

프레스 데이터를 활용한 GAN 기반 품질예측모델 연구

강미영*

Research on GAN-based Quality Prediction Model using Press Data

Mi-Young Kang*

요약

프레스 데이터를 활용한 품질 예측에서 정확도 향상을 위해 GAN(생성적 적대 신경망) 모델을 적용하는 연구를 수행하였다. 본 연구에서는 프레스 공정 데이터의 다양한 특성을 분석하고, GAN을 이용하여 품질에 영향을 미치는 중요한 특징을 효과적으로 학습할 수 있는 모델을 설계하였다. 데이터 전처리 단계에서는 중요한 특징 간의 관계를 모니터링하기 위해 데이터셋을 재구성하고, 품질 예측에 필요한 중요한 패턴을 학습하도록 GAN을 최적화하였다. 이 모델을 통해 프레스 공정에서 생성된 데이터 기반의 품질 예측 결과를 실제 품질 데이터와 비교하여, GAN 기반 품질 예측 모델의 성능을 검증하고 그 유효성을 평가하였다.

ABSTRACT

We conducted a study to apply a GAN model to improve accuracy in quality prediction using press data. In this study, we analyzed various characteristics of press process data and used GAN to determine the effect on quality. In the data preprocessing stage, we designed a model that can effectively learn important features, reorganized the dataset to monitor relationships between important features, and optimized GAN to learn important patterns required for quality prediction. By comparing quality prediction results based on data generated from the press process with actual quality data, we verified the performance of the GAN-based quality prediction model and evaluated its effectiveness.

키워드

Data PreProcessing, GAN, Machine Learning Model Optimization, Press Data, Quality Prediction
데이터 전처리, 생성적 적대 네트워크, 기계학습 모델 최적화, 프레스 데이터, 품질 예측

1. 서론

최근 인공지능은 제조 분야에서 핵심 기술로 떠오르고 있으며, 특히 품질 예측 및 관리에서 큰 역할을 하고 있다. 제조 공정, 특히 프레스 공정은 데이터에 매우 민감하여 미세한 변화가 제품 품질에 큰 영향을 미칠 수 있다. 이러한 이유로 과거 프레스 공정 데이

터를 활용하여 품질을 예측하는 머신러닝 및 딥러닝 모델 기반 기술이 활발히 연구되고 있다.

프레스 데이터는 제조 공정 중 발생하는 다양한 센서 데이터, 기계 작동 상태, 압력, 온도, 속도 등의 측정값을 포함한다. 이러한 데이터는 공정 전반에 걸쳐 제품의 품질을 실시간으로 모니터링하고 관리하는 데 사용된다[1]. 제조 산업에서 공정 데이터는 품질 관리

* 교신저자 : 호남대학교 정보통신공학과
• 접수일 : 2024. 10. 30
• 수정완료일 : 2024. 11. 21
• 게재확정일 : 2024. 12. 12

• Received : Oct. 30, 2024, Revised : Nov. 21, 2024, Accepted : Dec. 12, 2024
• Corresponding Author : Mi-Young Kang
Dept. Information & Communication Engineering, Honam University,
Email : kmy2021@honam.ac.kr

와 이상 감지에 중요한 역할을 하며, 이를 통해 제품의 결함을 사전에 예측하고 조치를 취함으로써 생산 효율성을 높이고 비용을 절감할 수 있다[2]. 그러나, 공정 과정에서 발생하는 데이터는 종종 불균형하며, 품질 불량 데이터는 소량으로 존재하는 경우가 많아 데이터 부족 문제가 발생한다[3].

