

프레스 공정을 위한 품질 예측 모델

이기성¹, 이종찬^{2*}

¹호원대학교 컴퓨터게임학과, ²군산대학교 소프트웨어학부

Quality Prediction Model for Press Process

Gi-Sung Lee¹, Jong-Chan Lee^{2*}

¹Department of Computer & Game, Howon University

²School of Software, Kunsan National University

요약 제조업 분야에서의 품질 관리는 핵심적인 과제 중 하나로, 프레스 공정 데이터의 효율적인 활용은 제품 품질 향상과 생산 프로세스 최적화에 중요한 역할을 수행한다. 제조업체에서 품질 향상과 불량품 검출의 매우 중요하지만, 기존의 판별 방법은 불량품의 다양한 형태와 패턴을 효과적으로 처리하지 못하는 한계가 있었다. 특히 데이터 부족 문제와 불균형한 데이터 분포로 인해 품질 관리 모델의 성능 향상이 어려웠다. 본 논문에서는 적대적 생성 망을 활용하여 프레스 공정 데이터를 증강하고, 품질 관리 모델의 정확도와 일반화 능력을 향상시키는 접근 방법을 제안한다. 적대적 생성 망의 생성자에 강화학습 모델, 판별자에 심층신경망 모델을 적용하여 데이터 생성 및 불량품 판별을 수행한다. 특히 GAN(Generative Adversarial Networks) 모델에 강화학습을 도입하여 생성자의 성능을 개선하였다. 강화학습은 불균형한 클래스 분포와 다양한 불량 패턴에 대해서도 강건한 성능을 보여줌으로써 실제 공정 환경에서의 적용 가능성을 높인다. AI 모델 개발과 제조공정의 적용 및 검증을 통하여 실질적인 품질 및 비용 절감 개선에 기여한다.

Abstract Quality management is one of the key challenges in the manufacturing sector, and the efficient use of press process data plays an important role in improving product quality and optimizing production processes. Although quality improvement and defect detection are very important for manufacturers, methods of discrimination have limitations in not being able to effectively handle various forms and patterns of defective products. In particular, improvement of the performance of the quality management model is difficult due to a lack of data and unbalanced data distribution. In this paper, we propose a new approach that enhances press process data by utilizing adversarial generation networks and improves the accuracy and generalization ability of quality management models. Data generation and defect determination are performed by applying a reinforcement learning model to the creator of the adversarial generation network and a deep neural network model to the discriminator. Reinforcement learning was introduced in generative adversarial networks (GANs) model to improve the performance of the generator. Reinforcement learning also improved its applicability in real manufacturing environments by showing robust performance against unbalanced class distributions or various defective patterns. It could contribute to substantial quality and cost reduction improvement through the development of AI models and the application and verification of manufacturing processes.

Keywords : GAN, Manufacturing Data, Data Analysis, Reinforcement Learning, DNN

본 논문은 2023년도 호원대학교 지원에 의하여 출판되었음.

*Corresponding Author : Jong-Chan Lee(Kunsan National Univ.)

email: chan2000@kunsan.ac.kr

Received September 19, 2023

Accepted October 6, 2023

Revised October 4, 2023

Published October 31, 2023

1. 서론

프레스 공정은 제조 공정 중 하나로, 금속 시트, 플라스틱 등의 원재료를 특정 형태로 가공하는 과정이다. 프레스 공정은 다양한 산업 분야에서 사용되며, 자동차, 전자제품, 가전제품, 건설 장비, 공작 기계 등 다양한 제품의 제조에 핵심 역할을 한다. 특히 프레스 공정에서 양품과 불량품을 신속하게 판단하는 것은 생산 프로세스의 효율성을 향상시키고 불필요한 재작업 및 폐기물 감소에 중요하다. 과거에는 인간의 시각 검사 및 경험에 의존하여 제품 품질을 평가하는 것이 일반적이었다. 그러나 이러한 방법은 불완전하고 주관적일 수 있으며, 대량 생산 및 높은 정밀도 요구 사항을 충족하기에는 한계가 있다 [1-5]. 이에 따라 최근 몇 년 동안, 인공지능과 기계 학습 기술의 발전은 프레스 공정에서의 품질 검사를 혁신적으로 개선하고 있다.

