

굴착기 주행디바이스의 고장 진단을 위한 AI기반 상태 모니터링 시스템 개발

Development of AI-Based Condition Monitoring System for Failure Diagnosis of Excavator's Travel Device

백희승^{1*} · 신종호² · 김성준²

Hee Seung Baek^{1*}, Jong Ho Shin² and Seong Joon Kim²

Received: 14 Oct. 2020, Revised: 02 Feb. 2021, Accepted: 22 Feb. 2021

Key Words : Diagnosis, AI (Artificial Intelligence), Vibration, Wavelet, Condition Monitoring

Abstract: There is an increasing interest in condition-based maintenance for the prevention of economic loss due to failure. Moreover, immense research is being carried out in related technologies in the field of construction machinery. In particular, data-based failure diagnosis methods that employ AI (machine & deep learning) algorithms are in the spotlight. In this study, we have focused on the failure diagnosis and mode classification of reduction gear of excavator's travel device by using the AI algorithm. In addition, a remote monitoring system has been developed that can monitor the status of the reduction gear by using the developed diagnosis algorithm. The failure diagnosis algorithm was performed in the process of data acquisition of normal and abnormal under various operating conditions, data processing and analysis by the wavelet transformation, and learning. The developed algorithm was verified based on three-evaluation conditions. Finally, we have built a system that can check the status of the reduction gear of travel devices on the web using the Edge platform, which is embedded with the failure diagnosis algorithm and cloud.

기호 설명

$x(n)$: original signal
 $g(n)$: high-pass filter
 $h(n)$: low-pass filter
 $\phi(t)$: scale function(approximation coefficients)
 $\psi(t)$: wavelet function(detail coefficients)
 j : particular scale
 $k2^j$: transition factor related to movement in time axis

1. 서론

최근 사후 정비로 인해 발생하는 경제적 손실을 방지하기 위한 고장 예지 및 건전성 관리(PHM: Prognostics and Health Management)관련 연구¹⁾가 활발히 이루어지고 있으며, 정보 통신 기술 발달과 Computing power의 비약적인 발전에 힘입어 관심이 지속적으로 높아지고 있다.

이러한 기술 트렌드 (Trend)를 반영 하듯 건설기계 분야에서도 많은 고장 진단 기술들이 개발²⁾되고 있으며, 건설기계의 주요 부품인 유압부품에서도 상태 모니터링을 통한 고장 진단 기술들이 개발³⁻⁴⁾되어 적용되고 있다.

이러한 기계 시스템의 고장을 진단하기 위해 상태를 판단할 수 있는 정보 즉, Data를 예측하고 고장을 판단할 수 있는 주요 특징(Feature)들을 예측 Data로부터 추출하여 고장 여부를 판단하게 된다. 고장 여부를 판단하기 위해서는 일반적으로 물리적 모델 기

* Corresponding author: heeseung1.baek@doosan.com

1 Advanced Research Team, R&D, Mottrol BG, Doosan Corporation, Incheon, 51528 Korea

2 Department of Industrial Engineering, Chosun University, Gwangju, 61452 Korea

Copyright © 2021, KSFC

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

고장 모드는 기어에서 발생하기 쉬운 기어 Tooth breakage, Crack, Pitting 3가지를 선정하였다. 이해를 돕기 위해 소형 주행디바이스의 구조 및 고장 진단 영역, 고장 모드 등을 Fig. 3에 표현하였다.

3.1 Data Acquisition

AI 기반 고장 진단 알고리즘 개발을 위해 정상 Data와 기어에서 발생하기 쉬운 고장 모드 3가지에 대하여 특성 Data를 측정 하였다.

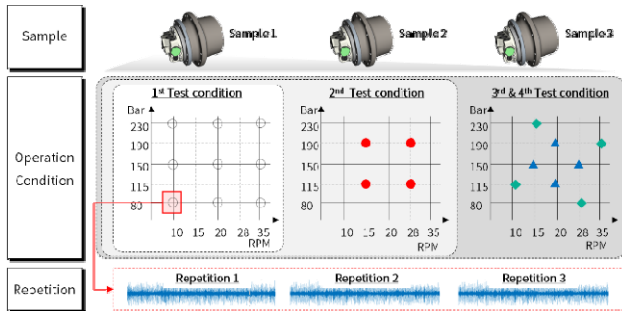


Fig. 4 Condition for Data Acquisition


Data 측정을 위한 구동 조건은 주행 디바이스가 구동할 수 있는 최소, 최대 회전수 및 압력 조건을 고려하여 선정하였다. 1st Test Condition은 주행디바이스의 전반적인 구동 조건을 임의로 선정하였으며, 2nd, 3rd Test Condition은 1st Test Condition의 Data로 학습된 AI 알고리즘의 정확도 결과를 토대로 필요한 구동 조건을 선정하였다.

