

<http://dx.doi.org/10.17703/JCCT.2024.10.3.801>

JCCT 2024-5-89

전이 학습을 이용한 선형 이송 로봇의 정렬 이상 진단 시스템

A Diagnosis system of misalignments of linear motion robots using transfer learning

홍수빈*, 이영대*, 박아름**, 문찬우***

Su-bin Hong*, Young-dae Lee*, Arum Park**, Chanwoo Moon***

요약 선형 로봇은 자동화 시스템에서 부품의 이송이나 위치 결정에 널리 사용되며 보통 높은 정밀도가 요구된다. 선형 로봇을 응용한 시스템의 제작회사에서는 로봇의 이상 유무를 작업자가 판단하는데, 작업자의 숙련도에 따라 이상 상태를 판단하는 정확도가 달라진다. 최근에는 인공지능 등의 기술을 사용하여 로봇 스스로 이상을 검출하는 방법에 관한 연구가 진행되고 있다. 본 논문에서는 전이 학습을 이용하여 선형 로봇의 볼 스크류 정렬 이상과 선형 레일 정렬 이상을 검출하는 시스템을 제안하고 가속도 센서와 토크 센서 정보를 이용한 별개의 실험을 통해 제안한 시스템의 이상 검출 성능을 검증 및 비교한다. 센서로부터 얻어진 신호를 스펙트로그램 이미지로 변환한 후, 영상 인식 인공지능 분류기를 사용하여 이상의 종류를 진단하였다. 제안한 방법은 선형 로봇뿐만 아니라 일반적인 산업용 로봇에도 적용할 수 있을 것으로 기대한다.

주요어 : 선형 로봇, 전이 학습, 이상 진단, 선형 레일 정렬 이상, 볼 스크류 정렬 이상

Abstract Linear motion robots are devices that perform functions such as transferring parts or positioning devices, and require high precision. In companies that develop linear robot application systems, human workers are in charge of quality control and fault diagnosis of linear robots, and the result and accuracy of a fault diagnosis varies depending on the skill level of the person in charge. Recently, there have been many attempts to utilize artificial intelligence to diagnose faults in industrial devices. In this paper, we present a system that automatically diagnoses linear rail and ball screw misalignment of a linear robot using transfer learning. In industrial systems, it is difficult to obtain a lot of learning data, and this causes a data imbalance problem. In this case, a transfer learning model configured by retraining an established model is widely used. The information obtained by using an acceleration sensor and torque sensor was used, and its usefulness was evaluated for each case. After converting the signal obtained from the sensor into a spectrogram image, the type of abnormality was diagnosed using an image recognition artificial intelligence classifier. It is expected that the proposed method can be used not only for linear robots but also for diagnosing other industrial robots.

Key words : Linear motion robot, Transfer Learning, Fault diagnosis, Linear rail misalignment, Ball screw misalignment

*정회원, (주) 나인벨 (제1저자)