품질 예측 모델은 제조 공정 중 수집된 데이터를 바탕으로 제품의 품질을 예측하는 시스템이다. 이러한 모델은 공정 중 실시간으로 품질을 예측해 결함 발생 가능성을 조기에 감지함으로써 제품 불량률을 줄이는 데 큰 기여를 한다[4]. 그러나 기존의 품질 예측 모델들은 충분한 학습 데이터를 요구하며, 특히 불량 데이터를 충분히 확보하지 못하면 모델 성능이 저하될 수 있다[5]. 따라서 소량의 데이터를 활용해 예측 성능을 유지하거나 향상할 수 있는 새로운 접근이 필요하다.

GAN(Generative Adversarial Networks)은 생성자와 판별자라는 두 개의 신경망으로 구성된 딥러닝 모델로, 2014년 Goodfellow에 의해 처음 제안되었다[6]. 생성자는 실제 데이터를 모방한 새로운 데이터를 생성하는 역할을 하며, 판별자는 생성된 데이터가 실제 데이터인지 가짜 데이터인지 구분하는 역할을 한다. 두 네트워크가 서로 경쟁하면서 학습이 진행되며, 결과적으로 생성자는 실제 데이터와 유사한 데이터를 생성할 수 있게 된다. GAN은 데이터 증강, 이미지 생성, 텍스트 생성 등 다양한 응용 분야에서 사용되고 있으며[7], 특히 제조 공정과 같이 데이터 확보가 어려운 분야에서 유용하게 활용될 수 있다[8].

GAN은 데이터가 부족한 상황에서도 가상의 데이터를 생성하여 학습 데이터셋을 확장하는 데 유용한 기술로, 소량의 불량 데이터를 증강해 품질 예측 모델의 성능을 향상하는 데 적용할 수 있습니다[9]. 특히, 제조 공정의 프레스 데이터와 같은 시계열 데이터 또는 복잡한 센서 데이터를 GAN을 통해 증강할 경우, 기존의 오버샘플링 기법보다 더욱 실제 데이터에 가까운 증강 데이터를 확보할 수 있다[10]. 이전 연구에서는 DCGAN(Deep Convolutional GAN), WGAN(Wasserstein GAN) 등의 GAN 변형 모델이 데이터 증강에 효과적임을 입증했으며[11], 이를 바탕으로 제조업 품질 관리에도 적용이 시도되고 있다.

기존의 품질 예측 연구들은 주로 충분한 학습 데이터가 존재하는 환경에서의 예측 정확도 향상에 초점

을 맞추었다. 그러나 프레스 공정 데이터는 불량 데이터가 소량으로 존재하기 때문에, 기존 모델로는 데이터 부족 문제를 해결하기 어려운 실정이다. 본 연구는 GAN을 활용해 프레스 데이터 기반의 품질 예측 모델을 구축함으로써, 소량의 불량 데이터만으로도 신뢰할 수 있는 예측을 가능하게 하고자 한다. 또한, 기존 연구와 달리 다양한 GAN 변형 모델을 실험하여 프레스 데이터 증강에 가장 적합한 모델을 도출하고, 품질 예측에 있어 증강 데이터가 미치는 영향을 체계적으로 분석하고자 한다.

II. 프레스 데이터 품질 예측 모델

프레스 데이터 품질 예측 모델 연구에서는 프레스 데이터와 같이 품질 예측에 중요한 시계열 데이터를 증강할 때, GAN은 오버샘플링 등의 전통적 데이터 증강 기법에 비해 실제 데이터의 특성을 잘 반영하는 가상 데이터를 생성할 수 있다.

본 연구에서는 DCGAN, WGAN 등의 다양한 GAN 변형 모델을 활용해 프레스 데이터를 증강하고, 각 모델의 증강 성능을 비교한다.

제조 공정에서 발생하는 다양한 데이터, 특히 프레스 공정 데이터를 활용하여 제품의 품질을 예측하고 이를 통해 제조 효율성을 높이는 것을 목표로 한다.

