

굴착기 피스톤 유압펌프 상태진단 기술 Fault Diagnosis Method for Excavator Hydraulic Axial Piston Pumps

정준하 · 신경호 · 김건

Joon Ha Jung, Kyung Ho Sun, and Keon Kim

1. 서 론

굴착기는 가장 많이 사용되는 대표적인 건설기계로 건설현장에서 다양한 역할을 수행한다. 건설현장은 대부분 진동과 충격이 심하고, 먼지 등의 입자가 다량 발생하는 등 작업환경이 열악하다. 굴착기는 이런 열악한 환경에서도 운전이 가능하도록 설계 및 제작된다. 그러나 아무리 강건하게 설계되고 제작된 시스템이라도 예상하지 못한 불확실성은 항상 존재하며, 이런 불확실성은 예상보다 이른 시기에 고장을 발생시켜 일정에 차질이 발생하게 된다. 또한, 굴착기는 접근성이 떨어지는 도서 산간의 건설현장에서도 사용되어, 고장이 발생할 경우 정비에 많은 비용과 시간이 소모된다. 이처럼 굴착기의 특수한 환경으로 인해 굴착기의 상태를 정확하게 예측하고 고장이 발생하기 전에 이상징후를 파악하여 미리 알려줄 수 있는 기술인 Prognostics and Health Management (PHM) 연구에 대해서 관심이 증가하고 있다.¹⁾

PHM 개념은 1980년대 회전익 항공기의 반복되는 사고를 방지하고자 처음 도입된 이후로, 다른 산업분야로 확대 적용되고 있다. 2010년대 들어 데이터 취득 비용이 감소하고 인공지능 기술이 발전함에 따라 데이터 기반 (Data-driven) PHM 연구가 점차 확대되고 있다. 특히 딥러닝을 포함한 머신러닝의 대중화는 저렴한 비용으로도 높은 PHM 정확도를 달성할 수 있게 만들어, PHM 기술의 보편적인 보급이 가능하게 하고 있다. 이러한 연구 추세는 저널 및 학회에 제출되는 논문을 통해서 확인이 가능하다. PHM분야에서 가장 영향력이 있는 PHM Society의 학회에 제출된 논문에서도 머신러닝 및 딥러닝을 사용한 논문의 비중이 2017년 이후 꾸준히 증가하고 있다. 또한, 기계시스템 PHM 논문이 게재되는 Mechanical Systems and Signal Processing (MSSP) 저널에서도 머신러닝 및 딥러닝을 주제로한 논문의 숫자가 2010년대부터 증가하고 있다. 2018년 이후에는 Fig. 1에 나타나 있듯이 Generative Adversarial Network (GAN), Domain Adaptation, Multi-task Learning, Few-shot

Learning 등 영상처리에 사용되는 다양한 딥러닝 기법이 기계시스템 PHM 논문에도 사용되고 있다. 다만, 아직까지는 인공지능 기법을 활용한 PHM 기술은 연구단계에 머물러 있는 상황이다. 특히, Fig. 2에 정의된 PHM의 3가지 기능 중 상태진단과 수명예지는 데이터의 부재로 인해 개발 및 적용이 쉽지 않은 상황이다.

굴착기를 대상으로 인공지능 기술을 활용한 PHM 기술을 도입하기 위한 연구도 진행되고 있다. 특히 굴착기의 핵심 부품인 유압펌프는 매우 중요한 장비로, 기존의 유압펌프 상태진단 방법은 주로 오일과 냉각수의 오염도를 측정하여 성분분석을 통해 변화를 추적하는 방식으로 이루어지고 있다. 그러나 해당 방법으로는 진단할 수 있는 고장 유형이 많지 않고, 고장이 어느정도 진행이 되어야만 감지가 가능하다. 따라서 최근에는 이런 단점을 보완하기 위해 유압펌프의 진동신호를 활용하여 인공지능 기법을 적용한 PHM 기술 연구를 진행하고 있다. 본 기고문에서는 인공지능 기법을 적용한 유압펌프의 상태진단 방법을 살펴보고, 적용 사례를 소개하고자 한다.




