

## 웨이블릿 도메인 기반의 유압라인 결함 검지기법 연구

이동희\*, 김병우\*\*

\*울산대학교 전기전자컴퓨터시스템공학과

\*\*울산대학교 전기공학부

e-mail:ehdgml9997@naver.com

## A Study on the Detection Method of Fault Diagnosis Using Wavelet

Dong-Hee Lee\*, Byeong-Woo Kim\*\*

\*Dept. of Electrical, Electronic and Computer Engineering, University of Ulsan

\*\*Dept. of Electrical Engineering, University of Ulsan of Computer Science, Korea University

## 요약

fault diagnosis technology is essential in various industrial sites. In particular, demand of the technique will continue to increase in order to improve efficiently or injury of human resources. For precise diagnosis, research is needed on the multi-class detection technique that can diagnose various defects. In this study, we extracted feature points from time, frequency, and wavelet domains on pressure sensor data in the hydraulic system. Based on the extracted feature points, accuracy verification about multiple faults was performed to predict five classes through the MLP algorithm. In addition, we achieved maximum 20% improvement to compare the feature points of frequency conversion with wavelet conversion.

## 1. 서론

다양한 산업군의 고장 진단 기술은 수많은 제조와 연관된 AI 시장에서 필수적으로 여겨진다. 사람의 접근성 및 위험성을 고려하거나 인건비의 합리적인 측면으로 보았을 때 지속적으로 기술 고도화가 요구되며 앞으로의 새로운 산업군에서도 핵심적인 기반 기술로 수요는 증대될 것이다.

사람의 접근이 어려우며 광범위한 현장을 대상으로 스마트 팩토리와 같은 관리 체계를 위해서는 수많은 AI 핵심 기술의 집합체로 이루어진다. 그 중, 고용자의 위험성과 현장 건물 및 공정의 이상을 미리 예측하여 알려주는 시스템은 앞으로 필수적으로 요구될 것이다. 예를 들어 사람의 눈을 대체하는 카메라의 영상 이미지로 누출 등의 시각적 변화를 감지할 수 있으며, 다양한 시그널 센서 기반으로 내부적인 변화를 미리 감지하여 이른 진단을 가능하도록 발전할 것이다.

특히 구분하기 위한 내부 변화를 감지하기 위해 진동 및 압력 센서 기반으로 시그널의 변화 및 특징을 분석하여 AI 알고리즘을 통해 검진하는 기술을 개발하는 연구의 사례는 꾸준히 대두되고 있다. [1-3]

본 논문에서는 여러 환경의 유압시스템을 대상으로 압력 센서를 통해 계측된 데이터를 주파수 및 웨이블릿 신호로 가공하여 AI 알고리즘 진단 정확도를 개선시키는 기법에 대해 연구를 진행하였다. 기존 연구 중 단순한 이진 분류에 비해

특히 다양한 결함에 대한 다중 검출을 세부적으로 진행함으로써 사전에 위험성을 체계적으로 판단할 수 있는 기술 개발에 이바지하였다.[5]

## 2. 웨이블릿

최근 주기 신호 및 다양한 시그널 프로세싱 분야에서 유망한 웨이블릿 변환을 활용한 연구가 진행되고 있다. 기존 신호 처리에 많이 사용되는 푸리에 변환(Fourier Transform)은 특성상 주파수 영역에서만 신호 분석이 가능하여 시간 정보를 함께 파악할 수 없는 단점이 존재한다.

