

Generative Adversarial Networks 의 응용 현황

김동욱, 김세송, 정승원
동국대학교 멀티미디어공학과
e-mail : kimdongwook@dongguk.edu

Applications of Generative Adversarial Networks

Dong-Wook Kim, Sesong Kim, and Seung-Won Jung
Dept. of Multimedia Engineering, Dongguk University

요약

Generative adversarial networks (GAN)에 대한 간략하게 설명하고, MNIST (숫자 손 글씨 데이터 셋)를 이용한 간단한 실험을 통해 GAN 구조 구조의 이해를 돋는다. 그리고 GAN 이 어떻게 응용이 되고있는지 다양한 논문들을 통해 살펴본다. 본 고에서는 GAN 논문들을 크게 이미지 스타일 변경, 3D 오브젝트 추정, 손상된 이미지 복원, 언어의 시각화, 기타 등으로 분류하였다.

1. 서론

“내가 다시 창조할 수 없는 것은 내가 이해한 것 이 아니다.” - 물리학자 리처드 파인만

기존의 인공신경망을 학습시키는 방법으로는 개와 고양이를 구분하고, 음성을 인식을 할 수는 있었지만 개를 직접 그리거나 음성을 만들지는 못했다. 그런데 GAN은 이미지 등을 직접 만들 수 있다. 기존에 오토인코더(Autoencoder)나 RBM(Restricted Boltzmann machine) 등이 비지도학습을 통해 이미지를 생성할 수 있었지만 GAN은 기존의 기술보다 큰 성과를 보여주고 있다. GAN은 몬드리올 대학의 Ian Goodfellow가 2014년에 NIPS에 제출한 논문이다. 특히 Nips 2016에서 가장 뜨거운 키워드로 GAN이 주목되면서 큰 이슈가 되었다. 페이스북의 Yann LeCun이 지난 10년간 있었던 머신 러닝 연구 중 가장 재미있는 아이디어라고 평했던 GAN에 대해 본 고에서는 그 원리에 대한 간단한 설명과 현재 어떻게 응용되고 연구되고 있는지 서술하고자 한다.

2. 본론

GAN은 이름 그대로 경쟁적으로 무엇인가 생성하는 네트워크이다. GAN은 두개의 네트워크로 구성된다. 하나는 무엇인가(이미지 등)을 생성하는 네트워크이다. Generator라고 한다. 다른 하나는 생성된 무엇인가(이미지 등)가 제대로 생성되었는지 판별하는 네트워크이다. Discriminator라고 한다. Goodfellow의 GAN 논문에서는 Generator을 위조지폐 범에 비유하고, Discriminator는 위조지폐 범을 잡는 경찰에 비유하였다. Generator은 최대한 진짜 같은 위조지폐를 만든다. 반면 Discriminator은 지폐가 진짜인지 가짜

인지 판별한다. 이때 위조지폐 범과 경찰이 서로 경쟁적으로 학습을 하게 되면 최종적으로 위조지폐 범은 진짜 같은 위조지폐를 만들 수 있게 된다. 그럼 (1)은 GAN에 대한 간단한 실험 결과이다. MNIST를 학습을 시켜 Generator가 진짜 같은 손 글씨를 생성할 수 있게 하였다. MNIST는 구조가 간단하여 간단한 fully connected layer만 사용해도 학습이 가능하다. 그림 (1)은 Generator와 Discriminator에 대한 예시이다. (a)는 Generator이다. Input layer에 크기가 10이 Noise를 넣어주었다. Hidden Layer의 크기는 256으로 해주었다. 결과로 28 * 28 크기의 Fake image가 생성된다. (b)는 Discriminator이다. Input layer에 28 * 28 크기의 Fake image나 Real image를 넣어주었다. Hidden layer의 크기는 Generator와 같이 256으로 해주었다. 입력이 Fake image면 0을, 입력이 Real image면 1을 출력하도록 학습한다. (c)는 MNIST 60000 장 이미지에 대해 200번 학습 시킨 후 생성한 결과 이미지 10개이다.