2.1 합성곱 신경망(CNN)

합성곱 신경망(Convolution Neural Network, CNN)은 딥러닝의 한 종류로, 주로 이미지 및 영상 데이터 분석에 사용된다. CNN은 데이터에서 특징을 자동으로 학습하는 능력을 가지고 있으며, 특히 공간적 데이터의 패턴을 잘 포착한다. 이 특성 때문에 CNN은 이미지 분류, 객체 탐지, 이미지 생성 등 다양한 컴퓨터 비전 관련한 핵심 기술로 자리잡았다.

CNN의 주요 특징으로는 1) 공간 불변성 : 합성곱 연산과 풀링 과정을 통해 위치에 상관없이 동일한 패턴을 학습. 2) 파라미터 공유 : 동일한 필터를 전체 입력 데이터에 걸쳐 적용하여, 학습해야 할 파라미터의 수를 크게 줄임. 3) 계층적 학습 : 초기 계층은 예지와 같은 저차원 특징을 학습하고, 깊은 계층으로 갈수록 복잡한 고차원 특징(예: 얼굴, 사물 등)을 학습

한다. 아래 그림에서 합성곱 신경망 구조를 보여준다.

입력 계층, 합성곱층, 풀링층, 전결합층, 출력층으로 구성된 것을 알 수 있다.

그림 1에서와 같이, 제조에서 CNN은 이미지나 영상을 통해 제품의 결함을 찾아내고, 생산 과정에서 반복되는 문제를 식별하는데 사용될 수 있다.

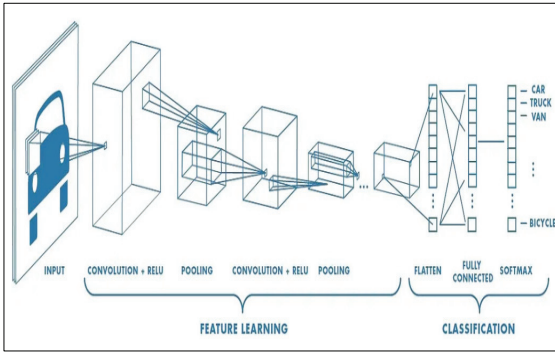


그림 1. CNN 구조
Fig. 1 CNN structure

2.2 순환 신경망(RNN)

순환 신경망(Recurrent Neural Networks, RNN)은 시계열 데이터와 같이 시간적으로 연속성이 있는 데이터를 처리하기 위해 고안된 인공신경망이다. 주식 데이터나 제조 공정에서 수많은 센서로부터 수집되는 데이터가 대표적이다.

그림 2의 RNN의 주요특징으로는 1) 순차 처리 : 입력을 순차적으로 처리하여 새로운 입력이 처리될 때 업데이트되는 숨겨진 상태를 유지합니다. 이 숨겨진 상태는 시퀀스의 이전 부분에 대한 정보를 캡처하는 메모리 역할을 한다. 2) 가중치 공유 : 모든 시간 단계에서 동일한 가중치가 사용되어 매개변수 수를 줄이고 RNN을 가변 길이 입력 시퀀스에 적합하게 만든다. 3) 시간을 통한 역전파 : RNN 훈련에는 오류가 시퀀스를 통해 역방향으로 전파되는 과정이 포함되며 전체 시퀀스를 기반으로 가중치를 업데이트하는데 사용된다.

제조에서 RNN은 센서에서 생성된 시계열 데이터를 통해 오류를 모니터링하고 예측하며, 생산 중 순차적 데이터 스트림의 패턴이나 이상 현상을 식별하는데 사용될 수 있다.




그림 2. RNN 구조
Fig. 2 RNN structure

2.3 GAN

GAN은 생성자와 판별자라는 두 개의 네트워크로 구성된 딥러닝 모델이다. 생성자는 실제 데이터와 유사한 가상의 데이터를 생성하고, 판별자는 생성된 데이터가 실제 데이터와 얼마나 유사한지를 판단한다.

두 네트워크가 서로 경쟁하며 학습을 진행하므로, 최종적으로 생성자는 실제와 유사한 데이터를 만들 수 있게 된다.