**정회원, 서울사이버대학교 경영학과 교수

***정회원, 국민대학교 전자공학부 교수 (교신저자)

접수일: 2024년 3월 20일, 수정완료일: 2024년 4월 22일

게재확정일: 2024년 4월 25일

Received: March 20, 2024 / Revised: April 22, 2024

Accepted: April 25, 2024

***Corresponding Author: mcwnt@kookmin.ac.kr

School of Electrical Engineering, Kookmin Univ, Korea

I. 서 론

선형 이송 로봇(Linear motion robot)은 자동화된 생산시스템에서 다른 장치의 위치 결정이나 부품의 이송 등에 사용되며 일반적으로 높은 수준의 정밀도가 요구된다. 선형 로봇을 사용하여 자동화 시스템을 구성할 때 기구적인 정렬 불량(정렬 오차)이 발생할 수 있는데, 이는 소음과 진동을 발생시키고 전체 장치의 성능에 큰 차질을 가져오게 된다. 따라서 선형 이송 로봇 응용 장비의 생산기업에서는 일정 범위 이하로 정렬 오차 유격을 유지하는 품질관리가 필요한데, 지금까지는 주로 작업자가 기계의 상태를 본 후, 측정장비를 사용하여 고장과 불량을 판단하였으나, 시간이 오래 걸리고 작업자의 숙련도에 영향을 받는 문제가 있었다. 이에 따라 보조적인 수준이라도, 로봇에 이상이 있는 경우 스스로 검지할 수 있는 방법의 개발이 요구되는 상황이다. 기계장치가 스스로 고장을 검지하는, 특히, 장치에서 발생하는 진동신호로부터 고장을 자동으로 검지하는 자동 진동 진단 기술은 오래전부터 연구되었던 분야이다. 그중에서도 모터, 터빈과 같이 베어링으로 지지되는 회전축에서 발생하는 진동신호를 바탕으로 볼 베어링의 외륜과 내륜의 이상 유무를 검지하는 연구가 많이 이루어졌는데, 진동신호의 포락선 스펙트럼(envelope spectrum)을 통해 검지하는 방법[1], 웨이블릿(Wavelet) 변환을 이용하는 방법[2], 기계학습을 이용해 판단하는 방법 [3], 그리고 최근에는 심층학습(Deep Learning)을 이용한 방법[4] 등이 제안되었다. 볼 베어링의 진동 신호는 회전속도가 일정할 때는 주기적으로 반복되는 동일한 주파수 분포를 갖는 주기정상성(cyclostationary) 성질을 가지며 기존의 연구에서 이상 유무의 검지도 주로 이런 특성을 이용하여 이루어지는데 속도가 가변인 경우에는 차수추정을 통해 보정한다[1]. 베어링의 진동 진단과 비교하면 1축 선형 이송 로봇의 자동 진단에 관한 연구는 거의 이루어지지 않았다. 로봇의 운동범위가 제한되어 있고, 로봇 자체 기구부의 고유 진동이 포함되어 주파수 응답이 회전기기에 비하면 복잡한 양상을 보인다. 1축 선형 로봇에 관한 연구로는, 주로 구조적인 진동 특성에 관한 연구가 있었고[5], 전이학습(transfer learning)된 모델을 사용하여 선형 운동 가이드를 지지하는 베어링의 플레이킹(flaking)을 검출하는 연구[6], 전이 학습 방법을 사용하여 이송 회전축 베어링의 이상을 검지하

는 연구[7]가 있었는데 고장 또는 정상의 두 종류로 구분하는 이진 분류를 수행하였다. 반면, 지금까지 기구적인 정렬 유격 이상(misalignment) 검출에 관한 연구는 이루어지지 않았다.

본 논문에서는 기존의 전이학습을 이용한 자동 진단 방법을 활용하여, 반도체 장비에 사용되는 1축 선형 이송 로봇의 유격 이상을 검출하기 위한 전이 심층학습 모델기반 자동진단 시스템을 제안한다. 전이학습을 포함한 심층학습 모델은 복잡한 비선형 패턴을 근사하는데 최적의 방법이다. 이상 상태의 검출에는 진동신호를 이용하는 것이 일반적인 방법이나, 구동기 토크 신호를 사용하는 연구도 있었다[8]. 본 논문에서는 두 방법의 성능 비교를 위해 진동신호와 별도로 토크의 정보를 고장 진단에 사용한다. 토크 신호로도 충분한 이상 상태 검출이 가능하다면, 구동기의 피먹임 제어기에서 토크를 이미 검출하므로 별도의 검출 센서가 필요 없기 때문에 이상 검출 시스템의 구성에 유리한 점이 있다. 검출하는 이상 상태의 종류는 이전의 연구와는 차별적으로 다중분류기를 사용하여 선형 이송 로봇에서 자주 발생하는 LM (linear motion) 레일의 정렬 이상(misalignment)과, 볼 스크류(ball screw)의 정렬 이상을 대상으로 한다. 이 값들은 제조업체에서는 허용값 이내가 되도록 관리하는 값들이다. 기구적 정렬 이상 문제로 발생하는 진동은 동작 구간에서 주기 정상적 특성을 갖지 않아 기존의 신호처리를 통한 고장 검출이 어려우므로 심층학습을 통해 전체 진동 파형을 인식하는 방법이 유리할 것으로 판단된다. 본 논문은 로봇 스스로 이상 상태를 진단함으로써 진단 속도와 편의성을 높이는데 목적이 있다. 논문의 구성은 다음과 같다. 2장에서는 제안하는 선형 이송 로봇의 자동진단 방법에 대해 서술하고 3장에서는 데이터 세트의 구성과 실험 결과에 대해 그리고 마지막 4장은 결론으로 구성하였다.

