Journal*.
- Ni, Q., Ji, J. C., and Feng, K. (2022), Data-driven prognostic scheme for bearings based on a novel health indicator and gated recurrent unit network, *IEEE Transactions on Industrial Informatics*, **19**(2), 1301-1311.
- Niazi, S. G., Huang, T., Zhou, H., Bai, S., and Huang, H. Z. (2024), Multi-scale time series analysis using TT-ConvLSTM technique for bearing remaining useful life prediction, *Mechanical Systems and Signal Processing*, **206**, 110888.
- Park, H., Kim, D., Kim, M., Park, M., Bae, H., and Park, Y. (2023, December), A novel training mechanism for health indicator construction and remaining useful lifetime (RUL) prediction. In *2023 IEEE International Conference on Big Data (BigData)*, IEEE, 809-818.
- Qin, Y., Yang, J., Zhou, J., Pu, H., and Mao, Y. (2023), A new supervised multi-head self-attention autoencoder for health indicator construction and similarity-based machinery RUL prediction, *Advanced Engineering Informatics*, **56**, 101973.
- Ran, B., Peng, Y., and Wang, Y. (2024), Bearing degradation prediction based on deep latent variable state space model with differential transformation, *Mechanical Systems and Signal Processing*, **220**, 111636.
- Varlamov, A. A., Rimshin, V. I., and Tverskoi, S. Y. (2018, December). The General theory of degradation. In *IOP Conference series: materials Science and engineering* (Vol. 463, No. 2, p. 022028). IOP Publishing.
- Xu, Y., Xia, T., Wang, D., Chen, Z., Pan, E., and Xi, L. (2024), Dynamic time scales ensemble framework for similarity-based remaining useful life prediction under multiple failure modes, *Engineering Applications of Artificial Intelligence*, **127**, 107389.
- Xu, Z., Bashir, M., Liu, Q., Miao, Z., Wang, X., Wang, J., and Ekere, N. (2023), A novel health indicator for intelligent prediction of rolling bearing remaining useful life based on unsupervised learning model, *Computers & Industrial Engineering*, **176**, 108999.
- Yan, M., Xie, L., Muhammad, I., Yang, X., and Liu, Y. (2022), An effective method for remaining useful life estimation of bearings with elbow point detection and adaptive regression models, *ISA transactions*, **128**, 290-300.
- Yan, T., Wang, D., Xia, T., Zheng, M., Peng, Z., and Xi, L. (2023), Entropy-maximization oriented interpretable health indicators for locating informative fault frequencies for machine health monitoring, *Mechanical Systems and Signal Processing*, **198**, 110461.
- Yu, W., Kim, I. Y., and Mechefske, C. (2019), Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme, *Mechanical Systems and Signal Processing*, **129**, 764-780.
- Zhou, H., Huang, X., Wen, G., Lei, Z., Dong, S., Zhang, P., and Chen, X. (2022), Construction of health indicators for condition monitoring of rotating machinery: A review of the research, *Expert Systems with*

Applications, **203**, 117297.

Zhou, J., Yang, J., and Qin, Y. (2024), A systematic overview of health indicator construction methods for rotating machinery, *Engineering Applications of Artificial Intelligence*, **138**, 109356.

Zhu, J., Jiang, Q., Shen, Y., Xu, F., and Zhu, Q. (2023), Res-HSA: Residual hybrid network with self-attention mechanism for RUL prediction of rotating machinery, *Engineering Applications of Artificial Intelligence*, **124**, 106491.

Zio, E. (2022), Prognostics and Health Management (PHM): Where are we and where do we (need to) go in theory and practice, *Reliability Engineering & System Safety*, **218**, 108119.

저자소개

추정호 : 대전대학교 경제학과에서 2024년 학사학위를 취득하고 부산대학교 산업공학과 석사과정에 재학 중이다. 연구분야는 딥러닝, 건전성 및 예측 관리, 운영 유지보수이다.

박한별 : 경성대학교 산업경영공학과에서 2021년 학사학위를 취득하고 부산대학교에서 산업공학과 박사과정에 재학 중이다. 머신러닝을 산업 현장의 특성에 맞게 응용하려는 연구를 수행하고 있으며, 주로 운영 유지보수 분야를 다루고 있다.

박연경 : 고려대학교 산업공학과에서 2006년 학사, 동대학교 소프트웨어공학과에서 2019년 석사를 취득 2006년부터 LIG넥스원 IPS 연구소 연구원으로 재직 중이다. 관심 분야는 CBM+, IPS이다.

배혜림 : 서울대학교에서 1996년에 학사, 1996년 석사, 2002년 박사학위를 취득하였고, 2002년부터 2003년까지 삼성카드에서 근무했으며, 2005년부터 부산대학교 산업공학과 교수를 역임하고 2024년부터 부산대학교 데이터사이언스전문대학원 교수로 재직 중이다. 관심 분야는 정보시스템 설계, 클라우드 컴퓨팅, 비즈니스 프로세스 마이닝, 항만 물류, 인공지능이다.