GAN은 다양한 분야에서 데이터 증강을 통해 성능을 향상하는 데 활용되고 있으며, 제조업에서 데이터가 부족한 상황에서 활용할 수 있는 강력한 도구로 주목받고 있다.

생성자는 랜덤 노이즈를 생성하는 벡터 z 를 입력으로 하고, 판별자가 판별하고자 하는 입력 프레스 데이터를 출력으로 하는 뉴럴 네트워크 유닛이다.

학습과정에서는 실제 프레스 데이터를 판별자로 하여금 진짜라고 학습시키는 과정과, 벡터 z 와 생성자에 의해 생성된 fake 프레스 데이터를 가짜라고 학습시키는 두개의 과정으로 나뉜다.

여기서 판별자는 이 두번의 과정을 따로 학습하는 것이 아닌, 첫번째 과정에서의 Real 프레스 데이터와 Fake 프레스 데이터를 판별자의 입력으로 합쳐서 학습한다.

아래의 그림 3은 GAN의 프레스 데이터 학습 방법을 보여주고 있다. 학습 초기에는 생성된 데이터의 분포는 실제 데이터의 분포와 차이가 크며 판별기 또한 부분적으로 정확한 판별을 시행한다.

학습이 진행되며 생성된 데이터의 분포는 실제 데이터의 분포와 유사해지도록 학습되며 학습이 충분히 이루어진 상황에서는 판별기가 실제 데이터와 생성된 데이터를 구분하지 못하는 상태로 학습된다.

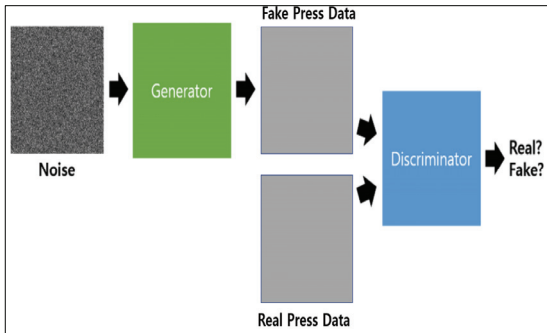


그림 3. GAN의 프레스 데이터 학습 방법
Fig. 3 GAN's Press Data Learning Method

GAN는 제한된 프레스 공정의 실제 결합 데이터를 보완하기 위해 합성 데이터를 세트로 생성하고 까다로운 엡지 케이스를 생성하여 결합 감지 모델의 강건성을 향상시킨다. 또한 이상 탐지 프레임워크로 훈련 데이터에 존재하지 않는 미묘한 결함을 식별하는데 사용된다.

2.4 DCGAN

DCGAN는 GAN을 확장한 모델로, CNN을 사용해 생성자와 판별자 네트워크를 구성하여 이미지 생성의 성능을 크게 향상시킨 모델이다. 2015년 Radford, Metz, Chintala에 의해 제안되었다.

DCGAN은 기존 GAN 모델의 문제점을 개선하기 위해 몇 가지 핵심적인 아키텍처 설계를 도입했다. 특히 CNN을 사용하여 이미지 데이터를 효율적으로 학습할 수 있도록 구조를 변경했으며, DCGAN의 주요 특징은 다음과 같다.

1) CNN기반의 아키텍처

: DCGAN은 전통적인 GAN과 달리, 완전 연결층 대신 합성곱층과 전치 합성곱층을 사용한다.

2) 배치 정규화

: DCGAN은 생성자와 판별자에 배치 정규화를 적용하여 학습 안정성을 높였다. 배치 정규화는 각 층의 출력을 정규화해 입력 값의 분포를 일정하게 유지함으로써, 학습 속도를 높이고 기울기 소실 문제를 완화한다.