II. 선형 이송 로봇의 정렬 이상 진단 시스템

1. 자동진단 방법의 구성

본 논문에서 제안하는 정렬 유격 이상 자동 진단 시스템의 구성은 그림 1과 같다. 대상이 되는 1축 선형 이송 로봇은 반도체 장비에 사용되는 웨이퍼 이송용 로봇이다. 우선, 가속도 센서와 토크센서로부터 진동 신호

와 토크 신호를 검출한다. 토크 신호는 장비에 장착된 토크 센서나 서보 드라이버의 전류 센서로 검출할 수 있는 장점이 있다. 검출된 신호는 STFT (Short time Fourier transform)을 하고 이 신호의 파워스펙트럼이 시간에 따라 변화하는 것을 시각화한 스펙트로그램 (Spectrogram)을 구한다. 스펙트로그램은 음성 신호의 시각화에 많이 사용하는 기법이다[9]. 스펙트로그램의 크기를 분류기 입력에 맞게 조절한 후 인식 분류기에 입력하여 이상의 유무와 종류를 분류한다. CNN (Convolutional Neural Network) 기반의 알고리즘은 각 계층마다 서로 다른 영상 데이터의 특성을 추출하며 학습하는 방식이다. 이번 진단시스템에서는 사전 학습된 모델인 CNN 기반VGG-19 모델 [10]을 실험으로 취득한 진동 스펙트로그램 데이터로 재학습시켜 사용한다. 고장 진단기의 각 과정에서 사용된 관련 배경 연구는 다음과 같다.




그림 1. 제안하는 진단 시스템
 Figure 1. The proposed diagnostic system

(1) STFT [8]

신호 $x(t)$ 의 STFT $X(\tau, \omega)$ 는 식(1)과 같이 $x(t)$ 와 짧은 시간 간격에서만 0이 아닌 값을 갖는 윈도우 함수 $w(\tau)$ 의 곱의 푸리에 변환이다. 윈도우 함수는 Hann 윈도우나 Gaussian 윈도우를 주로 사용한다.

$$X(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t-\tau)e^{-i\omega t} dt \quad (1)$$

(2) 스펙트로그램 [9]

스펙트로그램은 STFT한 결과에서 $|X(\tau, \omega)|^2$ 의 값을 시간 축과 주파수 축의 2차원으로 시각화한 것으로 진폭을 색깔이나 명암으로 표시한다.

(3) VGG 및 전이학습 [10]

VGG(Visual Geometry Group)는 이미지 인식을 위한 심층학습 모델로서, 224 x 224픽셀 크기의 이미지를 입력하여 이미지의 내용을 클래스 별로 분류할 수 있다. VGG-16과 VGG-19 모델이 사용되고 각각 16개와 19개의 컨볼루션 층을 갖는다. 산업용 시스템의 진단에 심층

학습을 적용하는 경우 모델을 학습시킬 충분한 데이터를 얻을 수 없는 경우가 많으며 특히, 이상 상황에 대한 데이터가 부족하여 데이터 세트가 불균형 (imbalance)해질 수 있다. 이런 경우에 전이학습(Transfer Learning)이 사용될 수 있는데, 전이학습은 유사한 문제에 대해 많은 데이터 세트로 검증된 모델을 재학습시켜 새로운 문제의 해결에 적용하는 방법이다.

2. 데이터 세트의 구성

데이터 세트는 그림 2에서와같이 LM 레일의 정렬 유격 이상과 볼 스크류 축의 정렬 유격 이상이 있는 상황에서 속도를 달리하며 로봇을 구동할 때 발생하는 진동과 토크 신호를 가속도 센서와 토크 센서로 수집하여 구성한다. 각 데이터 세트는 표 1과 같이 구분한다. 정상인 상태와 선형 레일에 중대한 정렬 이상과 경미한 정렬 이상이 있는 경우, 그리고 볼 스크류 축에 중대한 정렬 이상과 경미한 정렬 이상이 있는 경우로 구분하여 5개의 데이터 그룹으로 각 정보를 분류하였다.




그림 2. 정렬 이상의 정의
 Figure 2. Definition of misalignments

표 1. 데이터 클래스 세트
 Table 1. Data class sets

데이터 세트 이름	의미 I	Misalignment range
N	Normal	-
LR-H	Large linear rail misalignment	~0.1 mm
LR-M	Minor linear rail misalignment	~0.05 mm
BS-H	Large ball screw misalignment	~0.6 mm
BS-M	Minor ball screw misalignment	~0.3 mm

III. 실험 및 결과

1. 실험 장치 구성

실험 장치는 그림 3과 같이 웨이퍼 전송용 1축 선형 로봇에 가속도 센서와 토크 센서를 장착하여 구성하였다. 가속도 센서의 샘플링 주파수는 48 KHz이고 토크 센서는 100 Hz이다. 그림 4는 정상상태, 레일 유격 이상이 있는 경우, 그리고 볼 스크류 축 유격 이상이 있는 상황에서의 가속도 신호와 스펙트로그램을 나타낸 것이고 그림 5는 같은 조건에서의 토크 신호의 원신호와 스펙트로그램의 예를 그린 것이다. 진동신호와 스펙트로그램은 각각의 상황에서 다르게 나타나지만 규칙성을 찾기는 어렵다.