웨이블릿 변환은 제한된 길이 기반으로 특정한 기저함수(basis function)를 사용하여 원래 신호를 변환하는 기법이다. 연속 웨이블릿 변환에서 이분 구간으로 샘플링을 통해 아래의 식1과 같이 정의된다.

$$DWT(j, k) = 2^{-\frac{j}{2}} \int_R f(t) \frac{1}{s} \psi^*(2^{-j}t - k) dt \quad [1]$$

이와 같은 과정으로 본래의 연속 웨이블릿 변환은 아래의 식 2,3과 같이 discrete wavelet function과 scaling function으로 분류한다.

$$\psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k) \quad [2]$$

$$\phi_{j,k}(t) = 2^{-\frac{j}{2}} \phi(2^{-j}t - k) \quad [3]$$

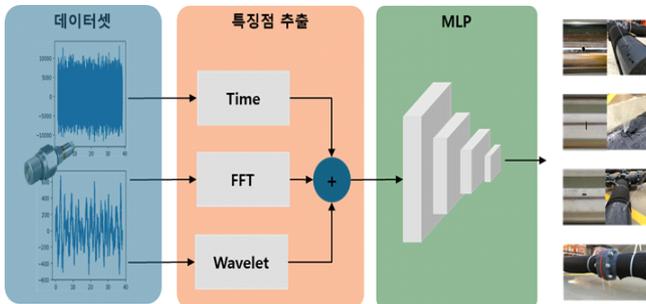
이산 웨이블릿 변환을 활용한 신호 분석 시 신호의 wavelet coefficient는 다음과 같이 얻을 수 있다.

$$a_{2j}(k) = \int f(t)\phi_{j,k}(t)dt \quad [4]$$

$$d_{2j}(k) = \int f(t)\psi_{j,k}^*(t)dt \quad [5]$$

위의 식4,5를 통해 approximations과 details을 얻을 수 있다. 각 함수들을 이용하여 신호의 주파수의 특징들을 분해하도록 한다. 각 주파수별 분해능을 가지고, 생성된 approximation을 다시 wavelet 함수를 반복 적용하면서 주파수 영역별로 세분화하여 다중 주파수 영역에 대해 분해할 수 있다.

### 3. 결함 진단 프로세스



[그림 1] AI 결함 진단 프로세스

#### 3.1 데이터셋

다중 결함 진단을 위한 다양한 결함을 설계하여 계측한 압력센서 기반의 WDS(Water Distribution System) 데이터셋을 채택하였다. [4]

본 데이터셋은 두 가지의 네트워크로 구성된 테스트베드를 대상(Looped, Branched)으로 계측을 실시하였다. 압력센서는 워터 펌프로 가장 가까운 지점과 먼 지점(P1,P2)에 부착하였다.

본 테스트베드에서 사용된 압력 센서는 PCB 업체의 102B16 모델로, 1에서 689 kPa 측정 범위를 가진다. 또한 7.25 uV/Pa 의 Sensitivity를 가진다. 또한 압력센서의 Frequency는 25kHz로 약 30초씩 측정되었다.

위와 같은 조건 속에서 파이프라인의 결함 유형은 4가지로 정상 조건을 포함한 총 5가지의 누수 유형을 구축하였다. pinhole에 대한 세 가지의 Leak로 구성하였다; 원형으로 핀홀이 발생한 Orifice leak, 종방향으로 길게 직사각형 핀홀이 발생한 Longitudinal leak, 횡방향으로 핀홀이 발생한 Circumferential leak 뿐 아니라 Gasket 미체결로 인한 Leak에 대해 데이터셋을 구성하였다.

결함 진단을 위해 각 테스트 베드별로 정확도를 예측하고,

또한 0.18L/s와 0.47L/s의 각 유속 조건에 따라 분류하여 정확도를 검출을 실시하였다.

#### 3.2 데이터 전처리

압력센서는 25kHz로 분해능을 가지며, 약 30초간 측정되었다. 각 클래스 별로 0.1초마다 샘플링하여 총 샘플 1500개로 구성하였다. 그림 1과 같이 압력센서의 시계열 데이터 기반으로 시간, 주파수, 웨이블릿 도메인 기반으로 특징점 추출을 진행하였다.

