

# 시스템 고장 예지를 위한 물리 특성 기반 열화 특징 추출 방법

안다운\*<sup>1</sup>, 최승환\*<sup>2</sup>, 이수웅\*<sup>3</sup>, 박준규\*\*

## Physical Characteristics-based Degradation Feature Extraction for System-Level Prognostics

Dawn An\*<sup>1</sup>, Seung-Hwan Choi\*<sup>2</sup>, Suwoong Lee\*<sup>3</sup>, and Jun-Kyu Park\*\*

본 논문은 2024년도 산업통상자원부 및 한국산업기술평가관리원(KEIT) 연구비 지원(‘RS-2024-00423589’) 및 한국생산기술연구원 기관주요사업 “제품 제조현장 작업파트너 로봇 기술 개발(kitech EO-24-0007)”의 지원으로 수행한 연구임

### 요약

고장 예지는 운용 중 시스템의 상태 모니터링 데이터를 기반으로 미래 열화 거동 및 잔존유효수명을 예측하여 비용 효율적인 정비를 가능하게 하는 핵심 기술로 여겨진다. 상태 모니터링 데이터는 대부분 진동, 전류, 토크 등의 센서 신호로 취득되기 때문에 이로부터 열화 상태를 대표하는 특징을 추출하는 단계가 필수적이다. 그러나 고장 예지를 위한 유의미한 열화 특징 추출 방법은 동일한 대상을 통해서도 수많은 연구가 진행될 정도로 여전히 도전적인 과제이다. 본 논문에서는 물리적 특성에 기반한 열화 특징 추출의 사례로 베어링과 압출기의 고장 예지 방법을 소개하고, 구동 모듈 고장 예지를 위해 전류와 토크의 상관관계에 기반한 새로운 열화 특징 추출 방법을 제안한다. 제안된 방법은 두 개의 모듈에 적용되었으며, 전체 수명 데이터를 사용하였을 때 두 모듈에서 유사한 수준의 열화 한계치 설정이 가능하여 모듈 수준 고장 예지의 가능성을 시사하였다.

### Abstract

Prognostics is considered a key technology for cost-effective maintenance, as it predicts degradation behavior and remaining useful life based on condition monitoring data of an in-service system. Condition monitoring data is mostly collected through sensor signals such as vibration, current, and torque, making the degradation feature extraction essential. However, extracting degradation features remains a challenging task. This paper introduces prognostics methods for bearings and extruders as examples of degradation feature extraction based on physical characteristics. Furthermore, a new feature extraction method based on the correlation between current and torque is proposed for a drive modules prognostics. The proposed method was applied to two modules, and similar levels of degradation thresholds was obtained when using the full lifespan data, suggesting the feasibility of module-level prognostics.

### Keywords

prognostics, degradation feature, physical characteristics, bearing, extrusion system, drive module

\* 한국생산기술연구원 연구원(\*<sup>1</sup> 교신저자)

- ORCID<sup>1</sup>: <https://orcid.org/0000-0001-7803-8023>

- ORCID<sup>2</sup>: <https://orcid.org/0000-0003-1898-9884>

- ORCID<sup>3</sup>: <https://orcid.org/0000-0001-6547-9225>

\*\* 한국전력연구원 에너지신기술연구소 선임연구원

- ORCID: <https://orcid.org/0000-0002-8912-5787>

· Received: Nov. 13, 2024, Revised: Dec. 04, 2024, Accepted: Dec. 07, 2024

· Corresponding Author: Dawn An

Advanced Mobility System Group, Korea Institute of Industrial

Technology, 320, Techno sunhwan-ro, Daegu, Korea

Tel.: +82-53-580-0174, Email: dawnan@kitech.re.kr

## I. 서 론

상태기반정비 및 예지정비는 운용 중 시스템의 건전성 모니터링 데이터를 바탕으로 현재 상태를 진단하고 유지·보수 시점을 예측함으로써 시스템의 안전을 보장하고 비용을 절감하는 효율적인 정비 방법으로 여겨지고 있다[1]. 특히, 고장 예지는 미래의 열화 거동을 예측하고 현재 시점부터 유지·보수까지 남은 시간인 잔존유효수명(RUL, Remaining Useful Life)을 예측하는 기술로서 예지 정비를 가능하게 한다[2].

일반적으로 고장 예지는 건전성 데이터 취득, 열화 특징 추출, 열화 거동 및 RUL 예측의 세 단계로 나눌 수 있다. 이 중 열화 특징 추출은 원시 데이터로부터 유의미한 열화 정보를 추출하는 과정으로, 이후 RUL 예측 정확도에 중요한 영향을 미친다. 그러나 일반적으로 적용 가능한 유효한 열화 특징 추출 방법은 아직 찾아보기 힘들며, 이에 따라 동일 데이터를 대상으로 한 다양한 연구가 진행되고 있다.