프레스 공정은 제품의 형상을 결정하고 제품의 미세한 차이나 변동이 품질에 영향을 미칠 수 있는 민감한 과정으로 다양한 문제가 발생할 수 있다. 프레스 공정에서 다양한 문제와 고려 사항은 아래와 같다[6].

- 품질 변동성: 프레스 공정에서 생산되는 제품의 품질은 원재료의 품질, 프레스 기계의 조정, 작업자의 기술 등에 영향을 받아 변동성을 가진다. 이러한 품질 변동성은 고객 만족도를 저해하고 재작업 및 폐기물 처리 비용을 증가시킬 수 있다.
- 결함 감지: 프레스 공정에서의 결함은 제품의 불량으로 이어질 수 있으며, 이는 소비자에게 부적절한 제품을 제공하거나 재작업 및 보증 청구 비용을 증가시킬 수 있다. 따라서 불량품을 신속하게 감지하고 조치해야 한다.
- 설정 및 유지 관리: 프레스 기계의 설정과 유지 관리는 공정의 안정성과 품질에 큰 영향을 미친다. 기계의 오작동 또는 부적절한 설정은 제품 결함으로 이어질 수 있으므로 이를 철저히 관리해야 한다.

이러한 문제를 해결하기 위해 인공지능을 활용한 품질 관리 및 생산 최적화 솔루션이 개발되고 있다. 이러한 솔루션은 센서 데이터, 비디오 분석, 이미지 인식 등을 활용하여 실시간으로 생산 데이터를 분석하고 불량품을 감지하며, 예방 정비를 위한 유지 보수 일정을 최적화하는 등의 기능을 제공한다[7-10]. 따라서 본 논문은 프레스 공정에서의 양품과 불량품 판단을 위하여 GAN(Generative Adversarial Networks) 기반의 접근 방법을 제시한다. 이를 통해 생산라인에서의 실시간 품질 관리 및 결함 예

방을 위한 기반을 마련하고자 한다. 프레스 공정에서 발생하는 다양한 데이터를 수집하고 분석하는 GAN 기반 시스템을 제안하고, 이 시스템을 활용하여 양품과 불량품을 판단하고 이상 징후를 감지하는 모델을 제시한다. 그리고 실험 및 실제 제조 환경에서의 성능을 검증하고 결과를 분석하여 GAN 기반 품질 관리의 유용성을 입증한다.

2장에서 제안 시스템 구조를 제시하고 3장에서는 GAN 기반 접근 방법을 기술하며, 4장에서 실험 및 결과 분석, 그리고 마지막으로 결론 및 향후 연구 방향을 기술한다.

2. 제안 시스템 구조

프레스 공정 후 주름, 터짐 및 Burr 발생 등의 불량이 발생하고 있으며 이로 인한 폐기 비용이 증가하고 있다. 공정 불량량의 90%가 금형 관리 미흡과 공정 조건을 작업자의 경험적 판단에서 운영하는 것에 기인하는 것으로 파악되고 있다. 본 연구에서는 프레스 공정에 영향을 미치는 데이터를 전처리하고, 분석하여 시각화하는 품질 예측 모델의 도출을 목표로 한다. Fig. 1과 같이 데이터의 수집, 전처리, 정밀한 분석 과정, 실제 현장의 공정 운영 조건에 설정하여 운영 최적화를 수행한다.

