

AI 기반 검사장비 교체주기 예측 플랫폼

강 선 우*, 오 성 현*, 김 정 곤^o

AI-Based Prediction Platform of Replacement Cycle for Inspection Equipment

Seon-Woo Kang*, Sung-Hyun Oh*, Jeong-Gon Kim^o

요 약

최근 스마트 공장의 증가에 따라, 공정 장비의 노후화와 유지관리 비용이 증가하고 있다. 이로 인해서 생산 장비의 수명을 예측하는 기술의 필요성이 커지고 있다. 자동화 생산 라인의 동작이 잠시 중단되면 큰 비용 손실을 초래할 수 있다. 따라서, 장비 상태 모니터링과 실시간 고장 예측 기술이 필수 불가결하다. 장비 고장에 관계없이 수리하는 PM(Preventive Maintenance) 방식을 사용하지 않고 오작동 주기를 예측하는 PdM(Predictive Maintenance)으로 생산성을 높일 수 있다. 본 논문에서는 SCU(Shift-by-wire Control Unit) 검사 장비에 적용할 AI(Artificial Intelligence) 기반 PdM 기술을 개발하였다. 개발된 플랫폼은 실시간 장비 상태 예측을 수행한다. 장비의 결함을 예측하기 위해 시뮬레이션을 통해 SCU 검사 장비의 전압과 주파수 데이터 셋을 생성했다. 그리고 이 데이터를 RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory) 및 GRU(Gated Recurrent Unit)의 세 가지 모델에 적용하고 성능을 비교하였다. 시뮬레이션 결과를 통해 R2-score 0.992의 정확도로 GRU가 최적의 예측 속도와 정확도를 달성했다. 이러한 결과를 기반으로, GRU를 이용한 PdM 플랫폼을 개발하였다. 개발된 플랫폼은 실시간으로 입력되는 데이터를 기반으로 하루 주기의 데이터를 예측하는 기능을 갖도록 했다.

Key Words : AI, PdM, Monitoring Program, Inspection Equipment, Shift-by-wire Control Unit

ABSTRACT

Recently, with the rise of smart factories, the aging of process equipment and maintenance costs are increasing. As a result, there is an increasing need for technology to predict the lifespan of production equipment. A brief shutdown of an automated production line can result in significant financial losses. Therefore, equipment condition monitoring and real-time failure prediction technology are indispensable. Productivity can be increased with PdM (Predictive Maintenance), which predicts malfunction cycles, rather than PM (Preventive Maintenance), which repairs equipment regardless of failure. In this paper, we developed AI (Artificial Intelligence)-based PdM technology to be applied to SCU (Shift-by-wire Control Unit) inspection equipment. The platform developed performs real-time equipment condition prediction. In order to predict equipment failure, a data set of voltage and frequency for SCU inspection equipment was created through simulation. Then, this data was applied to three models: RNN (Recurrent Neural Network), LSTM (Long Short-Term Memory), and GRU (Gated Recurrent Unit), and their performance was compared. Through the

♦ First Author : Tech University of Korea Department of Electronics Engineering, swkang@tukorea.ac.kr, 학생회원

o Corresponding Author : Tech University of Korea Department of Electronics Engineering, jgkim@kpu.ac.kr, 종신회원

* Tech University of Korea Department of Electronics Engineering, osh119@tukorea.ac.kr, 학생회원

논문번호 : 202308-063-C-RN, Received August 27, 2023; Revised November 29, 2023; Accepted December 4, 2014

simulation results, the GRU model achieved optimal prediction speed and accuracy, with an R2-score of 0.992. Based on these results, a PdM platform using GRU was developed. The developed platform has a function that predicts daily cycle data based on real-time data input.

I. 서론

최근 전 세계 제조업체 내 핵심 장비의 노후화가 심각한 문제이다. 이 장비들 중 10년 이상 가동된 장비가 38.6%, 5년 이상 가동된 장비가 총 80%의 높은 비중을 차지하는 것으로 나타났다. 노후화된 장비를 계속 사용하여 생산할 경우 제조 장비 고장으로 인한 생산성 저하와 심지어 작업중 사고로 이어질 수 있다^[1].

PdM(Predictive Maintenance)이란 실시간으로 수집된 데이터의 조합을 통해 정상 작동 중 장비 상태를 지속적으로 분석하여 잠재적인 시스템 고장을 식별하는 기술을 말한다^[2,3]. 최근의 유지보수 동향을 보면 제조업에서 AI(Artificial Intelligence), 빅데이터, VR(Virtual Reality) 등을 활용한 PdM 기술이 장비의 유지보수 비용 절감에 필수 요소가 되고 있음을 알 수 있다^[4]. 최근의 연구는 빅데이터^[5]를 이용하여 특정 시계열의 데이터 간의 관계를 발견할 수 있는 일반적인 회귀 신경망을 이용한 새로운 장비 유지보수 예측 방법과 증강현실 스마트 안경 시스템^[6]을 이용한 예측 유지보수에 대한 접근법을 개발하고 있다. 이러한 방식으로 회귀 신경망 기반의 PdM 시스템이 지속적으로 개발되고 있다.