가장 활발히 진행되는 연구는 진동 신호를 이용한 베어링 고장 예지 연구이다[3]-[7]. 과거에는 베어링 고장 주파수에 기반한 고전적인 방법들이 많았으나[3][4], 이러한 방법은 고장 진단에는 효과적이지만 RUL 예측에서는 정확도가 낮다는 문제점이 있다. 최근에는 많은 데이터를 이용하는 딥러닝을 활용한 연구[5][6]나 비교적 적은 데이터에 새로운 물리적 개념을 융합한 연구[7]가 활발히 진행되고 있다. 그러나 단일 대상에 대한 오랜 기간의 연구는 열화 특징 추출이 매우 도전적인 과제임을 시사한다. 더욱이, 부품 수준을 넘어 모듈이나 시스템 수준의 고장 예지 연구는 여전히 드문 실정이다.

따라서 본 논문에서는 고장 예지 단계 중 열화 특징 추출 방법에 대한 연구—비교적 적은 데이터와 물리적 개념을 융합한 시스템 수준의 고장 예지 연구—를 진행하였으며, 크게 두 가지 목표를 두고 있다. 첫째는 정형화된 방법이 없는 열화 특징 추출 과정에 대한 이해를 돕기 위해 베어링과 압출 시스템의 사례를 소개하는 것이며, 둘째는 협동 로봇용 상용 구동 모듈의 RUL 예측을 위한 열화 특징 추출 방법을 제안하는 것이다. 기존 사례 및 제안 방법은 모두 물리적 개념에 기반한 1차 특징 추출 후, 변동성 및 노이즈를 줄이는 2차 특

징 추출 과정을 거친다.

본 논문은 다음과 같이 구성된다. 2장에서는 기존 열화 특징 추출 관련 연구 중 물리적 특성에 기반하여 유의미한 결과를 보였던 두 가지 사례를 소개한다. 3장에서는 구동 모듈의 시험 장치 및 데이터에 대해 설명하고, 열화 특징을 추출하기 위한 과정과 그 결과를 제시한다. 4장에서는 고장 예지의 목표인 구동 모듈의 RUL을 예측하기 위해 수행해야 할 향후 과제에 대해 논의하며, 마지막으로 5장에서 결론을 맺는다.

## II. 기존 연구 사례

### 2.1 베어링

베어링 진동 신호를 이용한 연구는 고장 예지 분야에서 가장 활발히 진행되어 온 분야 중 하나로, 특히 2012 IEEE PHM 학회에서 공개 경쟁 문제로 제공된 데이터[8]를 활용한 연구가 많이 이루어지고 있다. 제공된 데이터는 그림 1의 베어링 가속 시험 장치를 통해 얻어진 시계열 데이터로, 정상 상태의 베어링이 고장에 이를 때까지의 가속도를 측정하는 것이다. 시험은 회전 속도와 반경 방향 힘의 다른 조합을 이용한 세 가지 하중 조건에서 수행되었고, 샘플링 주파수 25.6 kHz로 0.1초 동안 10초 간격으로 모니터링되었다.

제공된 베어링 열화 데이터는 총 17 세트르, 조건 1과 조건 2에서 각각 7세트, 조건 3에서 3세트가 포함된다. 이 중 조건 1과 조건 2의 원시 데이터가 그림 2에 나타나 있다. 그림에서 왼쪽 7개와 오른쪽 7개의 데이터는 각각 하중 조건 1과 조건 2에서 얻어진 진동 신호로, x축은 시간, y축은 가속도를 나타낸다. 주목할 점은, 14개의 데이터가 명목상 동일한 베어링에서 얻어졌음에도 불구하고 같은 하중 조건에서도 취득 신호의 패턴과 수명에서 큰 차이를 보이며, 미리 정의된 고장 한계치(그림 2에서 초록색 수평선)에 도달하기도 전에 고장난 베어링도 다수 존재한다는 것이다. 이를 통해 동일한 베어링에서 얻어진 서로 다른 특성의 원시 데이터로부터 유의미하면서도 공통된 열화 특징을 추출하는 방법의 필요성을 확인할 수 있다.