주행디바이스 특성상 감속기가 회전하기 때문에 Control Part(고정부)에 Acceleration sensor를 부착하여 각각의 진동 특성 Data를 수집하였다. 총 수집된 진동 특성 Data는 총3개의 Sample에서 각 구동 조건마다 3회씩 반복 측정을 실시하였다. 또한, 진단 알고리즘의 진단 정확도를 향상 시키기 위해 총 4차에 걸쳐 구동 조건 별 시험을 실시하였다.

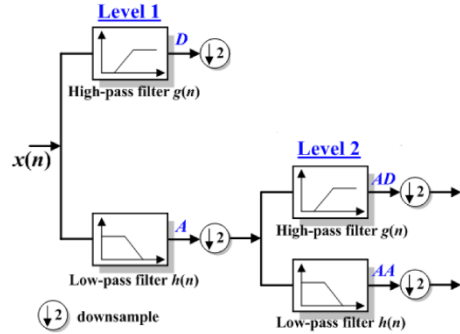
3.2 Feature Extraction

일반적으로 머신러닝과 같은 AI 알고리즘을 이용할 경우 측정 Data의 전처리를 통해 분류를 명확하게 할 수 있는 특징(Feature)을 추출하고, 이를 활용하여 AI모델 학습을 진행하게 된다.

본 연구에서도 측정된 진동 특성 Data로부터 고장을 명확히 구분하기 위한 특징 추출을 위해 이산 웨이블릿 변환(DWT: Discrete Wavelet Transform)을 이용하였다.⁵⁻⁶⁾



(a) Fundament of DWT Decomposition



(b) DWT Decomposition Tree

Fig. 5 Fundament and Tree of DWT Decomposition Visualization

DWT는 대표적인 비정상 신호의 시간 주파수를 분석을 위한 것으로 식(1)로 표현된다.⁵⁻⁶⁾

$$W(a,b) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{\infty} f(t)\psi^* \left(\frac{t-k2^j}{2^j} \right) dt \quad (1)$$

여기서, j 는 이산화 된 스케일 level을 의미하며 $k2^j$ 는 이산화 된 축(전이)를 의미한다. 실제 신호는 이산 적으로 계측되므로 n 개의 Data를 갖는 이산 신호 $x(n)$ 를 DWT하기 위해서 각신호 level j 에서 신호를 고주파 대역과 저주파 대역으로 분해 한다. 이때 고주파 필터 $g(n)$ 을 이용해 분해된 것을 상세 성분(Detail) D_j , 저주파 필터 $h(n)$ 을 이용해 분해된 것으로 근사 성분(Approximation) A_j 라고 하며, 근사 성분 분해에 사용되는 스케일 함수와 상세 성분 분해에 사용되는 웨이블릿 함수는 각각 식(2)와 식(3)으로 표현 할 수 있다.⁵⁻⁶⁾

$$\phi(t) = \sqrt{2} \sum_n h(n)\phi(2t-n) \quad (2)$$

$$\psi(t) = \sqrt{2} \sum_n g(n)\phi(2t-n) \quad (3)$$

DWT는 저주파 대역을 계속적으로 분할하면서 Data의 양이 증가하므로 각 level마다 Down Sampling을 통해 Data의 수를 반으로 줄임으로써 분해 신호의 총량을 유지한다. Fig. 5는 DWT의 기본적인 분해 원

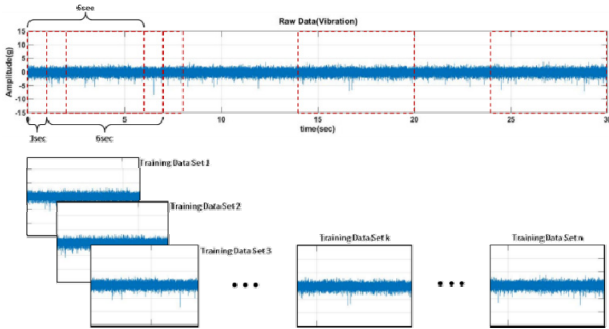


Fig. 6 Raw Data Time-Window Slicing

리를 가시화 하여 보여 준다. 3.1에서 설명한 것과 같이 진동 특성 Data를 측정하였으며, 진동 특성Data는 30초 또는 60초 동안 수집되었다. 수집된 Data는 Fig. 6에서 보는 것과 같이 6초단위로 Time-window로 추출하고 1초씩 Moving-Slicing하여 25개 또는 55개의 Subset으로 분할하였다.

