

논문 2022-17-17

소량 데이터 딥러닝 기반 강판 표면 결함 검출 시스템 개발

(Development of a Steel Plate Surface Defect Detection System Based on Small Data Deep Learning)

게이블라예프 압둘라지즈, 이 나 현, 이 기 환, 김 태 형*
(Abdulaziz Gaybulayev, Na-Hyeon Lee, Ki-Hwan Lee, Tae-Hyong Kim)

Abstract : Collecting and labeling sufficient training data, which is essential to deep learning-based visual inspection, is difficult for manufacturers to perform because it is very expensive. This paper presents a steel plate surface defect detection system with industrial-grade detection performance by training a small amount of steel plate surface images consisting of labeled and non-labeled data. To overcome the problem of lack of training data, we propose two data augmentation techniques: program-based augmentation, which generates defect images in a geometric way, and generative model-based augmentation, which learns the distribution of labeled data. We also propose a 4-step semi-supervised learning using pseudo labels and consistency training with fixed-size augmentation in order to utilize unlabeled data for training. The proposed technique obtained about 99% defect detection performance for four defect types by using 100 real images including labeled and unlabeled data.

Keywords : Steel plate, Defect detection, Deep learning, Data augmentation, Semi-supervised learning

1. 서 론

최근 인공지능 기술의 발달과 함께 제조 기술이 다양한 영역에서 발전하고 있는데 제품 생산과 직결되는 품질관리 영역에서는 제조 공정상의 이상 작동 상황 발생을 탐지하는 이상 탐지 기술과 제품의 품질 이상을 탐지하는 결함 검출 기술이 활발히 연구되고 있다. 이중 비약적인 성능 향상을 보여 주고 있는 딥러닝 기반의 영상 분석 기술을 이용한 제품의 결함 검출 기술은 상용화를 통해 실제 제조업 현장에 도입되고 있다. 그러나, 딥러닝 기술 기반의 결함 검사를 도입하여 실제 라인에 적용하기 위해서는 적지 않은 준비 과정이 필요하다. 먼저 선명한 제품 이미지를 얻기 위해 전문적인 조명 및 다중 카메라 등 고성능 머신 비전 장비의 설치가 요구된다. 또한 딥러닝 학습을 위해 다수의 정상 제품 이미지와 결함 유형 별 제품 이미지가 필요하다. 더욱이 우수한 검출 성능을 확보하려면 지도 학습이 필요한데 이를 위해 결함 제품 이미지에 결함 종류 및 위치 정보를 표시하는 라벨링을 수행해야 한다. 이후에는 고가의 GPU가 장착된 고성능 컴퓨터에서 장시간 학습이 필요하고, 시험을 통해 검출 성능이 만족스럽지 않으면 이 과정을 추가로 반복 진행해야 한다. 이와 같은 과정을 수행하기 위해 필요한 비용과 전문 인력은 다수 중소 제조업체에 큰 부담이 될 수 있다.

이렇게 학습에 많은 데이터와 비용을 요구하는 딥러닝 기술의 문제점을 극복하기 위해 다양한 연구가 이루어지고 있다. 학습데이터가 부족할 경우, 데이터를 효과적으로 증가시켜 주는 데이터 증강 (data augmentation) 기술 [1]과 소량의 데이터로도 학습을 수행할 수 있게 하는 퓨샷 학습 (few-shot learning) 기술 [2]을 활용할 수 있다. 학습 시간 비용을 줄이기 위해서는 대량의 유사 데이터로 사전 학습된 모델을 목표 도메인의 데이터 학습에 활용하는 전이 학습 (transfer learning) [3] 또는 도메인 적응 (domain adaptation) 기술 [4]을 시도할 수 있다. 또한 학습데이터의 라벨링 비용을 줄이기 위해 라벨링이 필요치 않은 비지도 학습 (unsupervised learning) [5]과 자기지도 학습 (self-supervised learning) [6], 라벨 데이터를 일부만 사용하는 준지도 학습 (semi-supervised learning) [7]을 고려할 수 있다. 그런데 퓨샷 학습, 도메인 적응, 자기 지도 학습 등의 기술은 아직 연구 초기 단계로 산업에서 요구하는 수준의 정확도를 제공하기 어려운 실정이다.

본 연구는 강판 제조과정에서 발생할 수 있는 다양한 종류의 표면 결함을, 적용 업체의 부담을 최소화하면서도 현장에 적용할 수 있는 높은 수준의 정확도로 검출할 수 있는 딥러닝 기반 결함 검출 시스템을 개발하는 것을 목표로 한다. 이를 위해 소량의 학습데이터와 라벨 데이터를 사용하는 데이터 증강 기법과 준지도 학습 기법을 제안한다. 또한 높은 결함 검출 성능을 가지면서도 저비용의 임베디드 시스템 개발 보드 상에서 운용할 수 있도록 최적의 결함 검출 모델을 설계한다.

본 논문은 다음과 같이 구성된다. II절에서 본 연구의 주요 기술에 대해 최근 연구 동향을 소개한 다음, III절에서 제

*Corresponding Author (taehyong@kumoh.ac.kr)

Received: Mar. 30, 2022, Revised: Apr. 17, 2022, Accepted: Apr. 19, 2022.
A. Gaybulayev: Kumoh Nat'l Institute of Technology (Ph.D. Student)
N.H. Lee: Kumoh Nat'l Institute of Technology (B.E. Student)
K.H. Lee: Kumoh Nat'l Institute of Technology (M.E. Student)
T.H. Kim: Kumoh Nat'l Institute of Technology (Prof.)

※ This paper was supported by Research Fund, Kumoh National Institute of Technology (2019-104-059).

안 기법의 전체 구조 및 세부 내용을 설명한다. IV절에서 제안 기법의 구현 방법과 과정을 설명하고 V절에서 성능 평가 결과를 고찰한 후 VI절에서 결론을 맺는다.

II. 관련 연구

본 절에서는 본 연구의 주요 연구 분야인 소량 데이터 기반 학습, 비라벨 데이터 학습 및 강판 불량 검출 기술에 관해 최근 연구 동향을 소개하고 제조 현장에서의 사용 가능성 등을 검토한다.

1. 소량 데이터 기반 학습

소량 데이터 기반 학습 기술은 크게 소량 데이터를 변환시켜 학습에 필요한 양의 데이터를 얻는 데이터 증강 기술과 소량 데이터만을 학습에 사용하는 퓨샷 학습 기술로 나눌 수 있다.