Fig. 1 PHM Trends

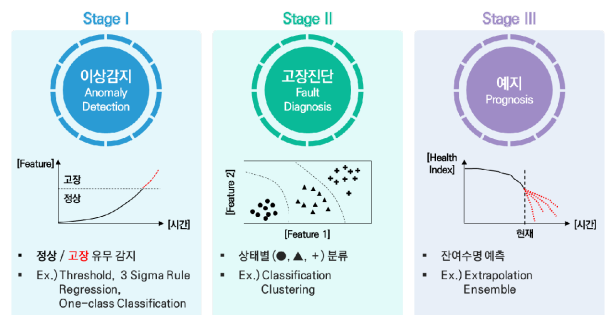


Fig. 2 Three Functional Steps of PHM

2. 유압펌프 구조 및 작동 원리

유압펌프는 큰 힘이 필요한 건설기계 및 항공부품에 많이 사용되는 에너지 변환 기계이다. 엔진으로부터 전달 받은 기계적 에너지를 유체에너지로 변환시켜, 유압이 필요한 곳에 공급하는 역할을 담당한다. 건설기계의 대표적 장비인 굴착기도 큰 동력이 소요되기 때문에 유압펌프를 사용한다. 굴착기에 사용되는 유압펌프는 효율이 좋고 유량 조절이 쉬운 가변용량 방식의 피스톤 유압펌프가 사용된다. 방식에 따라 사판과 사축의 기울어짐을 조절하여 토출 유량을 조절할 수 있는데, 구조상의 차이가 있을 뿐 두가지 방식의 기본 원리는 동일하다. 피스톤 유압펌프의 기본원리는 흡입, 차단, 압축 및 토출, 차단의 4가지 단계 사이클이 반복되면서 유량을 발생시킨다. 흡입 단계는 말 그대로 피스톤 내 공간이 증가하면서 진공이 발생하여 유체가 빨려 들어가는 과정이다. 차단 단계는 흡입과 토출이 동시에 일어나지 않도록 유로를 차단하는 단계로, 더 이상 흡입이 일어나지 않게 된다. 압축 및 토출 단계는 피스톤이 유체를 밀어내면서 압축된 유체가 토출되는 단계이다. 마지막으로 차단 단계는 유로를 차단하여 더 이상 토출이 일어나지 않게 된다. 이론적으로 펌프에서 발생시키는 유량은 피스톤수, 피스톤 직경, 피스톤 변위, 회전 속도, 각도의 tangential값에 비례한다.

사축식 및 사판식 피스톤 유압펌프는 Fig. 3에 표시된 엔진과 연결된 구동축이 회전하면서, 구동축과 연결된 피스톤(Piston)의 왕복운동을 발생시킨다. 피스톤은 실린더 블록과 함께 회전하는데, 사판식은 실린더 블록과 연결된 사판의 기울어짐에 따라 피스톤의 왕복운동을 통해 유량을 발생시킨다. 사축식은 실린더 블록 자체를 기울어지게 만들어 피스톤의 왕복운동에 따른 유량을 발생시킨다. 만약 사판/사축의 기울어짐이 없는 상태에서 동작하게 되면 피스톤의 왕복운동이 발생하지 않고, 구동축을 중심으로 회전만 하게 된다.

사축식과 사판식 유압펌프는 모두 고압의 유압이 필요한 곳에 사용되며, 가변용량이 가능하기 때문에 효율이 좋아 항공기나 산업용으로 주로 사용된다. 작동원리는 같지만 구조상 차이로 인해 각각 장점과 단점이 존재한다. 사판식의 경우 구동축과 피구동축이 일직선상으로 되어 있어 비교적 고속회전에 적합하고, 사축식에 비하여 구조가 간단하다. 반대로 사축식의 경우




Fig. 3 피스톤 펌프 구조: (a) 사판식, (b) 사축식

사판식에 비해 구조가 복잡하여 제작비용이 상대적으로 비싸지만, 효율이 더 높고 누설 손실이 적은 장점이 있다.

