

복합 MEMS 센서 기반의 기계설비 결함 진단시스템의 개발

최 우 진 *

Multi-MEMS-Sensor Based Machinery Fault Diagnosis System of Mechanical Device

Woo-Jin Choi*

본 연구는 2019년도 국가융복합단지 연계 지역기업 상용화 R&D의 재원으로 한국산업기술진흥원(KIAT)의 지원을 받아 수행한 연구과제(No. P0009958)임.

요 약

결함 진단시스템은 기계적인 결함을 사전에 파악함으로써 유지보수에 대한 계획을 미리 수립하고 유지보수에 필요한 더 많은 시간을 확보하도록 한다. 이를 위해 사용되는 여러가지 센서들 중에서 가속도 센서가 널리 이용되고 있다. 본 논문에서는 보다 정확한 진단을 위하여 정밀 가속도 센서와 더불어 복합 MEMS 센서를 함께 이용한 시스템의 개발에 대해 소개한다. 복합 MEMS 센서는 다수의 MEMS 센서가 하나의 모듈에 장착된 것으로서 회전기계와 선형운동 액추에이터의 운전 환경을 동시에 측정하기 위해 사용하였다. 이 센서들을 이용하여 수집한 데이터를 바탕으로 오토인코더와 딥러닝을 위한 신경회로망을 구축하여 기계설비의 결함진단을 시도하였다. 선형운동 기계설비에 대해서는 복합 MEMS 센서 내의 음향센서, 가속도 센서를 머신러닝에 이용하였다.

Abstract

The fault diagnosis system is designed to detect mechanical faults in advance so that plans for maintenance can be established in advance and more time required for maintenance is secured. Acceleration sensors are widely used among various sensors used for this purpose. In this paper, for the more reliable diagnosis, the development of a system that uses Multi-MEMS-Sensors together with precise acceleration sensors is introduced. Multi-MEMS-Sensors are equipped with a number of MEMS sensors mounted on a single module, and were used to measure the operating environment of rotating machinery and linear motion actuators at once. Based on the data collected using these sensors, an autoencoder and a neural network for deep learning were constructed to attempt to diagnose mechanical faults. For linear motion, acoustic sensor and accelerometer of Multi-MEMS-Sensor were used for machine learning.

Keywords

autoencoder, deep learning, machinery fault diagnosis, mechanical device

* (주)브이엠에스 기술연구소 연구소장
- ORCID:<https://orcid.org/0000-0002-2424-8954>

· Received: May 31, 2020, Revised: Jun. 16, 2020, Accepted: Jun. 19, 2020
· Corresponding Author: Woo-Jin Choi
VMS Co., Ltd., Busan, Haeundae-gu, Centum jungang-ro 90, QB Centum, 1106, Korea.
Tel.: +82-51-610-3071, Email: wjchoi@vmsco.co.kr

I. 서 론

4차 산업혁명, 사물인터넷(IoT), 스마트팩토리 등의 최근 트렌드에 따라 공장 기계설비의 자동화가 가속화 되고 있다. 이에 따라 기계설비의 정지, 고장 등에 따른 손실을 줄이기 위하여 결함 진단 분야에서도 인공지능형 진단 시스템의 개발이 요구되고 있다.

딥러닝과 기계학습은 데이터를 이용하여 모델을 학습한다는 공통점이 있지만 데이터를 학습하는 과정에서 큰 차이가 있다. 기계학습에서는 이미지를 인식하기 위해서는 사진을 그대로 사용하는 것이 아니라 사진 속의 객체를 가장 잘 구분할 수 있는 특성인자를 찾아낸다. 기계학습에서 모델의 성능을 결정하는 것은 이 특성인자가 얼마나 데이터를 잘 대표하는가이다. 반면 딥러닝의 경우에는 사람이 특성인자를 선정하는 것이 아니라 데이터로부터 모델을 학습하는 과정이며 목표를 잘 달성할 수 있는 특성인자를 스스로 찾는다. 기계분야에서도 복잡한 기계시스템으로부터 취득한 데이터로부터 특성인자를 찾아내는 것은 전문가의 지식을 많이 요구하기 때문에 기계학습의 적용에 어려움이 많았다.

반면 딥러닝은 특성인자를 자동으로 찾아내기 때문에 기계설비의 고장 진단 분야에서 딥러닝을 활용하려는 시도가 늘어나고 있다[1].