- ① 데이터의 수집: 프레스 가공의 검사 판정 데이터와 생산 조건 데이터를 수집한다. 이 데이터는 불량 발생과 관련된 정보를 포함해야 한다.
- ② 데이터 전처리: 수집한 데이터를 가공한다. 이 단계에서 결측치 처리, 이상치 제거, 데이터 스케일링(정규화), 라벨링 등을 수행한다.
- ③ 데이터 분석: 독립변수와 종속변수의 상관분석, 독립변수 간의 상관분석을 통하여 인자 간의 관련 유·무를 파악한다.
- ④ AI 모델 개발: 분석한 데이터를 사용하여 가공 품질을 예측하는 인공지능 모델을 개발한다. 이는 머신러닝 기반의 예측 모델로서, 분류(Classification) 기술을 사용하여 양품과 불량을 판별하는 모델을 구성한다.
- ⑤ 결과 기반 재현 검증: 모델의 예측 결과를 실제 가공 결과와 비교하여 모델의 성능을 평가하고 검증한다. 이를 통해 모델의 신뢰성과 정확성을 확인한다.
- ⑥ 양품과 불량 예측 모델 구성: 개발한 모델을 통해 양품과 불량을 예측하는 모델을 구성한다. 이 모델

은 실시간으로 가공 과정 중에 불량률 예측하고 조치하도록 한다.

- ⑦ 제조 공정 적용 및 검증: 모델이 개발되고 검증되면 실제 제조 공정에 적용하여 사용한다. 필요에 따라 모델을 조정하고 최적화한다.

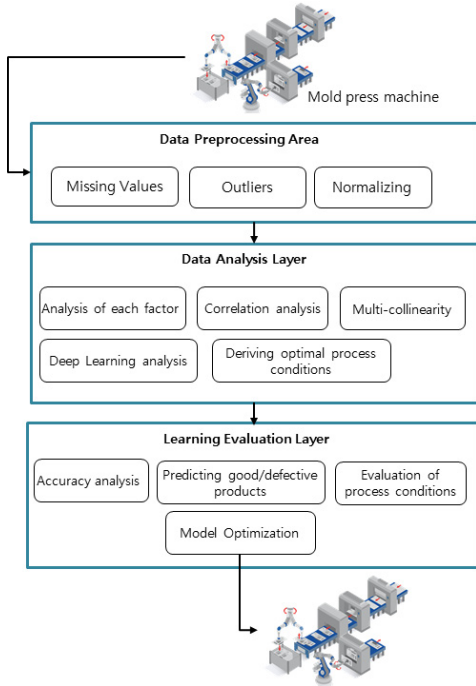


Fig. 1. AI-based data analysis procedure

3. GAN 기반의 품질 예측 모델

본 연구에서는 프레스 공정 데이터의 증강을 위해 GAN을 사용한다. 과거 연구에서는 데이터 증강을 위해 다양한 방법과 기술이 제안되었지만, GAN을 활용한 데이터 증강은 데이터의 다양성을 확보하고 모델 성능의 향상에 효과적인 방법이다.

- 데이터 부족 문제 해결: 프레스 공정에서 자료를 수집하는 것은 비용 증가와 데이터의 수집에 제한이 있을 수 있다. GAN을 사용하면 기존 데이터로부터 합성된 데이터를 생성할 수 있으므로 데이터의 부족 문제를 해결할 수 있다.
- 다양성 증가: GAN을 통해 생성된 데이터는 기존 데이터와는 다른 특성을 가질 수 있으며, 이는 모델의 다양성을 높인다. 더 많은 다양한 입력 데이터는 모

델의 성능을 향상시킨다.

- 불균형 클래스 대응: 프레스 공정 데이터에서 양품과 불량품 클래스가 불균형하게 분포할 수 있다. GAN을 사용하면 소수 클래스의 데이터를 늘릴 수 있으며, 이로써 모델이 불균형한 데이터에 대해 더 강력한 학습을 수행할 수 있다.