그림 1. 시험 플랫폼: PRONOSTIA[8]  
Fig. 1. Testing platform: PRONOSTIA[8]

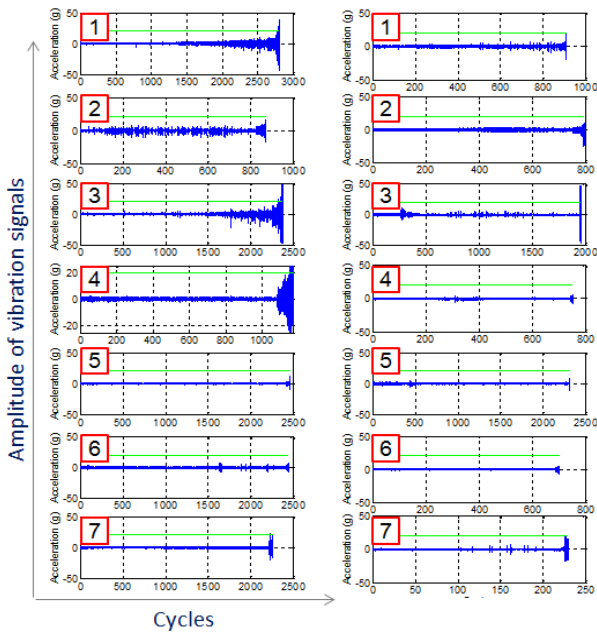


그림 2. 베어링 원시 데이터  
Fig. 2. Raw data from bearings

본 논문에서 사례로 소개하는 방법[7]은 열화 진행에 따른 강성 감소 등 물리적 특성 변화로 인해 고유 진동수가 변할 수 있다는 점에 초점을 맞추고 있다. 고유 진동수의 변화로 특정 주파수에서는 시간에 따른 진폭 감소를 동반할 수 있으며, 이러한 주파수들의 진폭 값을 1차 열화 특징으로 추출한 후, 노이즈를 줄이고 특징을 강화하기 위해 정보 엔트로피[9]를 도입하여 최종 열화 특징을 2차로 추출하였다. 그 결과가 그림 3에 나타나 있으며, 그림 2의 원시 데이터 14세트 전체에서 단조 감소하는 공통된 특징이 도출되었다. 이후, 이 열화 특징의 속성을 분석하여 한계치를 설정하고, RUL을 예측하였으며, 이를 포함한 열화 특징 추출 과정의 상세한

내용은 [7]에서 확인할 수 있다.

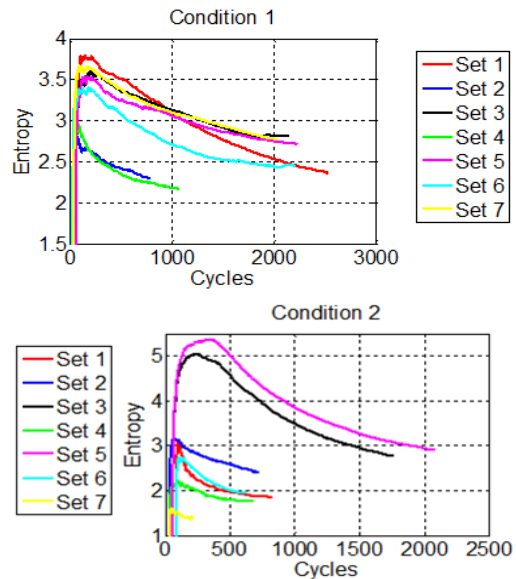


그림 3. 베어링 열화 특징 추출 결과[7]  
Fig. 3. Results of feature extraction: bearing data[7]

## 2.2 의료용 압출기

이전 절에서는 부품 수준에서 단일 신호를 이용한 특징 추출 방법을 소개했다면, 이번 절에서는 시스템 수준에서 모니터링된 다중 소스 데이터로부터 열화 특징을 추출하는 연구[10]를 소개한다. 그림 4의 압출 시스템은 실제 의료용 카테터를 생산하는 운용 중인 시스템으로, 주요 구성품으로는 모터, 스크류, 팁과 다이, 냉각 시스템, 풀러, 커터 등이 있다. 이 중 스크류는 카테터 품질에 중요한 영향을 미치면서 가장 빈번히 교체되는 구성품으로, 고장 예지 대상으로 선정되었다.



그림 4. 실제 운용 중인 압출 시스템[10]  
Fig. 4. In-service extrusion system[10]

압출 시스템에서 모니터링되는 데이터는 그림 5(a)에 나타낸 것처럼 스크류 속도(S.Spд.), 모터 부하(M.Load), 헤드 압력(H.Press.), 풀러 속도(P.Spд.) 등이 있으며, 빨간색으로 표시된 두 세팅 값(S.Spд.Set, P.Spд.Set)은 카테터 품질 향상을 위해 조정되는 값이다.


