

# 금속 표면 결함 탐지 및 영상 분할을 위한 딥러닝 기반의 다중 클래스 결함 학습

박재현<sup>1</sup>, 최우제<sup>2</sup>, 전세호<sup>1</sup>, 이동규<sup>1,2\*</sup>

경북대학교 융합학부<sup>1</sup>  
경북대학교 인공지능학과<sup>12\*</sup>

{aurumstar24, jeya9811, jsh4945, dglee}@knu.ac.kr

## Deep learning based Multi-class Defect Learning for Steel Defect Detection and Segmentation

Jae-Hyun Park, Woo-Je Choi, Sae-Ho Jeon, and Dong-Gyu Lee\*  
Kyungpook National University\*.

### 요 약

본 논문은 금속 표면 결함 탐지 및 영상 분할을 위한 다중 클래스 학습 방법을 제안한다. 기존의 U-Net 기반 금속 결함 탐지 연구에서는 영상을 정상/비정상으로 구분하였을 경우 다양한 결함의 종류에 효과적으로 대응하지 못하는 단점이 있다. 이러한 문제를 해결하기 위해서 결함의 종류를 세분화하여 모델을 학습시키고 이를 결함 탐지에 활용하여, 최종적으로 강인한 금속 결함 모델을 학습시킬 수 있다. 제안하는 방법은 공개 데이터셋에서 우수한 성능을 보임으로써 그 효용성을 입증하였다.

### I. 서 론

금속 제작 공정에 있어서 금속 표면 검사 및 결함 탐지는 생산된 금속의 품질을 보장하기 위해 필수적인 공정이다. 표면 결함은 철강의 부식을 촉진시키기 때문에 최종적으로 생산된 제품의 품질 및 안정성에 큰 영향을 끼칠 수 있다 [1]. 통상적인 금속 제조 공정에서 표면 결함 탐지는 사람에 의해 수행되어 왔으나, 이러한 방법은 시간이 많이 소요되고 작업자에 따라 불량 선별 기준이 변할 수 있기 때문에 동일한 품질의 결과물을 보장하기 어렵다는 단점이 있다. 이러한 문제점을 해결하기 위해, 카메라로 촬영된 영상으로부터 금속 표면을 검사하여 결함을 자동으로 탐지하고 그 위치를 특정하는 기술이 금속 산업 분야에서 많은 주목을 받고 있다 [2].

금속 표면의 결함 탐지를 위한 영상 분석 기술로 category-aware object detection network (CADN) [3], defect detection network (DDN) [4], U-Net [5] 과 같은 convolutional neural network (CNN) 기반의 영상 특징 추출 및 영상 분할 기법이 주로 활용되고 있다. 기존의 금속 결함 탐지는 결함의 종류와는 별개로 결함의 유무에 따라 결함의 위치를 판별하는 형식으로 학습을 진행한다. 이때 영상 내에 다른 종류의 결함이 동시에 존재하는 경우, 이것을 모두 결함으로 학습을 하지 않고 결함의 종류별로 구분하여 별도로 학습하게 된다. 각 결함의 유무를 판단하여 반복적으로 학습시킴으로써 다른 종류의 결함 인식 성능 및 학습 효율 저하가 발생한다.

본 논문에서는 금속 표면에 발생 가능한 결함 영역을 파악하고 정확한 결함 영역의 분할 제시가 가능한 심층 신경망 모델을 제안한다. 기존의 방법은 금속의 표면을 정상/결함 영역으로 나누어 분할하였지만, 제안하는 방법에서는 결함의 종류에 따른 패턴을 구분하여 학습함으로써, 한 장의 영상에 두가지 이상의 결함이 존재할 때 모든 결함을 효율적으로 탐지 및 분할 가능하다.

### II. 본론

#### 2.1 금속 결함 탐지 및 분할을 위한 네트워크 구조

본 연구에서는 금속 결함 탐지 및 결함 영역 분할을 위해서, 우리는 영상 분할에 우수한 성능을 보이는 U-Net [5] 구조를 활용한다. U-Net 은 영상 분할을 목적으로 제안된 end-to-end 방식의 fully-convolutional network 기반 모델로 수축 경로 (contracting path)와 확장 경로 (expansive path)로 구성되어 있다. 수축 경로에서 발생하는 입력 영상의 공간적 상관관계의 문맥 정보의 손실을 최소화하기 위하여, 동일 단계의 확장 경로 해당 레이어의 정보를 직접 전달함으로써, 정교한 영상 분할이 가능하다.

#### 2.2 모델 학습 방법

본 연구에서는 모델의 학습을 위해 데이터셋의 ground-truth mask 를 활용하여, 각각의 영상에 대해 금속 표면의 정상 상태 및 4 종류의 결함을 5 개 채널에 one-hot vector 형태로 인코딩 하여 처리한다.