데이터 증강 기술은 크게 영상처리 기반의 증강 기법과 생성 모델 기반 증강 기법으로 분류될 수 있다. 전통적인 영상처리 기반 증강 기법으로는 뒤집기 (flip), 회전하기 (rotate) 등의 공간 수준 변형과 흐리게 하기 (blur), 밝기 조절 등의 픽셀 수준 변형이 있다. 최근에는 학습 이미지의 일부분을 무작위로 가리는 컷아웃 (cut-out) [8], 서로 다른 클래스에 해당하는 데이터를 하나로 섞는 믹스업 (mix-up) [9], 다수의 이미지를 하나로 합치는 모자이크 (mosaic) [10], 한 이미지의 객체를 다른 이미지에 붙여 넣는 복사-붙여넣기 (copy-paste) [11] 등의 증강 기법이 객체 인식 및 의미 분할 (semantic segmentation) 등의 컴퓨터 비전 작업에서 좋은 성능을 보여주고 있다. VAE (Variational Auto-Encoder)나 GAN (Generative Adversarial Networks)과 같은 생성 모델을 기반으로 하는 증강 기법 [12]은 보유 데이터의 분포를 학습하여 동일 분포 내의 새로운 데이터를 생성한다. DAGAN (Data Augmentation GAN)은 실제 이미지를 2개 사용하여 생성 이미지가 실제 이미지 사이의 차이만큼 다른 분포를 갖도록 설계되었다 [13]. f-CLSWGAN은 WGAN (Wasserstein GAN) [14]에 클래스 임베딩을 사용하여 식별기 (discriminator)가 임베딩 및 라벨 수준 각각에서 생성 이미지의 클래스를 구분하도록 하였다 [15].

퓨샷 학습 기술은 매우 적은 수의 학습데이터를 통해 객체의 특징을 학습하는 기술로 데이터 증강 방법을 학습하는 환영 (hallucination) 기반 기법과 학습하는 방법을 학습하는 메타 학습 (meta-learning) 기반 기법 및 비교 방법을 학습하는 메트릭 학습 (metric-learning) 기반 기법으로 나눌 수 있다 [16]. 앞서 살펴 본 GAN 기반의 데이터 증강 기술은 퓨샷 학습 환경에 적용될 경우 환영 기반의 퓨샷 학습 기술로 분류될 수도 있다. 메타 학습 및 메트릭 학습 기반 퓨샷 학습 기법은 아직 연구 초기 단계로 주로 분류 (classification) 작업에 적용되는 수준이어서 아직 고성능이 요구되는 제조 현장에 적용되기 어려운 실정이다.

2. 비라벨 데이터 학습

데이터 학습에 정답 라벨을 사용하지 않거나 적게 사용하기 위해 비지도학습 (unsupervised learning), 준지도학습 (semi-supervised learning) 및 자기지도학습 (self-supervised learning) 등을 고려할 수 있다. 비지도학습은 학습 데이터 외에 학습에 추가로 활용할 정보가 없으므로 전통적으로 군집화 (clustering), 임베딩 (embedding), 차원 축소 (dimensionality reduction), 이상 탐지 (anomaly detection) 등의 목적으로 활용되어 왔다. 스스로 라벨을 만들어 비지도학습을 수행하는 경우 자기지도학습이라고 부를 수 있다. 자기지도학습은 보통 데이터셋에 어떤 라벨을 부여하고 명목 작업 (pretext task)을 수행하여 다른 작업에도 쉽게 적용될 수 있는 유용한 특징 표현을 학습하고, 이 사전 학습된 네트워크를 실제 작업에 대해 미세조정 학습 (fine-tuning)을 하는 방식으로 진행된다. 명목 작업으로는 이미지를 직소 퍼즐 형식으로 조각내고 뒤섞어 특정 조각의 위치를 찾는 작업 [17], 이미지를 90도 간격으로 회전하고 회전된 이미지의 각도를 찾는 작업 [18] 등이 시도되었다. 라벨을 사용하지 않는 순수 자기지도학습은 주로 이미지 분류에 적용되어 왔으나, 최근 객체 검출에 적용된 사례 [19]가 일부 등장하고 있다. 하지만, 자기지도학습 기반 모델의 객체 검출 성능은 지도학습 기반 모델의 성능보다 아직 많이 뒤처지므로 산업 분야에 활용하기에는 무리가 있다.

준지도학습은 라벨 데이터와 비라벨 데이터를 모두 사용하는 학습 방법으로 일부 데이터만 라벨 정보가 있을 경우 사용할 수 있다. 가장 기본적인 준지도학습 방법인 유사 라벨 (pseudo-labels)은 라벨 데이터를 이용해 사전 학습된 모델을 통해 비라벨 데이터를 추론하고 이 결과를 비라벨 데이터의 라벨로 지정하는 방법이다 [20]. 추론에 사용된 모델 성능이 양호하다면 유사 라벨 또한 신뢰할 수 있으므로 이를 지도학습에 다시 활용할 경우 추가로 성능 향상을 기대할 수 있다. π -모델 [21]은 학습 이미지를 증강하고 원래 이미지와 증강된 이미지 사이의 일관성을 추가 손실함수로 사용하여 분류 모델을 학습하는 방법인데 이후 객체 검출 분야에도 적용되었다 [22]. π -모델은 교사 및 학생 모델을 사용하는 Mean Teacher [23], 최신 증강기법을 적용한 UDA [24], 유사라벨과 샤프닝 (sharpening)을 사용한 MixMatch [25] 등으로 발전되었으나 모두 이미지 분류를 목적으로 하고 이미지 증강과 일관성 손실에 기반을 둔다는 점에서 차별성은 크지 않다. 최근에는 이미지 크기를 변경하고 이들 간에 일관성 손실을 적용하는 기법 [26] 등 객체 검출을 위한 준지도학습 기법에 대한 연구도 계속되고 있다. 준지도학습은 객체 검출 목적으로 사용가능하고 라벨 데이터 학습을 통한 기본 성능 확보와 비라벨 데이터 학습을 통한 추가 성능 향상을 기대할 수 있어 제조업 현장에서의 도입 가능성이 높다.

3. 강판 표면 결함 검출

철강 제품의 한 종류인 강판은 철로 만든 판으로 차량이나

선박, 가전제품 및 건축용도로 많이 쓰이고 있다. 보통 대량 생산 방식으로 제조하기 때문에 강판 표면에 발생하는 결함에 대한 검출 자동화가 필수적이다. 강판 표면 결함 검출은 고성능 머신 비전 카메라를 통해 강판 이미지를 획득하고 이를 분석하는 방식으로 이루어진다. 정상적인 강판 표면은 비교적 매끈하고 균질하기 때문에 결함 검출이 용이한 환경이라고 볼 수 있지만 영상 획득을 위한 조명 설치로 인해 표면 반사가 생기는 경우, 결함의 크기가 매우 작을 경우, 다양한 종류의 결함을 구분해야 할 경우 등의 환경 조건에 따라 검출 난이도가 높아질 수 있다. 또한 양질의 학습 데이터 획득에 필요한 조명 및 카메라를 설치하기 위해서는 제조 라인을 정지시켜야 하는 한편, 획득한 대량의 이미지에 대해 수작업으로 라벨링을 수행해야 하는 부담이 있다.

강판 표면의 결함 탐지를 위해 전통적인 이미지 필터링부터 최신 딥러닝 기술까지 다양한 방법이 시도되었다. Fang Guo 외 2인은 인간의 시각적 집중 방식의 분석을 바탕으로 Gaussian 및 Gabor 필터 등을 이용해 결함을 표시하는 특징 맵 (saliency map) 생성 기법을 제시하였다 [27]. Shuai Wang 외 3인은 ResNet [28]과 faster-RCNN [29]을 결합한 강판 결함 검출 및 분류 기법을 제시하였고 [30], Didarul Amin 외 1인 및 Praveen Damacharla 외 3인은 각각 Deep Residual U-NET [31]과 전이학습 기반 U-Net [32]을 이용하여 영상 분할 방식으로 결함을 검출하는 기법을 제시하였다. 최근에는 쌍둥이 (Siamese) 네트워크를 이용하여 추출한 비 유사도 (dissimilarity score)를 이용해 결함 여부를 파악하는 기법 [33], 지도학습과 약지도학습 (weakly supervised learning)을 결합하여 이상 탐지 방식으로 결함을 검출하는 기법 [34] 등 적은 학습 데이터를 가지고 강판 표면 결함 검출을 시도하는 연구가 등장하고 있다.

