

분류 모델 성능을 위한 합성 영상 생성에 의한 데이터 증강 기법

송창우*, 박화중
*(주)인텍플러스

{*cwsong, hjpark}@intekplus.com

Data Augmentation using Synthetic Images Generation for Classification Model Performance

Chang-Woo Song*, Hwa-Jong Park
*IntekPlus Co., Ltd

요 약

본 논문은 offline 데이터 증강을 통한 분류 모델 성능 개선 방법을 제안한다. 상용 딥러닝 소프트웨어는 제공되는 파라미터 이외에는 조절할 수 없기 때문에 영상 전처리 등의 별도의 기술이 필요하다. 산업 현장에서 얻을 수 있는 불량으로 판정된 영상은 전체 데이터에 비해 상대적으로 적기 때문에 데이터간 불균형이 발생한다. 이러한 데이터 불균형을 해소하기 위해 StyleGAN3를 활용하여 불량 영상을 생성한다. 그리고 데이터간 균형이 이루어질 만큼 생성된 합성 영상을 추가하여 상용 딥러닝 소프트웨어를 통해 재학습한다. 재학습한 모델은 기존보다 정밀도와 정확도 면에서 개선된 성능을 보였다.

I. 서론

머신 비전 시스템은 카메라, 조명 등을 활용하여 다양한 조건에서의 영상을 획득하고, 그 목적에 맞게 소프트웨어 등으로 영상처리 및 분석을 수행한다. 머신 비전 시스템은 제조 과정에서의 발생한 결함이나 표면 및 색상 검사 등의 품질 검사에도 광범위하게 활용 중이며 디스플레이, PCB(Print Circuit Board) 등 점차 그 영역을 확대해 나가고 있다. 하지만, 이러한 시스템은 시각적으로 유사한 물체의 편차를 구분하기 어렵다는 단점이 있다. 최근에는 이러한 단점을 극복하기 위해 딥러닝 등 학습을 통한 분석이 주목받고 있다. 다양한 산업 분야에서 자체 개발 또는 SUAKIT[1] 등 상용 딥러닝 소프트웨어를 활용한다. 이러한 분석 방법은 학습을 통한 방법으로, 성능의 지속적인 개선을 위해 재학습이 이루어지기 때문에 추가 검사 및 재작업에 투입되는 불필요한 인력을 배제하고 불량률을 줄일 수 있다는 장점이 있다.

딥러닝 등 학습을 통한 분석은 충분한 데이터와 컴퓨팅 자원을 기반으로 수행한다. 즉, 산업 분야에서 결함 등의 검사를 하기 위해서는 결함을 나타내는 데이터가 필요하다. 하지만, 산업 현장에서는 수율(yield)을 중요하게 생각하기 때문에 학습을 위한 불량으로 판정을 받은 데이터는 정상으로 판정을 받은 데이터에 비해 상대적으로 적다. 이러한 데이터 불균형은 자칫 편향(bias)된 결과를 낼 수 있다.


일반적으로 데이터 불균형을 해결하기 위해 데이터 증강(augmentation)을 활용한다. 데이터 증강은 부족한 데이터셋의 입력 영상에 회전(rotation), 밀림(shearing) 등 변화를 주면서 실질적인 학습 데이터셋의 규모를 키울 수 있는 방법으로, 학습 결과 모델의 과적합(overfitting)을 방지하는 효과도 있다. 데이터 증강은 offline과 online으로 나뉜다. Online 데이터 증강은 학습 중 실시간으로 데이터를 증강하는 방법이다. 회전 등 기본적인 online 데이터 증강 기법은 상용 소프트웨어인 SUAKIT에서도 인터페이스로 조작이 가능하다. Offline 데이터 증강은 학습 데이터로 입력 이전의 전처리(preprocessing)과정으로, 데이터셋 전체 수량에 변화를 준다[2].

SUAKIT과 같은 상용 소프트웨어는 그 내부 과정이 블랙 박스로 구성되어 제공되는 인터페이스 조작 이외에는 학습 과정에 관여할 수 없으므로, offline 데이터 증강을 활용하여 성능 향상을 기대해볼 수 있다. 따라서, 본 논문에서는 offline 데이터 증강으로 GAN(Generative Adversarial Networks)의 구조를 활용하여 불량으로 판정되는 영상 생성을 통해 성능을 개선하는 방법을 제안한다.

