

GAN을 이용한 커스텀 데이터셋 구축 방안 연구

설수진*, 이동희*, 김병우**

*울산대학교 전기전자컴퓨터공학과

**울산대학교 전기공학부

e-mail:tjftnwls00@naver.com

Custom dataset construction method using GAN

Su-Jin Seol*, Dong-Hee Lee*, Byeong-Woo Kim**

*Dept. of Electrical, Electronic and Computer Engineering, University of Ulsan

**Dept. of Electrical Engineering, University of Ulsan

요 약

본 논문에서는 GAN 기법을 이용한 커스텀 데이터셋 구축 방법을 제안한다. 최근 인공지능의 발전과 더불어 딥러닝 학습에 대한 관심이 높아지고 있다. 딥러닝 학습은 데이터셋을 기반으로 하여 학습에 맞는 커스텀 데이터셋을 필요로 한다. 하지만 양질의 대용량 커스텀 데이터셋을 구축하기 위해서 많은 인력과 시간이 필요하다. 이러한 한계성을 극복하기 위해 본 논문에서는 이미지 변환 기법과 GAN 기법을 활용하여 커스텀 데이터셋을 구축하는 방법을 제안한다. 생성한 커스텀 이미지의 유용성을 평가하기 위해서 YOLOv4 모델을 이용하여 mAP, F1 score 평가지표를 생성하였다. 평가 결과 커스텀 데이터셋의 정확도는 mAP(@0.75) 기준 4.49%가 증가하였고, GAN 기법을 활용한 커스텀 데이터셋의 정확도가 mAP(@0.75) 기준 13.56%가 증가하였다. 이를 통해 제안한 알고리즘의 유용성을 확인하였다.

1. 서론


최근 인공지능의 발전과 더불어 딥러닝 기술에 대한 관심이 높아지고 있으며, 자율 주행 분야, 제조업, 서비스업 등 전반적인 산업분야에 활용되고 있다. 딥러닝 기술을 적용하기 위해서는 각 환경 및 조건에 맞는 데이터셋을 필요로 한다.

딥러닝 학습은 적용하고자 하는 대상의 많은 양의 데이터를 필요로 한다. 사람, 동물, 차량 등 범용적인 데이터셋은 ms coco, kitti 등과 같이 구축되어 있으며, 학습에 필요한 방대한 양을 공유한다. 하지만 개별적이고 다양한 환경에서의 이미지 인식은 별도의 커스텀 데이터셋을 구축하여야 하며, 양질의 대규모 데이터셋을 구축하기 위해서는 많은 인력과 시간이 필요하다.


데이터 수집의 한계성을 극복하기 위하여 이미지 가공, 재생성을 통해 데이터셋을 구축하였다. 기존 이미지를 회전, 반전 등으로 이미지 변환 기법과 비지도 학습으로 이미지를 생성하는 GAN 기법을 실시하였다. 생성된 데이터셋을 활용한 딥러닝 학습으로 이미지 인식 정확도를 검증하였다.

2. 데이터셋 구축 및 검증 프로세스

본 연구에서는 커스텀 데이터셋 구축과 이미지 인식의 정확도를 통한 검증을 그림 1과 같은 프로세스를 진행하였다. 커스텀 데이터는 대용량 데이터셋이 구축되어 있지 않고, 특수한 상황에서 인지가 필요한 방사능 표지와 밸브를 대상으로 하였다.



[그림 1] 연구 진행 프로세스



[그림 2] 데이터셋 예시

2.1 데이터셋 구축

개별적인 대상을 인지하기 위하여 데이터셋이 구축되지 않은 방사능 표지와 밸브 이미지를 이용하였다. 웹 크롤링과 직접 촬영한 이미지를 통해 데이터를 수집하였다. 다음으로 물체의 위치와 종류를 나타내는 라벨링 작업을 실시하였다. 데이터 수집의 한계가 있어 다양한 방법으로 데이터를 증식하였다. 노이즈, 반전, 회전 등의 이미지 변환 기법으로 이미지를 가공하였고, WGAN, DCGAN 등 GAN 기법을 활용하여 이미지를 재생성하였다.