[7]에서는 AI 지원 분산 시스템 개발을 통한 네트워크 지연 시간 향상을 목표로 AI 기반 IoT(Internet of Things) 예측 시스템에 대한 연구를 수행하였다. 이는 서로 다른 에지 노드에 독립적인 AI 모델을 배치하여 센서 근처에서 데이터 처리를 가능하게 하고 네트워크 지연 시간을 개선했다. [8]에서 저자들은 기계 학습 알고리즘을 사용하여 제조 프로세스를 최적화하기 위한 IoT 기반 PdM 방법을 제안했다. 이 방법은 데이터셋 간의 상관관계를 분석하고 이상치 데이터 패턴을 탐지한 다음, 제조 공정 유형별로 문제를 식별하기 위해 분류 접근 방식을 사용한다. 제조 공정을 최적화하기 위해 제조 결함에 가장 많이 기여하는 변수를 식별하고 분석한다. 마지막으로, [9]에서 저자들은 IoT를 통해 중앙 처리 장치에 연결된 센서로부터 데이터를 수집하고 예측을 위해 RNN(Recurrent Neural Network)과 LSTM(Long Short-Term Memory)-RNN 두 가지 유형의 신경망을 적용했다. 예측된 결과를 기반으로 중요 장치에는 LSTM-RNN

이 권장되며, 단순성이 필요한 장치에는 RNN이 적용된다.

본 논문에서는 회귀 신경망의 예측 정확도와 처리 시간을 고려하여 GRU(Gated Recurrent Unit) 기반 실시간 모니터링 플랫폼에 대한 연구를 수행한다. 초기에는 데이터 셋을 설정하고 시계열 예측을 위한 가장 간단한 모델인 RNN을 사용하여 데이터를 예측하려고 했지만, 특정 규칙에 따라 변하는 난수를 예측하기 위해서는 데이터 셋으로 더 긴 시퀀스의 데이터를 입력해야 했다. 그러나 일반적인 RNN 모델의 성능은 시퀀스 길이가 증가함에 따라 저하된다. 따라서 예측 정확도를 높이기 위해 시퀀스 길이가 길어져도 문제가 없는 LSTM 모델을 도입하였고^[10], 이와 유사한 간단한 구조를 가지며 훈련 시간을 단축한 GRU 모델을 도입하였다.

본 논문에서는 모델의 선택과 조정과 함께 실시간으로 얻은 데이터를 시각화하는 GUI(Graphic User Interface) 플랫폼을 개발했다. 제안하는 시스템의 핵심 기술은 모니터링 환경을 추가하여 장비 고장만을 확인하는 것뿐만 아니라 사용자가 현재 입력 데이터의 추이와 예측값을 그래프로 나타내어 비교할 수 있도록 하였다. GUI의 메인 화면에서는 예측값과 연동된 정보들을 통해 장비의 예상 상태를 미리 알 수 있도록 설계했다. 이러한 정보는 장비에 갑작스럽게 이상치가 발생하는 경우 및 제품 검사 중 오류가 발생하는 경우 등에서 검사장비의 상태를 점검하기 위해 사용될 수 있다. 실제 제조 현장의 작업자는 제품에 불량 발생 시, 검사장비의 문제보다는 제품 자체의 불량에 대해서만 고려한다. 하지만, 검사장비에 문제가 발생하여 정상 제품을 불량으로 판단하게 된다. 이러한 가성불량의 경우 생산성 저하 문제를 야기한다. 따라서, 딥러닝 기반 검사장비 상태 예측을 통해 장비의 상태를 지속적으로 진단해야 할 필요가 있다.

본 논문의 구조는 다음과 같다. 2절에서는 제안하는 AI기반 PdM 플랫폼 개발 개요에 대해 설명한다. 3절에서는 제안하는 PdM (Predictive Maintenance) 플랫폼 구성 방안에 대해 설명한다. 그런 다음 4절에서는 개발된 시스템에 대한 실험과 평가를 수행한다. 5절에서는 본 논문의 결론을 맺는다.

II. AI 기반 PdM 플랫폼 개발 개요

2.1 개발 시스템 구성개요

본 절에서는 제안하는 시스템의 전체적인 개요를 설명한다. 먼저, 제안하는 시스템의 개념도는 그림 1에 제시하였다.