Fig. 2에 GAN 모델을 보인다. GAN의 생성자(Generator)는 원래 데이터의 분포를 학습하고 새로운 데이터를 생성한다. 양품 및 불량품의 분포를 학습하여 두 클래스에 해당하는 데이터를 생성한다. 판별자(Discriminator)는 생성된 데이터와 실제 데이터를 구별한다. 이 모델은 생성된 데이터와 실제 데이터 간의 차이를 학습하고, 생성된 데이터가 실제 데이터와 유사하게 보이도록 학습한다.

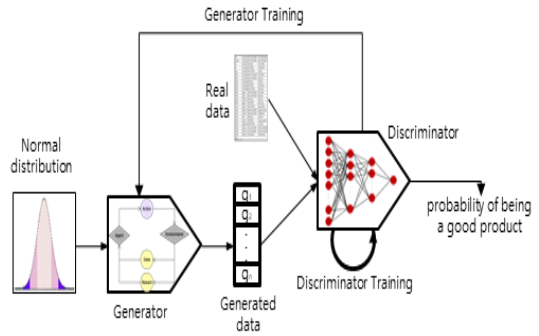


Fig. 2. GAN Model

3.1 생성자 학습

생성자는 원래 데이터 분포를 학습하고 새로운 프레스 공정 데이터를 생성한다. 생성자는 강화학습 에이전트로서, 먼저 잠재 공간(latent space)에서 무작위 벡터를 생성한다. 이 잠재 벡터는 정규 분포(가우시안 분포)에서 무작위로 샘플링되고, 생성자가 어떤 데이터를 생성할 것인지를 결정하는 잠재적인 특성을 포함한다. 이 벡터는 단순한 무작위 벡터가 아닌, 강화학습 에이전트의 상태 벡터로 사용된다.

생성자는 잠재 벡터를 입력으로 받아, 원래 프레스 공정 데이터와 유사한 패턴 및 구조를 가진 데이터를 생성한다. 생성자는 학습 과정 중에 원래 데이터 셋에 있는 데이터의 분포를 학습하고 실제 데이터와 유사한 데이터가 생성된다. 생성자는 손실 함수를 최소화하며, 실제 데이터와 생성된 데이터 간의 유사성을 높이기 위하여 역전파(backpropagation) 알고리즘을 사용하고 가중치 및 매개 변수를 조정한다. 생성자는 강화학습을 통해 개

선된 정책을 사용하여 더 실제 데이터와 근접한 데이터를 생성한다.

판별자와 생성자 간의 강화학습 인터페이스를 구현하기 위해 강화학습 알고리즘으로서 심층 강화학습 알고리즘인 DQN (Deep Q-Network)을 사용한다. 선택한 알고리즘은 보상 신호를 기반으로 판별자와 생성자의 정책(policy)을 개선하는 데 사용된다. GAN의 생성자에 DQN을 적용하기 위하여, 강화학습의 핵심 구성 요소인 에이전트, 환경, 행동, 보상, 상태를 GAN의 생성자에 맞게 정의하고 통합한다.

- ① 에이전트 (Agent): 에이전트는 GAN의 생성자를 나타낸다. 이 에이전트는 환경에서 행동을 선택하여 생성 데이터를 만들고자 반복적으로 시도한다.
- ② 환경 (Environment): 환경은 GAN의 학습 데이터와 판별자(Discriminator)로 구성된다. 생성자는 이 환경에서 행동을 수행하며, 판별자의 피드백을 받아 손실을 최소화하고 원래 데이터와 유사한 데이터를 생성한다.
- ③ 행동 (Action): 생성자가 어떤 유사 데이터를 생성할지 결정한다. GAN에서는 이것이 생성자의 가중치와 편향을 조정하는 것으로 해석할 수 있다. 생성자는 유사 데이터를 생성하기 위해 가중치를 조정하고, 이것이 행동에 해당한다.
- ④ 보상 (Reward): 보상은 생성자가 생성한 데이터의 품질을 측정하는 방법이다. GAN에서는 보상을 손실 함수로 정의할 수 있다. 생성자는 판별자의 피드백(진짜인지 가짜인지에 대한 정보)을 통해 손실을 계산하고 이 손실을 최소화하려고 시도한다. 이 최소화된 손실은 높은 보상으로 간주된다. 목표는 생성된 데이터가 진짜 데이터와 구별하기 어렵게 만드는 것이다.
- ⑤ 상태 (State): 상태는 에이전트가 행동을 선택하기 위한 정보를 나타낸다. GAN의 생성자에 상태를 적용할 때, 상태는 입력 벡터이다. 입력 벡터는 생성자가 현재 생성하고자 하는 데이터의 특성과 관련된 정보를 포함한다.