Time-window의 크기는 감속기 내부 기어들의 최소 회전 수를 고려하여 적어도 1회전 이상의 정보가 포함되도록 설정하여 하나의 Time-window안에 AI 모델 학습에 필요한 특징 정보들이 포함되도록 하였다.

이렇게 6초 단위로 추출된 Data는 DWT를 이용하여 분해 하였다. Fig. 7은 1개의 Moving-Slicing된 Data가 DWT로 분해된 상세 성분(Detail)을 보여주고 있다. 각 Level의 상세 성분(Detail)으로 부터 특징을 추출하고 이를 AI모델 학습을 위한 최종 Feature로 선정하였다.

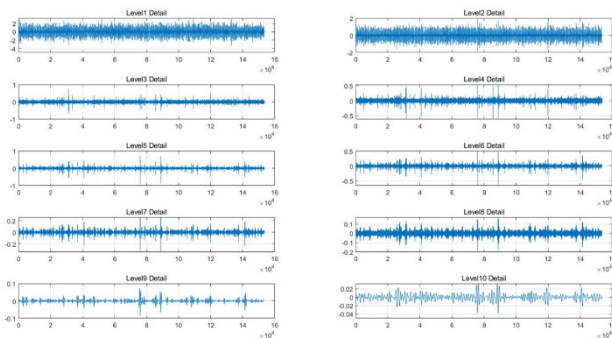


Fig. 7 Vibration data DWT Decomposition

3.3 AI Model Design & Training

고장 진단 AI 모델은 Concept에서 언급한 것과 같이 2단계로 나누어 진행하였다. 1단계에서는 정상과 비정상을 구분하고 2단계에서는 고장 모드를 구분하는 AI 모델을 개발하였다. 두 단계 모두 주로 분류 문제 해결에 많이 사용되는 Machine Learning의 대표적인 지도 학습모델 인 SVM (Support Vector Machine)




Fig. 8 Example SVM Kernel Function Application

을 이용하였다. SVM모델은 서로 다른 Class를 지닌 Data사이의 간격이 최대가 되는 Hyper Plane을 찾아 이를 기준으로 새로운 Data를 분류하는 모델이며, Data사이에 존재하는 Margin을 최대화하여 일반화 성능을 극대화한 모델이다. 일반적으로 고장 진단을 위한 Data들은 단순하게 선형적으로 분류하기가 어렵다. 이렇기 때문에 Data를 고차원 특징 공간으로 차원을 변경하여 분류가 어려운 Data를 명확하게 분류할 수 있도록 해주는 SVM모델의 Kernel기법이 주로 사용된다. 대표적인 Kernel로는 Linear, Poly nominal, Gaussian RBF(Radial Basis Function)Kernel 등이 있다.

본 연구에서 개발된 고장 진단 AI모델의 경우 두 단계 모두 Gaussian RBF Kernel을 적용하였다. 그리고 Kernel최적화를 위한 주요 Hyper Parameter인 Box constraint(=c)와 Scale(=gamma) 조절을 진행하였다. 여기서 Box constraint는 Data의 Sample들이 다른 Class에 놓이는 것을 허용하는 것을 결정하고, Scale은 결정 경계의 곡률을 결정하는 변수이다. 이 두 개의 Hyper Parameter값이 모두 커질수록 AI모델의 복잡도는 증가하며 낮을수록 복잡도는 낮아진다. 또한, Scale값이 너무 낮을 경우 언더피팅 가능성이 높고, 클 경우 오버피팅 될 가능성이 있기 때문에 각각의 Parameter값을 적절히 조절하는 것이 필요하다. 이를 위해 Table 1과 같이 Box constraint와 Scale를 Matrix로 설정하여 Grid Search를 진행하여 최적의 Parameter를 도출하였다. 도출된 Parameter토대로 개발된 고장 진단 AI 모델은 특정 모델의 1개의 Sample에서 수집한 Data를 이용하여 특정 Sample에 대해서는 기대 이상의 진단 정확도를 확보할 수 있었다.

