

Anomaly Detection of Machining Process based on Power Load Analysis

Jun Hong Yook* · Sungmoon Bae**†

*SeoYon E-Hwa Co.

**School of Industrial and Systems Engineering, Gyeongsang National University

전력 부하 분석을 통한 절삭 공정 이상탐지

육준홍* · 배성문**†

*㈜서연이화

**경상국립대학교 산업시스템공학과

Smart factory companies are installing various sensors in production facilities and collecting field data. However, there are relatively few companies that actively utilize collected data, academic research using field data is actively underway. This study seeks to develop a model that detects anomalies in the process by analyzing spindle power data from a company that processes shafts used in automobile throttle valves.

Since the data collected during machining processing is time series data, the model was developed through unsupervised learning by applying the Holt Winters technique and various deep learning algorithms such as RNN, LSTM, GRU, BiRNN, BiLSTM, and BiGRU. To evaluate each model, the difference between predicted and actual values was compared using MSE and RMSE. The BiLSTM model showed the optimal results based on RMSE. In order to diagnose abnormalities in the developed model, the critical point was set using statistical techniques in consultation with experts in the field and verified. By collecting and preprocessing real-world data and developing a model, this study serves as a case study of utilizing time-series data in small and medium-sized enterprises.

Keywords : Machining Process, Power Load, Anomaly Detection, LSTM, BiLSTM

1. 서론

스마트 공장(smart factory)은 4차 산업혁명의 핵심으로 평가되는데, 기존의 공장에 인공지능(artificial intelligence), 빅데이터(big data), 사물인터넷(Internet of Things), 클라우드 컴퓨팅(cloud computing) 등의 ICT(Information and Communications Technology) 기술들을 접목한 지능형 공장을 의미

한다. 이러한 스마트 공장이 구축됨에 따라 기업은 기존의 엔지니어 중심에서 자동화된 생산 시스템 중심으로 공장을 운영할 수 있게 되었다[11].

제조 현장에서는 생산 설비의 내부에 센서를 부착하여 수집된 설비의 제조 데이터와 MES(Manufacturing Execution System)나 ERP(Enterprise Resource Planning) 시스템을 통해 얻은 설비의 공정 데이터를 활용하여 설비의 예지 보전이나 제품의 불량률 예측하는 인공지능 기반의 이상 탐지 모델에 대한 연구가 활발히 진행되고 있다[6-9, 12]. 특히, 고도화된 설비를 활용하여 제품을 가공하는 절삭 가공 분야는 높은 품질, 생산원가 절감, 짧은 납기에 대응하기 위해서 작업공정

에서 발생하는 문제를 해결하기 위해 설비 모니터링 데이터를 활용하고 있다[1]. 절삭 가공은 고속 고경도 공구를 장시간 운영하기 때문에 공구 마모와 파손 감지 예측이 중요하다. 따라서 가공 장비에 센서를 설치하여 수집된 데이터를 분석하고 이를 통해 이상 상황을 조기에 탐지하는 것은 매우 중요하다.

절삭 가공에서 공구(tool)에 가해지는 부하량의 데이터는 시계열(time-series) 데이터로서 절삭 과정에 따라 일정한 패턴(pattern)을 가지게 된다. 즉, 양품을 가공할 때의 공구 부하 패턴을 학습하고 이 패턴을 벗어난 상황이 감지되면 이를 이상(anomaly)으로 진단하는 자동화된 시스템을 갖추게 된다면 불량률을 줄이고 생산성을 향상시킬 수 있게 된다. 하연우[2]는 자동화 리벳팅 공정의 서보모터 z 축 데이터를 활용하여 사이클 단위의 이상을 탐지함으로써 작업자가 직접 검수하는 과정을 줄여 공정의 생산성 향상으로 이어질 수 있다고 하였으며, 이재현[10]은 주기성을 가지고 특정한 패턴을 가진 데이터를 분석하기 위해 웨이블릿 계수를 구하고, 이 계수들에 SPC(Statistical Process Control) 차트를 적용하여 공정 이상여부를 탐지하였다. 진승중[3]은 용접 부위의 온도를 측정된 데이터를 기반으로 오토 인코더와 트리 기반 이상불 기법인 isolation forest를 활용하여 양품과 불량률 구분하는 연구를 수행하였고, 유근호[13]는 금형 온도 패턴을 분석하여 자동으로 양불 판정을 하기 위해 1차원 컨벌루션 네트워크를 활용하였다. 이러한 연구는 양불 판정을 위해 다양한 데이터를 활용하지만, 공구의 부하량을 기준으로 분석하지는 않았다.