2. 훈련

훈련과 테스트에 사용한 데이터의 세트는 표2와 같다. LM 가이드의 전체 변위는 750 mm이고 이동 속도는 250 mm/s ~ 700 mm/s 사이에서 10단계로 나누어 구동하면서 데이터를 측정하였다. 각 데이터 세트 별로 구동시 발생하는 가속도 신호와 토크 신호를 각각 100개씩 수집하여 스펙트로그램으로 변환한 후 크기를 VGG-19의 입력 크기에 맞게 조절하였다. 이때 레일 정렬 유격은 약 0.1 mm와 0.05 mm이며 볼 스크류 정렬 이상은 0.3 mm 와 0.6 mm이다. 이 실험용 로봇에 있어서 허용하는 레일 유격은 0.02 mm, 볼 스크류 유격은 0.1 mm 이다.




그림 3. 실험 장치
Figure 3. Experimental setup

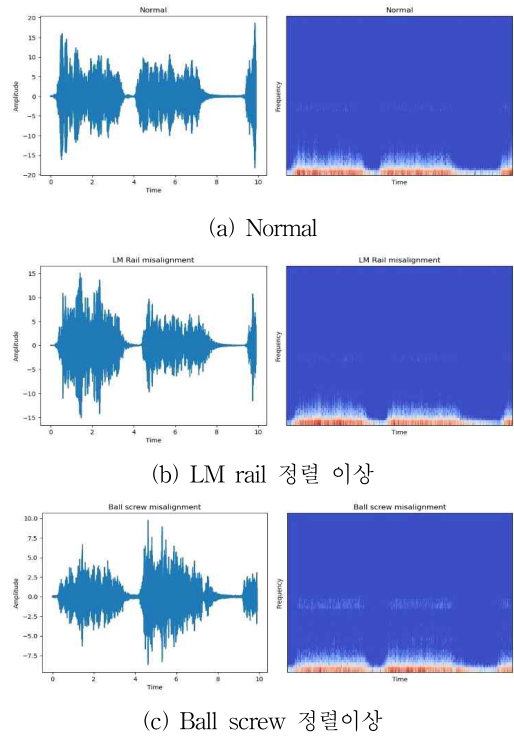


그림 4. 가속도 신호 (좌)와 스펙트로그램 (우)
Figure 4. Acceleration signal (left) and spectrogram (right)

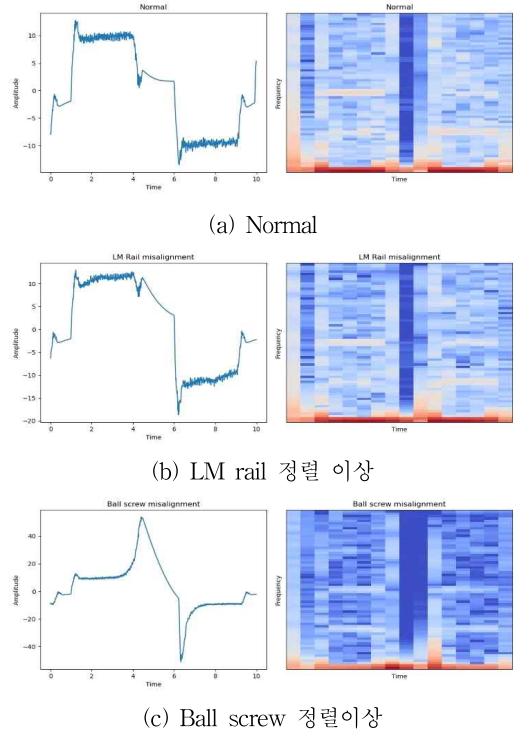


그림 5. 토크 신호 (좌)와 스펙트로그램 (우)
Figure 5. Torque signal (left) and spectrogram (right)

정렬 이상 검출 문제는 다음과 같이 구분해야 할 클래스의 수에 따라 4가지 문제로 나누어 훈련한 후 시험하였다.