Table 1 Hyper Parameter Grid Search Matrix

INDEX	Scale (= gamma)						
		1, 1	...	1, 10	1, 30	1, 50	...
Box - constraint (=c)	2, 1						2, 1000

	1000, 1	...	1000, 10	1000, 30	1000, 50	...	1000, 1000




Fig. 9 Concept Diagnosis Algorithm using Data Transfer AI Model




Fig. 10 Deep Neural Network for Data Transfer

하지만, AI 모델은 Data기반의 학습을 통해 이루어지기 때문에 Sample 변경과 시험기 변경으로 인해 발생하는 환경 요인에 의해 동일 모델에서도 미묘하게 진동 특성 Data가 변형되어 진단 정확도가 낮아지는 경향을 나타낸다. 이러한 문제를 해결하기 위해 Sample별로 다르게 나타나는 특성 Data의 공통적인 특징을 활용하여 범용성을 확보하는 방법으로 Data의 Transfer개념을 추가 하였다. 일반적으로 Data의 특성에 의존하지 않는 AI 모델의 범용성을 확보하기 위하여 AI 모델의 전이 학습(Transfer Learning)을 활용하지만, 개발된 고장 진단 AI 모델은 SVM으로써 전이 학습 개념의 적용이 불가능하다. 이르기 때문에 별도로 고장 진단 AI모델에 전 단계에서 Data 자체를 공용화 시키는 Data Transfer AI 모델을 개발하였다. Data Transfer를 위한 AI 모델은 DNN 모델을 활용하였으며, 전체 Data중 80%를 학습용으로 사용하고, 각각 10%씩 테스트용과 검증 용으로 사용하였다. 이를 이용하여 Fig. 9와 같이 Sample 2, 3의 Data를 Sample 1의 구동 조건의 Data로 전이하도록 학습 시켰다.

3.4 Evaluation

개발된 고장 진단 AI모델의 성능을 평가하기 위해 크게 3가지 조건을 선정하여 조건 별로 각각의 진단 Step별 정확도를 평가하였다. 3가지 조건은 구동 조건, 반복 조건, Sample 변동 조건이며, 조건 별 상세 내용은 Fig. 11에 자세히 표기 하였다.

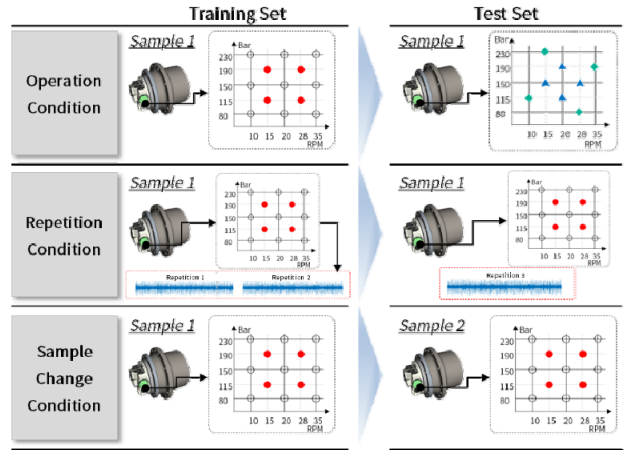


Fig. 11 Condition for Evaluation Accuracy

여기서 제시한 구동 조건은 일정 영역의 구동 조건에서 수집한 Data를 이용하여 학습시킨 AI 모델에 학습에 사용하지 않았던 구동 조건에서의 Data를 적용하여 고장 여부 및 고장 모드의 정확도를 확인하기 위함이다. 또한 반복 조건의 경우는 일정 영역의 구동 조건에서 수집된 Data의 산포 영향성을 확인하기 위한 목적으로 진행하였다. 마지막으로 Sample 변동 조건의 경우 Sample간의 변동을 통해 AI모델의 확장 적용 가능성을 확인하기 위해 평가하였다. 이는 Sample 1에서 수집한 Data를 이용하여 학습시킨 AI 모델이 Sample 2, 3에서도 진단할 수 있는지를 확인하기 위한 목적이다.