절삭 공정에서 공구에 가해지는 부하량을 직접적으로 측정하기 위해 공구에 직접 센서를 부착해야 하지만, 고속으로 회전하는 공구에 센서를 부착하는 것은 현실적으로 매우 어려운 문제이다. 따라서 간접적으로 공구의 부하량을 측정해야 하는데 그 중 하나가 공구의 스피들(spindle)에 전달되는 전력 부하량을 활용하는 방법이다. 스피들은 공구를 고속으로 회전시켜 자재를 절삭하는 설비의 핵심 부품인데, 절삭량이 적으면 스피들에 공급되는 전력 부하량이 낮고, 절삭량이 많으면 전력 부하량이 높다는 특성이 있다. 정진욱[4]은 머시닝 센터의 전력 사용량과 작업자가 기록한 제품 생산량이 선형적인 관계가 있다는 점에 착안해 로버스트 선형 회귀를 이용하여 잘못 기록된 제품 생산량을 탐지하였다. 정민영[5]은 용접 공정에서 수집된 압력, 전류, 전압, 용전 시간 데이터를 GMM(Gaussian Mixture Model)-Mahalanobis 거리 개념을 이용하여 공정 이상 탐지 모델을 개발하였다. 하지만 이러한 기존 연구는 스피들의 전력 부하량을 활용하여 절삭 공정의 이상을 탐지하지 않기 때문에 이에 대한 연구가 필요하다. 본 연구는 샤프트를 가공하는 중소기업의 절삭 공정으로부터 수집된 전

력 부하량 데이터를 이용하여 전통적인 시계열 기법과 인공지능 기반 시계열 기법을 사용하여 이상 상황을 탐지하는 연구를 수행하였다.

본 논문은 다음과 같이 구성되어 있다. 먼저 2장에서는 샤프트 생산 공정에 대해 설명하고, 수집되는 데이터에 대한 기초 분석 결과를 기술한다. 3장에서는 수집된 데이터를 전처리하는 과정을 설명하였다. 4장에서는 최적 모델을 찾아내기 위해 수행한 학습 기법과 이에 대한 평가를 기술하고, 학습한 모델을 활용하여 이상 상황을 감지하기 위한 임계점 설정에 대해 설명하였다. 마지막으로 5장에서는 본 연구의 결론과 향후 연구과제를 제시하였다.

2. 절삭 공정 데이터 분석

2.1 샤프트 가공 공정 및 공정 수집 데이터

샤프트(shaft)는 회전 운동이나 직선 왕복 운동으로 동력을 전달하는 둥근 막대 모양의 기계 부품으로 <Figure 1>과 같은 형태를 보인다. 이는 자동차 엔진에 공기의 양을 조절하는 스로틀 밸브에 사용된다. 대상 기업은 스로틀 밸브에 사용되는 샤프트 가공을 위한 로터리 전송 기계(rotary transfer machine)를 자체 개발하여 사용 중인데, 하나의 설비에서 11개 공정을 로터리 방식으로 부품을 이송하고 가공한다. 각 공정은 평균 22초의 빠른 사이클 타임을 가지고 있으며, 부품을 로터리 방식으로 가공하기 때문에 한 공정에서 발생한 이상 상황은 이후에도 제품 품질에 영향을 미치게 된다.



<Figure 1> Shaft product

가공 설비는 <Figure 2>와 같으며 샤프트를 가공하기 위하여 각 공정이 로터리 방식으로 회전하면서 연속적으로 이루어진다. 공작물은 원형 경로에서 인덱싱되는 팔레트 유형 고정 장치에 위치 및 고정된다. 한 사이클 동안 공작물에 대해 순차적 가공 작업이 동시에 수행된다. 인덱싱된 테이블을 수평으로 회전하면 이전 공정에서 가공한 공작물이 후속 가공 공정으로 이송되며 이후 후속 작업이 반복된다. 11개의 공정 중 주요 공정으로는 원통형의 원자재를 거칠고 빠르게 절삭하는 황삭, 구멍을 뚫는 드릴, 황삭된 부분을 정밀하게 다시 한번 절삭하는 정삭 공정이

있고, 이 공정에 대한 스핀들의 전력 데이터를 수집하여 분석한다.