3) 완전 연결층 제거

: DCGAN은 전통적인 GAN 구조의 완전 연결층을 제거하고, 대신 전체 네트워크를 합성곱층으로만 구성했다. 이로 인해 모델이 더 깊어지면서도 효율적으로

학습이 가능. 또한, 완전 연결층의 파라미터 수가 줄어 모델의 복잡도도 감소하게 된다.

4) 리키렐루와 하이퍼볼릭탄젠트 활성화 함수

: DCGAN은 판별자 네트워크의 은닉층에서 리키렐루 활성화 함수를 사용하고, 생성자의 출력층에서는 하이퍼볼릭탄젠트 활성화 함수를 사용한다. 리키렐루는 렐루의 변형으로, 음수 값의 기울기를 약간 허용함으로써 기울기 소실 문제를 줄이는 데 도움을 준다. 또한, 하이퍼볼릭탄젠트 함수는 생성자의 출력을 -1에서 1 사이로 스케일링해 이미지 생성에 유리한 분포를 제공한다.

III. 실험 환경

본 연구는 GAN 모델 학습과 대규모 프레스 데이터 처리의 높은 계산 요구를 충족시키기 위해 고성능 컴퓨팅 시스템에서 수행되었으며, GPU는 GAN 모델의 병렬 처리와 깊이 있는 학습을 가속화하는 데 사용되었다.

모델 구현과 데이터 처리는 파이썬 언어로 수행되었으며, 파이토치는 GAN의 유연한 구성과 맞춤형 네트워크 구조 설정에 용이하여 선택하였다. CUDA와 cuDNN은 GPU 성능을 최적화하여 모델 학습 시간을 단축하였다.

연구에 사용된 프레스 데이터는 공장 생산 공정에서 수집된 것으로, 각 생산품의 품질 관련 주요 측정값을 포함하고 있다. 각 데이터 포인트는 다음과 같은 변수들로 구성된다.

총 데이터 수 : 약 50,000개
특성 : 공정 중 수집된 압력, 온도, 속도, 기계 상태 등의 센서 데이터
레이블 : 양품(비불량)과 불량 여부를 나타내는 이진 레이블 (0=불량, 1=비불량)
데이터 분할 : 학습 데이터 70%, 검증 데이터 15%, 테스트 데이터 15%

불량 데이터의 비율이 적은 편이기 때문에, 데이터 불균형 문제를 해결하기 위해 데이터 증강 기법을 활용하였다. GAN을 이용해 증강된 프레스 데이터는 학습 데이터셋에 추가하여 품질 예측 모델 학습에 사용

되었으며, 데이터 전처리는 결측값 처리와 정규화를 포함하여 모델 학습에 적합하게 조정하였다.

3.1 품질 예측 모델 구성

품질 예측을 위해 딥러닝 모델을 구축하고, GAN으로 증강된 데이터가 포함된 학습 데이터로 모델을 훈련시킨다. 품질 예측 모델의 성능을 평가하기 위해 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 점수 등의 평가 지표를 사용하여 모델의 성능을 비교한다.

본 연구에서는 GAN을 활용해 프레스 데이터의 특성에 맞는 새로운 데이터를 생성했다.

프레스 데이터의 품질을 예측하기 위해 CNN 기반의 품질 예측 모델을 사용했다. GAN을 통해 생성된 데이터와 실제 데이터를 포함해 학습시켰으며, 하이퍼 파라미터 설정은 다음과 같다.

- 배치 크기: 64
- 학습률: 0.0002 (GAN과 CNN 모델 모두 동일하게 설정)
- 에포크 100 (조기 종료 기법을 사용하여 검증 손실이 10 에포크 동안 개선되지 않으면 학습을 중지)
- 최적화 함수: Adam (파라미터 $\beta_1=0.5$, $\beta_2=0.999$)

위와 같은 구성으로 실험 환경을 설정하여 GAN 기반의 데이터 증강과 품질 예측 모델 성능을 분석했으며, GAN이 생성한 프레스 데이터와 품질 예측 모델의 성능을 평가하기 위해 다음의 평가 지표를 사용하였다.