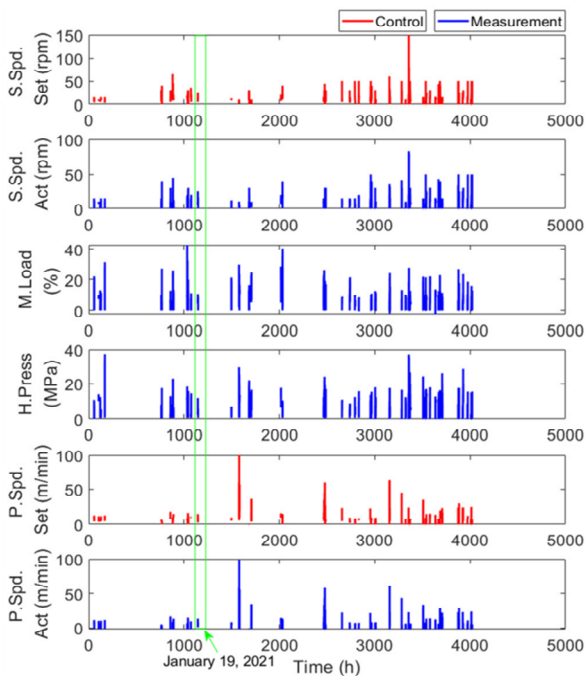


그림 5. 압출 시스템 원시 데이터  
(a) 전체 모니터링 기간, (b) 특정일 하루[10]  
Fig. 5. Raw data from the extrusion system  
(a) Entire monitoring period, (b) Specific day[10]

그림 5(a)에서 x축은 압출 시스템의 누적 사용 시간을 나타내며, 데이터는 2020년 7월부터 2022년 3월(스크류 교체)까지 약 2년 동안 카테터 생산을 위해 압출 시스템이 가동될 때마다 모니터링되었다. 그림에서 막대 모양으로 보이는 것들은 각각 하루 동안의 취득 데이터이며, 초록색 네모 안에 있는 데이터는 특정일(2021년 1월 19일) 하루 동안 측정된 데이터로, 시간 축을 확대하여 스크류 속도를 대표로 살펴보면 그림 5(b)와 같이 나타난다.

시간에 따른 변화가 명확히 나타나지 않는 다중 소스 데이터로부터 스크류의 마모를 대표하는 열화 특징을 추출하기 위해, [10]에서는 열화가 진행됨에 따라 변화하거나 변해야 할 속도, 부하, 압력 간의 물리적 관계를 파악하는데 중점을 두었다. 스크류 마모로 인한 기계적 변화는 모터 부하와 스크류 속도의 상관관계를 통해 분석하였으며, 카테터 품질 저하를 방지하기 위해 헤드 압력과 풀러 속도의 변화를 에너지 보존 법칙 측면에서 고려하였다. 이러한 물리적 관계를 기반으로 1차 특징을 추출한 후, 가중 누적 평균을 적용하여 신호를 강화하고 노이즈를 줄인 최종 2차 특징 추출 결과가 그림 6에 나타나 있다. 이후 한계치 설정 및 RUL 예측에 대한 구체적인 내용은 [10]에서 확인할 수 있다.




그림 6. 압출 시스템 열화 특징 추출 결과[10]  
Fig. 6. Result of feature extraction: extrusion system data[10]

### III. 구동 모듈의 열화 특징 추출

#### 3.1 대상 장치 및 데이터

구동 모듈은 다양한 산업 분야에서 동력 전달과 기계 장치의 구동을 위해 널리 사용되며, 그림 7(a)의 6축 매니플레이터는 구동 모듈을 활용한 대표적인 응용 사례 중 하나이다.

본 논문에서는 그림 7(b)의 상용 구동 모듈(LTD, Jiangsu Kaiserdrive Intelligent Technology co.)을 대상으로 하여 등속 속도 12 rpm, 토크 115 N·m의 하중 조건하에서 정·역회전과 감·가속을 반복하여 13초 주기로 속도가 반복되는 내구 시험을 두 개의 모듈에 대해 진행하였다.




그림 7. 시험 장치 (a) 6축 매니퓰레이터, (b) 시험 모듈  
Fig. 7. Test equipment  
(a) 6-axis manipulator, (b) Test samples

고장이 발생할 때까지 시험이 진행되는 동안 모니터링되는 데이터 종류는 속도, 전류, 토크, 가속도, 온도, 효율 등이다. 이 중 가속도는 시스템 동작의 반응 특성으로, 직접적인 지표인 다른 측정 변수들과 차이가 있으며, 온도와 효율은 전류로 대체 가능하다는 특징이 있다. 따라서 본 논문에서는 그림 8에 나타난 것과 같이 속도(V), 전류(C), 토크(T) 세 가지를 구동 모듈의 열화 특징 추출에 사용한다. 데이터는 1 kHz의 샘플링 주파수로 10분마다 30초간 측정했으며, 10분마다 반복되는 한 번의 측정을 한 사이클이라고 정의한다. 각 사이클마다 모니터링된 3만 개 데이터의 RMS(Root Mean Square) 값의 시간에 따른 변화가 그림 8에 나타나 있다.