그림 1에서 볼 수 있듯이, 제안하는 시스템은 세 가지 주요 구성요소로 구분할 수 있다. 첫 번째 구성 요소는 검사장비 하드웨어로, SCU(Shift-by-wire Control Unit) 제품에 대한 검사를 수행하고 그에 따라 로그 데이터를 저장한다. 두 번째 구성 요소는 AI 엔진으로, 검사 장비가 생성한 로그 데이터를 기반으로 모델을 훈련한 후 실제 장비 데이터를 이용해 장비 상태를 진단하고 예측한다. 마지막으로, 세 번째 구성 요소는 AI 엔진에서 진단 및 예측 데이터를 수신하고 장비 상태를 시각화하는 PC (Personal Computer)의 모니터링 프로그램이다. 이 모니터링 프로그램은 여러 장비의 상태를 관리하여 궁극적으로 생산 자동화 공

장의 장비 관리 효율성을 향상시키기 위한 것이다.

2.2 GRU(Gated Recurrent Unit)

본 논문은 검사장비의 데이터 셋을 처리 및 학습하기 위해 PyTorch를 사용하였다. 따라서, 검사장비에서 수집된 CSV(Comma- Separated Values) 데이터를 머신러닝에서 사용하는 데이터 형식인 tensorflow 데이터 셋으로 바꾸어 PyTorch의 모델에 입력한다. 이를 통해서 레이어 수, Batch size, epoch, 학습률을 설정하여 최적의 모델을 구성하였다.

본 논문에서 구현하는 시스템은 시계열 데이터를 사용하기 때문에 시퀀스를 이용한 모델이 사용된다. 시퀀스를 이용한 모델인 RNN, LSTM, GRU의 구조와 성능을 비교하였다. 그림 2는 각 시계열 예측 모델의 구조를 보인다.

RNN 모델은 입력과 출력을 시퀀스로 처리하는 모델이다. RNN은 짧은 시퀀스 처리에 유리하지만 장기 의존성 문제로 관련 정보의 주기가 길 때 학습 능력이 저하된다. LSTM 모델은 데이터의 장기적인 의존성을 감지하고 빠르게 훈련한다. LSTM은 입력, 망각 및 출력의 세 가지 게이트가 추가되고 각 상태 값이 메모리 공간 셀에 저장된다. 이러한 셀 구조를 통해 장기 의존성 문제를 부분적으로 해결했다. GRU는 LSTM의 처리속도를 개선한 모델이다. GRU는 업데이트 및 재설정 게이트만 있고 출력 게이트는 없는 LSTM의 최신 버전으로, LSTM보다 파라미터가 적다. 따라서, GRU는 LSTM보다 정확도가 약간 감소하지만 처리속도가 빠르다.