		Gaussian SVM				Gaussian SVM			
True Class	Normal	711	189	79.0%	21.0%	5901	41	99.3%	0.7%
	Abnormal	169	2451	93.5%	6.5%	14	6004	99.8%	0.2%
		80.8%	92.8%	Accuracy 89.83%		99.8%	99.3%	Accuracy 99.54%	
		19.2%	7.2%	Normal Abnormal Predicted Class		0.2%	0.7%	Normal Abnormal Predicted Class	

(a) Operation condition (b) Repetition Condition

		DNN / Gaussian SVM				DNN / Gaussian SVM			
True Class	Normal	174	4	97.8%	2.2%	157	19	89.2%	10.8%
	Abnormal	21	581	96.5%	3.5%	38	566	93.7%	6.3%
		89.2%	99.3%	Accuracy 96.79%		80.5%	96.8%	Accuracy 92.69%	
		10.8%	0.7%	Normal Abnormal Predicted Class		19.5%	3.2%	Normal Abnormal Predicted Class	

Application: Sample 2

Application: Sample 3

(c) Sample Change Condition

Fig. 12 Classification Accuracy with Three condition (Step 1)

True Class \ Predicted Class	Fault 1 (T/B)	Fault 2 (Crack)	Fault 3 (Pitting)	Accuracy
Fault 1 (T/B)	787	51	0	93.9%
Fault 2 (Crack)	89	829	60	84.8%
Fault 3 (Pitting)	4	0	820	99.5%
	89.4%	94.2%	93.2%	Accuracy 92.27%
	3.0%	5.8%	6.8%	

(a) Operation condition

(b) Repetition Condition

True Class \ Predicted Class	Fault 1 (T/B)	Fault 2 (Crack)	Fault 3 (Pitting)	Accuracy
Fault 1 (T/B)	195	51	5	77.7%
Fault 2 (Crack)	0	111	15	88.1%
Fault 3 (Pitting)	0	33	175	84.1%
	100.0%	96.9%	89.7%	Accuracy 82.22%
	0.0%	43.1%	10.3%	

Application: Sample 2

Application: Sample 3

(c) Sample Change Condition

Fig. 13 Classification Accuracy with Three condition (Step 2)

정상과 비정상을 구분하는 Step 1단계에서는 89.8%이상으로 높은 수준의 진단 정확도를 나타냈다. 세부적으로 Step1 단계에서의 정상과 비정상을 진단하는 정확도를 확인한 결과 비정상 진단의 정확도가 정상 진단 정확도 보다 높게 나타났다. 이는 정상과 고장 모드 상태 별 Data의 불균형으로 인해 발생된 것으로 추정된다. 고장 상태의 Data를 정상 상태의 Data보다 약3배 이상 많이 AI모델 학습에 사용하게 되어 고장의 진단 정확도가 더 높게 나타난 것으로 생각된다. 이러한 이유로 정상 Data가 증가할 경우 정상 진단 정확도 향상되어 전체 진단 정확도가 향상될 것으로 예상된다.

또한, Step2 단계에서 고장 모드를 진단하는 정확도는 3가지 조건에서 82.2%이상의 고장 모드 진단이 능력을 확인할 수 있었다. 특히, 구동 조건 및 반복 조건에서 90%이상의 높은 진단 정확도를 가졌다. 하지만 Sample 변동 조건에서 다소 정확도가 낮게 나타나는 경향을 보였다.

4. 원격 모니터링 시스템 개발

개발 된 AI기반의 고장 진단 알고리즘을 이용하여 원격으로 주행디바이스 감속기의 상태를 모니터링 할 수 있는 시스템을 구축하였다.





Fig. 14 Structure of Web Based Monitoring System

상태 모니터링 시스템의 구조는 Fig. 14과 같다. 내구 시험 장치에서 시험을 진행하는 주행디바이스(시험품)에 Acceleration sensor를 부착하고, Edge Platform (Computer) 에서 시험품의 상태를 알 수 있는 진동 특성 Data를 계측하고 고장 진단 알고리즘을 통해 정상 여부 및 고장 모드를 파악하게 된다. 또한, 시험품 고장 진단 정보와 상태 정보 Data를 TCP/IP를 통해 Edge Platform에서 AWS(Amazon Web Service)로전달한다. 이렇게 전달된 정보는 제품 설계자 및 시험기 운영자가 PC또는 Mobile에서 URL접속을 통해 손쉽고 원격으로 Web상에서 볼 수있게 된다. 그리고 고장 발생 시 Edge Platform에서는 내구 시험 장치의 비상 정지 신호를 송신하여 시험 장치를 멈추게 한다. Web기반의 모니터링 프로그램에서는 제품 설계자 및 시험기 운영자에게 고장 발생 여부를 메일과 문자 메시지로 자동 전송하도록 시스템을 구축 하였다. 시스템에 사용된 Edge Platform은 Window기반 PC로써 진동 신호 계측이 가능하여 Data 분석 및 진단이 가능하며, 유/무선 통신을 통해 관련 Data를 송/수신 할 수 있다.