III. 제안 기법

본 절에서는 제조 현장에서 수집해야 할 학습 데이터와 수작업으로 진행해야 할 라벨링을 최소화하면서도 우수한 강판 표면 결함 검출 성능을 가진 딥러닝 학습 기법을 제안한다.

1. 전체 구조

적은 수의 학습 데이터와 라벨 데이터를 가지고 높은 검출 성능을 확보하기 위해서는 성능 향상에 필요한 기법들을 잘 선별하여 최적화해야 한다. 먼저 부족한 학습 데이터를 보충하기 위해서는 데이터 증강의 활용이 필수적이다. 전통적인 영상처리 기반의 증강 기법은 생성 데이터의 분포가 제한적이어서 대량의 증강 데이터로만 학습할 경우 특정 데이터에 의존적인 과적합이 발생할 가능성이 높다. 따라서 본 연구에서는 정상 제품 데이터에 기하학적 방식으로 결함을 생성해 붙여 넣는 프로그램 기반 증강 기법과 라벨 데이터의 결함 분포를 학습하는 생성 모델 기반 증강 기법을 사용한다. 이들 증강 기법을 통해 생성된 데이터는 최신 딥러닝 객체 검출 모델을 사전 학습하는데 사용된다.

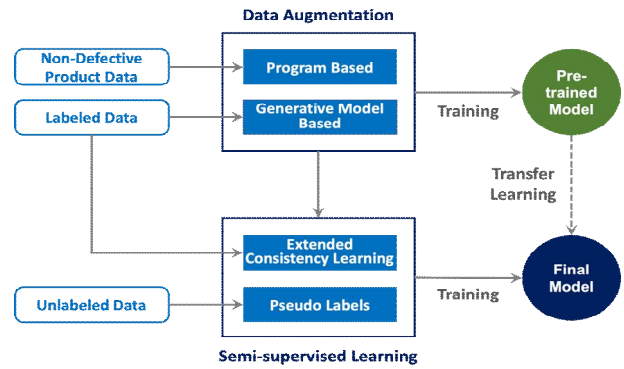


그림 1. 제안하는 기법의 전체 구조
Fig. 1. Overall Structure of the Proposed Method

다음으로 주어진 소량의 라벨데이터와 비라벨데이터는 준지도 학습에 사용된다. 준지도 학습기술로는 뒤집기를 이용해 라벨 데이터를 증강시키고 원 데이터와 증강 데이터 간의 일관성 오차를 기반으로 학습하는 기존의 방법 [22]을 활용하되 증강 방식을 늘려 일관성 학습의 범위를 확장하였다. 또한 비라벨데이터에 대해서는 전통적인 유사 라벨 기법을 사용하여 라벨데이터 수를 증가시키고 이를 이용한 추가 학습으로 성능 향상을 얻도록 하였다. 제안하는 학습 기법의 전체 구조는 그림 1에 도시한 바와 같다.

2. 데이터 증강

강판 표면 결함 이미지의 증강을 위해 먼저 증강 대상 결함 유형을 결정해야 한다. 강판 표면 결함은 긁힘 (scratch), 균열 (craze), 패임 (pit), 오염 (stain), 부식 (rust), 백점 (white spot), 흑점 (black spots) 등 강판 특성 및 제조 환경에 따라 다양한 형태로 나타날 수 있다. 본 연구에서는 비교적 작은 크기의 결함이라 할 수 있는 흑점, 백점, 오염, 긁힘의 4가지 유형을 대상으로 한다.

프로그램 기반의 결함 생성 방법은 다음과 같다. 수집한 데이터 중 임의의 정상 강판 이미지를 불러와 임의의 위치를 선택하고 그 위치에 어울리는 밝기로 각 유형의 결함을 기하학적으로 생성한다. 먼저 흑점과 백점은 각각 검은색과 흰색의 원형 점을 가우시안 분포의 농도로 만들되 가로 세로의 폭을 임의로 조정하고 노이즈를 추가하여 실제 결함과 유사한 이미지를 생성한다. 긁힘 결함은 베지에 (Bézier) 곡선을 기반으로 생성하되 커브의 길이, 각도, 농도 등은 배경의 밝기를 고려하여 임의로 생성한다. 오염 유형의 결함은 비정형 모양의 얼룩 형태를 모사하여 임의의 가우시안 분포 모양을 여러 개 생성하여 혼합하는 방식을 사용하였다. 이 증강 방식에서는 결함의 크기와 생성 위치를 생성 프로그램에서 결정하기 때문에 결함 종류와 위치에 대한 라벨을 자동으로 생성할 수 있다.

생성모델 기반의 결함 생성 방법은 생성 과정을 자동화하고 자연스러운 이미지를 생성하기 위해 다소 복잡한 절차로 수행된다. 생성하는 결함 이미지의 라벨 정보를 자동으로 생성하기 위해서는 학습에 사용되는 전체 이미지 대신 결함 영

역의 이미지를 생성 모델에 입력해야 한다. 그런데 생성 모델은 입력 이미지 전체의 분포를 학습하기 때문에 결함 영역에 있는 결함 뿐 아니라 배경의 분포도 학습하여 이미지를 생성하게 된다. 이렇게 생성된 이미지를 정상 이미지에 붙여 넣을 경우 결함 영역의 배경과 정상 이미지의 배경이 자연스럽게 연결되지 않아 학습 이미지로 사용하기 어렵게 된다. 이러한 문제를 해결하기 위해서는 결함 영역의 배경을 먼저 제거한 후 결함 부분만을 생성 모델에 입력하여야 한다.

주어진 소량의 라벨 데이터는 결함 부분에 대한 경계상자 (bounding box) 정보를 갖는다. 먼저 경계상자 영역 즉, 결함 영역 이미지에 대해 결함 부분과 배경 부분을 구분해주는 결함 분할 맵 (segmentation map)을 작성한다. 다음으로 각 결함에 대해 결함 영역 이미지를 입력받아 결함 분할 맵을 출력하는 의미 분할 모델을 학습한다. 학습된 모델은 결함 영역 이미지로부터 배경이 없는 결함만을 추출해 줄 수 있는 분할 맵을 생성하게 된다.

