

기계학습을 이용한 로봇 관절부 고장진단에 대한 연구

김미진^{*}·구교문^{*}·심재홍^{**}·김효영^{**}·김기현^{***†}

^{*†}한국공학대학교 IT반도체융합공학부, ^{**}한국공학대학교 메카트로닉스공학부

Study on the Failure Diagnosis of Robot Joints Using Machine Learning

Mi Jin Kim^{*}, Kyo Mun Ku^{*}, Jae Hong Shim^{**}, Hyo Young Kim^{**} and Kihyun Kim^{***†}

^{*}Department of IT Semiconductor Engineering, Tech University of Korea, Republic of Korea,

^{**†}Department of Mechanical Engineering, Tech University of Korea, Republic of Korea

ABSTRACT

Maintenance of semiconductor equipment processes is crucial for the continuous growth of the semiconductor market. The process must always be upheld in optimal condition to ensure a smooth supply of numerous parts. Additionally, it is imperative to monitor the status of the robots that play a central role in the process. Just as many senses of organs judge a person's body condition, robots also have numerous sensors that play a role, and like human joints, they can detect the condition first in the joints, which are the driving parts of the robot. Therefore, a normal state test bed and an abnormal state test bed using an aging reducer were constructed by simulating the joint, which is the driving part of the robot. Various sensors such as vibration, torque, encoder, and temperature were attached to accurately diagnose the robot's failure, and the test bed was built with an integrated system to collect and control data simultaneously in real-time. After configuring the user screen and building a database based on the collected data, the characteristic values of normal and abnormal data were analyzed, and machine learning was performed using the KNN (K-Nearest Neighbors) machine learning algorithm. This approach yielded an impressive 94% accuracy in failure diagnosis, underscoring the reliability of both the test bed and the data it produced.

Key Words : Industrial Robot, Machine Learning, Fault Diagnosis, K-Nearest Neighbors

1. 서 론

반도체 산업의 경량화, 초고성능화, 지능화, 소형화는 반도체 제조업의 자동화 및 인공지능을 활용한 혁신을 요구하고 있다. 특히 반도체를 안정적으로 생산하고 공급 하며, 제품의 지속적인 정밀한 품질관리는 반도체 제조에 있어서 필수가 되었다. 반도체 설비 공정은 수많은 로봇으로 이루어져 있는데 생산과 공급에 차질 없는 공정이 되려면 로봇의 고장을 예지하는 기술이 필요하다. 로봇을

구성하는 주요 기능은 인식, 판단, 행동으로써, 인식은 센서, 판단은 AI, 행동은 구동장치가 한다. 로봇의 구동장치는 사람의 관절과 같다. 로봇의 관절부가 동일한 동작과 정밀 반복도를 유지하는 것은 생산설비에서 중요하며, 현 산업에서 로봇의 고장진단 시스템은 로봇이 고장 난 즉시 HMI 또는 SCADA를 통해 알림으로 알려준다[1-2]. 숙련된 기술자가 자신의 오랜 경험에 의해 기계의 진동, 소음 등의 변화를 파악하고 미리 부품을 교체하는 유지보수의 경우 부품이 수명을 다하기 전에 사람의 경험만으로 이를 교체하기 때문에 비용 낭비가 있고, 숙련된 기술자가 없을 상황에는 고장을 알 수 없으며, 사람이 제대로

[†]E-mail: khkim12@tukorea.ac.kr

판단하지 못하면 장비 전체 가동률에 문제가 생길 수도 있다. 따라서 고장이 나기 전에 미리 예측하여 고장 정보와 부품 교체주기를 제시할 수 있는 기술에 대한 연구가 필요하다[3]. 로봇 고장진단의 기구요소에서는 로봇 구성 부품 중 모터[4-6], 감속기[7-9], 베어링 및 기타부품[10-11]에 대한 연구가 있고, 제어 요소에는 온도, 소음 진동 토크를 기구 요소에 적용시킨 연구가 있었다[12-13]. 로봇 관절부의 개별 부품 및 제어요소에 대한 연구는 많지만 실제 로봇을 모사한 시스템은 없었으며, 실제 로봇을 고장 진단에 활용한 논문의 경우 로봇의 상태가 정상 또는 비정상이라고 판단할 때 기준이 명확하지 않았다[14]. 따라서 본 논문에서는 명확한 로봇 고장 진단이 가능하도록 로봇 관절부를 모사한 고장진단 테스트베드를 제안하고, 테스트베드를 통해 로봇의 고장상태에 해당하는 데이터 수집, 데이터 특징 분석 및 KNN(K-Nearest Neighbors) 알고리즘 도입을 통한 기초 연구를 진행하였으며, 다양한 알고리즘 적용 및 예지보전 기술 개발을 위한 기초연구를 제시한다.