<Figure 2> Rotary Transfer Machine

이상 탐지 모델을 개발하기 위해 수집한 데이터의 특징은 아래와 같다.


- 대상 공정: 황삭, 드릴링, 정삭
- 데이터 수집 기간: 2022년 7월 12일 ~ 8월 31일
- 공정 사이클타임: 20초 ~ 24초
- 데이터 수집 주기: 100ms
- 수집 데이터: 시간, 제품 품번, 생산 수량, 사이클 타임, 공정의 공구 예측 수명, 공정의 공구 사용 횟수, 공정의 전력 값, 운전 상태, 비가동 사유

전력 데이터 이외에도 공구의 수명에 연관된 톨 카운트도 같이 수집을 하였다. 황삭, 드릴, 정삭 공정에 사용되는 공구는 각 공정의 특성에 따라 예상 수명도 다르다. 황삭 공정 공구는 많은 양을 절삭 가공하기 때문에 상대적으로 짧은 수명을 가지는데 예상 수명은 40,000번이고, 드릴은 300,000번, 정삭은 80,000번 가공이다. 즉, 황삭에서는 40,000번을 가공하면 가공 불량률 방지하기 위해 공구를 교체하는 것이 원칙이다. 하지만 예상 수명 수치는 참고 자료일 뿐, 제조 현장에서는 작업자의 판단에 따라 예상 수명의 약 70% 내외를 가공한 경우 공구 교환을 진행한다. 운전 상태는 자동, 수동정지, 설비이상, 설비수리 등으로 설비를 가동하기 전 시험운전을 하고, 안정화되면 운전 상태가 자동으로 바뀌어 대량으로 샤프트를 가공하게 된다.

2.2 기초 데이터 분석


<Figure 3>은 황삭, 드릴, 정삭의 전력 데이터의 일부분을 보여주고 있다. 세 공정 모두 일관된 주기(평균 22초)를 가지고 동일한 패턴이 반복됨을 알 수가 있다. 황삭의 경

우 1,200W 이상 1,800W 이하의 범위에 전력량이 분포한다. 드릴과 정삭의 전력 부하량은 모두 100W 이상 500W 이하를 보이지만 그 패턴은 공정에 따른 특징을 보이고 있다. 이는 황삭이 상대적으로 거칠고 많은 양을 절삭하기 때문에 많은 부하를 필요로 하기 때문이다.



<Figure 3> Power Loads of Processes

황삭 공정 한 사이클에서 전력 부하량의 변화 패턴은 <Figure 4>와 같다. 사이클에서 7초에서 12초에 해당하는 가공 대기 시간은 실제 부품을 절삭 가공하지 않고 이전 공정에서 가공을 마친 부품을 황삭 공정으로 이송시키면서 이송되어 온 부품을 정위치에 고정하는 시간이다. 이때 스핀들은 회전을 멈추지 않고 부품 가공을 위해 공회전을 하면서 대기한다. 가공 대기 시간 이후 절삭이 시작되면 스핀들에 부하가 걸리게 되면서 전력량이 급격히 증가하는 패턴을 보인다. 하지만 드릴과 정삭 공정은 데이터 이상치가 빈번하게 발생하고 가공 패턴이 일정하지 않은 문제를 발견하였고, 최종적으로 황삭에 대한 학습모델을 개발하기로 결정하였다.




<Figure 4> A Cycle of Rough Grinding Electric Power

3. 데이터 전처리

수집된 원본 데이터를 보면 공구의 이상이나 제품의 불량은 아니지만 데이터 송신 오류로 인해 null 값이 수집되는 경우도 있고, 센서의 오류로 이상치가 발생하기도 하였다. 또한 각 사이클 간의 가공 대기 구간에서의 전력값의 차이가 발생하여 이에 대한 보정이 필요하였다.