각 결함 영역 이미지에 대해 의미 분할 모델을 이용해 배경이 없는 결함 이미지들이 생성되면 이를 GAN 기반 데이터 생성 모델에 입력하여 결함 데이터의 분포를 학습한다. 본 연구에서는 실제 이미지와 유사하면서도 동일하지는 않은 결함 이미지를 생성하기 위해 DAGAN [13]을 자체적으로 개선한 f-DAGAN (feature-based DAGAN)을 데이터 생성 모델로 사용한다. f-DAGAN의 구조는 그림 2와 같이 DAGAN과 동일하게 2장의 실제 이미지 x_i 와 x_j 를 이용해 분포를 학습하되 생성 이미지 x_g 수준뿐 아니라 중간 특징 벡터 v_z 수준에서 각각 판별자 (discriminator) D_2 및 D_1 학습을 수행하여 보다 더 자연스러운 이미지를 생성하게 된다. f-DAGAN의 목적함수는 아래와 같다.

$$E_{v_i, v_j} [\log(D_1(v_i || v_j))] + E_{x_i, x_j} [\log(D_2(x_i || x_j))] + E_{z, v_i} [\log(1 - D_1(\text{avg}(G'(z), v_i) || v_i))] + E_{z, x_i} [\log(1 - D_2(G(z) || x_i))]$$

위 식에서 $v_i = \text{Enc}(x_i)$, $v_j = \text{Enc}(x_j)$ 이고 G' 는 G 의 전반부 네트워크로 $G'(z) = v_z$, $|G'(z)| = |v_i| = |v_j|$ 이며 $||$ 는 연결 (concatenation) 연산자이다.

결함 이미지가 생성되면 이를 결함이 없는 정상 강판 이미지에 붙여 넣어 최종 이미지를 완성한다. 그런데 f-DAGAN에 의해 생성된 결함은 학습 데이터의 분포에 따라 생성되기 때문에 다양한 농도로 나타날 수 있다. 따라서 결함을 임의의 위치에 붙여 넣게 되면 붙여 넣는 위치의 배경 농도와 어울리지 않을 경우 식별이 어렵거나 부자연스러운 결과를 얻을 수 있다. 이 문제를 해결하기 위해 결함에 어울리는 배경의 톤을 예측하는 분류 모델을 사용한다. 분류 모델은 실제 결함 영역 이미지를 이용해 배경을 제거한 결함 이미지를 입력받아 결함 배경의 평균 농도를 예측하도록 학습한다. 학습된 분류 모델에 f-DAGAN으로 생성한 결함 이미지를 입력하면 결함에 어울리는 적정 배경 농도를 얻을 수 있다.

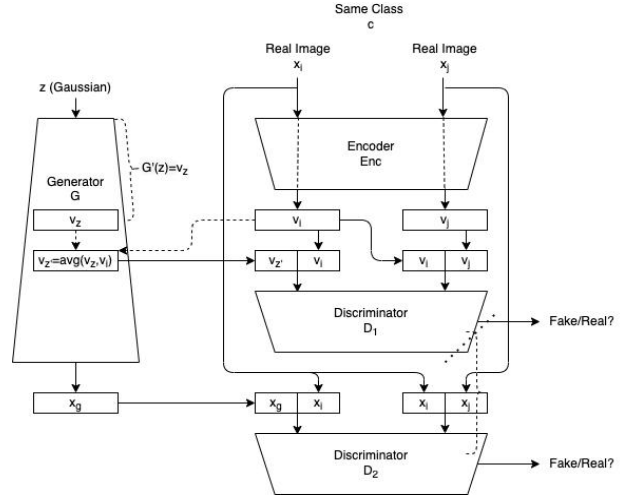


그림 2. f-DAGAN 네트워크 구조
Fig. 2. The f-DAGAN Network Structure

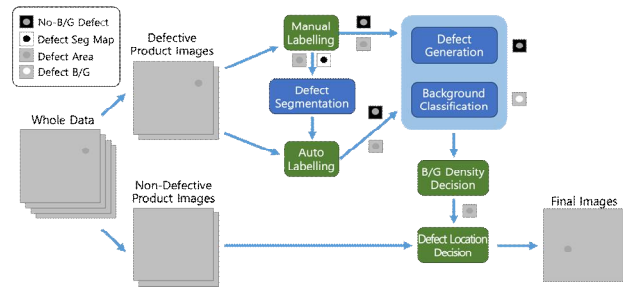


그림 3. 생성모델 기반 데이터 증강 과정
Fig. 3. Data Augmentation based on Generative Models

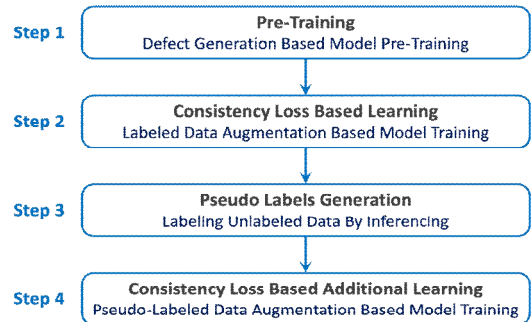


그림 4. 제안하는 준지도 학습 절차
Fig. 4. The Proposed Semi-Supervised Learning Procedure

정상 강판 이미지에서 붙여 넣을 위치를 결정할 때, 임의로 선택된 위치의 배경 농도가 분류 모델이 예측한 적정 배경 농도 범위에 있지 않을 경우 배경 농도 조건을 만족할 때까지 붙여 넣을 위치를 반복하여 찾게 된다. 생성 모델 기반의 강판 표면 결함 이미지 생성 과정은 그림 3과 같다.

3. 준지도 학습

강판 표면 결함 검출 준지도 학습 절차는 그림 4와 같이




그림 5. 라벨 데이터 일관성 손실 기반 학습
Fig. 5. Consistency Loss Based Training of Labeled Data




그림 6. 고정 크기 증강 기법 예
Fig. 6. Sample Fixed-Size Augmentation Methods

네 단계로 구성된다.

단계 1은 결함 생성 프로그램 또는 생성 모델을 이용해 가상의 결함 데이터를 생성하고 결함 검출 모델 학습을 수행하는 사전 학습 단계이고, 단계 2는 라벨 데이터를 증강하고 이를 이용해 결함 검출 모델을 추가로 학습하되 기존의 지도 손실에 추가로 일관성 손실을 이용하여 학습을 수행하는 단계이다. 단계 3은 단계 2까지 학습된 모델을 이용해 비라벨 데이터를 추론함으로써 유사 라벨을 생성하는 단계이고, 단계 4는 단계 3에서 얻어진 유사 라벨 데이터를 이용해 단계 2와 동일한 방식으로 추가 학습하는 단계이다.

그림 5는 단계 2와 단계 4의 학습 방법을 구체적으로 보여준다. 라벨 이미지 또는 가상 라벨 이미지에 대해 이미지 및 결함의 크기를 변경하지 않는 고정 크기 증강 기법으로 라벨 이미지를 증강한 후 라벨 이미지와 증강 라벨 이미지를 학습 데이터로 사용하여 결함 검출 학습을 진행한다. 단, 예측된 결함의 종류와 위치에 대한 기존의 지도 손실에 추가로 라벨 이미지 예측과 증강 라벨 이미지 예측 사이의 예측 결함 종류와 위치가 일치하는 지에 대한 일관성 손실을 사용하여 학습을 진행한다. 결함 종류에 대한 일관성 손실 ℓ_{con-t} 과 결함 위치에 대한 일관성 손실 ℓ_{con-l} 의 식은 아래와 같다.

$$\ell_{con-t} = E_k [l_{con-type}(f_{type}^k(I), f_{type}^k(\hat{I}))]$$

$$\ell_{con-l} = E_k [l_{con-loc}(f_{loc}^k(I), f_{loc}^k(\hat{I}))]$$

위 식에서 f_{type}^k 과 f_{loc}^k 는 각각 모델의 결함 k 에 대한 유형 및 위치 예측, I 와 \hat{I} 는 라벨 이미지와 고정 크기 증강 라벨 이미지, $l_{con-type}(f_a, f_b) = JS(f_a, f_b)$ 는 두 유형 예측 값 f_a 와 f_b 의 Jensen-Shannon divergence [35],

$l_{con-loc}(f_c, f_d)$ 는 두 경계상자 예측 f_c 와 f_d 의 시작점 x, y 좌표 및 가로, 세로 폭 차이의 제곱평균을 의미한다.