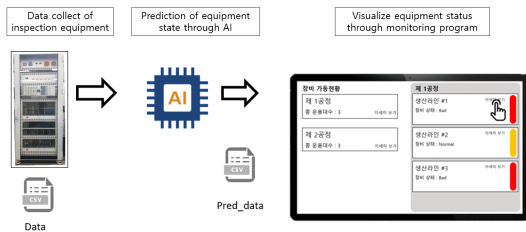


그림 1. 전체 시스템 구성도
Fig. 1. Overall system configuration

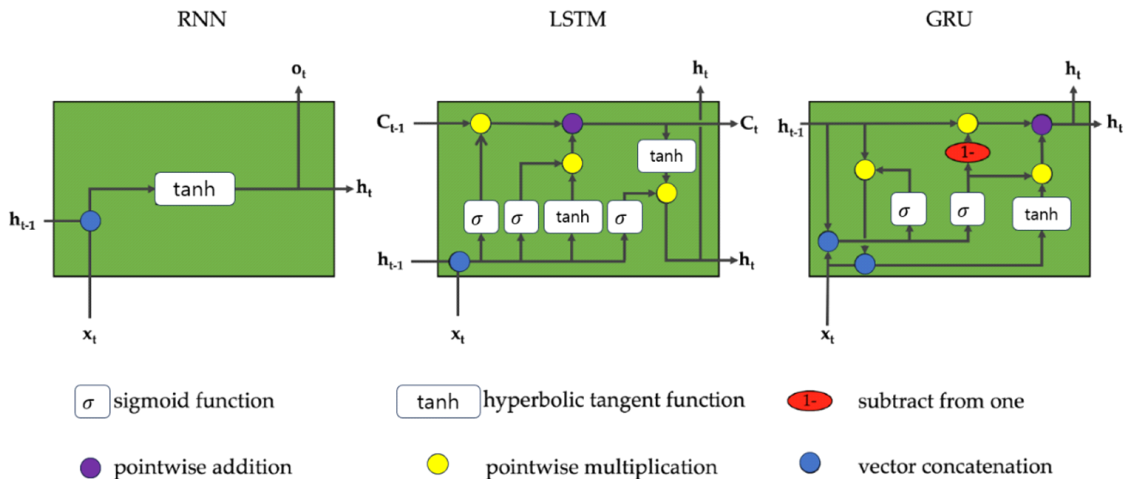


그림 2. 시계열 예측 모델의 구조
Fig. 2. Structure of time series data prediction model

2.3 GUI 실시간 데이터 구성(Tkinter and Matplotlib)

본 논문에서 구현하는 GUI를 구성하기 위하여 Tkinter 라이브러리를 사용하여 정보와 버튼을 구성하였고, Matplotlib 라이브러리를 이용해 실시간 그래프를 구현하였다. Tkinter를 이용하여 시스템의 정보창을 메인 화면과 라인 장비 1, 라인 장비 2를 만들어 각 화면에 전체적인 정보와 각 장비의 정보를 담았다. 그리고 버튼을 누르면 화면이 전환되는 형식을 사용하여 사용자 접근성을 개선하였다. Matplotlib를 이용하여 실시간 그래프와 장비 상태를 만들어 시간이 지남에 따라 그래프가 이동하고, 전압 또는 주파수 강하가 일어났을 때 메인 화면에 장비의 이상 상태를 확인할 수 있도록 구성하였다.

2.4 SCU 검사장비 개요

본 하위 절에서는 SCU 제품과 검사장비에 대해 설명한다. 먼저, SCU(SBW Control Unit) 제품은 SBC(Shift by Cable) 타입 변속기에 부착하여 SBW(Shift by Wire) 시스템으로 변환시킬 수 있는 핵심 부품이다. 이를 통해, 유압이 아닌 모터의 힘으로 주행 기능을 바꿀 수 있도록 돕는 기능을 수행한다. SCU 검사장비와 SCU 제품은 그림 3에서 확인할 수 있다. 그림에서 볼 수 있듯이, 검사장비에서 SCU 제품으로 전압 및 주파수 신호를 제공하여 제품의 동작상태를 시험한다. 그러나, 검사장비의 노후화로 SCU 제품에 인가되는 전압 및 주파수 신호가 강아되는 문제가 발생한다. 이러한 결과는 정상적인 SCU 제품을 불량으로 판단하는 문제가 발생한다. 따라서, 본 개발에서는 SCU 검사장비에서 나온 데이터 중 기계 장애에 큰 영향을 미치는 데이터로 전압과 주파수를 선정했다.




그림 3. 검사 과정 개념도
Fig. 3. Conceptual diagram of inspection process

III. PDM 플랫폼 구성방안

본 논문에서 개발한 AI PdM 플랫폼은 SCU 검사장비의 전압과 주파수 데이터를 GRU 모델의 입력으로 사용하여 장비의 상태를 예측하였다. 이후, 사용자는 모니터링 프로그램을 통해 SCU 검사장비의 전압과 주파수 예측값을 확인하도록 개발하였다. 따라서, 사용자는 장비에 문제가 발생하기 전 유지보수를 할 수 있도록 하였다.

개발된 시스템의 경우 편리성과 이식성을 위해 가상데이터를 사용하여 GUI 상에 나타낸다. 따라서, 데이터를 실시간으로 받을 수 있는 환경이면 프로그램을 통해 확인이 가능하다. 해당 시스템을 통해 예측하는 경우 다음과 같은 과정이 필요하다. 먼저, 모델의 학습을 위한 학습데이터 구축단계, 축적된 데이터로 모델을 훈련하는 훈련 단계와 훈련된 모델을 실시간 데이터 예측에 사용하는 테스트 단계, 마지막으로, 예측된 데이터를 GUI로 시각화하는 단계가 필요하다.

3.1 데이터셋 구성

본 개발에서는 실제 SCU 검사장비의 출력데이터와 제조 장비의 노후화에 대한 세계적인 추세에 따라 가상데이터 셋을 구축하였다. 본 개발에서 생성한 가상데이터의 논리적인 설명을 위해 노후장비에서 발생하는 전압 강하 특성을 분석 및 적용하였다^[11]. [9]에서는 노후화된 장비의 77%가 수명이 10년 미만임을 보여준다. 따라서, PM(Preventive Maintenance) 접근법을 기반으로 장비 교체 기간을 10년으로 설정하고 장비 이상 증상 발견 시점을 5년과 7년으로 설정하였다.

