

영상 분할을 위한 적응적 데이터 증강 기법

박화중*, 송창우

*(주)인텍플러스, (주)인텍플러스

*hjpark@intekplus.com, cwsong@intekplus.com

Adaptive Data Augmentation for Image Semantic Segmentation

Hwa-Jong Park*, Chang-Woo Song

*IntekPlus Co., Ltd, IntekPlus Co., Ltd

요 약

최근 산업 현장에서 딥러닝을 적용하는 사례가 증가하고 있다. 딥러닝 모델을 학습시키기 위해서는 많은 양의 데이터가 필요하지만, 결함 데이터는 특성상 정상 데이터에 비해 매우 적은 비율로 생성된다. 결함 데이터의 부족은 결국 딥러닝 모델이 결함 데이터를 분류, 혹은 탐지하는 성능을 감소시키기 때문에 높은 성능의 딥러닝 모델을 사용하려면 데이터 부족 문제를 해결해야 한다. 본 논문은 결함 데이터 부족 문제를 해결하기 위한 방법으로 결함 데이터를 생성하는 데이터 증강 알고리즘을 제안한다. 제안된 알고리즘은 추가적인 라벨링 작업이 필요하지 않으며 증강시킨 데이터의 수와 비례하여 성능이 상승하는 것을 확인하였다.

I. 서 론

최근 산업 현장에서 결함을 분류하거나 결함을 탐지하기 위해 딥러닝 모델을 많이 사용하고 있다.[1] 딥러닝 모델을 학습시키기 위해서는 많은 양의 데이터가 필요하다. 하지만 정상 데이터는 많이 얻을 수 있는 반면 결함 데이터는 매우 부족하기 때문에 딥러닝 모델을 학습시키기에 어려움이 있다. 부족한 데이터를 증가시키기 위해 Generative adversarial networks[2]를 사용하여 데이터를 생성하거나[3], Cutmix[4]와 같은 데이터 증강 기법이 연구되어 왔지만 Segmentation 모델을 학습시키기 위해서는 결함 영상마다 결함 레이블이 필요하다는 추가적인 문제가 존재한다. 본 논문에서는 이러한 문제를 해결하기 위해 새로운 결함 데이터를 생성하는 데이터 증강 알고리즘을 제안한다.

II. 본론

2.1 데이터 증강 알고리즘

본 논문에서는 정상 영상 I 와 결함 영상 D , 결함 레이블 D' 을 사용하여 새로운 결함 영상 G , 새로운 결함 레이블 G' 을 생성하는 것을 목표로 한다. 먼저, G 와 G' 을 초기화 한 후, D' 을 통해 결함의 위치를 찾고, D 에서 결함 주변을 포함하는 패치 p_i (여기서, $\{p_i\}_{i=1}^k$ 는 D' 에 존재하는 결함 수)를 추출한다. 여기서 추출된 p_i 를 사용하여 I 와의 유사도 행렬 S 를 계산한다. 유사도 상위 0.5%의 위치 중 한 곳을 임의로 선택하여 G 와

G' 의 해당 위치에 결함을 추가한다. G 와 G' 생성은 식 1)과 같이 나타낼 수 있다.

$$G, G' = f(I, D, D') \quad \dots 1)$$

여기서 함수 f 는 알고리즘 1과 같다.

2.2 실험 환경 및 결과

실험에서 사용한 실제 데이터인 결함 영상의 수는 총 413 개를 사용하였으며, 성능 비교를 위해 알고리즘 1을 통해 결함 데이터를 각각 2배, 8배로 증가시켰다. 딥러닝 모델은 SUAKIT[5]의 Segmentation 모델을 사용했다. 평가 지표는 Segmentation에서 주로 사용하는 평가 지표인 IoU(Intersection over Union)를 사용하였으며, 실험 결과는 표 1과 같다. 알고리즘 1을 통해 생성된 결함 이미지는 그림 1과 같다. 본 논문에서 사용한 실제 데이터셋은 보안상의 이유로 공개가 불가능 하기 때문에 본 논문에 나온 모든 그림은 Kaggle[6]의 공개 데이터셋을 사용한다.

표 1. 실험에서 사용한 데이터 수 및 결과

	실험 1	실험 2	실험 3
결함 영상 수	413	826	3304
증강 비율	-	x2	x8
IoU	0.62	0.65	0.69




그림 1. 제안된 알고리즘을 사용한 결과.

알고리즘 1 : 데이터 증강 알고리즘

입력 : 정상 이미지 I , 결함 이미지 D , 결함 레이블 D'

출력 : 생성된 결함 이미지 G , 생성된 결함 레이블 G'

- 1: G' 초기화(모든 값은 255)
- 2: G 초기화(I 와 동일)
- 3: D 와 I 사이의 와핑 매트릭스 M 계산
- 4: M 을 사용하여 D 와 D' 을 I 로 와핑
- 5: **for** $i = 1$ to k **do**
- 6: D 에서 p_i 추출(Crop)
- 7: p_i 와 I 의 유사도 행렬 S 계산
- 8: S 에서 상위 0.5% 이내의 임의의 위치 (x,y) 선택
- 9: G, G' 의 (x,y) 위치에 결함 및 결함 레이블 삽입
- 10: **end**

2.3 실험 결과 분석

데이터를 각각 2 배, 8 배로 증가시킨 경우, 데이터를 증가시키지 않은 경우보다 IoU 가 각각 0.03, 0.07 씩 증가했다. 또한 새로 생성된 영상 중에는 어색한 결함 영상이 생성되는 것을 확인하였다. 하지만 학습 데이터에 어색한 결함 영상이 포함되어 있더라도 성능을 향상시키기에는 충분하였음을 확인할 수 있다. 이는 학습 데이터의 질이 약간 떨어지는 것 보다는 데이터 부족 문제가 딥러닝 모델의 성능에 더 크게 적용된다는 것을 알 수 있다.

III. 결론

본 논문에서는 실제 산업 현장에서 사용할 수 있는 알고리즘을 제안한다. 알고리즘을 통해 데이터의 수를

증가시킨 경우, IoU 수치가 데이터의 수에 비례하여 증가하는 것을 알 수 있다. 설명한 알고리즘의 장점으로 1. 딥러닝 네트워크의 학습을 위한 새로운 결함 이미지를 생성하여 딥러닝 모델의 성능을 향상시키는 것. 2. 새로운 결함 영상만 생성되는 것이 아니라 새로운 결함 레이블도 함께 생성되기 때문에 추가적인 라벨링 작업이 필요하지 않다는 것이다.

참 고 문 헌

- [1] Tao, Xian, et al. "Automatic metallic surface defect detection and recognition with convolutional neural networks." Applied Sciences 8.9 (2018): 1575.
- [2] Goodfellow, Ian, et al. "Generative adversarial networks." Communications of the ACM 63.11 (2020): 139-144.
- [3] Frid-Adar, Maayan, et al. "Synthetic data augmentation using GAN for improved liver lesion classification." 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018). IEEE, 2018.
- [4] Yun, Sangdoo, et al. "Cutmix: Regularization strategy to train strong classifiers with localizable features." Proceedings of the IEEE/CVF international conference on computer vision. 2019.
- [5] COGNEX SUAKIT, (<https://www.cognex.com/ko-kr/products/deep-learning/suakit>).
- [6] Kaggle, (<https://www.kaggle.com>).