

GAN 기반 비공기압 타이어 창의적 디자인 생성 연구

이현준, 박미예, 박찬, 정남진, 최동현
 (주)에이아이네트웍스
 e-mail:ai@aipchal.com

Creative Design Generation Research of Non-Pneumatic Tires Based on GAN

Hyun-Jun Lee, Mi-Ye Park, Chan Park, Nam-Jin Jung, Dong-Hyun Choi
 AI Networks Co.,Ltd

요약

본 논문에서는 generative adversarial network (GAN)을 이용한 비지도 학습을 통해 학습한 데이터로부터 비 공기압 타이어의 창의적 디자인을 생성하는 기법을 제안한다. 기존 연구가 Spoke 디자인에 다양한 타이어 디자인을 적용했다면 이번엔 GAN 모델 중 하나인 Projected GAN 생성 모델을 이용해 실제로 생산되거나 설계된 도면 등으로 다양한 이미지 데이터셋을 학습하여 새롭게 디자인을 생성한다.


1. 서론

비 공기압 타이어는 펑크에 의한 타이어 손상이 없으며, 이 물질 관통에도 승차감을 유지하고 기온 변화에 따른 압력 변동이 없어 주기적인 압력 관리가 필요 없다[1]. 해당 타이어는 현재 여러 기업에서 만들어지면서 농기계, 전지차, 군용차량, 자전거, 경차 등에 적용되고 있다. 비 공기압 타이어는 환경적 측면에서도 이바지하는데 4단계의 공정(주조/사출-성형-가류-검사)을 거치고 페타이어는 소재가 단일하여 녹여서 2차 제품으로 가공할 수 있다[2]. GAN(Generative Adversarial Nets)은 두 개의 인공 신경망을 활용하며 하나는 이미지 생성, 다른 하나는 판별하는 신경망이다[3]. 본 연구의 최종 목표는 GAN(Projected GAN) 모델을 이용하여 비 공기압 타이어의 다양한 디자인과 패턴을 학습하여 새롭고 창의적인 디자인을 생성하는 시스템을 개발한다.

2. 본론

2.1 비공기압 타이어의 특징

비 공기압 타이어는 주로 Spoke의 형상의 띄고 있으나 최근 만들어지는 비 공기압 타이어의 디자인이 다양해지고 있으며 만들어져 공개된 타이어의 디자인은 [그림 1]과 같은 각 디자인 특성을 가진다. [그림 1]에 해당하는 디자인의 설명은 [표 1]과 같다.




[그림 1] 비 공기압 타이어 디자인

[표 1] 비 공기압 타이어 Spoke 디자인 특성

종류	특성
Spoke	Plate, Honeycomb, Curve, triangle 등의 디자인으로 나뉘는 일반적인 비 공기압 타이어
Bon	보로노이 스타일의 디자인. 구조적 안정성 및 효율성을 가짐
Turf	부드러운 승차감 및 잔디 찢김 최소화
iFlex2	기존의 iFlex보다 향상된 내구성, 친환경성, 그립감 및 핸들링 제공
Drawing	실물로 생성되기 이전 단계의 도면 이미지
Visionary concept	3D 프린팅을 통해 맞춤형 타이어 제작하며 고무의 양을 최소화하고 센서 내장

2.2 데이터셋

실제 비 공기압 타이어 디자인을 주로 이용하였다. 이러한 디자인은 현실에서 사용될 수 있는 제품으로 현실적인 유용성을 확보하기 위해 중요하므로 원형을 유지하고 출력해야 한다. 또한, 원형이 아니거나 복구하기 어려운 이미지와 같은 데이터들은 데이터셋에서 제외하였다. 이렇게 데이터셋을 정제함으로써 비 공기압의 특성에 집중할 수 있도록 하였다. 이에 따라 약 70장 정도의 이미지가 남게 되었고 도면 디자인, 비 공기압 타이어 이미지 등을 이용하여 모델을 학습하게 되었다.



[그림 2] 데이터셋

2.3 Projected GAN

일반적인 GAN 모델을 이용해 이미지 데이터셋을 학습하기에는 시간이 오래 걸리고 데이터셋의 문제로 온전한 원형을 유지할 수 없었다. 데이터셋이 원형의 데이터이며 패턴을 지니게 되는 이미지인 만큼 회전이나 뒤집기, 비율 변형 등의 방법으로 데이터 증강의 방법이 좋은 이미지를 얻기에 효율적이지 않았다. 이에 따라 개량된 모델인 Projected GAN[4] 모델을 이용했다. 해당 모델은 기존의 GAN 모델이 Discriminator가 학습이 어렵기에 생성물의 결과가 좋게 나오기까지의 시간이 걸렸다면 Discriminator의 feature들을 채널, 해상도별로 mixing 작업을 진행하였고, 사전학습모델 중 하나인 EfficientNet-Lite1 모델을 backbone으로 설정, 사전학습 모델의 4개의 서로 다른 scale에서 feature map을 사용하였고 Deep layer의 feature map을 효과적으로 활용하기 위해 Random Projection을 도입했다. 이 과정을 통하여 GAN의 수렴 속도 및 성능을 크게 향상할 수 있었다. 평가 지표인 FID에서 FastGAN, StyleGAN2-ADA보다 좋은 결과[4]를 보이며 SOTA(State Of The Art) 1위를 달성했다. Projected

GAN의 생성 모델은 StyleGAN2[5], FastGAN[6], FastGAN-Lite 이렇게 3가지이다.