구체적인 강화학습 알고리즘을 사용하여 GAN의 생성자를 학습시킬 때, 생성자는 행동을 선택하고 손실을 최소화하기 위해 DQN을 적용한다. 이를 통해 생성자는 진짜 데이터와 구별하기 어려운 유사 데이터를 생성한다.

3.2 Training Discriminator

프레스 공정의 데이터 증강을 위해 GAN의 판별자로

서 DNN(Deep Neural Network)을 적용한다. 판별자의 입력층은 프레스 공정 데이터의 특징을 입력으로 받아들인다. 이 데이터는 프레스 작업에서 발생한 관련된 정보를 포함한다. 은닉 계층(Hidden Layers)은 여러 개의 은닉 계층을 사용하여 모델의 복잡성을 증가시킬 수 있습니다. 각 은닉 계층은 여러 개의 뉴런(유닛)으로 구성된다. 은닉 계층의 뉴런 수와 계층 수는 데이터의 복잡성에 따라 조절할 수 있습니다. 더 복잡한 데이터 셋일 경우 더 깊거나 넓은 네트워크를 고려할 수 있다. 출력층(Output Layer)은 판별자의 최종 출력을 담당한다. 이것은 생성자가 생성한 데이터(가짜 데이터)와 실제 데이터(진짜 데이터)를 구별하는 역할을 수행한다. 출력층은 시그모이드 함수를 통해 출력값을 0에서 1 사이의 값을 출력한다. 판별자 네트워크는 이진 분류 문제로 학습된다. 학습 데이터셋은 가짜 데이터와 진짜 데이터로 구성되며, 손실 함수(loss function)는 이진 교차엔트로피(binary_crossentropy)를 사용하여 손실을 최소화하는 방향으로 가중치와 편향을 업데이트하여 학습한다. DNN 모델은 Fig. 3과 같다[11].

판별자에 DNN을 사용한 이유는 많은 매개 변수와 연산이 필요한 LSTM에 비하여, 간단한 데이터 패턴을 학습하는 데에는 DNN이 효율적이기 때문이다. 데이터가 제한적인 경우, DNN이 더 적은 데이터로도 우수한 성능을 보일 수 있다. 특히 LSTM은 복잡한 모델 구조이고, 작은 데이터셋에서는 과적합 위험이 크다. 반면에 DNN은 모델의 복잡성이 없어 과적합 문제의 발생 가능성이 적다.

```

model = Sequential()
model.add(Dense(64, activation='relu', input_dim=20))
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(64, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(32, activation='relu'))
model.add(Dense(2, activation='softmax'))
model.compile(loss=(binary_crossentropy),
optimizer='adam', metrics=['accuracy'])
    
```

Fig. 3. Statistics by Class Variable

강화학습을 사용하는 생성자와의 인터페이스를 구체적으로 설계하기 위해서는 판별자와 생성자 간의 상호작용 및 학습 프로세스를 고려해야 한다. 판별자 네트워크는 기본적으로 이진 분류 문제를 해결하기 위해 지도 학습을 수행한다. 판별자의 보상(reward)은 판별자가 올바르게 가짜와 진짜 데이터를 분류한 정확성(accuracy)에

기반한다. 판별자가 정확하게 분류하면 긍정적인 보상을 받고, 오분류하면 부정적인 보상을 받는다. 판별자는 이러한 보상 신호를 사용하여 자체적으로 업데이트되며, 이는 판별자의 더 강력한 분류 능력을 향상시킨다.