SCU 검사장비의 경우 이상 증상은 기능보드의 전압 강하 또는 측정 주파수 감소로 나타난다. 따라서 이상 장비 상태를 판단하는 기준으로 전압 및 주파수 강하를 사용했다. 시뮬레이션을 통해 생성한 기능보드의 전압 데이터 추세는 그림 4에 나와 있으며, x축은 날짜를 나타내고 y축은 전압 값을 나타낸다. 여기서, 전압 및 주파수 강하 패턴을 생성하기 위한 수식을 다음과 같이 적용하였다.

$$voltage = -0.00000015 \times date^2 + 16 + random \quad (-0.1 \leq random < 0.1) \quad (1)$$

$$freq = -0.0003 \times date^2 + 16 + random \quad (-100 \leq random < 100) \quad (2)$$

그림 4는 출력값을 일 단위로 가정하고, 앞서 언급

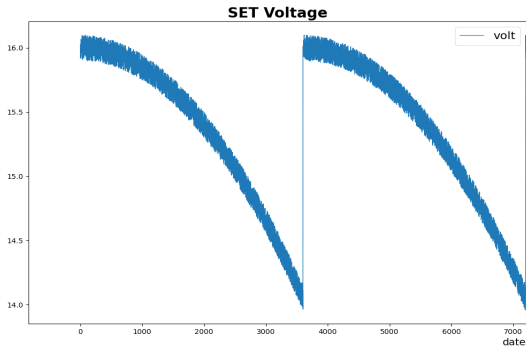


그림 4. 전압 데이터 셋
Fig. 4. Voltage data set

한 장비 수명을 고려하여 10년 주기로 데이터를 생성하였다. 따라서, 3600개의 데이터는 장비 수명의 1주기를 나타낸다. 학습 데이터셋의 경우 2 cycle(7200개 데이터)을 사용하였으며, 테스트 세트의 경우 매일 실시간 데이터가 생성되어 시스템에 입력되는 것으로 가정했다.

3.2 GUI 정보창

그림 5와 그림 6은 서로 다른 생산라인의 장비 상태 예측 그래프를 나타낸다. Line 1은 장비 수명 주기의 3/4지점(2,700개의 데이터)을 나타내며, 이는 약 7년을 기준으로 하였다. Line 2는 장비 수명 주기의 1/2지점(1,800개의 데이터)을 나타내며, 약 5년을 기준으로 하였다. 이는 장비마다 오작동하는 임계점이 상이한 특성을 고려했다. 따라서, 같은 장비라도 수명 주기가 다르므로 각 장비의 상태를 고려하여 PdM을 적용하도록 하였다.

그림 7은 개발된 모니터링 프로그램의 메인 화면을 보인다. 메인 화면은 현재 장비의 상태, 기능보드 교

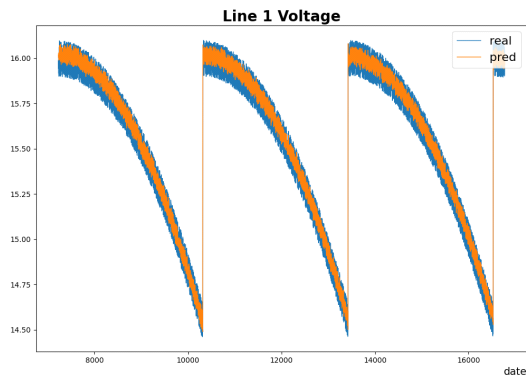


그림 5. 생산라인 1의 전압 데이터
Fig. 5. Voltage data of manufacturing line 1




그림 6. 생산라인 2의 전압 데이터
Fig. 6. Voltage data of manufacturing line 2

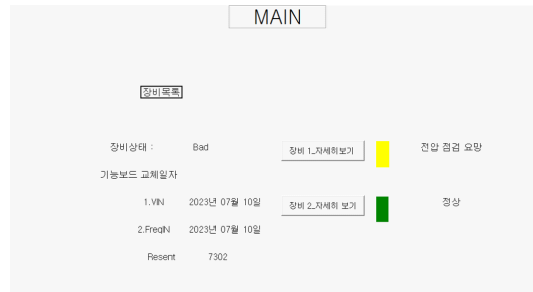


그림 7. GUI 메인 화면
Fig. 7. Main screen of GUI

체일자, 각 장비의 실시간 상태 등을 확인할 수 있다. 먼저, 기능보드 교체일자는 교체작업을 수행한 작업자에 의해 최신화되는 정보이다. 다음으로, 장비 자세히 보기 버튼은 생산라인에 배치된 장비의 상태 예측 그래프를 확인할 수 있다. 또한, 그림의 오른쪽에 표시된 장비 상태들은 장비의 현재 상태를 판단하여 제공한다. 장비 상태가 정상인 경우 초록색, 주의의 경우 노란색, 장비 교체가 필요한 경고의 경우 빨간색으로 구성하였다. 오류 문구는 장비 상태와 각 생산라인 검사장비의 어떤 모듈이 문제인지 나타낸다. 위의 상태들을 종합하여 생산라인의 상태를 판단하여 제공한다.

