

## GRU 기반 장비 교체 주기 예측 방식 성능 평가

조영제, 강선우, 오성현, 김정곤\*

한국공학대학교 전자공학부

tkdwp58@tukorea.ac.kr, swkang@tukorea.ac.kr, osh119@tukorea.ac.kr, jgkim@tukorea.ac.kr\*

## Performance Evaluation of GRU-based Equipment Replacement Cycle Prediction Method

Jo Young Jae, Kang Seon Woo, Sung Hyun Oh, Jeong Gon Kim\*

Dept. of Electronic Engineering Tech University of Korea

## 요 약

본 논문에서는 생산 예측관리 기술을 이용한 플랫폼 구현을 서술하고자 하였다. 장비들이 고장나면서 발생하는 제품의 손상이나 경제적 손실이 막대하기 때문에 장비를 정지하지 않고 상태를 확인하고 고장을 예측하는 기술의 필요성이 언급되고 있다. 이는 과거 장비가 고장 났을 때 하는 정비와 정기적으로 고장 여부에 상관없이 정비하는 정기점검정비 방법의 단점들을 보완해주는 기술이라고 할 수 있다. 공장에서 경제적 이익과 장비의 안정성은 중요하기 때문에 이 기술의 확보는 필연적이다. 본 논문에서는 AI(Artificial Intelligence)를 이용한 예측 유지 보수 기술을 개발하였다. 24시간 매일 모니터링할 수 있도록 실시간으로 장비의 상태를 예측, 확인할 수 있는 생산관리 플랫폼 제안한다. PdM(Predictive Maintenance) 기술은 공정 기술 예측관리를 통해서 생산력을 증대시키는 기술이다. AI를 기반으로 하여 실시간 장비 모니터링을 위한 구조를 설계하였다. 본 논문에서는 AI 모델 중 GRU(Gated Recurrent Unit)를 이용한 AI 예측관리 플랫폼을 구현함으로써 실용성을 검증한다.

## 1. 서 론

최근 국내 제조기업의 핵심 설비의 노후화가 심각하다. 가동된 기간이 10년 이상인 경우가 38.6%, 5년 이상인 경우는 총 80%로 높은 비중을 차지하고 있다. 이처럼 노후화된 장비를 이용하여 계속 생산을 한다면 장비 이상으로 인한 생산성 하락, 심지어는 산재로까지 이어질 수 있다[1]. 따라서, 노후화된 장비를 유지 보수하고자 하는 시스템을 개발하고자 하였다. 또한, 최근 제조시스템은 4차산업혁명의 주요 기술 중 하나인 AI(Artificial Intelligence) 기반의 스마트팩토리로 변화하고 있다. 이는 공정의 데이터를 수집하여 공정 운영을 개선하는데 다양하게 활용가능하다[2]. 스마트팩토리 시장이 연평균 성장률 11.2%를 보이며 2020년 56억 달러의 큰 시장 규모를 가지기도 하는 뚜렷한 성장세를 보인다. 미국의 경우, 유지 보수의 시장이 2000억 달러를 넘어서고 있으며 이 중, 잘못된 유지 보수비용으로 30%의 비용이 든다고 한다[3].


이처럼, 제조기업의 노후화가 심각하여 유지 보수의 필요성이 강조되고 있는데, 4차 산업 혁명의 스마트팩토리와 같이 공정의 데이터를 수집하여 장비의 부품을 교체하는 주기를 예측하는 시스템을 개발하고자 하였다.

## II. 본론

## 1. 데이터 선정

제조업 생산 장비의 평균 수명이 10년이라고 한다. 또한, 장비의 노후화 시, 장비의 출력값이 정상치를 벗어난다고 가정하였다. 따라서, 장비의 출력값을 전압과 주파수 2가지 요소를 선정하였다. 전압의 경우, 5.0V ~ 4.5V를 정상 범위로 설정하였다. 또한, 주파수의 경우 16k ~ 15.5k를 정상 범위로 설정하였다.

장비의 노후화를 가정하기 위해 peak에서 전압과 주파수가 점진적으로 하강하고, 장비의 교체 시기를 가정하기 위해, 정상 범위의 최소치에서 다시 데이터를 peak로 올리는 방식으로 장비의 노후화, 교체를 가정하였다.



[그림 1] 생성된 전압, 주파수 데이터

일일 1개 data를 수집하는 장비가 있고, 3600일(10년)간 사용되는 장비의 교체 주기를 감안하여 3600개의 데이터의 주기에 따라 peak에서 정상치의 최소치로 하강하는 형태의 데이터셋을 생성하였다.