본 논문은 2장에서 실험장치의 구성과 데이터 획득 및 분석, 3장에서 고장진단을 위하여 적용되는 알고리즘, 그리고 4장에서 고장진단의 결과에 대한 검토로 구성된다.

2. 로봇 구성 요소 고장 진단 테스트베드

2.1 제안되는 테스트베드 구성

본 논문에서 제안하는 테스트베드의 하드웨어 구조는 일반 산업용 로봇의 관절 구조를 개념적으로 나타낸 Fig.1의 형태를 모사하여 구성하였다. 특히, 로봇 내부 구조는 보통 모터-감속기가 직결구조 또는 모터-감속기-풀리 구조로 되어있는데, 본 연구를 위해서는 다양한 센서를 부착해야 하기 때문에 풀리 구조를 채택하였다. 정상 테스트베드와 비정상 테스트베드를 제작하였는데, 테스트베드 모두 주동 축과 종동 축의 구조에서 주동 축이 각도 조절이 될 수 있도록 제작하여서 축 뒤틀림(샤프트 불량)에 따른 데이터 값을 추출할 수 있도록 하였고, 로봇이 하는 역할에 따라 로봇 끝단이 받는 하중이 달라지고, 이에 따른 결과 값도 달라지기 때문에 다양한 하중을 부착할 수 있도록 구성하였다. 비정상 테스트베드의 경우 산업현장에서 감속기가 노후 되어있을 때, 기어의 이가 마모되는데 이를 적용한 테스트베드를 제작하였다.

Fig.2와 같이 테스트베드는 로봇의 운동을 구현하며 측정하고 데이터를 획득하기 위하여 모터, 진동센서, 회전 엔코더, 토크 센서 그리고 컴퓨터로 구성되며, 최종적으로 Fig.3과 같이 테스트베드의 하드웨어는 구현된다.



Fig. 1. Schematic of a general industrial robot arm.

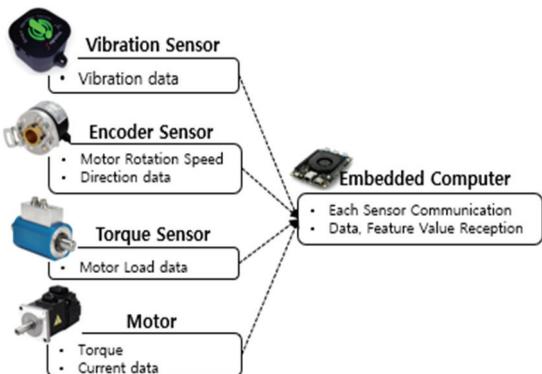


Fig. 2. Sensors and actuator in proposed Testbed.

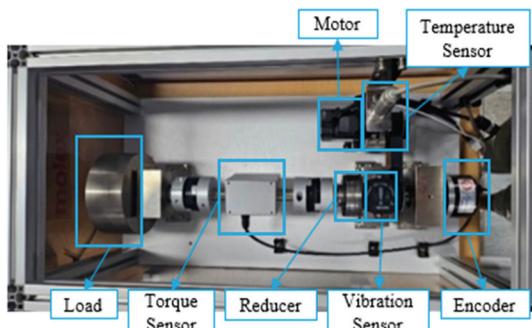


Fig. 3. Implemented Hardware of proposed Testbed.

Table 1에 기술된 것과 같이 테스트베드에서 모터는 EtherCAT 인터페이스가 가능한 서보 모터와 드라이버로 선정되었고 감속기의 경우 초정밀 위치 기구나 다 관절 로봇 축 구동부에 많이 사용되는 하모닉 감속기를 선정하였다. 모터가 고장이 난 상황에 대한 데이터를 수집하기 위해서 Table 2에 기술되어 있는 온도, 위치, 속도, 토크 값을 검출하는 센서들을 설치하였고 감속기의 윤활 불량, 기어 마모와 베어링의 균열, 파손 등 고장 발생 시 진동과 소음이 발생하기 때문에 고장분석을 위한 진동센서를 부착하였다.