단계 3에서는 위 고정 크기 증강 기법을 적용하여 비라벨 이미지를 증강하고, 이를 원래의 비라벨 이미지와 함께 단계 2까지 학습된 모델에 입력한 후 결함의 종류와 위치를 예측한다. 각 예측에 부여되는 신뢰도 점수 (confidence score)가 특정 문턱 값을 넘는 경우, 해당 예측을 그 이미지의 유사 라벨로 부여한다.

그림 6은 단계 2~4에서 사용하는 고정 크기 증강 기법의 예시를 보여준다. 밝기 변경, 노이즈 추가, 대비 변경 등의 증강 방법은 이미지의 좌우 크기와 객체의 위치를 변경하지 않으며, 좌우 및 상하 뒤집기, 180도 회전 증강에서는 변경된 객체의 위치를 쉽게 계산할 수 있다. 이미지가 정사각형 형태일 경우 90도 및 270도 회전도 변형된 이미지의 크기가 동일하고 변경된 객체의 위치와 크기를 쉽게 알 수 있으므로 고정 크기 증강 기법으로 활용할 수 있다.

IV. 구현 방법

본 절에서는 데이터 수집부터 모델 구현, 학습 및 추론 관리 시스템 구축에 이르기까지 제안된 강판 표면 결함 검출 시스템의 세부적인 구현 방법에 대해 설명한다.

1. 데이터 수집 및 증강

강판 제조업체로부터 수집한 이미지는 총 500장으로 이중 100장을 학습용, 400장을 시험용으로 사용하였다. 학습용 이미지는 40장의 정상제품 이미지와 60장의 결함 제품 이미지로 구성된다. 결함 제품 이미지는 흑점, 백점, 긁힘, 오염의 네 가지 결함 유형에 대해 각각 15개씩의 이미지가 있는데 라벨 데이터와 비라벨 데이터가 대략 같은 수로 구성된다. 시험용 이미지는 네 가지 결함 유형에 대해 각각 100장의 이미지로 구성된다. 모든 이미지는 1280×1280 크기로 256 농도의 그레이스케일을 가진다. 검출하고자 하는 결함의 크기는 직경 2mm로 이미지에서 10~15 픽셀 정도를 차지하도록 설정해 촬영하였다. 학습의 각 단계에서 사용되는 이미지 수는 표 1에 정리되어 있다.

표 1. 각 학습 단계에 사용된 이미지 수
Table 1. The Number of Images Used in Each Training Stage

| | Normal | Black Spot | White Spot | Stain | Scratch |
|--------|--------|---------------------|---------------------|---------------------|---------------------|
| Step 1 | 40 | 10k (generated) | 10k (generated) | 10k (generated) | 10k (generated) |
| Step 2 | - | 8 (labeled) | 8 (labeled) | 7 (labeled) | 7 (labeled) |
| Step 3 | - | 7 (unlabeled) | 7 (unlabeled) | 8 (unlabeled) | 8 (unlabeled) |
| Step 4 | - | 40 (pseudo-labeled) | 40 (pseudo-labeled) | 40 (pseudo-labeled) | 40 (pseudo-labeled) |
| Test | - | 100 | 100 | 100 | 100 |




그림 7. 수집된 결함 이미지 샘플 (흑점, 백점, 오염, 긁힘)
Fig. 7. Sample Defect Images Collected (Black Spot, White Spot, Stain, Scratch)




그림 8. 프로그램 생성 결함 이미지 샘플 (흑점, 백점, 오염, 긁힘)
Fig. 8. Sample Defect Images Generated by the Program (Black Spot, White Spot, Stain, Scratch)




그림 9. 생성 모델 생성 결함 이미지 샘플 (흑점, 백점, 오염, 긁힘)
Fig. 9. Sample Defect Images Generated by the Generative Model (Black Spot, White Spot, Stain, Scratch)

단계 1에서는 프로그램 및 생성 모델 기반으로 각 결함에 대해 10,000장씩을 생성하여 사전 학습에 사용하였다. 생성 모델 기반 데이터 증강에서 결함 분할 모델로는 가장 널리 쓰이고 있는 DeepLabV3+ [36]를 사용하였고, 배경 농도 분류 모델로는 학습 특징을 중요도에 따라 재조정하여 우수한 성능을 보여주는 SE-Net [37]을 사용하였다. 수집된 결함 이미지 샘플과 프로그램 및 생성 모델 기반으로 생성한 결함 이미지 샘플은 각각 그림 7~9와 같다. 결함 유형은 좌측부터 흑점, 백점, 오염, 긁힘 순이다.

2. 모델 구현 및 학습

표면 결함 검출에 사용되는 강판은 일반적으로 폭이 1m에 이르는 대형 강판의 형태이기 때문에 강판 전체를 촬영하려면 고가의 고해상도 머신비전 카메라를 사용하거나 여러 대의 머신비전 카메라로 분할 촬영을 해야 한다. 또한 컨베이어 시스템이나 로봇에 의해 강판이 계속 이동되는 환경이므로 제조 공정에 지장을 주지 않기 위해서는 검출 시간을 최소화해야 한다. 본 연구에서는 분할 촬영 환경에서 한 대의 머신비전 카메라가 1280×1280 크기로 촬영하는 설정으로 결함 검출 시스템을 구현하였다. 우수한 결함 검출 성능을 가지면서도 검출 속도가 빠른 객체 검출 모델을 기반 모델(base model)로 선정하기 위해 다양한 최신 모델에 대한 시험을 수행하였고 이를 통해 YOLOv5l6 모델 [38]을 기반 모델로 선정하였다. YOLOv5l6 모델은 기존 YOLOv5의 'large' 모델인 YOLOv5l에 P6 출력 계층을 추가한 모델로 YOLOv5l보다 객체 검출 성능 (mAP@0.5:0.95)이 10% 가량




그림 10. 학습 및 추론 관리 플랫폼 구조
Fig. 10. The Structure of the Training and Inference Management Platform

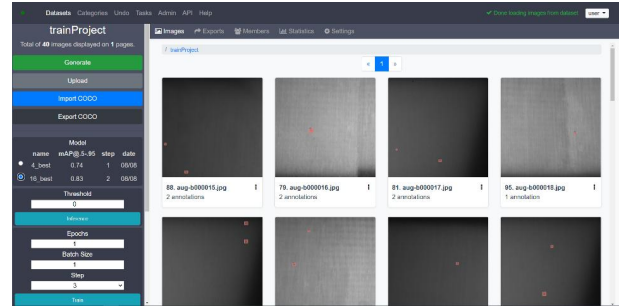


그림 11. 학습 및 추론 관리 서비스 화면
Fig. 11. A Screenshot of the Training and Inference Management Service

향상되었다. 또한 기본 이미지 입력 크기가 640×640에서 1280×1280로 픽셀 수 기준 4배 증가하였는데 이에 비해 검출 시간은 NVidia사의 V100 GPU 기준 3.24배만 늘어나 약 20%의 속도 향상 효과를 가진다. 추가로 유사한 결함 유형을 보다 잘 구분하게 하기 위해 YOLOv5l6 모델의 클래스 분류를 위한 손실함수를 기존 교차엔트로피 손실에서 초점 손실 (focal loss) [39]로 변경하였다. 준지도 학습 모델의 구현 및 학습은 Pytorch 플랫폼을 이용하였고 각 단계에서의 학습은 150 에폭 (epoch) 시간 동안 진행하였다.