2.2 딥러닝 학습

구축한 데이터셋의 유용성을 판단하기 위하여 딥러닝을 통한 학습을 진행하였다. 학습 모델은 이미지 인식의 정확도를 평가하는 YOLOv4 모델을 사용하였다. YOLOv4는 빠른 속도의 학습이 가능하며, 지속적으로 속도 및 정확도를 개선하고 있는 YOLO 알고리즘의 최신 버전이다. 학습 데이터는 수집 데이터, 수집 데이터+가공 데이터, 수집 데이터+GAN 데이터 세 가지의 데이터셋으로 구분하고, 512x512의 동일한 크기의 입력 이미지로 학습을 진행하였다.

2.3 정확도 평가

객체 인식의 성능 평가를 위해 mAP과 F1 score를 지표로 이용하였다. mAP과 F1 score는 Recall(재현율)과 Precision(정밀도)의 관계로 정확도를 평가한다. mAP 지표는 Recall 값에 따른 Precision의 평균을 나타내며, F1 score는 Recall과 Precision의 조화평균을 나타낸다.

표 1은 수집 데이터, 가공 데이터, GAN 데이터의 일부를 동일한 비율로 섞어 테스트 데이터로 사용하였다. 가공 데이터 또는 GAN 데이터로 구축된 데이터셋은 이미지 인식의 정확도를 향상시켰다.

이미지 변환 기법으로 가공된 데이터보다 GAN 기법이 사용된 증식 데이터가 높은 정확도를 보인다. GAN 기법으로 특징을 추출하여 생성된 새로운 이미지가 데이터셋의 편향성을 줄여준다.

[표 1] 이미지 인식의 정확도 평가(테스트 : 전체 데이터)

데이터셋 (데이터셋의 양)	mAP (@0.5)	mAP (@0.75)	F1-score (@0.5)	F1-score (@0.75)
수집 데이터 (n/2개)	70.08	37.81	0.77	0.52
수집+가공 데이터 (n개)	70.55 (+0.47)	42.30 (+4.49)	0.77 (+0.00)	0.56 (+0.04)
수집+GAN 데이터 (n개)	77.72 (+7.64)	51.37 (+13.56)	0.82 (+0.05)	0.64 (+0.12)

3. 결론

본 논문에서는 GAN 기법을 이용하여 데이터셋 구축 방법에 대하여 연구를 진행하였다. 부족한 데이터셋의 한계를 극복하기 위하여 이미지 변환 기법과 GAN 기법을 통해 데이터 증식을 실시하였다. 구축된 데이터셋의 딥러닝 학습을 통하여 데이터의 정확도 평가를 진행하여 데이터셋의 유용성을 검증할 수 있었다. 이미지 변환 기법과 비교하여 GAN 기법을 통해 생성된 이미지가 인식에 높은 정확도를 보이며 편향성이 적은 데이터셋을 구축한다.

감사의 글

본 연구는 산업통상자원부가 지원한 “자동차산업미래기술 혁신을위한오픈플랫폼생태계구축(과제번호: P0018434)” 과 “xEV 부품산업 저변 확대를 위한 e파워트레인 핵심부품 개발플랫폼 체계화 기술 개발 (과제번호: 20010132)”사업의 지원을 받아 수행된 연구 결과입니다.

참고문헌

- [1] Abdul Jabbar, Xi Li, Bourahla Omar, “A survey on Generative Adversarial Networks: Variants, Applications, and Training”, arXiv, arXiv:2006.05132v1, 2020
- [2] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio, “Generative Adversarial Networks”, arXiv, arXiv:1406.2661v1, 2014
- [3] Alec Radford, Luke Metz, Soumith Chintala, “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks”, arXiv, arXiv:1511.06434v2, 2016
- [4] Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection”, arXiv, arXiv:2004.10934, 2020.