굴착기에 사용되는 유압펌프는 주행, 스윙, 작업 등의 모든 움직임을 가능하게 하면서도 효율이 좋아야 하는 특성이 요구되므로, 피스톤 유압펌프가 사용된다. 굴착기 내 부품에서 필요한 유량이 많으면 사판각을 증가시켜 유량을 늘리고, 유량이 필요한 곳이 적으면 사판각을 감소시켜 적은 유량을 공급하도록 제어한다. 굴착기가 주로 사용되는 건설현장의 경우 필요한 유량이 수초마다 변화하기 때문에 transient 상태에 가깝다. 이런 굴착기의 악조건 속에서는 펌프의 고장이 더 자주 그리고 예상보다 이른 시점에 발생 가능성이 높아지므로, 굴착기 유압펌프 대상의 PHM 기술이 필요한 상황이다.

3. 인공지능 기술을 적용한 유압펌프 PHM 연구동향

피스톤 유압펌프의 PHM 관련 연구는 주로 피스톤 슈(shoe)마모, 사판의 마모, 베어링 고장 등을 진단하고자 하는 노력이 대다수를 차지하였다. 2010년대 중반까지는 Hilbert-Huang Transform, Discrete Cosine Transform, Empirical Mode Decomposition 등과 같이 신호처리 기술을 개발하여 운전데이터와 진동신호로부터 고장을 진단할 수 있는 연구가 많이 진행되었다.^{2,4)} 2010년대 후반부터는 머신러닝과 딥러닝 등의 인공지능 기법을 적용한 진단 논문들이 주를 이루고 있다. 유압신호에 support vector regression을 적용하여 마모된 피스톤 슈를 진단하기도 하고, deep belief network를 이용해 진동신호로부터 피스톤 마모, 막힘, 실린더 블록 손상 등의 고장을 진단한 연구도 존재하였다. 2020년 이후 출판된 논문 중에서는 variational

autoencoder (VAE), convolutional neural network (CNN) 등과 같은 딥러닝이 적용되고, 전이학습 (transfer learning)도 적용된 연구도 진행된 바 있다.⁵⁻¹⁰⁾ 다만, 논문에서 대상으로 하는 유압펌프는 굴착기에 장착되는 것이 아닌 항공용 등 다른 용도가 대부분으로, 굴착기 유압펌프에 그대로 적용이 어려운 상황이다.

4. 유압펌프 상태진단 방법론 및 적용사례

굴착기 유압펌프의 상태진단 기술을 개발하기 위해서는 굴착기의 운전 특성을 고려해야 한다. 일반적인 steady 상태로 운전하는 기계시스템과는 달리 굴착기의 유압펌프는 시간에 따라 물리량이 변하는 transient 상태인 경우가 대부분이다. 굴착기의 작업 및 움직임에 따라 필요한 유량이 달라지게 되며, 이에 따라 유압펌프의 사판각/사축각이 조절되면서 유압펌프의 물리적 특성이 시간에 따라 변화한다. 이러한 조건을 고려하지 않고 상태진단 기술을 개발하게 되면 진단의 정확도가 떨어질 수 밖에 없다. 따라서 굴착기의 운전모드를 구분이 선행되고, 각 운전모드에 따라 상태진단을 하는 전략이 필요하다. 3.1에서는 상태진단을 하기에 앞서 굴착기의 운전모드를 구분하는 방법론에 관해 기술하고, 3.2에서 본격적인 상태진단 방법론에 관해 기술하였다.