3. 학습 및 추론 관리 시스템 구축

제안된 4 단계의 학습 과정은 고성능 GPU가 설치된 서버에서 수행하지만 추론은 저비용 결함 검출 시스템 구축을 위해 임베디드 시스템 환경에서 진행하였다. 이러한 단계별 학습 과정과 별도 시스템에서의 추론을 용이하게 수행하기 위해 웹 기반으로 학습 및 추론 과정을 관리할 수 있는 플랫폼을 구축하였다. 학습 및 추론 관리 플랫폼은 그림 10과 같이 GPU가 설치된 리눅스 서버와 Nvidia사의 에지 컴퓨팅 보드인 Jetson AGX Xavier로 구성된다. 리눅스 서버에는 웹 환경에서 시험 및 추론 관리 서비스를 제공하는 소프트웨어를 구현하였고, 소켓 통신 인터페이스로 서버와 Jetson AGX Xavier 보드가 연결하여 임베디드 시스템 기반의 추론 환경을 구성하였다.

웹 기반 학습 및 추론 관리 서비스 화면은 그림 11과 같이 좌측의 단계별 학습 및 추론 제어 부분과 우측의 학습 및 추론 결과 이미지 표출 부분으로 구성된다. 사용자는 데이터를 가져와 각 단계별 학습을 진행할 수 있으며 학습된

모델을 불러와 연결된 임베디드 시스템에서 추론을 수행하고 결과를 시각적으로 확인할 수 있다.

V. 성능 평가

제안된 강판 표면 결함 검출 시스템의 성능 평가는 구축된 학습 및 추론 관리 플랫폼을 통해 진행하였다. 학습 및 시험 데이터는 IV.1절에서 기술한 것과 같이 각각 100장, 400장이며 학습 및 추론 관리 시스템 서버에 미리 저장해 두었다. 학습 및 추론 관리 서비스 화면에서 각 단계 버튼을 누르면 해당 단계의 절차가 수행되고 각 단계가 종료되면 시험 데이터를 이용해 학습 모델의 성능을 평가한다. 화면에서 추론 버튼을 누르면 4단계까지 학습된 모델과 시험데이터가 소켓 인터페이스를 통해 Jetson AGX Xavier로 전송되고 전송이 완료되면 추론 과정이 수행된다. 추론이 완료되면 성능평가 결과와 결함 검출 정보가 다시 서버에 전송되어 화면에 표시된다. 각 단계의 시험 및 추론 성능은 IoU (Intersection over Union) 및 confidence 문턱 값을 각각 0.5, 0.9로 설정하여 추론한 후 각 결함에 대한 추론 결과에 대해 표 2의 기준으로 TP (True Positive), FP (False Positive), FN (False Negative)를 판정하고 이를 이용해 f1-score를 산출하였다. 단계 1에서 프로그램 기반 생성 데이터와 생성 모델 기반 생성 데이터 각각으로 YOLOv5l6 모델을 사전학습하고 시험데이터로 성능을 평가한 결과는 표 3과 같다.

프로그램 기반 생성 데이터와 생성모델 기반 생성 데이터로 사전 학습한 모델의 성능이 모두 매우 우수한 편인데 이는 두 데이터 증강 방법이 모두 원래 데이터의 분포와 유사한 이미지를 생성했기 때문으로 판단된다. 두 방법 중 생성 모델 기반 생성 데이터로 학습된 모델이 약간 더 우수한 결함 검출 성능을 보였기 때문에 단계 2부터는 생성모델 기반 사전 학습된 모델을 사용하였다. 시험 데이터에 대한 각 단계별 및 유형별 결함 검출 성능은 표 4와 같다.

단계별 학습 결과를 보면 소량의 라벨 데이터만을 사용한 단계 2 학습 후의 성능 향상은 매우 제한적이지만 단계 3의 비라벨 데이터 유사 라벨링을 통해 얻어진 추가 라벨 데이터를 활용한 단계 4의 학습 후에는 평균 1% 포인트 이상의 성능 향상이 있었다. 다만 1단계 사전 학습 모델의 결함 검출 성능이 우수해서 오히려 2~4단계의 준지도학습 성능을 제대로 확인하기 어려운 측면이 있다. 강판처럼 표면이 균질하지 않은 제품이라면 이미지 증강의 난이도가 높아져 1단계 사전 학습 모델의 성능이 다소 하락할 수 있어 준지도 학습의 효과를 확인하기에 보다 용이할 수 있다. 임베디드 시스템에서의 추론은 단계 4의 학습 모델과 동일 모델을 사용하였으므로 동일한 성능을 보였고 시험 이미지 1장의 평균 추론 시간은 0.166초를 기록했다. 따라서 하나의 임베디드 시스템에서 초당 평균 6장의 강판 표면 이미지 결함 검출이 가능하다.

표 3의 결과에서 프로그램 기반 및 생성 모델 기반 데이터 증강으로 생성된 데이터의 학습 성능이 거의 유사하게

표 2. 결함 추론 결과에 대한 판정 방법
Table 2. Evaluation Method of Inference Outcomes

| Verdict | Condition |
|---------|--|
| TP | For an predicted defect, when there is a corresponding actual defect with the same defect type, and the IoU of the actual and predicted bounding boxes is greater than or equal to the threshold |
| FP | For an predicted defect, when there is no corresponding actual defect with the same defect type, or the IoU of the actual and predicted bounding boxes is less than the threshold |
| FN | For an actual defect, when there is no corresponding predicted defect with the same defect type, or the IoU of the actual and predicted bounding boxes is less than the threshold |

표 3. 각 생성 데이터로 사전 학습된 모델의 성능 비교 (f1-score)

Table 3. Performance Comparison Between Pretrained Models with Each Generated Data (f1-score)

| Generated Data Type | Overall | Black Spot | White Spot | Stain | Scratch |
|------------------------|---------|------------|------------|-------|---------|
| Program Based | 96.48 | 97.58 | 96.72 | 94.69 | 96.93 |
| Generative Model Based | 97.70 | 98.80 | 99.50 | 94.30 | 98.30 |

표 4. 학습 모델의 단계별 결함 검출 성능 (f1-score)

Table 4. Step-by-Step Defect Detection Performance of the Trained Models (f1-score)

| | Overall | Black Spot | White Spot | Stain | Scratch |
|--------|---------|------------|------------|-------|---------|
| Step 1 | 97.70 | 98.80 | 99.50 | 94.30 | 98.30 |
| Step 2 | 97.91 | 98.83 | 99.61 | 94.62 | 98.60 |
| Step 3 | 97.91 | 98.83 | 99.61 | 94.62 | 98.60 |
| Step 4 | 98.99 | 99.30 | 99.41 | 98.29 | 99.30 |
| Test | 98.99 | 99.30 | 99.41 | 98.29 | 99.30 |