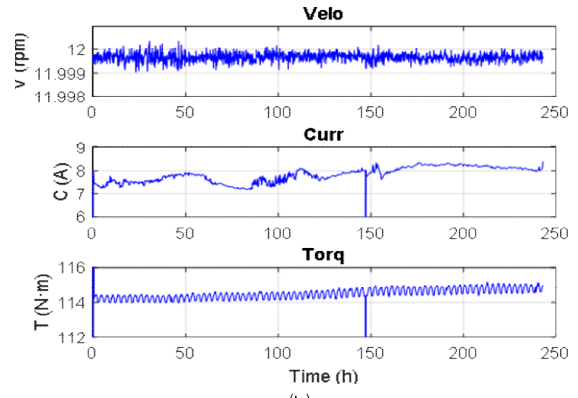
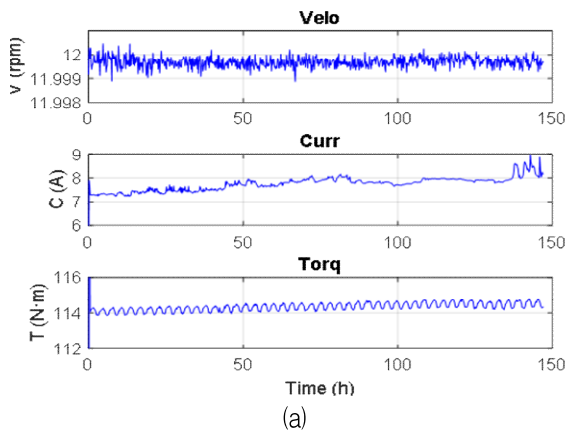


그림 8. 구동 모듈 원시 데이터의 RMS 값  
(a) 모듈 1, (b) 모듈 2  
Fig. 8. RMS value of drive module raw data  
(a) Module 1, (b) Module 2

두 모듈 모두에서 속도는 거의 변화가 없고, 전류와 토크는 미미한 상승 경향을 보인다. 다음 절에서는 주어진 이 세 종류의 데이터로부터 열화 특징을 추출하는 과정을 제시한다.

### 3.2 열화 특징 추출 과정 및 결과

구동 모듈의 열화 진행에 따른 물리적 특성 변화는 아래와 같이 요약할 수 있으며, 이를 바탕으로 1차 특징을 추출한다.

DC 모터에서 전류와 토크는 비례 관계에 있다.

열화가 진행될수록 전류는 증가할 것으로 기대된다.

열화가 진행될수록 토크와 속도는 (제어가 되더라도) 감소할 수 있다.

위 세 가지 특성을 살펴보면, 열화가 진행됨에 따라 전류와 토크의 특성이 상충될 수 있음을 알 수 있다. 그림 8에서 전류는 위 ②의 경향과 일치하지만, 토크는 ③에 반하여 ①의 내용과 같이 전류와 비례하는 거동을 보인다. 따라서 본 논문에서는 토크를 직접 사용하기보다는 전류와의 상관도 변화향을 새롭게 도입하여, 다음 식 (1)을 1차 특징 추출식으로 제시한다.

$$\text{std}_k(\text{corr}_{k-30:k}(\mathbf{d}_k^C, \mathbf{d}_k^T)) \times \frac{(\text{rms}(\mathbf{d}_k^C) - C_{\min}) / (C_{\max} - C_{\min})}{(\text{rms}(\mathbf{d}_k^V) - V_{\min}) / (V_{\max} - V_{\min})} \quad (1)$$

여기서  $d$ 는 사이클마다 취득되는 데이터의 열벡터이고,  $k$ 는 사이클 인덱스로 10분마다의 측정을 나타낸다(즉,  $k-30$ 는  $k$ 로부터 300분(5시간) 이전을 의미함). 그리고  $C, T, V$ 는 각각 전류, 토크, 속도를 의미하며,  $C_{min}=6.5, C_{max}=9.5, V_{min}=11.95, V_{max}=12.05$ 로 측정 데이터에 기반하여 설정되었다.

먼저, 본 논문에서 새롭게 제시한 열화 특징 수식인 식 (1)의 첫 번째 항은 전류와 토크의 다섯 시간 누적 상관도(Corr)의 표준 편차(Std)를 나타낸 것으로(누적 시간은 경험에 의해 결정된 값으로 대상에 따라 달라질 수 있음), 그림 9에 나타낸 것처럼 시간에 따라 증가하는 경향을 보이며 열화 특징으로서 유효성이 확인된다. 여기에 앞서 언급된 열화 진행에 따른 전류와 속도의 일반적인 변화 특성을 식(1)의 두 번째 항과 같이 추가하면, 그림 10과 같이 1차 열화 특징이 추출된다. 그림 10의 결과는 그림 9의 전반적인 경향을 유지하면서 수명 후기의 특성값을 증가시켜 제시된 식 (1)이 열화 특성에 적합함을 확인해 준다.