3.1 머신러닝 기반 운전모드 구분

굴착기는 작업 종류, 스윙, 주행 등의 움직임에 따라 필요한 유량이 달라지기 때문에, 사판/사축각에 의해 필요 유량이 제어된다. 따라서 시간에 따라 계속 변하는 transient 상태에서 상태진단을 하는 것이 어렵기 때문에, 먼저 굴착기가 현재 어떤 동작을 하고 있는지 구분하는 것이 필요하다.

실제 건설현장에서 굴착기의 세분화된 운전모드는 수십에서 수백가지에 이를 정도로 다양하지만, 모든 경우의 수를 고려하여 고장을 진단하는 것은 현실적이지 않다. 따라서 10개 내외의 대표적인 운전모드로 그룹화하여 구분하는 것이 가장 합리적이다. 실제로도 굴착기 제조사에서는 출하 전 검사를 위한 표준 운전모드를 선정하여 테스트를 수행한다. 이를 준용하여 실제 굴착기에서 운전모드를 시험할 수 있는 6가지를 선정하였다. 선정된 6가지 운전모드에는 (1) 엔진 RPM 상승 및 하강, (2) 붐암버킷 상승 및 하강, (3) 가상 땅 파기, (4) 실제 땅 파기, (5) 선회, (6) 주

행이 포함된다.

운전모드를 구분하기 위해서 사용되는 데이터는 운전 지령값과 측정값 등이 포함된 운전데이터를 활용하는 것이 가장 적합하다. 각 운전모드별로 특정 패턴이 있으므로, 운전데이터의 조합을 통해 운전모드의 구분이 가능하다. 실제 H사의 굴착기 특정 기종에서 수집된 운전데이터를 수집하여 분석을 진행하였다. 수집된 170여개 운전데이터를 이용하여 6개의 운전모드를 구분하기에는 너무 많아 물리적 의미가 적은 운전데이터를 제거하는 과정을 추가하였다. 변화가 없는 변수, Boolean 데이터 및 peak 데이터 등 물리적 의미가 적은 변수, Correlation을 통해 중복되는 변수를 제거하는 과정을 통해 유압펌프와 관련된 15개의 인자들을 최종적으로 선별하였다. 선별된 운전데이터 15개에는 엔진 회전수와 펌프 토출압력, 펌프 사판각 등이 있다. Fig. 4와 같이 6가지 운전모드를 겹쳐서 그렸을 때 일부 운전모드들은 쉽게 구분이 가능해 보이지만, 일부 공통된 움직임이 있는 운전모드는 시각적으로는 구분이 어려워 보였다.

6개의 운전모드를 구분하기 위해서 물리적 지식에 기반한 decision tree와 학습에 의한 decision tree 방법을 2가지를 시도하였다. 먼저 물리적 지식에 기반한 decision tree는 운전데이터를 조합하여 Fig. 5와 같이 5단계를 순서대로 따라가면 각각의 기준에 맞게 분류가 이루어진다. 각 기준은 각 운전모드의 물리적 특성을 반영하여 정의되었다. 먼저 선회 모드의 경우 선회와 관련된 운전데이터 1개가 어느 값 이상이 되는 경우 선회모드로 구분하도록 정의되었다. 그 다음 단계는 주행모드로, 선회모드와 동일하게 주행모드와 관련된 운전데이터 값이 일정 수준 이상이 되면 주행모드로 구분되도록 정의되었다. 다음 단계는 RPM/UP & Down으로, index를 새롭게 정의. 마지막은 Boom arm bucket up/down과 Digging 모드의 구분은 해당 파트의 실린더 압력을 조합하여 새로운 인자를 정의하여 정의된 어느 정도 수준에서 구분이 가능함. 다만, 실제 땅을 파는 모드와 땅을 파는 척하는 모드의 구분은 해당 방법으로는 구분이 어려웠다.