나타났지만 프로그램 기반 증강 기법의 경우 새로운 유형의 결함 이미지를 생성하기 위해서는 별도의 프로그램을 작성해야 하는 부담이 있으며, 기하학적인 방법으로 생성하는 것이 매우 어려운 결함 유형이 존재할 수 있다는 단점이 있다. 생성 모델 기반 증강 기법은 분포 학습을 위해 각 결함 유형에 대한 실제 라벨 데이터가 필요하며 생성 과정이 다소 복잡하다는 단점이 있지만 결함 유형의 분포를 학습하기 때문에 결함의 모양이나 유형에 제한이 없다는 점에서 유용성과 확장성이 더 높다고 할 수 있다. 다만, 결함의 크기 및 좌우 폭의 차이가 클 경우 가장 큰 크기의 결함을 기준으로 결함영역 이미지를 생성해야 한다.

IV.2절에서 기술한 바와 같이 본 연구의 결함 검출 기본 모델인 YOLOv5l6의 클래스 분류 손실함수에 초점 손실을 사용하였다. 원래의 교차 엔트로피 손실을 사용한 경우 오염 결함의 검출 성능이 다른 결함 유형보다 약 4% 포인트나 낮았다. 이는 오염 결함 이미지가 백점 결함 이미지와

유사하여 백점으로 잘못 분류함으로써 기인했다. 이러한 문제점은 표 4의 단계 4 결과에서 확인할 수 있듯이 클래스 분류 손실함수를 초점 손실로 변경함으로써 상당 부분 해결할 수 있었다.

한편, 본 연구에서는 단계 2~4의 고정크기 증강기법으로 그림 6에서 나타난 것과 같이 총 10가지를 사용했는데 각 증강 기법을 조합할 경우 증강 이미지 수를 늘릴 수 있어 학습 데이터를 추가로 확보할 수 있다. 또한 일관성 학습을 수행할 때 입력 데이터로 원본 데이터와 증강 데이터 쌍 뿐만 아니라 서로 다른 증강 데이터 쌍도 포함시킬 경우 모델의 추가학습이 가능하다. 따라서 이러한 기법들을 학습에 적용할 경우 모델의 성능 향상을 기대해 볼 수 있다.

VI. 결론

본 논문은 강판 제조 현장에서 라벨 데이터와 비라벨 데이터로 구성된 소량의 강판 표면 이미지를 학습하여 산업 등급의 우수한 결함 검출 성능을 가지는 강판 표면 결함 검출 시스템을 제시하였다. 세부적으로는 학습 데이터 부족 문제를 극복하기 위한 프로그램 기반 및 생성 모델 기반 데이터 증강 기법과 비라벨 데이터를 활용하기 위한 4 단계 준지도 학습 방법을 제안하였다.

제안 기법을 통해 비라벨 이미지를 포함하여 단 100장의 수집 이미지를 이용해 네 가지 결함 유형에 대해 약 99%의 결함 검출 성능을 얻을 수 있었으며 임베디드 시스템에서 초당 6장의 이미지에 대해 결함 검출이 가능하였다. 이러한 결과는 본 연구의 결함 검출 시스템이 실제 강판 제조 현장에 도입되어 실시간으로 결함을 검출하는 데 적용될 수 있는 가능성이 매우 높음을 보여준다.

본 연구에서는 강판 결함의 직경이 대략 10~15 픽셀을 차지하도록 설정하여 강판 제품의 이미지를 촬영하였다. 강판 결함이 차지하는 픽셀 수를 줄이면 동일한 해상도의 이미지로 더 넓은 강판 영역을 담을 수 있으므로 촬영 장비 구축에 들어가는 비용과 결함 탐지 시간을 감소시킬 수 있다. 반면 결함 크기가 작아지므로 결함 탐지 성능이 떨어질 수 있는데, 후속 연구를 통해 직경이 5 픽셀 정도를 차지하는 결함에 대해서도 동일한 수준의 결함 검출 및 분류 성능을 가질 수 있도록 모델을 최적화할 계획이다. 또한 학습 대상 이미지 수, 결함 크기 및 결함 종류의 변화 등에 따른 결함 검출 성능 변화를 분석하고 산업 현장에서 사용할 수 있는 수준의 정확도를 얻기 위해 필요한 조건을 제시하고자 한다. 추가로 제안 기법의 범용성을 확인하기 위해 강판 이외의 제품에 대해서도 본 결함 검출 시스템을 적용하여 성능 평가를 수행할 예정이다.

References

[1] C. Shorten, T. M. Khoshgoftaar, "A Survey on Image Data Augmentation for Deep Learning," *J Big Data*, Vol.

6, No. 1, pp. 1-48, 2019.

- [2] Y. Wang, Q. Yao, J. T. Kwok, L. M. Ni, "Generalizing from a Few Examples: A Survey on Few-shot Learning," *ACM Comput. Surv.* Vol. 53, No. 3, pp. 1-3, 2021.
- [3] K. Weiss, T. M. Khoshgoftaar, D. D. Wang, "A Survey of Transfer Learning," *J Big Data* Vol. 3, No. 1, pp. 1-40, 2016.
- [4] S. Bernhard, P. John, H. Thomas, "Analysis of Representations for Domain Adaptation," *Advances in Neural Information Processing Systems 19: Proceedings of the 2006 Conference*, MIT Press, pp. 137-144, 2007.
- [5] M. Khanam, T. Mahboob, W. Imtiaz, H. A. Ghafoor, R. Sehar, "A Survey on Unsupervised Machine Learning Algorithms for Automation, Classification and Maintenance," *International Journal of Computer Applications*. Vol. 119, No.13, pp. 34-39, 2015.
- [6] A. Jaiswal, A. R. Babu, M. Z. Zadeh, D. Banerjee, F. Makedon, "A Survey on Contrastive Self-Supervised Learning," *Technologies*, Vol. 9, No.1 pp. 2, 2021.
- [7] J. E. Van Engelen, H. H. Hoos, "A Survey on Semi-supervised Learning," *Mach Learn* Vol. 109, No. 2, pp. 373 - 440, 2020.
- [8] T. DeVries, G. W. Taylor, "Improved Regularization of Convolutional Neural Networks with Cutout," *arXiv:1708.04552*, 2017.
- [9] H. Zhang, M. Cisse, Y. N. Dauphin, David Lopez-Paz, "mixup: Beyond Empirical Risk Minimization," *arXiv:1710.09412*, 2017.
- [10] A. Bochkovskiy, C. Y. Wang, H. Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection", *arXiv:2004.10934*, 2020.
- [11] G. Ghiasi, Y. Cui, A. Srinivas, R. Qian, Tsung-Yi Lin, Ekin D. Cubuk, Quoc V. Le, Barret Zoph, "Simple Copy-Paste is a Strong Data Augmentation Method for Instance Segmentation," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 2918-2928, 2021.
- [12] B. Christopher, C. Liang, G. P. B. Ricardo, G. Roger, H. Alexander, A. D. David, V. H. Maria, W. Joanna, R. Daniel, "GAN Augmentation: Augmenting Training data Using Generative Adversarial Networks," *arXiv preprint*. 2018.
- [13] A. Antoniou, A. Storkey, H. Edwards. "Data Augmentation Generative Adversarial Networks," In *Proceedings of the International Conference on Learning Representations Workshops (ICLR Workshops)*, 2018.
- [14] M. Arjovsky, S. Chintala, L. Bottou, "Wasserstein GAN," *arXiv:1701.07875*, 2017.
- [15] Y. Xian, T. Lorenz, B. Schiele, Z. Akata. "Feature Generating Networks for Zero-shot Learning," In