## 2. 시계열 예측 모델 선정(성능 평가 요소, 파라미터 등)

데이터를 학습시키고, 예측하기 위한 성능 평가 과정이 필요하다. 모델에는 과거의 데이터로 1일 뒤의 장비의 출력값을 예측하는 시계열 예측 모델로 RNN(Recurrent Neural Network) 계열의 3가지 모델에 대해 비교 분석해보았다. 본 연구에서는 시계열 예측 모델의 성능 평가 기준으로 R2 score를 이용하였다[5]. R2 score의 선형 회귀 모델 평가 기준은 다음과 같다. R2 score는 일반적으로 0~1범위를 가진다. R2 score는 다음과 같이 식 1로 나타낼 수 있다. (1)식에서 볼 수 있듯이, 오차의 평균(MSE) / 분산(V)은 회귀 모델의 실제값(real)과 예측값(pred)으로 구하며, 이는 예측값과 실제값의 차이를 정규화한 값이다. 따라서, R2 score가 1에 가까울수록 예측값과 실제값의 차이가 작아지며 예측값의 정확도가 높아진다.

\* : 교신저자


$$R^2 = 1 - \frac{SSE}{SST} = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2}{\frac{1}{n} \sum_{i=1}^n (y^{(i)} - \mu_y)^2} \quad (1)$$

### 3. 시계열 예측 모델별 성능 평가

[표 1] AI 모델별 예측성능 평가

Model	Seq length	Batch size	Lr	R2 (volt/freq)	비고
RNN	7	128	.01	.991 / .992	seq_length증가
RNN	30	128	.01	.992 / .996	RNN의 피크 문제점
LSTM	30	128	.01	.996 / .996	긴 학습시간(90초)
GRU	30	128	.01	.996 / .994	짧은 학습 시간(60초)

최초에 RNN model을 이용하였으나, 정확도가 의도한 수치보다 낮아 seq\_length를 증가시켰고, RNN의 seq\_length가 증가하여 생긴 문제점을 해결하여 더 긴 길이의 data set으로 예측하는 LSTM(Long Short-Term Memory) model을 이용하였다. LSTM 및 GRU 모델 구조는 그림 2에서 비교하였다. 이를 통해, 설정한 조건 값에서는 비슷한 성능을 보이고 학습 시간이 더 짧은 GRU model을 선정하였다. GRU model은, 기존의 LSTM의 많은 파라미터 tanh 연산으로 인해 학습시간이 오래 걸리는 단점을 보완하며 성능은 비슷하게 나타나는 개선 모델이다.




[그림 2] LSTM에 비해 간소화된 GRU model의 구조


그림 3과 그림 4는 GRU 모델의 예측성능을 보인다. 높은 R2 score에서 확인한 것과 같이, 실제 값(관측값, real)과 예측값(pred) 사이에 상당한 유사성이 있음을 확인할 수 있다.

### 4. 장비의 이상 예측 및 데이터 저장

장비의 출력값과 예측값을 비교하여 같은 차원에 다음날의 데이터가 예측되어 나타나게 된다. 예측 값의 데이터가 장비의 정상 범위를 벗어나는




[그림 3] 전압 예측 값



[그림 4] 주파수 예측 값

경우, 관측 프로그램 상에 경고메시지를 띄우고, 해당 장비가 비정상 됨을 표시한다. 또한, 해당 날짜에 장비의 고장을 판단하였다고 그림5처럼 시스템 상에 기록하도록 개발했다.



[그림 5] 개발된 GUI 화면

## III. 결론

대부분의 공장들이 기계를 이용하여 자동화되고 있는 추세이다. 이러한 기계들 중 하나만 문제가 생기더라도 공정에 문제가 발생했다고 말할 수 있다. 본 논문에서는 AI를 이용한 PdM 공정관리를 하는 과정을 나타내었다. 먼저 장비로부터 값을 입력 받는 것을 가정하여 데이터셋을 생성하였다. 회귀 신경망인 GRU를 사용하여 장비의 상황을 예측하여 적절한 유지 보수 시점을 예측할 수 있다. 이를 GUI에 탑재하여 장비를 실시간 모니터링할 수 있음을 보였다. GRU는 AI 종류 중에서 예측성능이 뛰어난 장점이 있다. 하지만 앞서 소개한대로 명확한 한계와 단점이 존재한다. 예측을 최적화하기 위하여 데이터 처리 기법을 이용하면 예측성능을 높일 것이며, 이를 통해 공정 장비의 안정성을 높일 것이다. 이를 통하여 실시간 AI 예측 플랫폼을 구현하고 스마트팩토리와 여러 공정에 사용하여 생산력을 증대할 수 있을 것으로 보인다.

## ACKNOWLEDGMENT

본 성과는 교육부와 한국연구재단의 지원으로 지원을 받아 수행된 3단계 산학협력 선도대학 육성사업(LINC 3.0)의 연구결과입니다.

## 참 고 문 헌

- [1] Yu K. S., and Moon Y. M. “스마트공장 설비진단 및 예지보전 기술의 발전 동향”, Information and communications magazine, pp.36-48, Jun. 2020.
- [2] So B. E. “Study on built smart factory using sensors and virtual process design”, pp. 22-23, Dec. 2017.
- [3] Biswal S., and Sabareesh G. R. “Design and development of a wind turbine test rig for condition monitoring studies”, 2015 International conference on industrial instrumentation and control(ICIC), pp. 891-896, May 2015.
- [4] Roh Y. J., and Bae S. H. “Forecasting of Traffic Accident Occurrence Pattern Using LSTM”, pp. 59-73, Jun. 2021.