생성자와 판별자 간의 경쟁적 학습을 통해 생성자는 점차 더 현실적인 데이터를 생성하고, 판별자는 점차 더 정확한 분류기가 된다. 이렇게 구현된 판별자와 생성자 간의 강화학습 인터페이스를 통해 GAN은 더 효과적으로 학습하고, 생성자는 더 현실적인 데이터를 생성한다.

3.3 생성 데이터 검증

GAN을 사용하여 생성된 데이터의 품질을 확인하기 위하여 통계적 검증 방법을 사용하였다. 이 방법은 생성된 데이터와 실제 데이터 간의 통계적 특성을 비교하여 데이터의 유사성을 정량적으로 평가한다. 우선, 생성된 데이터와 실제 데이터의 평균과 분산을 비교한다. 이 값들이 유사하면 데이터 분포의 중심과 분산이 유사하다는 의미이다. 그리고 생성된 데이터와 실제 데이터 간의 특성 간의 상관관계를 비교한다. 두 데이터 셋의 특성 관련성이 유사하면 데이터 분포의 유사성을 확인할 수 있다. 통계적 검증의 결과를 해석하여 생성된 데이터와 실제 데이터 간의 유사성을 결정한다. 유사성이 높을수록 생성된 데이터의 품질이 더 높다고 볼 수 있다.

4. 성능 분석

4.1 데이터 구조

Table 1에 제조 데이터 분석을 위한 주요 공정 데이터를 보인다. 주요 인자를 중심으로 기술하였으며, 분석 결과를 제시한다. 데이터 전처리 및 분석된 데이터를 기반으로 DNN을 학습시키고 학습 결과를 확인한다.

Table 1. Process factors for analysis

Classification	Category		
Data type	Text, Number		
Data Properties	Approximately 2100 numerical data of Press Continuous Process Equipment		
Data collection method	MES data collected from the sensor. Cycle time 4 seconds, Processing time 0.5 seconds		
Main parameters	Item No	-	
	working time	-	
	Press time	ms	
	Pressure 1	bar	
	Pressure 2	bar	
	Pressure 3	bar	

4.2 시험 결과

제시한 모델을 근거로 데이터(양품과 불량품)의 분류 결과를 해석하기 위하여 혼동행렬(Confusion Matrix)을 적용한다. 혼동행렬에서 사용하는 지표인 TP(True Positive)는 양품의 양품 예측, FP(False Positive)는 불량품의 양품 예측, FN(False Negative)은 양품의 불량품 예측, TN(True Negative)는 불량품의 불량품 예측을 의미한다. 정확도(Accuracy)는 데이터의 실제값과 예측값이 동일한 건수가 차지하는 비율로서 $\frac{TN+TP}{TN+FP+FN+TP}$ 이다. 정밀도(Precision)는 양품 예측 데이터에서 실제로 양품인 비율로서 $\frac{TP}{TP+FP}$ 이다. 즉 예측값의 정확도를 추정한다. 재현율(Recall)은 실제 양품에서 정확히 양품으로 예측한 비율로서 $\frac{TP}{TP+FN}$ 로서 실제적인 정답 비율이다. F1 점수(Score)는 정밀도와 재현율의 조화평균으로 $2 \times \frac{Precision \times Recall}{Precision + Recall}$ 이다. 데이터 클래스의 불균형이 클 때 사용하는데, 1에 근접할수록 우수한 모델이다[11].