Time series 데이터에서 최댓값, 평균값, 표준편차, 왜도, 첨도, 실효값(Max, Mean, Standard deviation, Skewness, Kurtosis, RMS) 특징점들을 계산하였다. 그리고 FFT(Fast Fourier Transform)을 이용하여 시간 영역과 동일하게 최댓값, 평균값, 표준편차 왜도, 첨도, 실효값과 합집합, 주파수 최댓값을 포함하여 8개의 특징점을 계산하였다. 또한 이산 웨이블릿은 스케일은 5, 모 웨이블릿은 Daubechies를 사용하였다. 학습 input으로 Energy, Entropy, mean, standard deviation을 웨이블릿 coefficient (approximations, details) 대상으로 총 8개로 구성하였다. 각 센서 별로 24개의 특징점을 계산하여, 총 48개의 특징점을 추출하였다.

#### 3.2 데이터 전처리

압력센서는 25kHz로 분해능을 가지며, 약 30초간 측정되었다. 각 클래스 별로 0.1초마다 샘플링하여 총 샘플 1500개로 구성하였다. 그림 1과 같이 압력센서의 시계열 데이터 기반으로 시간, 주파수, 웨이블릿 도메인 기반으로 특징점 추출을 진행하였다.

Time series 데이터에서 최댓값, 평균값, 표준편차, 왜도, 첨도, 실효값(Max, Mean, Standard deviation, Skewness, Kurtosis, RMS) 특징점들을 계산하였다. 그리고 FFT(Fast Fourier Transform)을 이용하여 시간 영역과 동일하게 최댓값, 평균값, 표준편차 왜도, 첨도, 실효값과 합집합, 주파수 최댓값을 포함하여 8개의 특징점을 계산하였다. 또한 이산 웨이블릿은 스케일은 5, 모 웨이블릿은 Daubechies를 사용하였다. 학습 input으로 Energy, Entropy, mean, standard deviation을 웨이블릿 coefficient (approximations, details) 대상으로 총 8개로 구성하였다. 각 센서 별로 24개의 특징점을 계산하여, 총 48개의 특징점을 추출하였다.

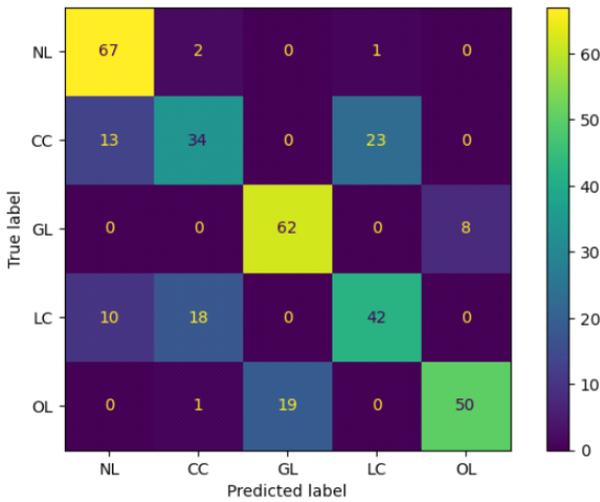
#### 3.3 결함 진단

시계열 데이터의 추출된 특징점들을 입력으로 딥러닝 알고리즘에 적용하여 주파수 변환과 wavelet 기반의 특징점에 따른 고장 진단 정확도 비교를 진행하였다.

### 3.3.1 알고리즘

다양한 도메인 기반의 특징점들을 입력으로 MLP(Multiple Layer Perceptron) 알고리즘을 기반으로 결합 검지를 진행하였다.

MLP은 딥러닝 기법의 다층 은닉 계층을 포함하는 인공신경망의 구조이다. SVM과 동일하게 지도학습에 주로 사용되며, 복잡한 패턴을 추출에 용이하다. 데이터 전처리에 따른 정확도 비교를 위하여 Hidden layer를 2개(48,24 뉴런의 계층)를 구성하여 결합 검지 알고리즘을 설계하였다. 이 때, Activation function은 relu, softmax로 설정하였고, Optimizer는 Stochastic Gradient Descent로 설계하였다. 1250 train과 test set의 비율은 7:3로 하였으며, Epoch는 2000회, batch size는 32회로 설정하여 학습을 실시하였다.