GAN 자체의 이론은 굉장히 단순하지만, Generator와 Discriminator의 구조를 CNN과 Batch normalization 등을 사용하여 더욱 복잡하게 만들 수 있다. 그럼 (2)는 DCGAN을 사용하여 생성한 얼굴 이미지들이다. DCGAN은 기본적인 구조는 위의 그림 (1)의 이미지와 같지만 Generator와 Discriminator의 구조가 좀더 깊고 복잡하다. GAN은 얼굴 외에도 학습의 대상과 방법에 따라 다양한 결과물을 생성할 수 있다. GAN을 어떻게 하면 더 효과적으로 학습을 시켜서 더 완벽한 결과를 만들 수 있을지에 대한 연구도 중요하지만 응용을 어떻게 할 것인지도 그만큼 중요하다. 아래에서는 GAN이 지금까지 어떤 식으로 응용되고 있는지 서술한다.

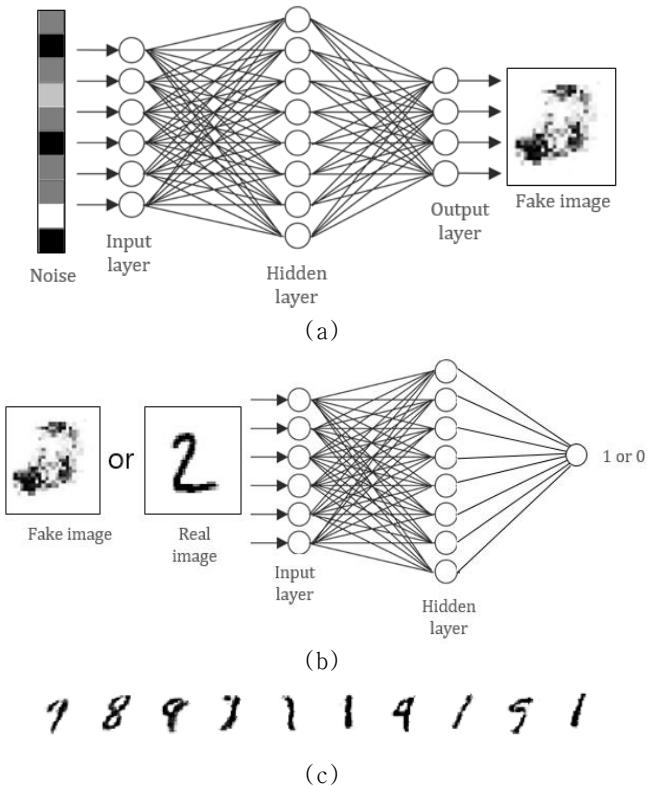


그림 (1) (a) Generator, (b) Discriminator, (c) 결과 이미지



그림 (2) DCGAN을 사용하여 생성한 얼굴 이미지

2.1. 이미지의 스타일 변경

GAN을 이용하여 입력 이미지 스타일을 바꾸는 연구는 GAN이 이슈가 되는데 큰 역할을 한 분야이다.[1] 입력한 이미지에 추가로 다른 이미지를 넣으면 추가 이미지의 스타일대로 입력 이미지를 바꿔준다. 이와 비슷하게, 흑백 이미지를 넣으면 컬러 이미지로 색칠해주거나[2], 스케치한 그림을 넣으면 색칠을 해주는 것[3], 실제 이미지를 캐릭터처럼 바꿔주는 것 또는 반대로 캐릭터 이미지를 실제 이미지처럼 바꿔주는 것[4] 등이 있다.

2.2. 3D 오브젝트 추정

2D 또는 2.5D 이미지를 토대로 3D 오브젝트의 모양을 추정하는 것도 가능하다. 2D 또는 2.5D 이미지의 가구를 입력으로 받아 3D의 모델로 만들어주거나[5], 손의 일부를 보고 손가락 전체 모양을 예측하는 것[6], 또는 사람 이미지에서 뼈대 모양을 추정해서 팔과 다리의 위치를 추정하는 것[7] 등이 있다.

2.3. 손상된 이미지 복원

이미지의 손상된 부분을 복원하는 것은 없는 부분을 생성하는 것이기 때문에 GAN을 이용하기에 적합하다. 저화질의 이미지를 고화질로 바꿔주는 것[8], jpeg 등의 압축을 통해 생긴 손상을 복원하는 것[9, 10] 또는 비가 내리는 풍경 이미지에서 비를 제거해주는 것[11] 등이 있다.

2.4. 언어의 시각화

문장을 읽고 문장에 알맞은 상황을 그림으로 그려주는 것[12] 또는 그림으로부터 상황을 설명하는 문장으로 만들어 주는 것[13]이 있다.