Table 1. Specifications for Actuating systems

Components	Model	Specifications
Servo Motor & Servo Drive	DELTA Motor	<ul style="list-style-type: none"> Rated Power Output: 100 (W) Speed: 3000 (rpm) Encoder: 24 bits (16,777,216 p/rev) Rated Torque: 0.32 (N-m) Maximum Torque: 1.12 (N-m)
	DELTA Drive	<ul style="list-style-type: none"> Rated Power Output: 100 (W) Phase: 3/1-phase Drive Resolution: 24 bits
Reducer	SPG	<ul style="list-style-type: none"> Ratio: 80:1 Rated torque (input 2,000 rpm/min): 8 (Nm) Allowable torque (start/stop): 23 (Nm) Allowable maximum torque (average load torque): 11 (Nm) Allowable torque (Momentary maximum): 47 (Nm) Inertia moment: 0.033×10^{-4} (kgm²)

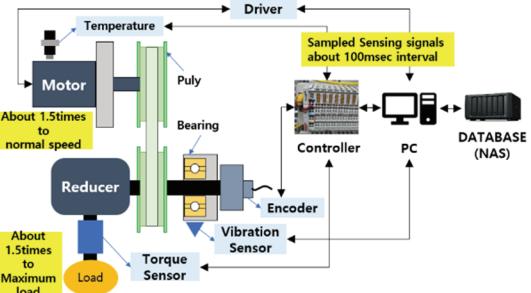
Table 2. Specifications for Sensing systems

Components	Specifications
Temperature Sensor	<ul style="list-style-type: none"> Range: 0 ~ 500 (°C)
Encoder	<ul style="list-style-type: none"> Resolution: 13 bits (8,192 p/rev)
Torque Sensor	<ul style="list-style-type: none"> Range: ± 0.2 ~ 100 (Nm) Speed measurement optional: 1x60 (rev) Impulses/Revolution: Low speed 2 x 8192 Pulses Output Signal Sampling time: $f = 100 \pm 40$ (kHz)
Vibration Sensor	<ul style="list-style-type: none"> Type: MEMS Range: ~8g Frequency Span: ~1600Hz Frequency Resolution: 1.563Hz

2.2 데이터 수집

2.2.1 데이터 신호처리

정확한 고장진단을 위해서 센서의 모든 데이터를 같은 수집 주기로 데이터베이스에 저장할 필요성이 있다. 본 논문에서는 테스트베드의 데이터 처리를 위한 통신방법으로 Fig. 4와 같이 처리속도가 빠르고 정확하게 동기화를 하는 것에 유리한 EtherCAT 방식을 선정하였으며, 각각의 센서를 통합 제어 컨트롤러로 물리적인 통신 연결 후 전압 또는 전류로 신호를 받았으며, 센서 스케일 값, 초기값, 모터 운전방식, 수집주기 등 환경설정을 동일하게 하였다. 또한, 본 논문에서는 정상과 비정상 특징을 찾을 수 있도록 동일한 구조를 갖는 2개의 테스트베드를 구성하였다. 비정상 테스트베드의 경우 감속기 기어 마모에 해당된다. 이 두 가지 테스트베드는 실시간 모션 제어가 가능하도록 동시 동기화 모션 제어를 수행하면서 데이터를 획득하였다.