Fig. 4는 DNN 모델을 적용하여 양품과 불량품을 예측한 결과이다. 여기서 support는 양품, 불량품 데이터의 수이다. 정확도, 정밀도, 재현율은 0.97 ~ 0.98 사이의 값을 보인다. GAN의 정밀도는 양품 97%, 불량품 98%, 재현율은 양품 98%, 불량품 87%, F1 점수는 양품 97%, 불량품 97%로서, 정밀도와 재현율이 높고, 거의 균등하게 유지됨을 알 수 있다.

Fig. 4는 DNN 모델을 적용하여 양품과 불량품을 예측한 결과이다. 여기서 support는 양품, 불량품 데이터의 수이다. 정확도, 정밀도, 재현율은 0.97 ~ 0.98 사이의 값을 보인다. GAN의 정밀도는 양품 97%, 불량품 98%, 재현율은 양품 98%, 불량품 87%, F1 점수는 양품 97%, 불량품 97%로서, 정밀도와 재현율이 높고, 거의 균등하게 유지됨을 알 수 있다.

	precision	recall	f1-score	support
0	0.98	0.97	0.97	560
1	0.97	0.98	0.97	561
accuracy			0.98	1123
macro avg	0.97	0.96	0.96	1123
weight avg	0.96	0.97	0.98	1123

Fig. 4. Statistics by Class Variable

Table 2는 정제된 데이터를 기반으로 GAN 분석 방법을 적용한 결과이다. 정밀도와 재현율의 수치가 높고 거의 유사함을 알 수 있다. 서로 보완적인 두 지표는 모두 수치가 높고, 균등하다면 우수한 성능을 의미한다.

Table 2. Confusion Matrix in GAN

Classification		Prediction	
		good	bad
Reality	good	553	7
	bad	16	547

5. 결론

본 연구에서는 GAN을 활용하여 프레스 공정에서 양품과 불량품을 판별하는 방법을 제안하였다. 불량품 검출은 제조업체에 중요한 문제로, 공정 효율성과 제품 품질의 향상을 위하여 중요하다. 이를 위해 신경망 기반의 판별 모델과 생성 모델 간의 경쟁을 통해 데이터의 특징을 추출하고 불량품을 식별하기 위하여 GAN을 활용하였다. 실험 결과, GAN 기반의 불량품 검출 시스템이 우수한 성능을 보였음을 확인하였다. 특히, 불량품의 복잡한 패턴을 효과적으로 감지하고 양품과의 구분력을 높일 수 있었다. 또한, GAN을 사용한 불량품 판별은 데이터의 라벨링과 클래스 분포의 불균형과 같은 일반적인 문제에도 강건하게 작동함을 확인하였다. 이는 실제 공정 환경에서의 적용 가능성을 높이는 중요한 장점으로 꼽힌다.

본 연구로 품질 예측의 정확도를 향상하면 불필요한 공정 작업 및 자원 낭비를 줄일 수 있으며, 이를 통하여 생산 프로세스를 최적화하고 비용을 절감할 수 있다. 실제 프레스 공정에서 제안 기술을 사용하여 생산 품질을 향상하고, 생산 과정을 최적화하는 방법을 개발한다면 산업 현장에서의 활용 가능성이 매우 커질 수 있다.

향후 연구에서는 GAN을 기반으로 한 불량품 판별 시스템을 실제 제조 공정에 적용하고, 최적화 및 실시간 모니터링 기술과 통합하여 더욱 효과적인 결과를 도출하는 방향으로 진화시킬 수 있을 것으로 기대된다.