IV. 실험 및 결과

본 절에서는 개발된 PdM 플랫폼의 실험 및 평가결과를 제시한다. 개발된 플랫폼에 적용된 시계열 예측 모델은 배치 사이즈, 학습률(Lr), 시퀀스 길이 및 훈련 시간 등의 시계열 예측 모델 학습을 위한 다양한 매개변수가 있다. 2.2절에서 설명한 것처럼 RNN, LSTM, GRU와 같은 다양한 시계열 예측 모델의 유형과 파라미터를 선택하기 위해 R2-score의 평가 기준에 따라 다양한 파라미터를 조정했다. 2개의 test set과 사전

데이터를 비교하여 시계열 예측 모델의 예측 정확도를 결정한다.

본 개발에서 최적화를 수행한 하이퍼파라미터는 Batch size, 학습률, 학습 Epoch, 시퀀스 길이, 시계열 모델이다. 먼저, simple-RNN을 이용하여 각 하이퍼파라미터의 변화에 따른 최적화를 수행하였으며, 확정된 하이퍼파라미터를 기반으로 모델을 선정하였다.

4.1 배치 사이즈와 학습률

배치 사이즈는 학습 중에 한 번에 처리해야 하는 데이터의 양을 나타내는 하이퍼파라미터이다. 즉, 배치 사이즈가 클수록 훈련 속도가 빨라질 수 있지만, 정확도가 낮아진다. 또한, 과적합 문제가 발생할 확률이 높아질 수 있다. 이와 다르게, 배치 사이즈가 작을수록 갑작스러운 변화에 대한 복원력이 높아질 수 있다.

학습률은 다음 값을 추정하는 데 사용되는 값 변경의 기울기를 나타내는 값이다. 학습률이 높으면 수렴에 필요한 시간을 줄일 수 있지만 오버슈팅의 위험이 증가한다. 학습 속도가 낮으면 교육 시간이 증가할 수 있다.

본 개발에서 초기 배치 사이즈는 가장 일반적으로 사용하는 64로 설정하였으며, 학습률은 0.01을 기준으로 비교하여 최적의 조합을 찾는 것을 목표로 했다. 또한, 시퀀스 길이를 7로 설정하고 Epoch를 10으로 고정했다.

그림 8에서 볼 수 있듯이 Batch size = 128과 Lr = 0.01의 조합은 실제 값인 true와 가장 유사하다. 그림 8에 제시된 각 조합의 성능은 표 1에서 확인할 수 있다. 표에서 볼 수 있듯이, Batch size = 128, Lr = 0.01일 때 R2-score는 0.9810으로 최적의 값을 달성

표 1. 각 파라미터의 조합성능
Table 1. Performance of each combination

Model	Batch size	Learning rate	R2-score
RNN	64	0.01	0.9723
RNN	128	0.01	0.9810
RNN	128	0.1	0.9732
RNN	128	0.2	0.9771

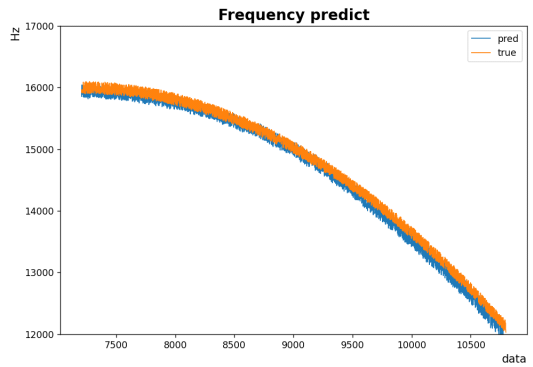


그림 9. GRU모델 예측결과
Fig. 9. Prediction result of GRU model

할 수 있다.

그림 9는 제안된 AI 모델을 기반으로 한 장비 상태 예측결과를 보여준다. 여기서, true로 표시된 주황색 선은 실제 값이고, pred로 표시된 파란색 선은 예측된 값을 의미한다. 3.1절에서 설명한 데이터셋으로 설정된 GRU 모델과 매개 변수를 사용하여 3600(10년) 테스트 데이터를 시뮬레이션하여 pred 값이 true값과 유사한 기울기로 점차 감소하는 것을 관찰했다. 또한, 두 그래프의 유사성을 나타내는 R2-score는 0.992로 값이 1에 가깝다.