- ① 2 클래스 타입 1 : 정상/비정상
 타입 2 : 정상/ LM 레일 정렬 유격 이상
 타입 3 : 정상/ 볼 스크류 정렬 유격 이상
- ② 3 클래스: 정상/LM 레일 정렬 유격 이상/볼 스크류 정렬 유격 이상

3 클래스 문제에 대해 훈련중의 손실 함수값은 가속도 센서인 경우 그림 6과, 토크 센서를 사용한 경우는 그림 7과 같다.

표 2. 실험용 데이터 세트

Table 2. Data sets for experiments

Data set	# Training data	# Test data	Type
N	80	20	spectrogram
LR-H	80	20	spectrogram
LR-M	80	20	spectrogram
BS-H	80	20	spectrogram
BS-M	80	20	spectrogram

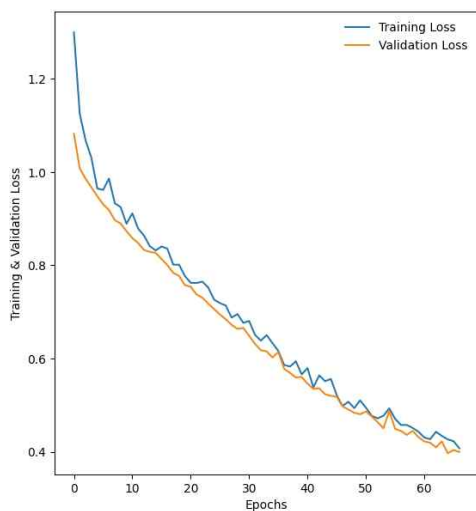


그림 6. 손실함수 (가속도 센서, 3 classes)
 Figure 6. Loss function (acceleration data, 3 classes)




그림 7. 손실함수 (토크 센서, 3 classes)
 Figure 7. Loss function (torque sensor, 3 classes)

3. 결과

구현된 자동 진단 장치의 테스트 결과는 표 3과 같다. 여기서 정확도는 각 문제에 대해 3회씩 트레이닝 데이터 세트와 테스트 세트를 선택하고, 훈련과 테스트를 반복한 결과의 평균값이다. 가속도 센서를 사용한 경우 정상/비정상을 구분하는 2 클래스 문제에서는 타입 1, 2, 3에 따라 89%, 91%, 89%의 정확도를, 정렬 유격 이상의 종류를 진단하는 3 클래스 문제에서는 78%의 정확도를 보였다. 토크 센서를 사용하는 경우는 모든 문제에서 가속도 센서를 사용한 경우에 비해 낮은 정확도를 보이며 3 클래스 문제에서 52%의 정확도였다. 추가 실험에서는 정렬 이상 유격이 아주 심각한 경우에 대하여 같은 방법으로 검출 정확도를 측정하였다. 추가 실험에서의 대략적인 유격은 LR-H: ~ 0.6 mm, LR-M: ~ 0.3 mm, BS-H: ~ 1.6 mm, BS-M: ~ 0.9 mm이다. 심각한 이상에서의 검출 정확도는 표 4와 같다. 유격 이상이 심한 경우에는 진동 패턴과 토크 패턴 모두 정상일 때와 차이가 크기 때문에 예상과 같이 높은 정확도를 보인다. 실험을 통해 얻는 판정 정확도는 일반적인 영상인식 문제의 정확도보다 낮는데, 산업용 기기인 경우 충분한 데이터세트를 확보가 불충분한 점에 기인한 것으로 생각된다.

표 3. 검출 정확도
Table 3. Diagnosis accuracy

Sensor type	Problem type	Accuracy %
Acceleration sensor	2 Classes type 1	89
	2 Classes type 2	91
	2 Classes type 3	89
	3 Classes	78
Torque sensor	2 Classes type 1	83
	2 Classes type 2	67
	2 Classes type 3	75
	3 Classes	52

표 4. 심각한 정렬 오차에서의 검출 정확도
Table 4. Diagnosis accuracy for severe misalignment

Sensor type	Problem type	Accuracy %
Acceleration sensor	2 Classes type 1	94
	2 Classes type 2	87
	2 Classes type 3	95
	3 Classes	90
Torque sensor	2 Classes type 1	98
	2 Classes type 2	95
	2 Classes type 3	100
	3 Classes	97