II. 본론

불량 영상 생성을 위해 GAN을 활용한다.

그림 1. (a) 정상 판정 영상 (b) 불량 판정 영상 (c) 생성된 합성 영상



GAN은 진짜(real)와 같은 데이터를 생성하려는 생성자(generator)와 생성된 가짜(generated fake)를 평가하는 구분자(discriminator)가 각각 존재하며 서로 대립하며(adversarial) 학습한다.

StyleGAN3[3]는 GAN의 구조로, 다양한 위치 변화에 따라 세부표현이 따라오지 않은 texture sticking을 해결한다. 의도하지 않게 학습되는 공간 정보(spatial information)는 texture sticking을 유발하는 원인 중 하나이다. 이는 영상 내 경계면에 패딩(padding)되는 커널 연산의 전처리 과정을 실제보다 넓게 연산하여 자르는(crop) 방법으로 해결한다. 이외에도 aliasing, positional encoding 등을 제거하여 자연스러운 합성 영상 생성을 가능하게 한다. 즉, 생성하고자 하는 합성 영상 내 존재하는 계층적인 구조를 자연스럽게 표현한다. 산업 현장에서의 검사 대상은 그 구조가 계층적이므로, 이를 활용하여 합성 영상을 생성한다.

주조(casting) 불량은 금속 주조 생성 공정에서 불규칙적으로 발생한다. 본 논문에서 사용하는 데이터셋은 주조 생산 제품에 관련된 오픈 데이터셋[4]으로, 정상 판정 영상과 불량 판정 영상으로 구분된다. 산업 현장에서는 불량 판정을 받은 데이터의 수가 상대적으로 적기 때문에 표 1와 같이 수량을 조절한다.

표 1. 분류 모델 생성을 위해 재구성한 종류와 수량

데이터셋	정상	불량
원본	2,875	3,758
재구성	2,875	192

객관적인 성능 평가를 위해 상용 소프트웨어 SUAKIT의 네트워크, 'small'을 통해 분류 모델을 학습한다. 재구성된 불량 영상은 StyleGAN3 모델 학습에도 사용한다. StyleGAN3 모델로 생성한 합성 영상은 그림 1. (c)와 같으며 정상 판정 영상 개수(2,875)와 동일하게 맞추어 재학습한다. 분류 모델 간 성능 비교 결과는 표 2와 같다.

표 2. 분류 모델 간 성능 비교 (%)

모델	정밀도	정확도
SUAKIT(small)	87.91	94.97
SUAKIT(small) + StyleGAN3	99.24	99.72

III. 결론

본 논문에서는 상용 딥러닝 소프트웨어에 국한되지 않고 분류 모델 성능을 개선하는 방법을 제안한다. 산업 현장에서 결함 등의 불량 판정 데이터의 수는 정상 판정 데이터에 비해 상대적으로 적기 때문에 정상과 불량 데이터 간 불균형이 있다. 주어진 불량으로 판정된 데이터

를 증강하기 위해 StyleGAN3를 활용한다. 이를 통해 부족한 데이터의 수를 맞춰주고 재학습한 모델은 불균형한 데이터셋으로 학습한 모델에 비해 정밀도와 정확도 면에서 향상된 결과를 보였다.

참 고 문 헌

- [1] Tsan T. C., et al. "TsanKit: artificial intelligence for solder ball head-in-pillow defect inspection," Machine Vision and Applications, pp.32-66, Mar. 2021.
- [2] Talukdar J., et al. "Data Augmentation on Synthetic Images for Transfer Learning using Deep CNNs," International Conference on Signal Processing and Integrated Networks (SPIN), pp.215-219, 2018.
- [3] Karras T., et al. "Alias-Free Generative Adversarial Networks," Advances in Neural Information Processing Systems 34 (NeurIPS), pp.852-863, 2021.
- [4] Dabhi R. "casting product image data for quality inspection," 2020, (<https://www.kaggle.com/datasets/ravirajsinh45/real-life-industrial-dataset-of-casting-product>).