2번째 방법으로는 학습에 decision tree 방법을 적용하여 운전모드를 구분하였다. 1번째 방법과 원리는 동일하지만, 물리적인 지식없이 15개의 운전데이터를 모두 사용하여 decision tree를 학습시키는 방법이다. 다만, 더 많은 단계 (node)를 거쳐 세분화된 모델을 데이터만 이용하여 학습시키는 방법을 적용하였다. 학습된 모델로 10-fold validation을 적용한 결과




Fig. 4 운전모드별 운전데이터 예시

96.27%의 분류 정확도를 확보할 수 있었다. 이는 첫 번째 결과보다 약 15% 향상된 결과로 매우 정확하게 운전모드를 구분할 수 있음을 보여준다. 다만, 학습에 의한 decision tree의 경우에도 실제 땅 파기와 가상 땅 파기 모드의 구분이 일부 잘못 분류되는 경우가 있음을 확인하였는데, 이2가지 모드는 실제 동작이 유사하므로 같은 운전모드로 간주하여도 문제가 없음을 확인하였다. 또한, 학습된 트리의 모델을 분석한 결과 상위 노드에서 사용된 운전데이터는 첫 번째 모델에서 사용한 모델과 일부 동일함을 확인하였다. 즉, 학습에 의한 decision tree는 물리적인 의미까지 포함되어 운전모드를 구분할 수 있다라고 결론지을 수 있다. 다만, 해당 방법의 검증은 특정 굴착기에서만 진행되었기 때문에, 물리적 특성이 다른 굴착기에 적용시 일부 튜닝이 필요할 것으로 예상된다.

3.2 인공지능 기반 유압펌프 실린더 블록 마모 상태 진단

실제 굴착기에 유압펌프를 장착하여 정상부품과 고장부품을 교체하여 실험한 데이터로 유압펌프의 진단을 수행하였다. 유압펌프의 고장모드로는 피스톤 슈(shoe) 마모가 가장 많지만, 실제 고장이 발생한 부품을 찾기가 어려워 기 확보된 마모된 실린더 블록을 고장으로 두고 시험을 진행하였다. 정상과 고장 실린더 블록 부품으로 3.1에서 선정한 6가지 운전모드에서 진행하고, 운전데이터와 별도의 가속도 센서를 유압펌프의 외부 하우징에 부착하여 진동 신호를 측정하였다.

인공지능 기법을 적용하여 실린더 블록 마모의 고장을 진단하기에 앞서, 데이터에서 고장에 의해 어떤 물리적인 변화가 있는지 먼저 확인하였다. 실린더 블록의 마모된 상태는 흡입-차단-압축 및 토출-차단으로 이어지는 피스톤 펌프 사이클에 영향을 줄 것으로 분석되었다. 구체적으로는 차단과 압축의 효과를 떨어뜨려 유압펌프에서 토출되는 유량이나 유압을 감소시킬 것으로 예상되었다. 운전데이터 중 유압펌프의 토출 유압과 관련된 변수와 지령값의 상관관계

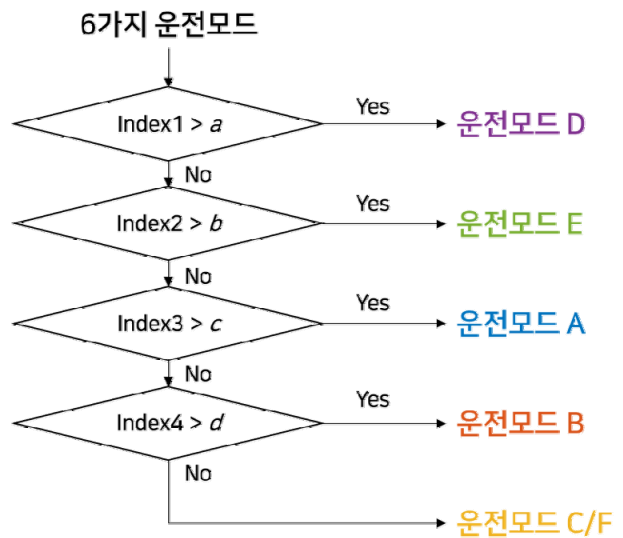


Fig. 5 물리 기반 운전모드 구분 decision tree

를 확인해본 결과 유압 저하가 발생한 것을 확인하였다.