기계설비는 고장 위험에 노출되어 있으며, 사용시간이 길수록 고장 위험성은 한층 높아진다. 제조공장 또는 가공 공장에 구축된 기계설비들이 고장 나면 제품의 생산성과 수익성에 큰 영향을 끼치게 되며 산업재해 또는 사후 조치로 인한 많은 비용이 지출되며 필요할 때에 설비를 사용하지 못하는 불편을 초래하게 된다[2][3]. 그러나 기계설비의 고장 원인은 확인이 어려우며, 기계설비에 고장 원인(부품 결함)이 잔존함에도 불구하고 기계설비가 막연히 오래 지속되기만을 바라면서 간단히 대체하고 있는 실정이다.

물론 풍력발전기를 비롯하여 각종 기계설비의 고장을 진단하기 위해 각 기계설비별로 ISO 진동기준이 마련되어 있다[4]. 하지만 기계설비에 구성된 부품들의 고장 원인(부품 결함)을 확인하여야 하는데, 기계설비에 구성된 부품들에서 측정되는 데이터의

분석을 통해 찾는 접근법들은 기계설비의 고장 원인을 정확하게 파악하기 위해 정확한 부품의 사양을 요구하며, 진단 전문가를 필요로 한다[5][6]. 이러한 문제점으로 인해 산업현장에서는 전문가의 경험과 개인적인 능력에 의존하여 고장 원인을 찾아야 하는 어려움이 있다.

또한, 종래의 진단 시스템은 기계설비와 같은 대상에 결합되는 가속도 센서, 온도센서, 클램프 전류 센서와 같은 다양한 센서와 센서들을 통합, 분기하기 위한 정션 박스, 신호처리장치, 디스플레이 장치 등으로 구성되는데 기계설비의 상태를 정밀하게 감시하기 위해서는 다양한 종류의 센서를 필요로 하고 각각의 센서들은 고가이기 때문에 고가의 기계설비에만 적용되거나 저가의 기계설비에는 센서의 종류를 단순화하여 적용하는 문제점이 있었다. 이에 대해 복합 MEMS 센서는 다수의 MEMS 센서가 하나의 센서모듈에 장착된 것으로서 기계설비의 원격 실시간 진단에 있어서 운전 환경을 측정하는 용도로 적용할 필요성을 인식해 오고 있었다[7].

본 논문에서는 비교적 저렴하고 다양한 종류의 센서가 내장된 복합 MEMS 센서 기반의 기계설비 결함 진단시스템의 개발에 대해 소개한다. 복합 MEMS 센서를 이용하여 기계설비의 운전 환경을 측정함으로써 기계설비의 정지, 과도상태 등을 판단하여 진단에 필요한 정상적인 운전상태가 아닌 경우에 취득한 진동가속도 데이터는 학습에서 미리 제외시킬 수 있는 장점이 있다. 다음의 2장에서는 시스템의 주요 구성부에 대해 설명하고 딥러닝을 위한 구성도 및 진단 결과 화면을 제시하였으며, 3장에서는 결론 및 향후 과제에 대해 소개한다.

II. 본 론

2.1 진동 기반 상태 모니터링

진동가속도 센서 외에 변위센서를 추가하는 등 다수의 센서로부터 보다 정확한 기계설비의 결함 진단 결과를 얻기 위한 연구가 시도되어왔다[8].

하지만 여전히 대부분의 결함 진단시스템이 기계설비의 전반적인 운전환경을 고려하지 않고 진동가속도 신호만을 이용하여 진단을 하고 있다. 실제로

기계설비는 온도, 습도, 작동 조건의 변경 등으로 측정데이터에도 영향을 준다[1]. 이러한 문제점을 개선하기 위해 본 연구에서는 비교적 가격이 저렴한 복합 MEMS 센서(가속도, 온습도, 광센서, 자이로스코프, 자기, 음향센서 등)로부터 데이터를 받아 측정된 진동 데이터를 검증하여 사용하였다. 수집한 진동데이터는 오토인코더 모델과 딥러닝 모델이 내장된 인공지능망에 입력되어 기계설비의 결함을 진단하도록 설계하였다.

2.2 시스템의 개요

그림 1은 복합센서 기반의 인공지능형 결함 진단 시스템에 대한 개념도를 나타낸 것이다.