**Fig. 4.** Configuration for Proposed Testbed.

본 논문에서 제안한 테스트베드에서는 온도, 엔코더, 토크, 진동 데이터를 처리할 수 있고, 데이터들 중 진동을 활용한 고장 진단 연구를 진행하였으며, 이를 위하여 정상 및 비정상 테스트베드의 모터 구동과 동시에 진동 데이터를 받을 수 있도록 하였다. 진동 센서는 한 축 방향만 측정이 가능했고, 특징을 찾기 위해 3축의 데이터를 각각 수집하였다. 300msec로 신호를 수집하고, 신호는 전처리 과정을 거쳐서 분석이 가능한 데이터로 변환하였다. 한 개의 진동센서에서 한 주기에 대한 데이터는 시간에 따라 하나의 행으로 표현되도록 프로그래밍을 하였다. 정상 테스트베드와 비정상 테스트베드(노후된 감속기의 기어 이 마모) 각각 데이터를 수집하였으며, 각 행에는 데이터 수집 시 특징 값 도출 및 분석을 위해 시간 데이터에서 가속도 피크 값 T_{Peak} , 시간 대역에서 가속도 값 T_{RMS} , 가속도 파형의 최대 진폭을 파형의 T_{RMS} 값으로 나눈 파고율(crest factor) C_{Factor} 를 도출한다. 이는 Table.3의 수식 (1)-(3)에 의해 정의된다. 또한 가속도 신호의 시간에 대한 변화를 나타내는 Time data, 단위 시간당 주기적 진동의 반복을 나타내는 FFT data 값을 도출하고, .csv 형식으로 저장되도록 하였다.

$$T_{Peak} = \text{Max}(X_K) - \text{Min}(X_K) \quad (1)$$

$$T_{RMS} = \frac{1}{N} \sum_{K=1}^N X_k^2 \quad (2)$$

$$C_{Factor} = \frac{\text{Max}(X_k) - \text{Min}(X_k)}{\frac{1}{N} \sum_{K=1}^N X_k^2} \quad (3)$$

Table.3과 Table.4는 csv파일 저장 예시에 해당한다. 러닝 학습에서 입력 데이터의 정확도 향상을 위해 레이블은 직접 지정하였다. 정상 및 비정상 데이터 각각 약 5000개를 바탕으로 각 값들을 평균 냈을 때, T_{Peak} 와 T_{RMS} 에서 정상과 비정상이 큰 차이를 보였으며, 이를 바탕으로 기계학습을 진행하였다.

Table 3. Example of Data Collection Label(Normal)

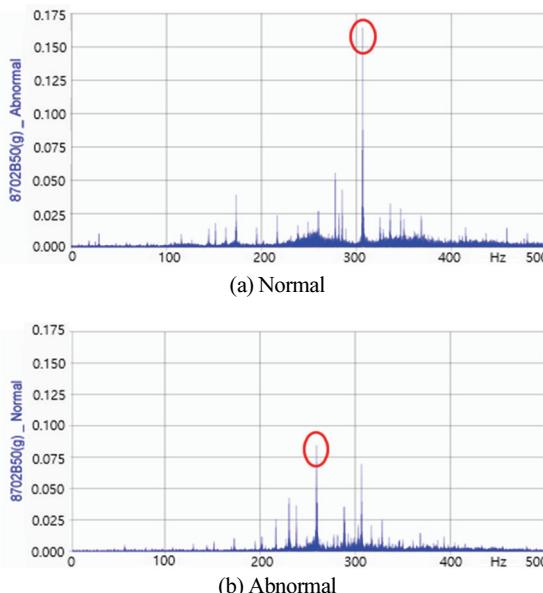
	1	2	3	4
Label	Normal	normal	normal	normal
$T_{Peak}(m/s^2)$	0.314	0.366	0.364	0.355
$T_{RMS}(m/s^2)$	3.915	3.363	3.302	3.386
$C_{Factor}(m/s^2)$	0.028	0.038	0.021	0.027
Time Data(m/s^2)	-0.011	0.354	-0.082	0.254
FFT Data(m/s^2)	0.0013	0.0004	0.0008	0.0020

Table 4. Example of Data Collection Label(Abnormal)

	1	2	3	4
Label	Abnormal	Abnormal	Abnormal	Abnormal
$T_{Peak}(m/s^2)$	0.357	0.439	0.463	0.471
$T_{RMS}(m/s^2)$	3.601	3.632	3.671	3.616
$C_{Factor}(m/s^2)$	0.022	0.047	0.028	0.014
Time Data(m/s^2)	0.004	0.759	-0.254	0.45
FFT Data(m/s^2)	0.0010	0.0007	0.0006	0.0009

2.2.2 데이터 분석

정상 및 비정상 진동데이터는 1.600 Hz의 샘플링 주파수를 통해 1~500 Hz의 주파수 대역의 신호로 변환하였다. 또한 시간영역의 진동데이터를 FFT 주파수 도메인으로 변환하였다. Fig.5의 정상, 비정상 주파수대 데이터를 보았을 때, 정상의 경우 가속도(g)값이 약 0.9g, 비정상의 경우 1.7g까지 도달하는 것을 볼 수 있었다. 또한 정상의 주