구체적으로는 병렬로 장착되어 있는 2개의 유압펌프 중 고장 부품이 들어간 펌프에서 담당하는 동작이 작동할 때의 유압이 감소하는 현상을 보였다. Fig. 6은 모두 고장품이 장착된 유압펌프에서 담당하는 세부 동작으로 파란색은 정상 실린더 블록에서의 데이터, 붉은색은 마모된 실린더 블록에서의 데이터를 의미한다. A동작과 B동작 모두 펌프 지령값 대비 유압이 줄어드는 현상이 눈으로도 확인이 가능하다. 다른 유압펌프에서 담당하는 동작에서는 유압 저하가 발생하지 않았다. 따라서 정성적인 분석에 의해서도 실린더 블록에 의한 마모에 의해 물리적인 변화가 발생함을 확인하였고, 이를 기반으로 인공지능 기술을 적용하여 상태진단 기술을 개발하였다.

유압펌프의 실린더 블록 마모로 인한 고장을 진단하고자 2가지 방법을 시도하였다. 먼저 3.1의 운전모드 구분하는 것과 유사하게 decision tree로 학습하여 진단을 수행하였다. 먼저 2개의 운전데이터만을 이용하여 정상과 실린더 블록 마모의 상태를 구분해 본 결과 운전모드별로 66%~100%로 차이가 있었다. Table 1의 결과처럼, 1개의 운전모드를 제외한 나머지는 80%이상의 높은 정확도로 진단이 가능함을 확인하였다. 운전모드 5가지 (3.1절에서 언급했던 6가지 중 1가지는 유압펌프의 물리적 변화가 없어 제외)를 구분하지 않고도 80%에 가까운 높은 정확도를 나타내었다. 다만, C 운전모드의 경우 다른 경우에 비해 비교적 낮은 정확도를 나타내었는데, 이는 세부 동작들이 동시에 이루어져 해당 유압펌프만이 담당

하는 세부 동작만 분리가 잘 되지 않았기 때문이다. 추가적으로, 3.1에서 선별한 15개의 운전데이터를 모두 사용하였을 때는 정확도가 더 높아짐을 확인하였다. 대부분 90%에 가깝거나 그 이상의 정확도로 고장상태 구분이 가능하였고, 모드를 구분하지 않은 경우에도 94%에 가까운 정확도를 나타내었다.

두번째 진단 방법으로는 별도로 측정된 진동 신호를 Convolutional Neural Network(CNN)로 학습하는 방법이다. 굴착기의 특성상 많은 외부 노이즈와 엔진 등의 다른 부품에서 전달되는 진동 등에 의해 유압 펌프 진동 신호 분석이 쉽지 않다. 주파수 분석 결과 동일한 작업모드임에도 다른 주파수 응답 특성을 나타내어 정성적인 분석으로는 실린더블록 마모에 의한 물리적인 특성을 확인하기가 어렵다.

Fig. 7과 Fig. 8에 나타나 있듯이, D작업모드의 주파수 특성과 E작업모드의 주파수 특성이 매우 다르다. 또한 E 작업모드에서는 실린더 블록이 마모된 펌프에서 펌프의 조화 주파수 성분의 크기가 증가하지만, D 작업모드에서는 일부 조화 주파수 성분의 크기만 증가하고 나머지는 감소하는 경향을 보이고 있다. 결론적으로 정확한 진동 신호 분석을 위해서는 노이즈 제거와 펌프의 진동 신호만을 강조할 수 있는 신호처리 기술 개발이 필요하다. 현재 단계에서는 그럴만한 검증할 수 있는 데이터가 많지 않아 CNN 모델을 이용하여 정상과 고장의 상태를 구분하는 방법을 취하였다.