그림 1. 인공지능형 결함 진단시스템의 개념도
Fig. 1. AI-type machinery fault diagnosis system

센서부는 통신모듈(WiFi), 정밀가속도센서, 복합 MEMS 센서를 포함한다. 데이터수집부는 통신모듈(Ethernet), 데이터저장모듈, 신호처리모듈을 포함한다. 머신러닝부에는 통신모듈(WiFi & Ethernet), 데이터베이스모듈, 교정모듈, 딥러닝모듈, 오토인코더모듈을 포함한다. 모니터링부는 알람모듈, 디스플레이모듈, 터치입력모듈을 포함한다. 다음의 표 1에서는 기존의 시스템과 비교하여 특징을 나타내었다.

표 1. 진단시스템의 특징 비교

Table 1. Comparison of features of diagnostic systems

비교항목	기존의 진단 인공지능시스템	복합 MEMS 센서 기반의 진단시스템
하드웨어	PC, 그래픽가속기	nVidia Jetson Nano기반
센서	진동가속도 운전환경 미반영	진동가속도 및 복합 MEMS 센서 적용
학습	배치학습	온라인학습 (학습시간 별도필요)
알고리즘	지도학습	비지도 및 지도학습
진단 대상설비	회전기계 - 운전속도 미반영	회전 및 선형운동 기계 - 운전속도 자동추정

2.3 시스템의 주요 구성부

2.3.1 센서부

센서부에는 실질적으로 기계설비의 진동가속도 측정할 수 있는 정밀 진단용의 IEPE방식의 정밀가속도센서가 준비되어 있다. 그리고 MEMS 기반의 센서가 함께 포함되는데 기계설비의 운전과 관련된 주변 환경 조건을 계측하고, 정밀가속도센서의 유효한 신호를 구분하는 용도로 사용된다. 복합 MEMS 센서로부터는 가속도(설비의 경사 측정용 또는 가속도의 크기값만을 얻는 용도로 사용하였음), 온습도, 빛, 자이로스코프, 자기, 음향센서 등의 센서값을 얻을 수 있다. 그림 2는 선형 액추에이터에 Bosch사의 복합 MEMS 센서를 응용한 예로서 가속도와 소음센서의 데이터로부터 결함진단을 하기 위하여 LM block 위에 장착하였다.

복합 MEMS 센서는 WiFi 통신을 통해 머신러닝 알고리즘이 탑재되어 있는 머신러닝부로 데이터를 전송한다. 한편, 데이터수집부의 신호입력단에 연결된 정밀 가속도센서의 값은 Ethernet 통신을 통해 머신러닝부로 데이터를 전송한다.




그림 2. 복합 MEMS 센서 (Bosch XDK110)
Fig. 2. Multi-MEMS-sensor (Bosch XDK110)

2.3.2 오토인코더 모듈

오토인코더 모듈은 데이터수집부에서 수집된 데이터가 입력레이어, 히든레이어, 출력레이어로 순차적으로 거치면서 인코딩과 디코딩을 통해 원래의 데이터로 재구성되도록 설계된다[9].

여기에서는 오토인코더가 지닌 비지도 학습의 특성을 이용하여 그림 3과 같이 기계설비의 정상적인 작동에 대한 신호를 학습한 후 입력레이어와 출력

레이어 간의 평균제곱오차(Mean of squared error)가 설정값 이상일 경우 이상상태로 판정하도록 하였다.

오토인코더 모듈에서 이상상태라고 판단한 경우에는, 다음 단계의 딥러닝 모듈이 이상상태라고 판단된 특징맵을 바탕으로 기계설비의 결함 진단 결과를 분류하도록 하였다. 개발한 진단 시스템의 알고리즘은 오토인코더 모듈과 딥러닝 모듈이 직렬로 연결된 캐스케이드 방식이다[10].

2.3.3 딥러닝모듈

딥러닝모듈은 그림 4와 같이 기계설비의 결함 정도를 소프트맥스 회귀 함수로 연산하여 확률수치를 출력값으로 출력하도록 구성하였다.

학습의 원리는 출력값에 대해 목표값을 설정하고, 출력값과 목표값 간의 오차를 경사하강법(Gradient descent method)을 이용하여 신경회로망의 결합 가중치를 학습이 진행됨에 따라 조금씩 수정하도록 해 나가도록 하였다.