그림 8. 배치 사이즈와 학습률에 따른 예측 그래프
Fig. 8. Prediction graph according to batch and learning rate

여기서, 본 개발은 주파수 값이 12,000Hz 보다 낮은 경우를 장비에 문제가 발생한 임계값으로 설정하였다. 따라서, 그래프의 pred 값이 12,000Hz 이하로 강하하는 경우, 장비에 문제가 발생했다고 판단하여 모니터링 프로그램을 통해 알림 제공을 수행하도록 한다.

4.2 학습 Epoch

AI 모델은 학습을 위한 반복 횟수가 증가하면 모델의 학습 손실이 감소한다. 그러나, 반복 횟수가 증가할수록 과적합이라는 문제가 발생한다. 따라서, 과적합을 방지하기 위해 손실 값이 증가하면 early stop을 적용하여 과적합을 방지하도록 설계했다. 그림 10에 나타난 바와 같이, 여러 번 반복된 테스트를 수행한 결과, 초기 설정이 epoch = 100이었음에도 불구하고, epoch = 30 전후에 early stop이 빈번하게 발생하는 것을 확인할 수 있다. 따라서, epoch는 30으로 설정했다.




그림 10. 반복 테스트 결과
Fig. 10. Repeated test results

4.3 시퀀스 길이 및 모델

시퀀스 길이는 RNN 모델에 대한 입력 데이터 셋의 차원을 나타낸다. 예를 들어 시퀀스 길이가 7인 경우 입력 데이터 셋은 행 * 열 * 시퀀스 길이 형식이다. 4.1과 4.2에 설정된 파라미터를 기준으로 시퀀스 길이 7을 사용하여 값을 조정했으며 테스트 결과는 표 2에 있다.

표 2에서 볼 수 있듯이, 더 높은 R2-score를 얻기 위해 RNN 모델의 시퀀스 길이를 늘렸을 때 Gradient

표 2. 시퀀스 길이와 모델에 따른 R2-score와 학습시간
Table 2. R2-score and learning time according to model type and sequence length

Model	Sequence length	R2-score	Learning time
RNN	7	0.9810	15 s
RNN	30	0.9650	45 s
LSTM	30	0.9930	62 s
GRU	30	0.9921	47 s

표 3. 선택된 GRU 모델 파라미터
Table 3. Final selected parameter of GRU model

Model	Sequence length	epoch	Batch size	Learning rate
GRU	30	30	128	0.01

가 사라지는 문제가 발생하여 R2-score가 감소했다. RNN의 사라지는 기울기 문제를 극복하기 위해, 우리는 RNN 모델의 동일한 조건에 비해 성능을 향상시킨 LSTM 모델을 사용했다. 또한, Tanh 레이어가 감소된 GRU 모델은 LSTM보다 24% 짧은 훈련 시간으로 유사한 성능을 보였다. 따라서 모든 조합을 검토한 후 표 3과 같이 최종 예측 모델을 선택하였다.

V. 결론 및 추후 연구 방향

본 논문은 장비 노후화와 전통적인 유지보수 방법으로 인한 비용 손실을 방지하는 것을 목표로 한다. 이를 해결하기 위해 최근 등장한 예측 유지보수 방식을 사용하여 AI 기반 장비 고장 관리 플랫폼을 구현했다. 기존에 공장에서 수행된 유지보수 데이터는 10년 주기로 설정되었으며, 이를 개선하기 위해 예측 유지보수를 수행할 때 유지보수 주기를 각각 7년과 5년으로 설정했다. 선택된 GRU 모델(epoch=30, sequence length=30, batch=128, lr=0.01)은 47초의 빠른 학습 시간(R2-score = 0.9921)으로 높은 예측 정확도를 보였다. 또한, 플랫폼에서 실시간 그래프 형식으로 예측값을 제시함으로써 장비의 현재 상태를 판단할 수 있게 되었다. 이를 통해, 제안하는 예측 유지보수 플랫폼은 효율적인 장비 관리 및 보수 비용 절약을 달성하고자 한다. 또한, SCU 검사장비 외 다른 장비에 본 기술을 적용하기 위해, 해당 장비의 고장유무 판단이 가능한 특정 파라미터(예: 진동, 온도, 전압 등..)를 선택한다. 이후, 시계열 데이터 취득 및 GRU 모델 학습을 수행하여 해당 장비에 최적화된 모델을 설계해야 한다. 추후, 위와 같이 다양한 장비에서 특징값을 선택하고 예측하는 보편적인 PdM 플랫폼으로 사용하는 방안을 연구하고자 한다.

References

[1] K. S. Yu and Y. M. Moon, "Recent trends in smart factory equipment diagnosis and predictive maintenance technologies," *KICS Inf. and Commun. Mag.*, vol. 37, no. 7, pp.

36-48, Jun. 2020.