진동 신호를 CNN 모델에 입력데이터로 사용하기 위해서 일정 시간 단위로 구분하였다. 다음 정상과 고장의 레이블을 부여한 다음, 정의된 CNN 모델을 학습시켜 진단 결과를 도출하였다. CNN 모델의 구조는 8개의 1D CNN layer로 구성되고, 중간에는 Rectified Linear Unit (ReLU)와 Max Pooling을 사용하였다. 비록 1회 시험에서 확보한 데이터로 얻은 결과이지만, CNN 모델을 사용할 경우 모든 운전모드에서 100% 진단 정확도를 나타내었다.




Fig. 6 동작별 펌프 지령값 대비 유압

Table 1 운전데이터 기반 진단 정확도 결과

운전모드	운전데이터	
	2개 (지령값, 유압)	15개
B	92.21	94.36
C	79.83	93.35
D	66.43	89.67
E	100.0	100.0
F	97.74	99.82
B~F	79.73	93.98

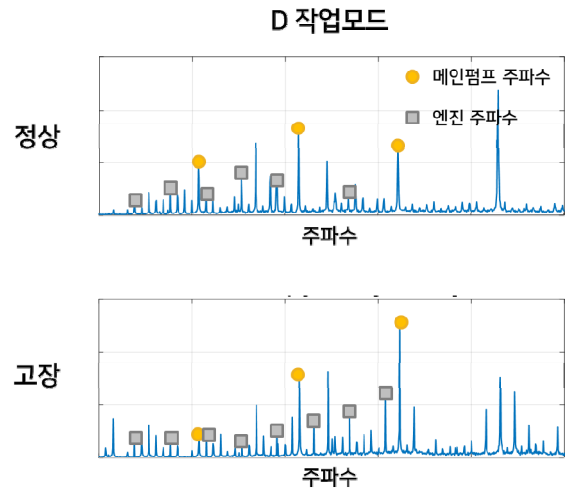


Fig. 7 D작업모드의 정상과 고장 주파수 응답

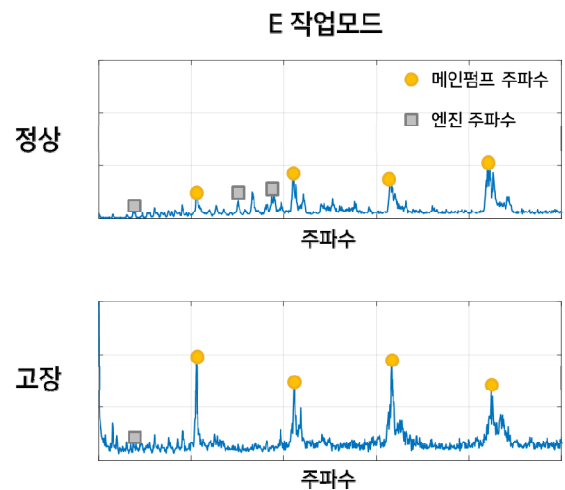


Fig. 8 E작업모드의 정상과 고장 주파수 응답

Table 2 진동 신호 기반 진단 정확도 결과

운전모드	CNN 모델
A	100.0
B	100.0
C	100.0
D	100.0
E	100.0
A~E	100.0

5. 결론

굴착기의 특성상 데이터 기반 진단 방법론 개발은 매우 도전적이고 쉽지 않다. 가혹한 환경과 불확실성이 산재해 진단이 쉽지 않은 조건이지만, 데이터가 축적될수록 더 정확한 진단기술을 개발할 수 있을 것으로 기대된다.

유압펌프 진단기술의 정확도를 향상시키고 다른 기종에도 적용할 수 있도록 확장가능한 기술을 개발하기 위해서는 기존에 수행한 시험을 반복하여 충분한 검증을 거쳐야 한다. 또한, 다른 종류의 고장을 진단하기 위한 장기적 전략을 수립해야 하고, 이외에도 도메인 적응 기법 등의 최신 인공지능 기술의 도입을 고려해볼 수 있다.