그림 9. 식 (1)의 첫째 항 (a) 모듈 1, (b) 모듈 2  
Fig. 9. Eq. (1) first term (a) Module 1, (b) Module 2




그림 10. 구동 모듈 1차 열화 특징 추출 결과  
(a) 모듈 1, (b) 모듈 2

Fig. 10. First-stage feature extraction results of drive module  
(a) Module 1, (b) Module 2

#### IV. 수명 예측을 위한 열화 특징의 특성 분석 및 향후 과제

물리적 특성에 기반한 1차 열화 특징은 일반적으로 변동성이 크고 노이즈가 많아 RUL 예측에 적합하지 않으며, 다음 네 가지 특성[11]을 만족하는 최종 열화 특징을 추출할 필요가 있다.

- 단조성(Monotonicity)
- 예측 가능성(Prognosability)
- 추세성(Trendability)
- 신호 대 잡음 비율(Signal-to-noise ratio)

이 네 가지 특성에 기반하여 검토한 결과, 그림 10에 나타낸 1차 특징은 두 모듈의 데이터에 대해 유사한 패턴을 보이는 추세성은 만족하지만, 신호 대 잡음 비율이 높아 단조성이 떨어지며, 예측 가능성을 위한 두 모듈에 공통된 한계치 정의가 어려운 문제가 있다.

따라서 본 논문에서는 위 네 가지 속성을 만족시킬 수 있는 2차 특징 추출 과정을 두 가지로 제시하고, 현재의 한계점 및 향후 과제에 대해 논한다.

첫 번째 접근방법으로, 일반적으로 지수 함수의 형태를 띠는 열화 거동을 단순화하기 위해 그림 10에 나타난 1차 특징 추출 값에 로그를 취한 결과가 선형이라고 가정한다. 그림 11이 그 결과로 검은색 선이 로그를 취한 1차 특징값이고, 이로부터 선형 회귀 모델을 구한 것이 빨간색 직선이다. 초록색 수평선은 빨간색 직선의 마지막 y축 값으로 두 모듈에서 서로 비슷한 값(모듈 1: -8.34, 모듈 2: -7.95)을 나타낸다. 2차 열화 특징으로서 이 빨간색 직선은 앞서 언급한 네 가지 특성을 만족한다.

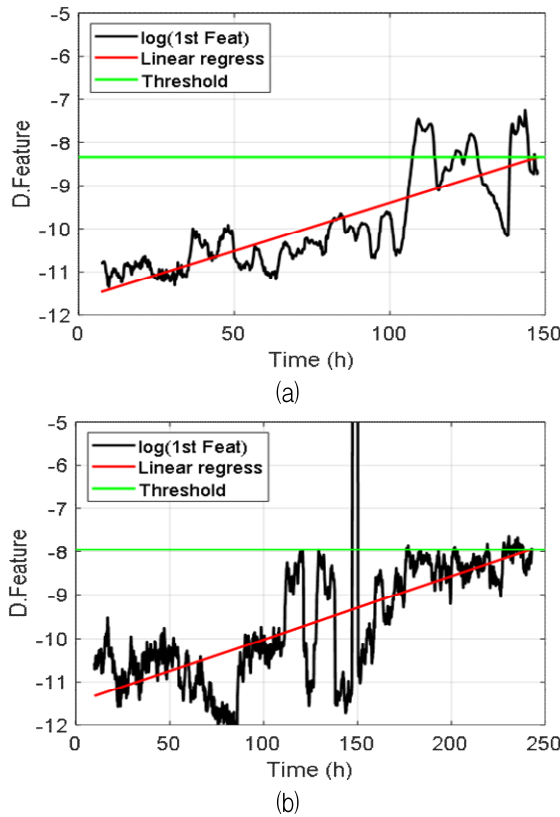


그림 11. 선형화 기반 최종 열화 특징 추출 결과  
(a) 모듈 1, (b) 모듈 2

Fig. 11. Feature extraction results using linearization  
(a) Module 1, (b) Module 2

두 번째 방법으로는 그림 10의 1차 특징 추출 결과에 PINN(Physics-informed Neural Networks)을 적용하여 최종 열화 특징을 추출하는 방법을 고려한다. 본 연구에서 사용한 네트워크 모델은 두 개의 노드