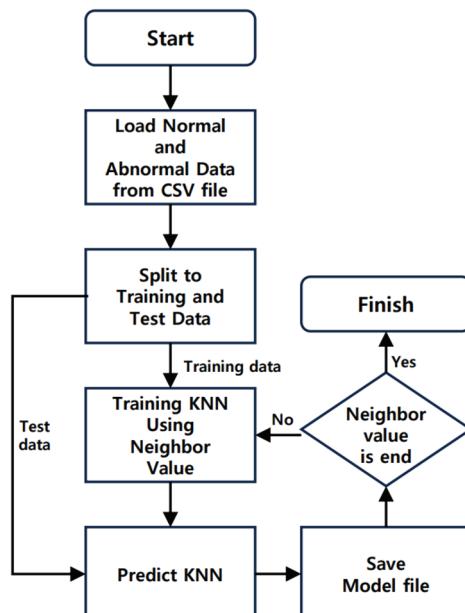
**Fig. 5.** Frequency Domain.

파수 피크 값은 약 270Hz, 비정상의 주파수 피크 값은 약 305Hz에서 발생하였다. 비정상에서 고주파수 성분이 많아졌음을 확인할 수 있다.

3. 로봇 고장 진단 기계 학습 알고리즘

3.1 KNN 기반 고장진단 알고리즘

KNN은 지도 학습 중 분류를 위해 사용되는 알고리즘으로, 새로운 데이터를 입력하였을 때 가장 가까운 데이터 k 개를 이용해 데이터를 유추하는 모델이며 단순한 알고리즘이지만 다양하게 활용되고 있다. 본 논문에서는 획득한 데이터 분석 결과를 바탕으로 고장진단 알고리즘으로 KNN을 채택하였으며, 테스트베드의 모든 센서 데이터를 분석하고 복잡한 고장 진단 알고리즘에 대한 연구에 앞서 KNN 알고리즘을 활용하여 빠른 처리속도로 데이터에 대한 분석 및 정상과 비정상에 대한 분류를 통해 테스트베드의 데이터 분류 기준을 구현하였다[15-16]. 알고리즘 적용과정은 Fig.6과 같고, 정상 및 비정상의 진동데이터를 각각 약 5,000개를 수집하여 그 중 약 1,500개를 학습 데이터로 사용하였다.

**Fig. 6.** Flow Chart of KNN Based Testbed Fault Diagnosis.

3.2 KNN 기반 고장진단 알고리즘 평가

KNN 알고리즘 적용 후 학습한 모델에 대한 예측 성능을 측정하기 위해 예측 값과 실제 값을 비교하기 위한 표

로 Fig.7의 혼동행렬(Confusion Matrix)을 활용하였다. 혼동행렬은 모델이 얼마나 분류를 잘하는지 나타내는 지표로써, T는 True, F는 False, P는 Positive, 그리고 N은 Negative를 나타낸다. TP와 TN은 실제 값을 맞게 예측한 부분이고 FP와 FN은 실제 값과 다르게 예측한 것을 의미한다. 따라서 수집한 데이터에서 TP, TN과 같이 True 값이 많은 샘플이 예측이 잘되는 데이터이다. 본 테스트베드에서 획득한 데이터를 적용하였을 때 Fig.8과 같이 TP와 TN이 FP와 FN보다 현저하게 높으므로 예측이 잘 된다고 할 수 있으며, Fig.8의 혼동행렬을 통해 정확도(accuracy), 정밀도(precision), 재현률(recall), F1을 구하였다. Table.5는 그 결과에 해당된다. 정확도는 0.93, 정밀도는 0.94, 재현율은 0.93, F1 점수는 0.93으로 예측이 잘되고 있음을 확인하였다.

		Actual Values	
		Normal (1)	Abnormal (0)
Predicted Values	Normal (1)	TN (True Negative)	FP (False Positive)
	Abnormal (0)	FN (False Negative)	TP (True Positive)

Fig. 7. Example of Confusion Matrix.