IV. 결론

본 논문에서는 선형 1축 로봇의 정렬 유격 이상을 진단하기 위하여 진동신호와 토크신호를 이용한 자동 진단 방법을 제시하였다. 진동신호를 이용하여 회전 운동하는 장치의 고장 자동진단은 오랫동안 연구되어 왔으나, 1축 로봇의 유격 이상 자동 진단에 관한 연구는 거의 이루어지지 않은 분야이다. 본 논문의 목적은 지금까지 인간 작업자에 의해 이루어진 제품의 이상 유무 검출을 로봇 스스로 수행하기 위함이다. 진동신호와 토크신호를 취득하여 STFT를 통해 변환한 후, 시간-주파수-진폭의 시각화 도구인 스펙트로그램을 구하고, 영상 분류기를 사용하여 고장의 종류를 분류하였다. VGG-19 기반의 영상 분류 모델을 이용하여 특징 추출기와 분류기를 선택적으로 학습하였고 학습된 분류기를 사용하여 정렬 유격 이상을 검출하였다. 센서로는 진동을 측정할 수 있는 가속도 센서와 토크 센서를 각각 사용하여 진단 성능을 평가하였다. 제안한 자동진단 방법을 사용하여 가속도 센서를 이용한 경우 2진 분류에서는 타입에 따라 89%, 91%, 89%의 정확도를, 3 클

래스 문제에서는 78%의 정확도를 보여서 유격 이상 유무와 이상의 종류를 판별할 수 있음을 확인하였다. 토크 센서를 이용하는 경우는 다소 낮은 정확도를 보였다. 더 높은 정확도를 얻기 위해서는 이상의 유무를 먼저 판단하고, 그 후 이상의 종류를 판단하는 방법이 유리할 것으로 판단된다. 제작된 자동 진단 시스템을 산업적으로 활용하기 위해서는 더 높은 정확도를 확보할 필요가 있지만 향후 연구에서 정확도가 개선된다면, 인공지능을 응용한 진단 방법은 다양한 산업용 기기의 이상 진단에 활용할 수 있을 것이다.

References

- [1] Randall, R., Antoni, J., (2011), Rolling element bearing diagnostics, *Mechanical Systems and Signal Processing*, 25, 485-520. <https://doi.org/10.1016/j.ymssp.2010.07.017>
- [2] Kankar, P., Sharma, S., Harsha, S., (2011), Rolling element bearing fault diagnosis using wavelet transform, *Neurocomputing*, 74, 1638-1645. <https://doi.org/10.1016/j.neucom.2011.01.021>
- [3] Zhao, H., Gao, Y., Liu, H., Li, L., (2019), Fault diagnosis of wind turbine bearing based on stochastic subspace identification and multi-kernel support vector machine, 7(2), 350-356, <https://doi.org/10.1007/s40565-018-0402-8>
- [4] Zhang, Shen, Zhang, Shibo, Wang, B., Habetler, T., (2020), Deep Learning Algorithms for Bearing Fault Diagnostics – A Comprehensive Review, *IEEE access*, 8, 29857 - 29881
DOI: 10.1109/ACCESS.2020.2972859
- [5] Yi, Y., Kim, Y., Choi, J., Yoo, J., Lee, D., Lee, S., (2004), Micro-scale Vibration Phenomena in a Linear Motion Guide Having Rolling Elements, *Transactions of the Korean Society for Noise and Vibration Engineering*, 14(10), 1029-1034
- [6] Cho, S., Kim, S., Choi, J., (2020), Transfer Learning-Based Fault Diagnosis under Data Deficiency, *Applied Sciences*, 10(21), 7768, <https://doi.org/10.3390/app10217768>
- [7] Yun, J., Kim, M., Koo, G., Shin, C., (2019), Fault Diagnosis and Analysis Based on Transfer Learning and Vibration Signals, *IEMEK J. Embed. Sys. Appl.* 14 (6),

287-293

- [8] Han, J., Park, S., Hong, S.,(2022), Performance Evaluation of the Continuous Wavelet Transformation Data in Motor Fault Diagnosis through XAI Algorithm, The Transactions of the Korean Institute of Electrical Engineers, 71(1), 225-232
- [9] Manhertz, G., Bereczky, A., (2021), STFT spectrogram based hybrid evaluation method for rotating machine transient vibration analysis, Mechanical Systems and Signal Processing, 154,107583
<https://doi.org/10.1016/j.ymssp.2020.107583>
- [10] Simonyan, K., Zisserman, A., (2015), Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv preprint arXiv:1409.1556.