- 정확도: 테스트 데이터셋에 대한 전반적인 예측 정확도
- 재현율: 양품 및 불량 판별의 성능을 세부적으로 평가
- F1 스코어: 불균형 데이터의 특성을 고려한 정밀도와 재현율의 조화 평균
- ROC-AUC: 품질 예측 모델의 양품/불량 판별 능력을 평가하는 곡선 아래 면적(AUC)을 사용하여 성능을 측정

IV. 결 과

각 모델의 성능 지표를 시각화하여, DCGAN이 데이터 증강에 미치는 효과를 확인할 수 있었다.

그림 4에서와 같이 SVM(Support Vector Machine) 모델과 다중 회귀 모델을 학습하고, DCGAN으로 증강된 데이터를 포함했을 때와 포함하지 않았을 때의 성능을 비교하였다. 각 모델의 예측 성능을 평가하고, 성능 지표(예: R^2 , RMSE 등)를 그래프로 모니터링하여 DCGAN이 데이터 증강을 통해 성능 향상에 미치는 영향을 확인할 수 있었다.




그림 4. DCGAN : SVM과 다중회귀분석

Fig. 4 Comparison of SVM and Multiple Regression Models with and without DCGAN-Augmented Data




그림 5. DCGAN : CNN 모델

Fig. 5 Performance Comparison of CNN Models with and without DCGAN-Augmented Data

그림 5는 CNN 모델에 DCGAN을 통한 데이터 증강을 적용했을 때와 적용하지 않았을 때의 성능을 비교하는 그래프이다. 각 성능 지표(정확도, 정밀도, 재

현율, F1 스코어, ROC-AUC)에서 두 모델 간의 차이를 확인할 수 있다. 이 결과는 DCGAN을 적용했을 때 프레스 데이터의 품질 예측 작업에서 효과적이라는 점을 보여주고 있으며, 예측 성능 향상에 유리하다는 것을 확인할 수 있다.

실험 결과를 통해 DCGAN을 활용한 데이터 증강은 프레스 공정의 품질 예측 모델 성능을 전반적으로 개선하였으며, 특히 데이터 불균형 문제를 효과적으로 해결하는 데 기여할 수 있다. 이러한 결과는 제조업 분야에서 데이터 부족 문제를 극복하고 품질 관리 시스템의 성능을 강화하는 데 있어 GAN 기반 접근법의 잠재력을 보여준다. 향후 연구에서는 다양한 GAN 아키텍처와 다른 머신러닝 알고리즘을 조합하여 성능을 더욱 개선하고, 실제 제조 환경에서 적용 가능성을 검증하는 것이 필요하다.

V. 결 론

본 연구의 결과는 GAN을 통해 생성된 프레스 데이터가 품질 예측 모델의 성능을 크게 향상할 수 있음을 보여준다. 특히 소량의 불량 데이터로도 품질 예측의 정확도를 유지할 수 있는 가능성을 제시하며, 이는 공정 중 품질 관리와 결함 예방에 큰 기여를 할 수 있다. 실험 결과를 통해, GAN으로 증강된 데이터가 품질 예측 성능에 미친 긍정적인 영향을 확인할 수 있었으며, 이는 제조업 현장에서 실제 적용 가능성을 높이는 중요한 결과라 할 수 있다.

이러한 접근법은 제조업에서의 데이터 부족 문제를 해결하고, 품질 예측 성능을 향상하는 데 기여할 수 있다. 향후 연구에서는 다양한 GAN 변형 모델의 추가적인 적용 및 다른 품질 데이터와의 융합을 통한 예측 성능 개선을 목표로 한다.