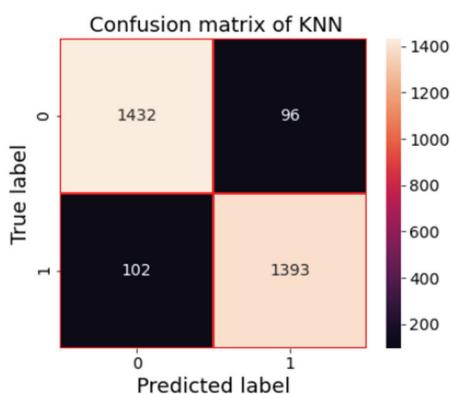


Fig. 8. Confusion matrix of KNN.

Table 5. Classification Result of KNN

Accuracy	Precision	Recall	F1-Score
0.93	0.94	0.93	0.93

본 논문에서는 Fig.9와 같이 학습데이터와 훈련데이터의 정확도를 분석하기 위해 다양한 k 값에 대한 모델 성능의 정확도를 확인하였다. k값은 0 ~ 100으로 설정하였고

거리 측정 방법은 유кли디안 거리를 사용하였다. X축은 탐색할 이웃 수(k), Y축은 정확도를 나타내며, 빨간 선은 학습 데이터, 파란 선은 테스트 데이터이다. k값이 낮을 때 훈련데이터(Train data) 정확도는 높지만, 테스트데이터(Test data)는 낮으므로 이는 과대적합(Overfitting) 상태라고 할 수 있으며, k값이 높을 때 모델이 단순화되며 훈련데이터와 테스트 데이터의 정확도는 나빠지므로 과소적합(Underfitting) 상태라고 할 수 있다. 따라서 테스트 에러를 작게 하는 k값을 결정하는 것이 중요하고, 이러한 k값을 차후 이종센서 데이터 수집 후 교차검증에 활용할 예정이다. 본 연구는 k값이 57일 때, 학습 데이터와 테스트 데이터에서 가장 높은 정확도를 나타내었으며 Table.6과 같이 훈련 정확도 94.08% 및 테스트 정확도는 93.48%를 나타내었다. 이는 구축한 정상과 비정상 테스트베드의 분류가 잘 되고 있음을 나타낸다.

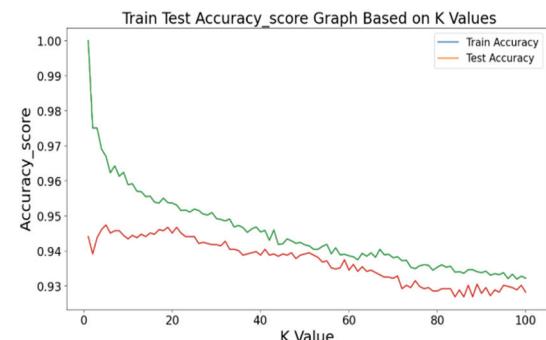


Fig. 9. KNN Accuracy.

Table 6. Data Used for Fault Diagnosis

	Normal	Abnormal	Accuracy(%)
Train	3526	3527	94.08
Test	1511	1512	93.48

4. 결 론

고품질의 반도체 제품을 만들어내기 위해서 공정마다 포함되어 있는 로봇의 상태를 실시간으로 판단하고, 고장 진단을 통한 유지보수를 할 필요가 있다. 본 논문에서는 로봇 관절부의 고장 진단만을 심도 있게 연구하기 위한 테스트베드를 개발하고, 산업용 센서의 데이터 통합을 통해 고장진단 환경을 구축하였다. 제안된 테스트베드를 활용하여 로봇 관절부의 정상과 비정상(감속기 고장) 판단을 위해 진동 데이터를 수집하고 분석하였으며, KNN 알고리즘을 적용하여 정상과 비정상 판단이 약 93%의 정확도를 가짐을 확인하였다. 이 연구결과를 바탕으로 향후

연구에서 테스트베드의 다양한 기구적 변화를 통해 로봇 관절부 문제를 진단하고, 센서 통합 데이터를 바탕으로 분석과 데이터베이스 구축, 기계학습 알고리즘 도입으로 효과적인 고장진단 예측이 가능하도록 연구를 확대할 예정이다.