[그림 2] Branched 데이터셋 기반의 Confusion matrix

### 3.3.2 정확도

그림 2는 각 결합 데이터에 따라 예측한 결과를 매트릭스로 표현한 Confusion Matrix이다. 가로축은 예측한 결과이며, 세로축은 실제 결과값이다. 실제 정상 상태(NL) 데이터를 67를 정상 데이터, 2개를 CC (Circumferential leak) 데이터, 1개를 LC (Longitudinal leak)로 예측하였다. 그림2와 같이 CC와 LC의 고장 데이터에 대한 올바른 예측이 어려웠음을 확인하였다. 이는 핀홀의 직사각형 크기가 동일하지만, 직사각형의 긴 선 부분과 유체 이동 방향이 종/횡 방향의 차이이기 때문에 양 결합에 대한 정확도가 혼란을 가져온 것으로 판단된다.

표2와 같이 FFT만 포함한 특징점 기반의 정확도와 Wavelet 특징점을 추가로 포함한 정확도를 비교한 것이다. Wavelet 기반의 데이터 전처리를 수행하였을 때, 테스트베드, 유체 속도 데이터셋의 결합 진단 정확도가 아래의 표1과 같이 모두 향상되었다. 특히 Looped 테스트 베드보다 Branch 테스트 베드에서 더 높은 정확도를 확인하였다.

[표 1] FFT 및 Wavelet 신호 기반 Looped과 Branched 데이터셋 MLP 알고리즘 정확도

	FFT		Wavelet	
	BR	LO	BR	LO
0.18	65.58%	72.92%	<b>85.99%</b>	<b>74.00%</b>
0.47	67.84%	79.08%	<b>75.4%</b>	<b>82.57%</b>

## 4. 결론

본 연구는 압력센서 데이터 기반의 유압 라인의 결합을 진단하는 학습 프로세스를 설계하였다. 특히 데이터 전처리 과정에서 시계열 데이터를 FFT뿐만 아니라 Wavelet 도메인에서 특징점을 추출하여 정확도 향상을 도모하였다. MLP 알고리즘 기반으로 Looped 테스트베드는 23% 향상하였고, Branched 테스트베드는 8~20%까지 정확도 향상을 확인하였다. 추후 다음 연구로 해당 특징점 기반으로 결합 진단에 적합한 알고리즘 개발에 적용할 수 있을 것으로 판단된다.

## Acknowledgement

본 연구는 2022년도 산업통상자원부의 재원으로 한국에너지기술평가원과 2024년도 산업통상자원부의 재원으로 한국산업기술기획평가원의 지원을 받아 연구 성과임. (2022303004020C, RS-2024-00407415)

## 참고문헌

- [1] 한국자동차공학회, 박진규, 임승훈, 이창희, 오정모, “기계 학습을 활용한 선박 기관의 고장진단 및 예측 기술에 관한 연구”, 889, 2021.
- [2] IEEE Eurasia Conference on IOT, Communication and Engineering, JongKyu Lee, “Fault diagnosis of bearing using Deep Neural Network with Dropconnect”, 2019
- [3] MDPI sensors, Niamat Ullah, “Pipeline Leakage Detection Using Acoustic Emission and Machine Learning Algorithms“, 23, 3226, 2023.
- [4] Dat in Brief, Mohsen Aghashahi, “ Benchmarking dataset for leak detection and localization in water distribution systems”, 48, 109148, 2023.
- [5] 한국자동차공학회, 이동희, 김병우, “압력센서 신호를 이용한 유압라인의 결합 검지기법 연구”, 1582-1585.2023.