를 갖는 하나의 은닉층으로 구성되며, 시간과 열화 값이 각각 입력층과 출력층을 이룬다. 각 층간 활성화 함수는 시그모이드와 선형 함수를 사용하였으며, 관련된 자세한 설명은 [12]에서 확인할 수 있다. 그림 10의 훈련 데이터로부터 열화 특성을 만족시키는 최종 특징을 추출하기 위해 모델 출력에 식 (2)와 같은 제한 조건을 부과한다.

$$\sum_{k=2}^n \max[0, z_{k-1} - z_k] \leq 0 \quad (2)$$

여기서 k는 사이클 인덱스, n는 최종 측정(사이클)의 개수, 그리고 z는 네트워크 모델의 아웃풋이다. 식 (2)는 열화값이 시간이 지남에 따라 작아지지 않도록 하는 조건을 만족시키며, 이 제한 조건에 따라 그림 12에서 검은색으로 나타난 1차 열화 특징으로부터 그림 12의 빨간색 곡선과 같은 최종 특징이 얻어진다.




그림 12. PINN 기반 최종 열화 특징 추출 결과  
(a) 모듈 1, (b) 모듈 2

Fig. 12. Feature extraction results using PINN  
(a) Module 1, (b) Module 2

최종 열화 특징은 단조성과 신호 대 잡음 비율을 충족하며, 그림에서 열화 한계치를 나타내는 초록색 수평선은 두 모듈에서 비슷한 값(모듈 1:  $3.75 \times 10^{-4}$ , 모듈 2:  $3.95 \times 10^{-4}$ )으로 예측 가능성 또한 만족한다. 다만, 추세성은 특히 열화 초기 패턴에서 두 모듈이 상이하여 보완이 필요하다.

앞서 제시된 두 가지 방법은 전체 수명 데이터를 사용했을 때 얻어진 결과이다. 열화 초기나 중간 단계까지의 데이터만 이용하여 RUL을 예측한다면, 예측 결과에 대한 변동성이 매우 클 것으로 예상된다. 다시 말해, 현재 제시된 방법은 초단기 예측에만 적합하며, 고장 예지의 목표인 유지·보수 준비가 가능할 만큼 충분한 시간 이전에 RUL 예측을 하기 위해서는 보다 강건한 특징 추출 방법이 필요함을 의미한다.

추후에는 물리적 특성에 기반한 1차 특징 추출 방법을 데이터 처리 측면에서 보완하고, PINN을 정교화하여 앞서 언급한 네 가지 특성을 만족하는 열화 특징을 추출하기 위한 방법론을 개발할 계획이다.

## V. 결 론

본 논문에서는 고장 예지를 위해 원시 데이터로부터 유의미한 열화 특징을 추출하는 연구를 수행하였다. 먼저 부품 단위의 단일 신호와 실제 운용 시스템의 다중 소스 데이터로부터 열화 특징을 추출한 사례를 소개하였으며, 이를 바탕으로 본 연구의 궁극적인 목표인 구동 모듈 고장 예지를 위한 열화 특징 추출 방법을 제안하였다. 제안된 방법은 전류와 토크의 상관관계 및 열화에 따른 물리적 특성 변화에 기반하여 수식으로 정의되었으며, 두 개의 모듈에 적용된 결과 공통된 열화 특징이 추출됨으로써 추세성을 만족함을 확인하였다. 또한, 신호 대 잡음 비율을 개선하여 예측 가능성 및 단조성을 높이기 위해 선형화 및 PINN을 활용한 추가 과정을 제시하였다. 최종적으로, 제안된 방법에 전체 데이터를 활용한 결과는 열화 특성에 요구되는 네 가지 조건을 대부분 충족시켰으나, 유의미한 RUL 예측에는 여전히 한계가 있었다.

향후 다중 소스 데이터를 이용한 구동 모듈의 고장 예지 연구를 지속하여, 강건한 열화 특징 추출을 위한 방법론을 개발할 계획이다.