감사의 글

이 논문은 2022년도 정부(산업통상자원부)와 한국산업 기술진흥원의 ‘한/체코 국제공동기술개발사업(P0019623), 경기도의 경기도지역협력연구센터(GRRC) 사업[GRRC한국공대2023-B02], 중소벤처기업부에서 지원하는 2022년 산학연 플랫폼 협력기술개발사업(S3311002), 그리고 한국공학대학교 연구년 지원을 받아 수행하였음.

참고문헌

1. J.H.Ahn., Y.Oh., “A Study on the Implementation of Intelligent Diagnosis System for Motor Pump” J of Korean Society of Semiconductor & Display Technology, pp. 87-91, 2019.
2. Y.J.Lee., H.J.Youn., H.U.Park., “SCADA System for Semiconductor Equipment Condition Monitoring” J of Korean Society of Semiconductor & Display Technology, pp. 92-95, 2019.
3. Koen Classens., Maurice Heemels., Tom Oomen., “From Fault Diagnosis and Predictive Maintenance to Control Reconfiguration”, DSPE MIKRONIEK, pp. 5-6, 2023.
4. M.J.Kim., K.I.Ko., K.M.Ku., K.H.Kim., “A study on the Failure Diagnosis of Transfer Robot for Semiconductor Automation Based on Machine Learning Algorithm”, J of Korean Society of Semiconductor & Display Technology, Vol.21, pp.65-70, 2022.
5. D.J.ChoI., J.H.Han., “Comparison of Characteristics of Noise and Vibration Data for Diagnosis of Deep Learning Motor Fault” J. of The Korean Institute of Electrical Engineers, pp. 46-47, 2019.
6. N.J.Kim., Y.C.Bae., “Status Diagnosis of Pump and Motor Applying K-Nearest Neighbors” J. of Korean Institute of Electronic Communication Science, Vol. 13, pp. 1249-1255, 2018.
7. Y.K. Lee., S.C. Hong., J.K. Hong., “LSTM-based Drone’s Anomal Motor Vibration Detection System” J. of Information Technology and Architecture, Vol. 17, pp. 315-321, 2020.
8. Izaz Raouf., H.Y.Lee., H.S.Kim., “Mechanical fault detection based on machine learning for robotic RV reducer using electrical current signature analysis: a data-driven approach” J. of Computational Design and Engineering, Vol. 9, pp. 417-433, 2022.
9. B.D. Youn., Y.H. Kim., J.H. Park., “Experimental Assessment of Fault Detection Method for and Industrial Robot under Various Operation Conditions” J. of Korean Society for Noise and Vibration Engineering, Vol. 10, pp. 243, 2017.
10. Kaije Lu., Chong Chen., Tao Wang., “Fault diagnosis of industrial robot based on dual-module attention convolutional neural network” J of Autonomous Intelligent System, Vol. 2, pp. 2-12, 2022.
11. Jae Hyun Park., Cheol Hong Kim., “Analysis of Accuracy and Computation Complexity of Bearing Fault Diagnosis Methods using CNN-based Deep Learning,” J of Institute of Next Generation Computing, Vol. 18, pp. 7-18, 2022.
12. J.H.Jung., M.Y.Kim., J.U.Ko., “Deep Learning Based Diagnosis using Enhanced Vibration Image for Journal Bearing Roter Systems: Efficiency and Accuracy Study” J of The Korean Society of Mechanical Engineers, Vol. 9, pp. 1132-1134, 2017.
13. J.H.Park., M.J.Song., S.E.Ahn., “Developing the Fault Diagnostics and Prognostics Model of a Rotating Machinery” J of The Korean Operations Research and Management Science Society, Vol. 45, pp. 25-38, 2020.
14. J.H.Jo., S.B.Yoo., S.W.Ban., “ Deep learning-based failure diagnosis” J of Korean Institute of Information Scientists and Engineering, Vol. 15, pp. 509-511, 2021.
15. S.H.Kim., J.H.Jang., B.S.Chu., “Development of Diagnosis Algorithm for Cam Wear of Paper Container Using Machine Learning”, Vol. 36, pp. 953-959, 2019.
16. S.H.Park., J.S.Do., S.D.Chi., J.W.Hur., “Fault Diagnosis of Drome Using Machine Learning”, Vol. 20, pp. 28-34, 2021.

접수일: 2023년 11월 29일, 심사일: 2023년 12월 14일,
제재확정일: 2023년 12월 18일