먼저 이상치를 처리하기 위하여 IQR(InterQuartile Range)을 적용하였으며, 황삭공정에서 86개의 이상치가 제거되었다. <Figure 5>는 황삭에서 이상치를 처리하기 위해 값의 분포를 분석한 결과를 보여준다. 결측치는 NULL 값으로 수집되고 있었으며 전체 데이터 대비 0.05% 정도이다. 결측치는 선형 보간법을 통해 앞, 뒤 값으로 유추하여 보간하였다. 선형보간법은 끝점의 값이 주어졌을 때 그 사이에 위치한 중간 값을 추정하기 위하여 선형적으로 이를 계산하는 방법이다.



<Figure 5> Data Distribution of Rough Grinding Electric Power

다음으로 가공 대기 구간의 전력값의 차이가 없도록 데이터를 보정하였다. 이론적으로는 모든 황삭 공정에서는 가공 대기 구간의 스피들 전략 값이 매 사이클마다 일정하게 유지되어야 한다. 하지만 가공 횟수가 증가함에 따라 스피들에 걸리는 전력 부하가 조금씩 증가하는 패턴이 감

지되었다. 따라서 실제 가공의 스피들 부하를 가공 대기 구간의 전력 부하 대비 상대 수치로 분석하기 위해 가공 대기 구간의 평균 전력값을 0으로 차감하는 전처리를 진행하였다. 따라서 <Figure 6>과 같이 황삭의 전력량 피크도 1,800W에서 200W 내외로 줄어들게 되었다.


4. 이상 탐지 모델 학습 및 검증

4.1 학습 기법

본 연구에서는 정상 패턴을 학습하기 위해 비지도학습 모델로 학습하고 각 모델을 평가하여 정상패턴을 가장 잘 표현하는 모델을 선정하였다. 해당 기업은 짧은 사이클 타임에 연속으로 제품을 대량생산하기 때문에 개별 제품에 대한 양품/불량 판정을 하지 못하고, 롯트(lot)단위로 양품, 불량을 판정한다. 데이터 수집 기간에는 불량 발생 롯트가 없어 학습에 사용된 데이터는 모두 양품으로 판정하고, 이를 기준으로 정상 상황에서의 가공 패턴을 학습하였다. 그리고 불량품이 가공되는 상황을 탐지할 수 있도록 선정된 학습 모델을 기준으로 임계점을 실무 전문가와 협의하여 통계적으로 유의미한 기법을 사용하여 설정하였다.

본 연구에서 사용한 기법은 시계열 분석에서 전통적으로 사용하는 홀트 윈터스(Holt-Winters Model) 모델과 딥러닝 모델 6종이고 이에 대한 간략한 설명은 다음과 같다.

- 홀트-윈터스 모형은 지수평활 기법의 단점인 계절성 추정 불가 문제를 극복해서 추세 및 계절성을 동시에 추정할 수 있는 기법이다.
- RNN(Recurrent Neural Network)은 순환 신경망으로 신경망을 구성하는 레이어에 순환하는 메커니즘을 가진 상태 값이 포함된 딥러닝 구조이다. 은닉층에서 나온 결과를 출력층 쪽으로 보내면서, 또한 다시 은닉층 노드의 다음 계산의 입력으로 보내는 특징이 있다.
- LSTM(Long Short-Term Memory)은 시점(time step)이



<Figure 3> Rough Grinding Power Load after Pre-processing


길어질수록 앞의 정보가 뒤로 충분히 전달되지 못하는 장기 의존성 문제를 해결하는 기법이다.

- GRU(Gated Recurrent Unit)는 LSTM의 장기 의존성 문제에 대한 해결책을 유지하면서, 은닉 상태를 업데이트하는 계산을 줄였는데, LSTM과 성능은 유사하면서 복잡했던 LSTM의 구조를 간단화시켰다는 특징이 있다.
- BiRNN(Bidirectional Recurrent Neural Networks)는 일반 RNN의 한계를 극복하기 위해 특정 시간 프레임의 과거와 미래에 사용 가능한 모든 입력 정보를 사용하여 학습을 한다.
- BiLSTM(Bidirectional Long Short-Term Memory)은 두 개의 LSTM이 입력 데이터에 적용되는 LSTM 모델의 확장이다. forward-LSTM와 backward-LSTM 두 개의 네트워크를 구성하여 이전 정보에만 의존하던 기존의 LSTM의 한계를 보완하여 후속 정보도 학습한다. LSTM을 두 번 적용하면 학습 장기 종속성이 향상되어 모델의 정확도가 향상된다.
- BiGRU(Bidirectional Gated Recurrent Unit)는 두 개의 GRU가 입력 데이터에 적용되는 GRU 모델의 확장이다. forward-GRU와 backward-GRU 두 개의 네트워크를 구성하여 이전 정보와 후속 정보 모두 학습한다.