2.5. 기타

입력 이미지에서 Saliency map을 추정하는 것이 있다[14]. 두개의 비슷한 이미지를 아주 그럴 듯하게 합성해 주는 것이 있다[15]. DCGAN이 얼굴을 생성하듯 지형 데이터를 생성한다[16]. CT촬영 이미지를 보정하거나 이미지 안의 암 등을 찾는다[17]. 아주 짧은 동영상을 생성하거나[18], 비디오의 다음 프레임을 예측해서 생성한다[19].

3. 결론

지금까지 GAN이 무엇인지, 어떻게 응용되고 있는지를 살펴보았다. 본 고를 통하여 GAN이 다양한 분야에서 성과를 낼 수 있기를 기대한다.

참고문헌

- [1] Li, C., & Wand, M. (2016, October). Precomputed real-time texture synthesis with markovian generative adversarial networks. In European Conference on Computer Vision (pp. 702-716). Springer International Publishing.
- [2] Cao, Y., Zhou, Z., Zhang, W., & Yu, Y. (2017). Unsupervised Diverse Colorization via Generative Adversarial Networks. arXiv preprint arXiv:1702.06674.
- [3] Liu, Y., Qin, Z., Luo, Z., & Wang, H. (2017). Auto-painter: Cartoon Image Generation from Sketch by Using Conditional Generative Adversarial Networks. arXiv preprint arXiv:1705.01908.
- [4] Zhu, J. Y., Park, T., Isola, P., & Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. arXiv preprint arXiv:1703.10593.
- [5] Yang, B., Wen, H., Wang, S., Clark, R., Markham, A., & Trigoni, N. (2017). 3D Object Reconstruction from a Single Depth View with Adversarial Learning. arXiv preprint arXiv:1708.07969.
- [6] Wan, C., Probst, T., Van Gool, L., & Yao, A. Crossing Nets: Combining GANs and VAEs with a Shared Latent Space for Hand Pose Estimation.
- [7] Chen, Y., Shen, C., Wei, X. S., Liu, L., & Yang, J. (2017). Adversarial PoseNet: A Structure-aware Convolutional Network for Human Pose Estimation.

- arXiv preprint arXiv:1705.00389.
- [8] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2016). Photo-realistic single image super-resolution using a generative adversarial network. arXiv preprint arXiv:1609.04802.
 - [9] Galteri, L., Seidenari, L., Bertini, M., & Del Bimbo, A. (2017). Deep Generative Adversarial Compression Artifact Removal. arXiv preprint arXiv:1704.02518.
 - [10] Guo, J., & Chao, H. (2016). One-to-Many Network for Visually Pleasing Compression Artifacts Reduction. arXiv preprint arXiv:1611.04994.
 - [11] Zhang, H., Sindagi, V., & Patel, V. M. (2017). Image De-raining Using a Conditional Generative Adversarial Network. arXiv preprint arXiv:1701.05957.
 - [12] Zhang, H., Xu, T., Li, H., Zhang, S., Huang, X., Wang, X., & Metaxas, D. (2016). Stackgan: Text to photo-realistic image synthesis with stacked generative adversarial networks. arXiv preprint arXiv:1612.03242.
 - [13] Liang, X., Hu, Z., Zhang, H., Gan, C., & Xing, E. P. (2017). Recurrent Topic-Transition GAN for Visual Paragraph Generation. arXiv preprint arXiv:1703.07022.
 - [14] Pan, H., & Jiang, H. (2017). Supervised Adversarial Networks for Image Saliency Detection. arXiv preprint arXiv:1704.07242.
 - [15] Wu, H., Zheng, S., Zhang, J., and Huang, K. 2017. Grgan: Towards realistic high-resolution image blending. arXiv:1703.07195
 - [16] Beckham, C., & Pal, C. (2017). A step towards procedural terrain generation with GANs. arXiv preprint arXiv:1707.03383.
 - [17] Yi, X., & Babyn, P. (2017). Sharpness-aware Low dose CT denoising using conditional generative adversarial network. arXiv preprint arXiv:1708.06453.
 - [18] Tulyakov, S., Liu, M. Y., Yang, X., & Kautz, J. (2017). MoCoGAN: Decomposing Motion and Content for Video Generation. *arXiv preprint arXiv:1707.04993*.
 - [19] Liang, X., Lee, L., Dai, W., & Xing, E. P. (2017). Dual Motion GAN for Future-Flow Embedded Video Prediction. arXiv preprint arXiv:1708.00284.