[2] X. Mehmeti, B. Mehmeti, and R. Sejdiu “The equipment maintenance management in manufacturing enterprises,” *IFAC-Papers OnLine*, vol. 51, no. 30, pp. 800-802, Oct. 2021.
(<https://doi.org/10.1016/j.ifacol.2018.11.192>)

[3] M. Jamal, S. T. Mohammad, and T. Paul, “Intelligent predictive maintenance (IPdM) in forestry: A review of challenges and opportunities,” *Forest*, vol. 12, no. 11, p. 1495, Oct. 2021.
(<https://doi.org/10.3390/f12111495>)

[4] B. E. So and S. S. Shin, “The built of smart factory using sensors and virtual process design,” *J. KIECS*, vol. 12, no. 6, pp. 1071-1080, Dec. 2017.
(<https://doi.org/10.13067/JKIECS.2017.12.6.1071>)

[5] S. Biswal and G. R. Sabareesh, “Design and development of a wind turbine test rig for condition monitoring studies,” in *Proc. 2015 Int. Conf. Ind. Instrumentation and Control*, pp. 891-896, May 2015.
(<https://doi.org/10.1109/IIC.2015.7150869>)

[6] N. Slawomir, B. Mohammed-Rafik, and F. Handi, “On predictive maintenance in industry 4.0: Overview, models, and challenges,” *Applied Sci.*, vol. 12, no. 16, p. 8081, Aug. 2022.
(<https://doi.org/10.3390/app12168081>)

[7] Y. Liu, W. Yu, T. Dillon, W. Rahayu, and M. Li, “Empowering IoT predictive maintenance solutions with ai: A distributed system for manufacturing plant-wide monitoring,” *IEEE Trans. Ind. Informat.*, vol. 18, no. 2, pp. 1345-1354, Feb. 2022.
(<https://doi.org/10.1109/TII.2021.3091774>)

[8] L. C. Him, Y. Y. Poh, and L. W. Pheng, “IoT-based predictive maintenance for smart manufacturing systems,” in *Proc. 2019 Asia-Pacific Signal and Inf. Process. Assoc. Annu. Summit and Conf.*, pp. 1942-1944, Nov. 2019.
(<https://doi.org/10.1109/APSIPAASC47483.2019.9023106>)

[9] J. S. Rahhal and D. Abualnadi, “IoT based predictive maintenance using LSTM RNN estimator,” in *Proc. 2020 Int. Conf. Electr., Commun., and Comput. Eng.*, pp. 1-5, Jun. 2020.
(<https://doi.org/10.1109/ICECCE49384.2020.9179459>)

[10] Y. J. Roh and S. H. Bae, “Forecasting of traffic accident occurrence pattern using LSTM,” *J. Korea Inst. Intell. Transp. Syst.*, vol. 3, no. 95, pp. 59-73, Jun. 2021.
(<https://doi.org/10.12815/kits.2021.20.3.59>)

[11] G. J. Lee, “순간정전 및 전압강하에 의한 피해 사례와 대책,” *J. Electr. World Monthly Mag.*, vol. 454, pp. 48-58, Oct. 2014.

강 선 우 (Seon-Woo Kang)



2018년 3월~현재 : 한국공학대
학교 전자공학과 학사과정
<관심분야> 인공지능, 스마트그
리드, 자율주행

오 성 현 (Sung-Hyun Oh)



2019년 2월 : 남서울대학교 전자
공학과 졸업 (학사)
2021년 2월 : 한국공학대학교 전
자공학과 졸업 (석사)
2021년 3월~현재 : 한국공학대
학교 정보통신학과 박사과정

<관심분야> 실내위치추위, 심층강화학습, AI+X, 5G
이동통신, 지능형교통시스템
[ORCID:0000-0002-1974-8612]

김 정 곤 (Jeong-Gon Kim)



1991년 2월: KAIST 전기 및 전
자공학과 졸업 (학사)

1993년 2월: KAIST 전기 및 전
자공학과 졸업 (석사)

1998년 2월: KAIST 전기 및 전
자공학과 졸업 (박사)

1998년 6월~1999년 5월: 하와

이주립대학교 전자공학과 Post Doc.

1999년 7월~2001년 3월: LG 텔레콤 선임연구원

2001년 4월~2003년 2월: 삼성전자 통신연구소 표준
연구팀 책임연구원

2010년 3월~2011년 2월: 미국 USC 전기공학과
Visiting Scholar

2018년 3월~2019년 2월: 미국 산호세 주립대학교 글
로벌 책임교수

2003년 3월~현재: 한국공학대학교 전자공학부 교수
<관심분야> 5G이동통신, 간섭제거, 무선자원할당
VLC, 위치추위, 기지국 협력통신, UDN AI, 협업로
봇, WPAN, WBAN 설계 및 응용분야

[ORCID:0000-0002-9349-2846]