4.2 학습 방법 및 평가 지표

스핀들 전력 패턴의 학습을 위해 시간에 따른 전력 데이터를 시계열 모델로 구성하여 학습을 진행하였다. 학습 데이터와 테스트 데이터는 70%와 30%로 분리하였으며, 총 길이 4,068,923개에 해당하는 황삭 공정의 전력 데이터를 학습에 사용하였다.

시계열 데이터를 위한 신경망 모델은 입력(X)과 출력(Y)의 길이를 다르게 설계할 수 있는데, 입력(X)인 윈도우 크기(window size)는 평균 사이클 타임인 22초 즉 220으로 설정하였고, 출력(Y)은 1로 설정하여 학습하였다. 윈도우 크기는 다음 step을 예측하기 위해 구별하는 입력의 크기로 학습을 위한 데이터로 사용되며, 무빙 윈도우(moving window)만큼 이동하며 학습을 진행한다(<Figure 7> 참고).



<Figure 7> Sliding Window Approach to Time Series Modeling

모델 구성과 학습에 필요한 하이퍼파라미터 중 레이어(layers), 유닛(units), 배치 크기(batch size)는 일부 데이터만을 이용하여 <Table 1>과 같이 순차적으로 증가시켜가며 최적의 값을 선정하였다. 그리고 모델을 학습시키는 단계에서는 역전파(backpropagation)과정에서 RMSProp optimization을 사용했으며, 오버피팅(over-fitting)을 방지하기 위해 학습 과정에서 일정 확률로 임의의 모델 연결을 무시하도록 하는 드롭아웃(dropout)을 0.2로 설정하였다. 반복횟수(epochs)는 100, 조기종료(early stopping)은 5로 설정하였다.

<Table 4> Hyper Paramater

Layers	Units	Batch size	RMSE	MAE
2	32	32	7.13	4.87
		64	6.30	4.35
		128	7.27	4.99
	64	32	6.18	4.23
		64	6.36	4.43
		128	6.25	4.44
	128	32	6.27	4.38
		64	6.38	4.48
		128	6.09	4.28
	256	32	5.90	4.15
		64	5.88	4.18
		128	6.01	4.22
3	32	32	6.76	4.49
		64	6.95	4.77
		128	8.98	6.48
	64	32	6.33	4.40
		64	6.11	4.26
		128	7.55	5.38
	128	32	7.06	4.75
		64	6.08	4.31
		128	6.40	4.60
	256	32	6.06	4.29
		64	6.04	4.37
		128	5.93	4.16
4	32	32	6.25	4.41
		64	6.62	4.57
		128	6.83	4.74
	64	32	6.26	4.43
		64	6.38	4.48
		128	6.64	4.62
	128	32	5.80	4.12
		64	5.90	4.12
		128	6.48	4.53
	256	32	6.98	4.78
		64	6.01	4.26
		128	6.31	4.50

정상 패턴을 정확히 예측하는 모델의 성능을 평가하기 위해 본 연구에서는 두 가지 지표를 선정하였다. 분석 대상 데이터는 자기 회귀 문제에 해당하므로 평균 절대 오차(MAE: Mean Absolute Error)와 평균 제곱근 오차(RMSE: Root Mean Square Error)를 비용함수로 사용하여 각 모델에 대한 성능을 측정하였다. MAE는 실제 측정된 실제값과 예측값의 절댓값의 평균으로 모든 오차(error)에 동일한 가중치를 부여한다. RMSE는 실제값과 예측값의 차이를 제곱한 값의 평균인 MSE에 루트를 씌운 값이다. RMSE는 MSE보다 이상치에 덜 민감하고 MAE와는 달리 모든 오류에 동일한 가중치를 주지 않고, 오류가 크면 더 큰 가중치를, 작으면 더 작은 가중치를 부여한다.