2.3.1 StyleGAN2

StyleGAN2는 StyleGAN[7]의 개선 버전이며 StyleGAN은 고해상도 이미지를 Progressive Growing을 통해서 이미지를 생성, AdaIN을 통해 각 레이어에 이미지와 스타일을 결합한다. StyleGAN2는 StyleGAN에서 학습 시에 생기는 노이즈를 제거하기 위해 CNN의 가중치를 정규화한 뒤, Progressive Growing을 제거해 자연스럽게 않은 이미지를 생성하는 문제를 개선함과 동시에 이미지의 품질을 개선하였다.

2.3.2 FastGAN

일반적인 GAN 모델은 연산량이 많고, 많은 학습 데이터가 필요하므로 데이터의 수가 적고 컴퓨팅 자원이 한정되어있는 경우에서 적용하기 어려웠다. 또한, GAN은 고해상도 학습에 어려움이 있었다. 이러한 문제를 해결하기 위해 FastGAN은 generator의 각각의 해상도마다 하나의 convolution layer를 사용하며 512x512 이상의 고해상도에서 convolution layer에서 하나의 channel만 사용하였다. 이에 따라 빠르고 안정적인 학습 속도와 고해상도 이미지 생성에 좋은 성능을 보여주었다.

2.3.3 FastGAN-Lite

Projected-GAN 모델을 개발하며 만든 모델로 FastGAN에서 Bigblock을 이용하여 각 convolution layer에 noise injection 작업이 있어 계산비용이 많이 들며 자원이 많이 필요했다. 이와 달리 FastGAN-Lite에서는 Smallblock을 이용해 noise injection 과정이 생략되어 모델을 간소화하고 계산 복잡성을 줄였지만 적은 리소스와 데이터에서도 효율적인 이미지를 생성할 수 있게 되었다.

2.4 수행과정


학습은 NVIDIA GeForce RTX 3080 Ti Laptop GPU를 사용하여 하이퍼파라미터를 조정된 결과, 최종 모델을 학습하는 데 약 10시간의 학습시간을 소요하였다. 비 공기압 타이어의 데이터를 학습한 모델이 없으므로 전이 학습을 적용하지 않은 초기 모델로 진행하였다. 사용된 파라미터들은 다음 [표 2]에 정리하였다.

[표 2] 하이퍼파라미터

종류	값	설명
cfg	fastgan_lite	생성 모델명
data	비공기압 타이어	데이터셋 경로
gpus	1	그래픽카드 개수
batch	256	배치 사이즈
cond	False	조건부 학습
mirror	0	데이터 증강 (뒤집은 이미지)
batch_gpu	16	gpu당 배치 사이즈
cbase	65536	모델 용량
cmax	256	복잡도 값
glr	None	생성모델 학습률
dlr	0.002	판별모델 학습률
king	1000	학습장수(1k=1000)
tick	4	진행 상황 출력빈도
snap	1	스냅샷
seed	0	시드값
workers	0	cpu 스레드 개수
restart	999999	시간 간격 설정

3. 결과 및 토의

Projected GAN의 모델 수행 결과는 [그림 3]과 같다. 데이터셋의 구조가 모두 동일한 원형이 들어가면서 타이어의 원형 패턴에 가까운 결과를 생성하였다. 데이터가 부족하여 다양성 면에서 다소 부족한 것을 알 수 있으며 결과적으로 Projected GAN은 학습 면에서는 굉장히 빠르게 타이어에 유사한 이미지에 수렴할 수 있는 걸 확인했다. 다만, 이미지를 생성할 때 학습된 모델의 이미지들은 패턴을 미세하게 변경하여 가지고 있어 실제로 확인했을 땐 중간마다 같은 결과가 생성되는 것처럼 보인다.



[그림 3] 생성 이미지

4. 결론

본 논문에서는 실존하거나 패턴이 있는 도면 이미지 디자인을 이용하여 병합하거나 새로운 디자인을 생성하기 위해 연구되었다. 이에 따라 Projected GAN을 통해 기존의 GAN 모델들보다 더욱 빠른 학습과 일관성이 있는 이미지를 생성하는 것을 확인했다. 또한, 생성된 이미지는 독창성이 부족하나 어느 정도의 패턴을 숙지하는 것을 확인했다. 추후 더 많은 데이터셋을 수집하고 이에 적합한 모델과 세팅을 통하여 심미성이 돋보이고 온전한 이미지를 생성할 수 있도록 개선할 예정이다.

사사

본 논문은 산업통상자원부 디자인혁신역량강화(2023) 사업의 지원으로 작성되었음.

참고문헌

- [1] 김기운, 박철우(2019). 비공기압 타이어의 기술동향, 문제점 및 해결방안 소개,오��저널41(10),26-31.
- [2] 車 주요뉴스, 펑크 위험 없는 ‘비공기압’ 타이어? - 또 유가 상승 - 전기차 충전 주유소에서? [모터그램]
- [3] 조영주, 배강민, 박종열, “GAN 적대적 생성 신경망과 이미지 생성 및 변환 기술 동향”, 전자통신동향분석 35권 제4호, pp. 91-102, 8월, 2020년
- [4] Axel Sauer, Kashyap Chitta, Jens Müller, and Andreas Geiger, “Projected GANs Converge Faster”, NeurIPS 2021
- [5] Tero Karras, Samuli Laine, Miika Aittala, Janne Hellsten, Jaakko Lehtinen, Timo Aila, “Analyzing and Improving the Image Quality of StyleGAN”, arxiv 2019
- [6] Bingchen Liu, Yizhe Zhu, Kunpeng Song, Ahmed Elgammal, “Towards Faster and Stabilized GAN Training for High-fidelity Few-shot Image Synthesis”, ICLR 2021
- [7] Tero Karras, Samuli Laine, Timo Aila, “A Style-Based Generator Architecture for Generative Adversarial Networks”, CVPR 2018