ACKNOWLEDGEMENTS

This study was supported by research fund from Honam University, 2024

References

- [1] J. Wang, C. Xu, J. Zhang and R. Zhang, "Big data analytics for intelligent manufacturing systems: A review," *J. of Manufacturing Systems*, vol. 62,, Jan. 2022, pp. 738-752. <https://doi.org/10.1016/j.jmsy.2021.03.005>
- [2] G. Duan and X. Yan, "A Real-Time Quality Control System Based on Manufacturing Process Data," *IEEE Access*, vol. 8, Nov. 2020, pp. 208506-208517. <https://doi.org/10.1109/ACCESS.2020.3038394>
- [3] C. Woong, "Development of Domestic Standardization in Smart Factory and Manufacturing Data," *The J. of The Korea Institute of Electronic Communication Sciences*, vol. 16, no. 5, 2021, pp. 783-788. <https://doi.org/10.13067/JKIECS.2021.16.5.783>
- [4] H. Sim, S. Choi and H. Kim, "Algorithm improvement through AI-based casting process parameter optimization," *The J. of The Korea Institute of Electronic Communication Sciences*, vol. 18, no. 3, 2021, pp. 441-448. <https://doi.org/10.13067/JKIECS.2023.18.3.441>
- [5] J. Choi and Y. Shin, "Model for Quality Assessment of Data Analytics Software in Manufacturing-Based IIoT Environments," *The J. of The Korea Institute of Electronic Communication Sciences*, vol. 14, no. 4, 2021, pp. 295-299. <https://doi.org/10.17661/jkiiect.2021.14.4.292>
- [6] S. Arora, R. Ge, Y. Liang, T. Ma and Y. Zhang, "Generalization and Equilibrium in Generative Adversarial Nets (GANs)," *Proceedings of the 34th International Conference on Machine Learning*, vol. 70, 2017, pp. 224-232. <https://arxiv.org/abs/1703.00573>
- [7] A. Xiao, J. Huang, D. Guan, X. Zhang, S. Lu and L. Shao, "Unsupervised Point Cloud Representation Learning With Deep Neural Networks: A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 9, 2023, pp. 11321-11339. <https://doi.org/10.1109/TPAMI.2023.3262786>
- [8] H. Khosravi, S. Farhadpour, M. Grandhi, A. Raihan, S. Das and I. Ahmed, "Strategic Data Augmentation with CTGAN for Smart

- Manufacturing: Enhancing Machine Learning Predictions of Paper Breaks in Pulp-and-Paper Production,” *Computer Science*, 2023, pp. 1-19.
<https://doi.org/10.48550/arXiv.2311.09333>
- [9] X. He, Z. Luo, Q. Li, H. Chen and F. Li, “DG-GAN: A High Quality Defect Image Generation Method for Defect Detection,” *Sensors*, vol. 23, no. 13, 2023, pp. 1-19.
<https://doi.org/10.3390/s23135922>
- [10] P. Lyu, H. Zhang, W. Yu and C. Liu, “A novel model-independent data augmentation method for fault diagnosis in smart manufacturing,” *Procedia CIRP*, vol. 107, 2022, pp. 949-954.
<https://doi.org/10.1016/j.procir.2022.05.090>
- [11] Y. Tang, C. Liu and X. Zhang, “Single image super-resolution using Wasserstein generative adversarial network with gradient penalty,” *Pattern Recognition Letters*, vol. 163, 2022, pp. 32-39.
<https://doi.org/10.1016/j.patrec.2022.09.012>

저자 소개



강미영(Mi-Young Kang)

2003년 전남대학교 대학원 정보통신공학과 졸업(공학석사)

2008년 전남대학교 대학원 컴퓨터 정보통신공학과 졸업(공학박사)

2008년~2010년 전남대학교 PostDoc.

2021년~현재 호남대학교 정보통신공학과 교수

2023년~현재 광주시 과학기술진흥위원회 위원

2023년~현재 광주시 도시공사 소프트웨어 사업

과업심의위원회 위원

※ 관심분야 : 임베디드 시스템, 인공지능,
스마트팩토리