4.3 분석 결과

아래 <Figure 8>은 황삭 공정의 실제 전력 데이터와 예측 데이터를 학습 모델별로 나타낸 것이다. <Table 2>는 평가 지표인 MAE와 RMSE를 정리한 것이다. 그림에서 파란색의 값은 실제 전력 부하를 나타내고 있으며, 붉은색의 값은 모델에서 예측한 전력 부하를 나타낸다. 홀트-윈터스 모델은 예측한 값이 실제 값과 큰 차이를 나타내는 것을 알 수 있으며 MAE나 RMSE 값도 다른 기법에 비해 차이가 많이 나는 것을 알 수 있다. 딥러닝 모델은 상대적으로 차이가 크지 않으나 그 중 BiLSTM 모델이 MAE 6.69, RMSE 10.37로 제일 우수한 성능을 나타낸 것을 알 수 있다. 따라서 정상 패턴을 가장 잘 나타내는 모델인 BiLSTM을 사용하여 이상 패턴을 감지하는데 활용하도록 한다.


<Table 6> Evaluation of Prediction Models

Models	MAE	RMSE
Holt-Winters	89.56	117.47
RNN	11.18	20.28
BiRNN	10.23	19.41
LSTM	8.90	13.02
BiLSTM	6.69	10.37
GRU	37.73	49.97
BiGRU	7.67	11.96

4.4 모델 검증


황삭 공정의 전력 데이터를 잘 예측하는 모델은 BiLSTM이다. 하지만 이상 상황을 판정하기 위해서는 정상 패턴 학습 데이터와 현재 수집되는 스피들 전력 데이터의 차이(RMSE)가 어느 수준일 때 이를 이상으로 판정해야 하는지에 대한 임계점 설정이 중요한 문제이다. 이를 위해 현업 실무자와 협의하면서 BiLSTM의 RMSE 분포를 활용하여 임계점을 설정하였다.

먼저 BiLSTM 모델로 정상적인 전력 패턴의 예측 오차를 구하여 <Figure 9>와 같은 정상 상황에서의 각 사이클의 예측 오차(RMSE) 분포를 확인하였다. RMSE의 평균과 분산은 각각 10.37과 2.00인데, 데이터가 6시그마 범위를 벗어날 확률은 99.99994%의 비율이므로 임계점을 평균과 6 시그마의 합인 22.37로 설정하였다. 이를 기준으로 제품 힘 변형 이상이 발생한 상황의 전력 데이터를 BiLSTM 모델에 입력하여 검증하였다. 이 때, 모델과 실제 데이터 간



<Figure 8> Comparison of Prediction Models of Rough Grinding

의 오차는 24.36으로 나타났는데, 이는 임계치 22.37을 벗어나는 상황이므로 선택한 모델이 이상 상황을 잘 진단하는 것으로 판단되었다.



<Figure 9> Distribution of Prediction Error

5. 결론 및 추후 연구

스마트 공장 보급사업을 통해 많은 제조기업들이 생산 라인에 각종 센서를 설치하고 현장 데이터를 수집하고 있다. 하지만, 수집된 데이터를 적극적으로 활용하는 비율은 상대적으로 미흡하여 데이터를 활용하는 연구가 활발히 진행되고 있다. 본 연구는 자동차 스톱을 벨브에 사용되는 샤프트를 절삭 가공하는 기업의 스피들 전력 데이터를 분석하여 해당 공정의 이상을 탐지하는 모델을 개발하였다.

절삭 가공 시 수집되는 데이터는 시계열 데이터이기 때문에 전통적인 시계열 기법인 Holt 윈터스기법과 다양한 딥러닝 알고리즘인 RNN, LSTM, GRU, BiRNN, BiLSTM, BiGRU를 적용하여 최적의 모델을 개발하였다. 이중 BiLSTM이 RMSE를 기준으로 최적의 결과를 나타내었다. 개발한 모델에 대해 이상으로 진단하기 위해 임계점을 현장 전문가와 협의하여 통계적 기법으로 설정하고 이에 대한 검증을 실시하였다. 제품 휨 변형으로 인해 불량품이 양산된 상황에서의 데이터를 분석하여 개발된 모델이 이상 상황으로 판정함을 확인하였다.