다음의 그림 4에는 데이터수집부로부터 얻은 4개의 채널에 대한 진동가속도 원신호(Raw data)를 사용한 예이며, 이 신호에 대한 엔벨로핑 결과 수치와 그래프를 상단에 나타내었다. 실험은 회전기계 결함 시뮬레이터(모델명: VibDemo)에 4개의 진동가속도 센서(모델명: CMSS 2100)를 장착하여 수행하였다.

그림 5는 딥러닝 모듈에 관한 내용이며, 딥러닝 알고리즘의 구현을 위해서 텐서플로를 사용하였으며, 소프트맥스 출력의 형태로 구현하였다[11].



그림 4. 진동가속도 엔벨로핑
Fig. 4. Vibration acceleration enveloping




그림 5. 소프트맥스 회귀의 구조 (딥러닝 모듈)
Fig. 5. Softmax (Deep learning module)

Anomaly detector (RAW)

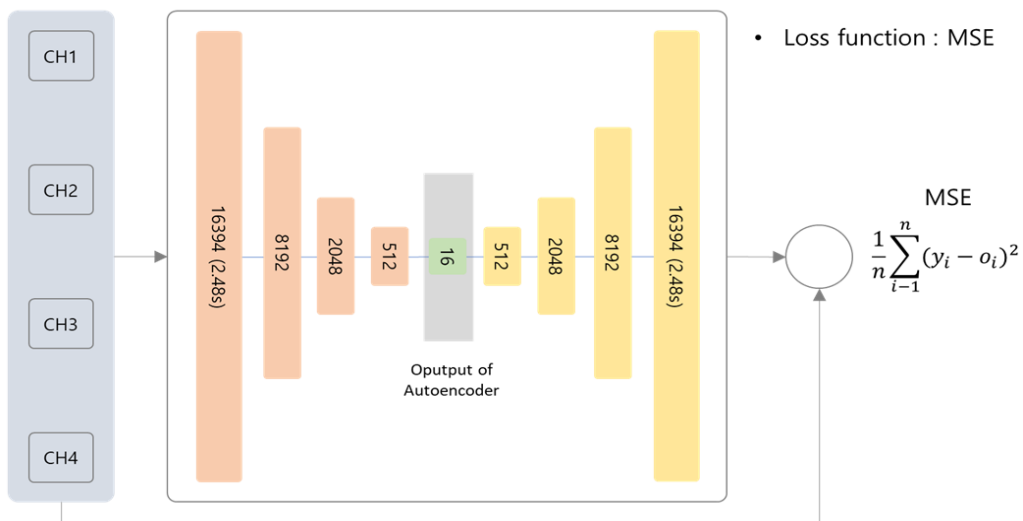



그림 3. 오토인코더
Fig. 3. Autoencoder

2.4 복합센서 기반의 결함 진단 시스템

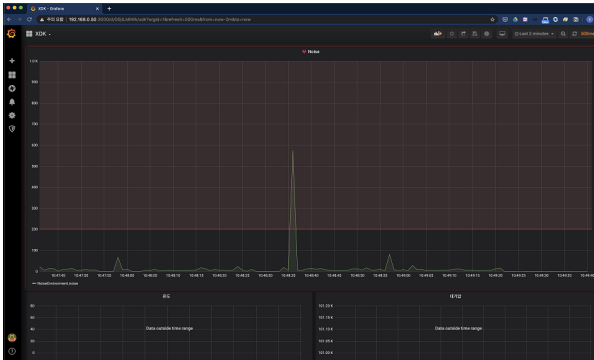
2.4.1 복합 MEMS 센서와 정밀가속도 센서

개발한 복합 MEMS 센서 기반의 인공지능형 결함 진단 시스템은 앞에서 설명한 바와 같이 센서부, 데이터수집부, 머신러닝부 및 모니터링부로 구성된다.

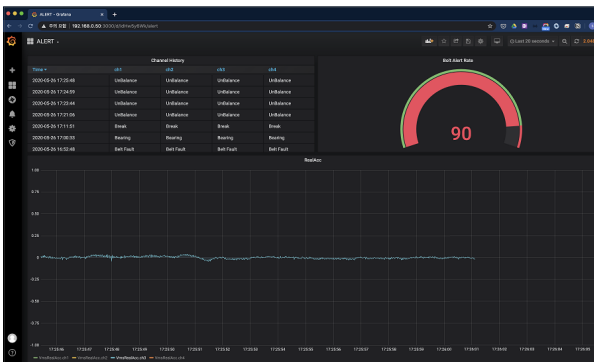
기계설비의 결함 진단을 위한 신호를 감지하기 위한 센서부는 운전환경을 모니터링하는 복합 MEMS 센서, 정밀가속도 센서, 데이터를 주고받을 수 있는 통신모듈로 구성된다.