## References

- [1] N. Sakib and T. Wuest, "Challenges and opportunities of condition-based predictive maintenance: a review", *Procedia CIRP*, Vol. 78, pp. 267-272, Jan. 2018. <https://doi.org/10.1016/j.procir.2018.08.318>.
- [2] H. M. Elattar, H. K. Elminir, and A. M. Riad, "Prognostics: a literature review", *Complex & Intelligent Systems*, Vol. 2, pp. 125-154, Jun. 2016. <https://doi.org/10.1007/s40747-016-0019-3>.
- [3] I. El-Thalji and E. Jantunen, "A summary of fault modelling and predictive health monitoring of rolling element bearings", *Mechanical Systems and Signal Processing*, Vol. 60-61, pp. 252-272, Aug. 2015. <https://doi.org/10.1016/j.ymsp.2015.02.008>.
- [4] W. K. Yu and T. A. Harris, "A new stress-based fatigue life model for ball bearings", *Tribology Transactions*, Vol. 44, No. 1, pp. 11-18, Jan. 2001. <https://doi.org/10.1080/10402000108982420>.
- [5] C. Cheng, G. Ma, Y. Zhang, M. Sun, F. Teng, H. Ding, and Y. Yuan, "A deep learning-based remaining useful life prediction approach for bearings", *IEEE/ASME transactions on mechatronics*, Vol. 25, No. 3, pp. 1243-1254, Feb. 2020. <https://doi.org/10.1109/TMECH.2020.2971503>.
- [6] S. M. Jung and W. J. Choi, "A study on deep learning-based fault diagnosis using vibration data of wind generator", *Journal of Korean Institute of Information Technology*, Vol. 20, No. 6, pp. 129-136, Jun. 2022. <https://doi.org/10.14801/jkiit.2022.20.6.129>.
- [7] D. An, J. H. Choi, and N. H. Kim, "Remaining useful life prediction of rolling element bearings using degradation feature based on amplitude decrease at specific frequencies", *Structural Health Monitoring*, Vol. 17, No. 5, pp. 1095-1109, Sep. 2018. <https://doi.org/10.1177/1475921717736226>.
- [8] P. Nectoux, R. Gouriveau, K. Medjaher, E. Ramasso, B. Morello, N. Zerhouni, and C. Varnier,



"PRONOSTIA: An experimental platform for bearings accelerated life test", IEEE international conference on prognostics and health management, Denver, CO, USA, Vol. 20, Jul. 2012.

- [9] C. E. Shannon, "A mathematical theory of communication", The Bell System Technical Journal, Vol. 27, No. 3, pp. 379-423, Jul. 1948. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>.
- [10] J. K. Park, H. Lee, W. Kim, G. M. Kim, and D. An, "Degradation feature extraction method for prognostics of an extruder screw using multi-source monitoring data", Sensors, Vol. 23, No. 2, pp. 637, Jan. 2023. <https://doi.org/10.3390/s23020637>.
- [11] S. Buchaiah and P. Shakya, "Bearing fault diagnosis and prognosis using data fusion based feature extraction and feature selection", Measurement, Vol. 188, pp. 110506, Jan. 2022. <https://doi.org/10.1016/j.measurement.2021.110506>.
- [12] MathWorks., Neural Network Toolbox, [https://ge0mllib.com/papers/Books/04\\_Neural\\_Network\\_Toolbox\\_Reference.pdf](https://ge0mllib.com/papers/Books/04_Neural_Network_Toolbox_Reference.pdf) [accessed: Nov. 13, 2024]

저자소개

안 다 운 (Dawn An)



2015년 2월 : 한국항공대학교  
기계공학과(공학박사)  
2015년 5월 : University of Florida  
기계항공공학과(공학박사)  
2015년 5월 ~ 2016년 5월 :  
University of Florida 박사후  
연구원

2016년 6월 ~ 현재 : 한국생산기술연구원 수석연구원  
관심분야 : PHM, 고장예지, 신호처리, XAI

최 승 환 (Seung-Hwan Choi)



2012년 2월 : 동아대학교  
전자공학과(공학사)  
2014년 2월 : 부산대학교  
로봇융합전공(공학석사)  
2013년 12월 ~ 현재 :  
한국생산기술연구원 연구원  
관심분야 : 로봇제어 및 신호처리,  
이상 검출 및 상태진단, AI 알고리즘

이 수 웅 (Suwoong Lee)



1999년 2월 : 동아대학교  
전기공학과(공학사)  
2002년 3월 : University of  
Tsukuba 지능기능시스템공학과  
(공학석사)  
2005년 3월 : University of  
Tsukuba 지능기능시스템공학과  
(공학박사)

2005년 4월 ~ 2009년 3월 : 일본  
AIST(산업기술종합연구소) Intelligent System Research  
Institute 박사후연구원  
2009년 4월 ~ 2012년 11월 : Yamagata University,  
Department of Bio-System Engineering, 조교수  
2012년 12월 ~ 현재 : 한국생산기술연구원  
모빌리티시스템그룹 수석연구원(그룹장)  
관심분야 : 물리적 인간-로봇상호작용, 로봇기술 응용  
운동기구, 로봇안전, 영상 기반 촉각센서

박 준 규 (Jun-Kyu Park)



2017년 2월 : 전남대학교  
전자공학과(공학박사)  
2018년 10월 ~ 2022년 5월 :  
한국생산기술연구원 박사후  
연구원  
2022년 5월 ~ 현재 : 한국전력  
전력연구원 선임연구원

관심분야 : PHM, AI, DSP, WT