본 연구는 비지도학습 모형으로 정확도, F1-score 등의 지표로 성능을 평가하기 어렵다는 단점이 있다. 따라서 이를 보완하기 위해 분류 모형(classification)을 적용하여 시퀀스 데이터를 분석하는 것도 필요해 보인다. 또한, 실제 제조 현장의 데이터를 사용하였지만, 상대적으로 짧은 기간의 데이터를 분석하였기 때문에 계절적 요인에 대한 분석을 수행하지 못하였다. 무더운 여름과 추운 겨울의 가공 환경이 차이가 나기 때문에 스피들에 가해지는 부하가 변

하는데 이에 대한 요인을 고려하여 모델을 확장하여 일반화하는 연구가 추가로 필요하다.

References

- [1] Choi, S. and Lee, D., Real-Time Prediction for Product Surface Roughness by Support Vector Regression, *Journal of Korean Society of Industrial and Systems Engineering*, 2021, Vol. 44, Issue 3, pp. 117-124.
- [2] Ha, Y.W., Yang, H.C., Yoo, K.H., Park, J.P., and Wang, G.N., FGLS estimation for process cycle pattern extraction and anomaly detection using Chi-square distribution, In *Proceedings of the Korean Institute of Industrial Engineers*, 2022, pp. 4029-4036.
- [3] Jin, S.J., Yoo, S.C., Kim, N.G., Ha, Y.W., and Wang, G.N., Welding process time series data anomaly detection using AutoEncoder / Isolation Forest algorithm, In *Proceedings of the Korean Institute of Industrial Engineers*, 2022, pp. 4130-4135.
- [4] Jung, J. and Jin, K.H., Anomalous Records Detection in Process data using Robust Linear Regression, In *Proceedings of Korea Institute of information and Communication Engineering*, 2022, pp. 513-515.
- [5] Jung, M.Y., Yu, G.H., Kim, N.K., Jin, J.S., Yoo, S.C., and Wang, G.N., Welding process anomaly detection using GMM-Mahalanobis distance, In *Proceedings of the Korea Society of Manufacturing Technology and Engineering*, 2021, pp. 5873-5878.
- [6] Kim, S.Y., Lee, J.Y., Mok, C.H., Kim, S.H., Moon, S.H., Kyeong, Y.Y., Chin, Y.G., Lee, Y.G., Choi, J.M., and Kim, S.B., Prediction of production process equipment defects using explainable outlier detection algorithm, In *Proceedings of the Korean Institute of Industrial Engineers*, 2021, pp. 428-442.
- [7] Kim, Y.S., Performance Evaluation of Sensor Pattern Anomaly Detection Using Deep Learning, [dissertation], [Incheon, Korea]: InCheon University, 2018.
- [8] Lee, H.Y., Kim, Y.J., and Kim, C.W., Process anomaly detection based on deep learning, In *Proceedings of the Korean Institute of Industrial Engineers*, 2016, pp. 5306-5323.
- [9] Lee, J.H. and Cho, S.J. Anomaly detection on the process utilizing robust deep autoencoder, In *Proceedings of the Korean Institute of Industrial Engineers*, 2019, pp. 2729-2750.
- [10] Lee, J.H., Kim, J.H., Hwang, J.B., and Kim, S.S., A

- Study on Fault Detection of Cycle-based Signal using Wavelet Transform, *Journal of The Korea Society For Simulation*, 2007, Vol. 16, No. 4, pp.13-22.
- [11] Lee, S.H. and Baek, J.G., Manufacturing Process Anomaly Detection Using Adversarial Autoencoder with Multiple Discriminator, *Journal of the Korean Institute of Industrial Engineers*, 2021, Vol. 47, No. 2, pp.217-223.
- [12] Park, C.S. and Kim, H.S., A Study on Defect Prediction through Real-time Monitoring of Die-Casting Process Equipment, *Journal of Korean Society of Industrial and Systems Engineering*, 2022, Vol. 45, Issue 4, pp.157-166.
- [13] Yoo, G.H., Yang, H.C., and Wang, G.N., Abnormal detection of the mold cylinder temperature cycle using 1D CNN, In *Proceedings of the Korean Institute of Industrial Engineers*, 2021, pp.5873-5878

ORCIDSung Moon Bae | <http://orcid.org/0000-0002-5227-2361>Jun Hong Yook | <http://orcid.org/0000-0001-9692-6817>