References

[1] Tao, F., Qi, Q., Liu, A., Kusiak, A., "Data-driven Smart Manufacturing", The Journal of Manufacture System, vol. 48, pp. 157-169, 2018.
DOI: <https://doi.org/10.1016/j.jmsy.2018.01.006>

[2] Kounta CAKA, Arnaud L and et al, "Review of AI-based methods for chatter detection in machining based on bibliometric analysis", The International Journal of Advanced Manufacturing Technology, 2022.
DOI: <https://doi.org/10.1007/s00170-022-10059-9>

[3] Koren, Y., Gu, X., Guo, W., "Reconfigurable Manufacturing Systems: Principles, Design, and Future Trends", Frontiers of Mechanical Engineering, vol. 13, pp. 121-136, 2018.
DOI: <https://doi.org/10.1007/s11465-018-0483-0>

[4] Kim, S. Y., "A Case Study of the Introduction of Smart Factory Operation Management (FOM) in the Fourth Industrial Revolution Era", Journal of Korean Association of Computer And Accounting, vol. 16, no.

1, pp. 43-62, 2018.
DOI: <https://doi.org/10.32956/kaoca.2018.16.1.43>.

[5] Liang, S., Rajora, M., Liu, X., Yue, C., Zou, P., Wang, L., "Intelligent Manufacturing Systems: A Review", International Journal of Mechanical Engineering and Robotics Research, vol. 7, no. 3, pp. 324-330, 2018.
DOI: <https://doi.org/10.18178/ijmerr.7.3.324-330>

[6] Ministry of SMEs and Startups of Korea. Press AI Dataset Guide Book. Korea AI Manufacturing Platform (KAMP). <https://www.kamp-ai.kr/>

[7] Wang, B., Tao, F., Fang, X., Liu, C., Liu, Y., Freiheit, T., "Smart Manufacturing and Intelligent Manufacturing: A Comparative Review", Engineering, vol. 7, no. 6, pp. 738-757, 2020.
DOI: <https://doi.org/10.1016/j.eng.2020.07.017>

[8] Mittal, S., Khan, M. A., Romero, D., Wuest, T., "A Critical Review of Smart Manufacturing & Industry 4.0 Maturity Models: Implications for Small and Medium-sized Enterprises (SMEs)", Journal of Manufacturing Systems, vol. 49, pp. 194-214, 2018.
DOI: <https://doi.org/10.1016/j.jmsy.2018.10.005>

[9] Cho, H. Y., "On-line Process Data-driven Diagnostics Using Statistical Techniques", Journal of the Korea Academia-Industrial cooperation Society, vol. 19, no. 3 pp. 40-45, 2018.
DOI: <https://doi.org/10.5762/KAIS.2018.19.3.40>

[10] Lee, D. Y, Park, J. W, Cho, S. H, Lee, J. S, "Maintainability Prediction of Guided Missile based on Machine Learning using Field Data", Journal of the Korea Academia-Industrial cooperation Society, vol. 23, no. 2 pp. 518-526, 2022.
DOI: <https://doi.org/10.5762/KAIS.2022.23.2.518>

[11] Lee, G. S and Lee, J. C, "Data Analysis and AI Model for Defect Prediction in the Injection Process", Journal of the Korea Academia-Industrial cooperation Society, vol. 23, no. 12, pp. 1001-1008, 2022.
DOI: <https://doi.org/10.5762/KAIS.2022.23.12.1001>

이 기 성(Gi-Sung Lee)

[중신회원]



- 1996년 2월 : 송실대학교 컴퓨터 과학과 (공학석사)
- 2001년 2월 : 송실대학교 컴퓨터 과학과 (공학박사)
- 2001년 3월 ~ 현재 : 호원대학교 컴퓨터게임학과 교수

<관심분야>

모바일 멀티미디어, 네트워크 보안, 머신러닝

이 종 찬(Jong-Chan Lee)

[정회원]



- 1996년 8월 : 숭실대학교 컴퓨터 과학과 (공학석사)
- 2000년 8월 : 숭실대학교 컴퓨터 과학과 (공학박사)
- 2000년 10월 ~ 2005년 2월 : 한국전자통신연구원 선임연구원
- 2005년 3월 ~ 현재 : 군산대학교 컴퓨터정보공학과 교수

〈관심분야〉

머신러닝, 빅데이터, 블록체인