(a) 복합 MEMS 센서의 출력값
(a) Monitored values of Multi-MEMS-Sensor



(b) 음향센서를 이용한 선형 액추에이터의 이상 진단
(b) Diagnosis of linear actuator using acoustic sensor



(c) 회전기계의 진단 (언밸런스 확률 90%)
(c) Diagnosis of rotary machine (unbalance probability 90%)

그림 6. 모니터링부에서의 표시
Fig. 6. Display screen of monitoring part

복합 MEMS 센서는 가속도, 온습도, 빛, 자이로스코프, 자기, 음향, 먼지 센서 등의 다수의 신호를 동시에 측정하도록 구성될 수 있는데, 본 연구에서는 8가지의 물리량을 측정할 수 있는 Bosch사의 XDK110 센서를 사용하였다.

그림 6에 nVidia Jetson Nano와 LCD터치장치로 구현한 모니터링부의 화면을 예시로 나타내었다. 온도, 습도, 조도, 압력 등의 복합 MEMS 센서 데이터값의 표시 화면과, 음향센서와 알람기준값을 이용한 이상 진단 화면, 4개 채널에 대한 진단 결과 화면을 각각 나타낸다.

이렇게 복합 MEMS 센서를 사용할 때의 장점은 종래의 IEPE 센서 신호처리에 따른 정확도에 중점을 둔 기계설비의 진단 기술을 보완하여 전체 설비나 장비의 운전 상태를 전반적으로 함께 모니터링할 수 있다는 장점이 있다.

한편, 정밀 가속도 센서는 나사 체결방식, 접착제 고정방식 등을 이용하여 기계설비에 직접 부착된다.

2.4.2 ARM Cortex-M7로 구현한 데이터수집부

데이터수집부는 전술한 센서부의 정밀 가속도 센서의 출력신호를 수신하여 상위 시스템(머신러닝부)으로 원신호를 보내는 역할을 한다. 머신러닝부는 원신호를 그대로 사용하거나 또는 푸리에 변환(FFT)의 전처리를 한 후 학습에 이용하게 된다. 데이터 수집부는 통신의 단절 시를 대비하여 데이터를 자체에 저장할 수 있는 저장부를 갖도록 설계하였다.




그림 7. 데이터수집부의 PCB 및 블록도
Fig. 7. PCB and blockdiagram of data acquisition part

그림 7은 ARM Cortex-M7으로 구현한 데이터수집부의 PCB 형상 및 기능 블록도를 나타낸 것이다. 최대 8개의 IEPE 진동가속도 센서를 부착할 수 있다.

III. 결론 및 향후 과제

본 논문에서는 오토인코더와 딥러닝 모델이 캐스캐이드 형태로 내장된 기계설비 진단 시스템의 개발 사례에 대해 소개하였으며 각 구성부는 다음의 특징을 가진다.

첫째, 머신러닝부는 오토인코더를 이용하여 이상 상태 감지(Anomaly detection)와 특징맵을 형성하도록 하였으며, 그 다음 딥러닝 모듈에서 결함을 분류하도록 설계하였다. 뿐만 아니라, 이러한 진단 알고리즘을 nVidia Jetson Nano 기반에서 실행하도록 하였으며, 수집한 데이터의 신호처리, 데이터베이스화를 함께 담당하도록 구현하였다.

둘째, 센서부는 기계설비의 운전 환경을 계측하기 위한 복합 MEMS 센서를 채용하였으며, 이것은 가속도, 온습도, 빛, 자이로스코프, 자기, 압력, 음향 센서 등의 복수의 센서를 갖추고 있어서 기계설비의 운전 환경을 저렴하게 구축할 수 있는 장점이 있었다. 특히, 기계설비의 진단에 불필요한 정지, 과도상태 등을 판단한 후, 진단에 필요한 정상 운전상태에서의 진동가속도 데이터만을 학습에 이용할 수 있도록 구현하였다.