각각의 픽셀에 부여된 라벨을 토대로 한 최종예측값은 소프트 맥스(softmax) 함수를 통해 확률분포 형태로 출력한다. 예측값의 오차 계산은 크로스 엔트로피(cross entropy) loss 를 측정하며, 라벨을  $p$ , 예측 값을  $q$  로 표기할때 최종적인 오차 계산의 수식은 아래 수식과 같다.

$$H(p, q) = - \sum_x p(x) \log q(x)$$

### III. 실험 및 분석

#### 3.1 데이터셋

제안하는 금속 결함 탐지 프레임워크를 학습 및 평가하기 위해 Severstal: Steel Defect Detection [6] 데이터셋을 활용한다. 해당 데이터셋은 kaggle 에서 2019 년 competition 활용된 데이터셋으로, train split 12600 장과 test split 5506 장으로 구성되어 있다. 한장의 영상은 256×1600 크기이며, 모든 영상은 픽셀 단위의 결함 마스크가 총 5 종류의 라벨(정상, 결함 1, 결함 2, 결함 3, 결함 4)로 제공된다.

#### 3.2 구현 환경 상세

본 논문에서는 수행된 실험은 다음과 같은 환경에서 수행되었다. 제안하는 모델을 학습시키기 위하여 learning rate =  $1 \times 10^{-4}$ , batchsize = 16 으로 설정하였다. 학습 단계에서 AdamOptimizer 를 활용하여 40 epoch 를 학습하였다. 모든 실험은 Google Colab 환경에서 Tensorflow 를 사용하여 구현되었다.

#### 3.3 실험결과 및 분석

본 실험에서 우리는 입력 영상의 결함 탐지 및 영상 내 결함 영역 분할 성능 측정을 위해 mean Intersection-over-Union (mIoU)를 사용하였다. 또한, 연구의 목적이 결함이 발생한 금속을 탐지하는데 있기 때문에, 학습단계에서는 정상 및 4 종의 결함 클래스로 학습하고, 최종 결함 탐지 성능 측정단계에서는 결함/비결함을 분류하여 성능을 측정하였다

| 방법          | 성능   |
|-------------|------|
| Vanilla CNN | 75.9 |
| U-Net [5]   | 91.3 |
| 제안하는 방법     | 94.1 |

표 1 Steel Defect Detection 데이터셋에서의 결함 탐지 성능 비교

표 1 은 금속 결함 탐지 성능을 기존 방법과 비교한 것이다. 제안하는 방법은 94.1 의 성능을 보여, 동일 환경에서 학습시킨 기본 CNN 구조 및 U-Net 구조에 비하여 2.8 높은 결함 탐지 결과를 보임으로써, 제안하는 방법이 효율적이고 유효함을 보였다.

### IV. 결론

본논문에서는 금속 결함 탐지를 위하여 U-Net 기반 멀티 클래스 학습 및 영상 분할 방법을 제안한다. 다양한 종류의 결함을 학습 단계에서 구분하여 별도의 클래스로 인식하도록 학습시키고, 최종적으로 분류할 때 멀티 클래스를 하나의 결함으로 인식하도록 함으로써, 금속 표면의 상태 비정상 인식 성능을 향상시켰다. 공개 데이터셋에서의 금속 결함 탐지 성능은 기존의 방법을 능가하면서 결함 종류에 따른 멀티 클래스 학습이 금속 결함 탐지에 효과적임을 보였다.

### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터지원사업(IITP-2021-2020-0-01808)과 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2021R1C1C1012590).

### 참 고 문 헌

- [1] S. Jinjie and J. Ming, "Influence of defects at the steel-mortar interface on the corrosion behavior of steel," Construction and Building Materials, 136, (2017): 118-125.
- [2] L. Qiwu, X. Fang, L. Liu, C. Yang, and Y. Sun, "Automated visual defect detection for flat steel surface: A survey," IEEE Transactions on Instrumentation and Measurement, 69, no. 3 (2020): 626-644.
- [3] Z. Jiabin, H. Su, W. Zou, X. Gong, Z. Zhang, and F. Shen, "CADN: A weakly supervised learning-based category-aware object detection network for surface defect detection," Pattern Recognition, 109, (2021): 107571.
- [4] Y. He, K. Song, Q. Meng, and Y. Yan, "An end-to-end steel surface defect detection approach via fusing multiple hierarchical features," IEEE Transactions on Instrumentation and Measurement, 69, no. 4 (2019): 1493-1504.
- [5] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," In International Conference on Medical image computing and computer-assisted intervention, pp. 234-241. Springer, Cham, 2015.
- [6] <https://www.kaggle.com/c/severstal-steel-defect-detection/data>.