- CVPR, 2018.
- [16] Y. Wang, Q. Yao, J. Kwok, L. M. Ni, "Generalizing from a Few Examples: A Survey on Few-Shot Learning," *ACM Computing Surveys*, Vol. 53, No. 3, pp. 1-34, 2020.
- [17] D. Kim, D. Cho, D. Yoo, I. S. Kweon, "Learning Image Representations by Completing Damaged Jigsaw Puzzles," 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), pp. 793-802, 2018.
- [18] S. Gidaris, P. Singh, N. Komodakis, "Unsupervised Representation Learning by Predicting Image Rotations," 6th International Conference on Learning Representations (ICLR), Vancouver, Canada, 2018.
- [19] L. Songtao, Z. Li, J. Sun. "Self-EMD: Self-Supervised Object Detection Without ImageNet." *ArXiv abs/2011.13677*, 2020.
- [20] D. H. Lee, "Pseudo-Label : The Simple and Efficient Semi-Supervised Learning Method for Deep Neural Networks," *ICML 2013 Workshop: Challenges in Representation Learning (WREPL)*, Vol. 3, No. 2, pp. 896, 2013.
- [21] S. Laine, T. Aila, "Temporal Ensembling for Semi-Supervised Learning," *arXiv:1610.02242*, 2016.
- [22] J. Jeong, S. Lee, J. Kim, N. Kwak, "Consistency-based Semi-supervised Learning for Object Detection," *NIPS'19: Proceedings of the 33rd International Conference on Neural Information Processing Systems*, pp. 10759 - 10768, 2019.
- [23] A. Tarvainen, H. Valpola, "Mean Teachers are Better Role Models: Weight-averaged Consistency Targets Improve Semi-supervised Deep Learning Results," *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*, pp. 1195 - 1204, 2017.
- [24] Q. Xie, Z. Dai, E. Hovy, T. Luong, Q. Le, "Unsupervised Data Augmentation for Consistency Training," *Advances in Neural Information Processing Systems 33 (NeurIPS 2020)*, pp. 6256-6268, 2020.
- [25] D. Berthelot, N. Carlini, I. Goodfellow, N. Papernot, A. Oliver, C. Raffel, "MixMatch: a Holistic Approach to Semi-supervised Learning," *NIPS'19: Proceedings of the 33rd International Conference on Neural Information Processing Systems*, pp. 5049 - 5059, 2019.
- [26] Q. Guo, Y. Mu, J. Chen, T. Wang, Y. Yu, P. Luo, "Scale-Equivalent Distillation for Semi-Supervised Object Detection," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 14522-14531, 2022.
- [27] F. Guo, J. Zhao, P. Jiang, "Surface Defects Detection of Steel Plate Based on Visual Attention Mechanism," 2017 Chinese Automation Congress (CAC), pp. 3174-3177, 2017.
- [28] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [29] S. Ren, K. He, R. Girshick, J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *Advances in Neural Information Processing Systems Vol. 28 (NIPS 2015)*, 2015.
- [30] S. Wang, X. Xia, L. Ye, B. Yang, "Automatic Detection and Classification of Steel Surface Defect Using Deep Convolutional Neural Networks." *Metals*, Vol. 11, No. 3, pp. 388, 2021.
- [31] D. Amin, S. Akhter, "Deep Learning-Based Defect Detection System in Steel Sheet Surfaces," *2020 IEEE Region 10 Symposium (TENSYP)*, pp. 444-448, 2020.
- [32] P. Damacharla, A. R. M. V., J. Ringenberg, A. Y. Javaid, "TLU-Net: A Deep Learning Approach for Automatic Steel Surface Defect Detection," *2021 International Conference on Applied Artificial Intelligence (ICAPAD)*, pp. 1-6, 2021.
- [33] A. M. Deshpande, A. A. Minai, M. Kumar, "One-Shot Recognition of Manufacturing Defects in Steel Surfaces," *Procedia Manufacturing*, Vol. 48, pp. 1064-1071, 2020.
- [34] J. Božič, D. Tabernik, D. Skočaj, "Mixed Supervision for Surface-defect Detection: from Weakly to Fully Supervised Learning," *Computers in Industry*, Vol. 129, 103459, 2021.
- [35] Wikipedia, "Jensen - Shannon Divergence", see https://en.wikipedia.org/wiki/Jensen-Shannon_divergence.
- [36] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff, H. Adam, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation," *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 801-818, 2018.
- [37] J. Hu, L. Shen, S. Albanie, G. Sun, E. Wu, "Squeeze-and-Excitation Networks," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018.
- [38] Ultralytics, "YOLOv5 v5.0 YOLOv5-P6 models," see <https://github.com/ultralytics/yolov5/releases>, 2021.
- [39] T. Y. Lin, P. Goyal, R. Girshick, K. He, P. Dollár, "Focal Loss for Dense Object Detection," *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2980-2988, 2017.

Abdulaziz Gaybulayev (게이불라예프 압둘라지즈)


2013 Information Science from Tashkent
University of Information Technologies
(B.S.)

2015 Computer Engineering from Tashkent
University of Information Technologies
(M.S.)

2018~Computer Engineering from Kumoh National Institute of
Technology. (Ph.D. Candidate)

Field of Interests: Deep Learning, Embedded Systems

Email: g.abdulaziz@kumoh.ac.kr

Na-Hyeon Lee (이 나 현)

2018~Computer Engineering from Kumoh
National Institute of Technology.
(B.E. Student)

Field of Interests: Deep Learning, Computer Vision

Email: ddongmogi@kumoh.ac.kr

Ki-Hwan Lee (이 기 환)

2022 Computer Engineering from Kumoh
National Institute of Technology.
(B.E.)

2022~Computer Engineering from Kumoh
National Institute of Technology.
(M.E. Student)

Field of Interests: Deep Learning, Smart Factory

Email: roran2002@kumoh.ac.kr

Tae-Hyong Kim (김 태 형)

1992 Electronic Engineering from Yonsei
University (B.S.)

1995 Electric and Electronic Engineering
from Yonsei University (M.S.)

1995 Electric and Electronic Engineering
from Yonsei University (Ph.D.)

2002~Computer Engineering from Kumoh National Institute of
Technology (KIT). (Prof.)

Career:

2001 Post-Doc. Researcher, Univ. of Ottawa

2008 Visiting Scholar, Univ. of California, Riverside

2020~Director of AI Big Data Center, KIT

Field of Interests: Deep Learning, Big Data Analytics, Smart
Factory, Time Series Analysis

Email: taehyong@kumoh.ac.kr