셋째, 오토인코더 모듈은 데이터수집부로부터의 원신호 또는 FFT 처리된 데이터를 입력하는 입력 레이어 유닛과, 입력레이어가 인코딩되어 특징맵을 가진 히든레이어로 압축되는 히든 레이어 유닛과, 히든레이어가 디코딩되어 출력레이어로 재구축되는 출력레이어 유닛으로 구성된다. 오토인코더 모듈은 기계설비의 정상적인 작동에 대한 신호를 온라인 학습하도록 설계하였으며, 입력레이어와 출력레이어 간의 평균제곱오차가 소정의 값 이상일 경우 이상 상태라고 판단하게 된다. 오토인코더 모듈에서 이상 상태라고 판단한 경우에 딥러닝 모듈은 특징맵을 바탕으로 기계설비의 결함 진단 결과를 생성하는 것을 특징으로 한다. 본 논문에서는 회전기계 결함 시뮬레이터 상에서의 벨트, 베어링, 마찰, 언밸런스

등의 기본적인 결함을 성공적으로 감지하여 진단 결과를 도출하였다.

앞으로 진단의 신뢰성 및 재현성을 확보하기 위한 노력을 계속해 나가고자 하며, 현재의 연구결과를 바탕으로 최종적으로는 더욱 작은 소형, 무선의 인공지능 진단장치를 개발하여 상용화 하고자 한다. 이를 위해 신경회로망의 구조를 단순하게 만들어서 계산속도를 향상시킬 수 있는 Pruning 기법의 도입, 신경회로망의 최적구조 탐색에 관한 연구를 계속 진행해 나가고자 한다.

References

- [1] H. Ahmed and A. K. Nandi, "Condition Monitoring with Vibration Signals", Wiley-IEEE Press, pp. 117-130, 2019.
- [2] C. Scheffer and P. Girdhar, "Practical Machinery Vibration Analysis & Predictive Maintenance", Elsevier, pp. 89-133, 2004.
- [3] B. S. Yang, "Failure analysis and diagnosis of induction motor using vibration signal analysis technology", GSinterview, pp. 9-11, 2019.
- [4] ISO 10816-21:2015 Mechanical vibration, 2015.
- [5] M. N. Hoque and S. Hamdan, "Vibration Measurement of Rolling Element Bearing", LAP LAMBERT Academic Publishing GmbH & Co. KG, pp. 13-54, 2011.
- [6] S. Goldman, "Vibration Spectrum Analysis", Industrial Press Inc., pp. 1-25, 1999.
- [7] W. J. Choi, S. M. Jung, T. Y. Hong, and C. K. Lee, "Remote Real-Time Diagnostics for Wind Mill using Vibration Sensors", The 2019 Fall Conference of Korea Wind Energy Association, pp. 336-337, Oct. 2019.
- [8] K. H. Kim, Y. J. Park, J. W. Yoon, and J. H. Kim, "Vibration diagnosis for a rotating machinery using multiple sensors", Proceedings of the 12th KACC, pp. 852-855, Oct. 1997.
- [9] Solaris, "Deep Learning with TensorFlow", Youngjin.com Inc., pp. 97-117, 2018.

- [10] VMS Co., Ltd., "Fault diagnosis system of mechanical devices using autoencoder and deep-learning", Patent KR 10-2027389, Sept. 2019.
- [11] M. Sadoughi, A. Downey, G. Bunge, A. Ranawat, C. Hu, and S. Laflamme, "A Deep Learning-based Approach for Fault Diagnosis of Roller Element Bearings", 2018 Annual Conference of the Prognostics and Health Management Society, Vol. 10, pp. 1-7, Sep. 2018.

저자소개

최 우 진 (Woo-Jin Choi)



1994년 2월 : 동아대학교

전기공학과(공학사)

1996년 2월 : 동아대학교

전기공학과(공학석사)

2013년 8월 : 동아대학교

전기공학과(공학박사)

1996년 1월 ~ 2001년 11월 :

(주)사라콤 연구1팀장

2001년 12월 ~ 2017년 12월 : 한라IMS(주) 기술연구소장

2018년 1월 ~ 2018년 10월 : 한라IMS(주) 연구위원

2018년 11월 ~ 현재 : (주)브이엠에스 기술연구소장

관심분야 : Artificial Intelligence, Fuzzy Theory,
Neuro-Controller, Genetic algorithm, Intelligent
Controller, Industrial Instrument, Vibration Analysis.