참고 문헌

- 1) K. Kim, "An Evaluation of Empirical Approach for Gearbox Diagnosis in the Construction Equipment", Annual Conference of the Prognostics and Health Management Society. Vol 11. 2019.
- 2) C. Lu, W. Shaoping, and C. Zhang, "Fault diagnosis of hydraulic piston pumps based on a two-step EMD method and fuzzy C-means clustering." Proceedings of the institution of mechanical engineers, part C: journal of mechanical engineering science 230.16, pp. 2913~2928, 2016.
- 3) Y. Wang, H. Li, and P. Ye, "Fault Feature Extraction of Hydraulic Pump Based on CNC De-noising and HHT," Journal of Failure Analysis and Prevention, Vol. 15, Issue 1, pp. 139~151, 2015.
- 4) H. Yu, H. Li, and Y. Li, "Vibration signal fusion using improved empirical wavelet transform and variance contribution rate for weak fault detection of hydraulic pumps," ISA transactions, Vol. 107, pp. 385-401, 2020.
- 5) C. Lu, S. Wang, and V. Makis, "Fault severity recognition of aviation piston pump based on feature extraction of EEMD paving and optimized support vector regression model," Aerospace Science and Technology, Vol. 67, pp. 105~117, 2017.
- 6) S. Wang, J. Xiang, Y. Zhong, and H. Tang, "A data indicator-based deep belief networks to detect multiple faults in axial piston pumps," Mechanical Systems and Signal Processing, Vol. 112, pp. 154~170, 2018.

- 7) Z. Li, W. Jiang, S. Zhang, Y. Sun, and S. Zhang, "A Hydraulic Pump Fault Diagnosis Method Based on the Modified Ensemble Empirical Mode Decomposition and Wavelet Kernel Extreme Learning Machine Methods," Sensors, Vol. 21, Issue 8, p. 2599, 2021.
- 8) H. Yu, and H. Li, "A conditional factor VAE model for pump degradation assessment under varying conditions," Applied Soft Computing, Vol. 100, pp. 106992, 2021.
- 9) S. Tang, Y. Zhu, and S. Yuan, "An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump," Advanced Engineering Informatics, Vol. 50, pp. 101406, 2021.
- 10) Y. Miao, Y. Jiang, J. Huang, X. Zhang, and L. Han, "Application of Fault Diagnosis of Seawater Hydraulic Pump Based on Transfer Learning," Shock and Vibration, 2020.

[저자 소개]



정준하

E-mail : joonha@kimm.re.kr
Tel : 042-868-7196

2019년 서울대학교 기계공학과 박사.
2019년~현재 한국기계연구원 시스템다이
나믹스연구실 선임연구원. 기계시스템
(원심펌프, 전동기, 스펀들 등의 회전기
기) PHM, 유압펌프 및 모터 PHM, 비전기
기 밸런싱 연구에 종사. 대한기계학회 등의 회원, 공학박사



선경호

E-mail : sunkh@kimm.re.kr
Tel : 042-868-7247

2010년 서울대학교 기계공학과 박사.
2010년~2011년 포스코 선임연구원,
2011년~현재 한국기계연구원 시스템다이
나믹스연구실 책임연구원. 기계시스템(원
심펌프, 전동기, 스펀들 등의 회전기기) PHM, 유압펌프 및
모터 PHM, 비전기기 PHM, 회전기기 밸런싱 연구에 종사.
한국PHM학회 등의 회원, 공학박사



김건

E-mail : keon.kim2@hyundai-di.com

2017년 서울대학교 기계공학과 석사.
2009년~현재 현대두산인프라코어 기
술원 소속. 2021년~현재 서울대학교 기
계공학과 박사과정. 건설기계 PHM 연구에
종사. 한국PHM학회 등의 회원, 공학석사