(a) Edge Platform Program



(b) Web-Based Monitoring Program

Fig. 15 Application Program for Remote Condition Monitoring System

그리고 Fig. 15에 표현된 것과 같이 Labview프로그램을 이용하여 Edge Platform에서 Data 계측과 고장 진단 알고리즘을 통해 고장 여부 진단이 가능하도록 프로그램 하였다. 그리고 진동 Raw Data, Channel별 Feature, 시험 품의 현재 상태를 Dash Board에 Display 해준다.

또한, 실제 설계자 또는 시험기 운영자가 볼 수 있는 Web기반의 모니터링 프로그램은 크게 3개의 창(Main, Feature Detail, Failure Analysis)으로 구성하였다. Main창에서는 Test정보 및 설계자, 시험기 운영자 정보 및 현재 시험품의 상태가 표시되며 또한, 계측되는 진동 Data로부터 획득한 Feature값들을 그래프로 표현해 준다. 그리고 Feature Detail 창에서는 각 Feature값들의 분포 변화 및 Color Map을 통해 내구 시험 동안의 Feature의 변화를 전체적으로 파악할 수 있도록 해 준다. 고장 시에는 Failure Analysis 버튼이 활성화 되어 선택이 가능해 지고 Failure Analysis 창에서는 고장 모드에 대한 상세 표현을 해준다.

5. Conclusion

본 연구에서는 소형 주행디바이스 감속기의 상태를 파악하기 위한 AI 기반의 고장 진단 알고리즘 개발하였다. 이를 통해 다양한 압력과 회전수 별 구동 조건에서 진동 Data만으로 이상 유/무 및 고장 모드 진단이 가능함을 확인 할 수 있었다. 이는 감속기의 기어들의 복잡한 물리적 모델을 활용하지 않고 계측된 진동 특성 Data 만으로도 고장을 진단할 수 있다는 것을 의미하며, Data 기반의 고장 진단 방법의 효과를 입증했다고 할 수 있다. 또한, 개발된 고장 진단 알고리즘을 적용한 Web기반 원격 모니터링 시스템 구축함으로써 고장 진단 알고리즘 기술 개발의 활용 가능성을 확인하였다.

현재 개발된 고장 진단 알고리즘은 소형 주행디바이스 특정 Model에 국한되어 있으나, 추후 개발된 기술을 바탕으로 Data 기반의 고장 진단 알고리즘이 가지고 있는 단점을 보완하고 기술을 확장 시켜

다른 유압 Component에서도 활용할 수 있는 범용적인 고장 진단 기술 개발을 진행 할 계획이다.

이해관계(CONFLICT OF INTEREST)

저자는 이 논문과 관련하여 이해관계 충돌의 여지가 없음을 명시합니다.

References

- 1) J. H. Choe, "Introduction of prognostics and health management," Journal of the KSME, Vol.53, No.7, pp.26-34, 2013.
- 2) Q. HE, X. HE and J. ZHU, "Fault detection of excavator's hydraulic system based on dynamic principal component analysis," Journal of Central South University of Technology, Vol.15, pp.700-705, 2008.
- 3) W. Bartelmus and R. Zimroz, "Vibration condition monitoring of planetary gearbox under varying external load," Mechanical Systems and Signal Processing, Vol.23, pp.246-257, 2009.
- 4) C. Lu, S. Wang 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, Vol.230, pp.2913-2928, 2015.
- 5) J. H. Kim, "A comparative study of discrete wavelet transform(DWT) and wavelet packet transform(WPT) for Li-Ion cell," Proceedings of KIPE Conference, pp.152-153, 2014.
- 6) J. Kim et al., "Discrete wavelet transform-based characteristic analysis and SOH diagnosis for a Li-Ion cell," Proceedings of The 7th International Power Electronics and Motion Control Conference, pp.2218-2223, 2012.