

GAN 압축을 위한 선생 생성자 유도 학생 판별자 정규화

김현진^o, 여상엽, 유재준

울산과학기술원 인공지능대학원

hyeonjin.kim@unist.ac.kr, sosick377@unist.ac.kr, jaejun.yoo@unist.ac.kr

요약

최근 생성적 적대 신경망(GANs)의 발전이 컴퓨터 비전 분야에서 뛰어난 성능을 보여주면서, 이를 엣지 장치(Edge devices)에 탑재하는 것에 대한 관심이 높아지고 있다. 그러나 생성적 적대 신경망의 높은 메모리 사용량과 연산량은 제한된 용량과 연산능력을 가진 엣지 장치에 적용하기 어려움을 야기하였고, 이는 효율적인 GAN 압축 기술의 필요성을 부각시켰다. 이를 해결하기 위해 여러 논문들이 선생 생성자(Teacher generator) 및 판별자(Teacher discriminator)와 학생 생성자(Student generator)간 지식 증류기법(Knowledge distillation), 학생 생성자(Student generator)와 학생 판별자간 격차보완기법을 제시하였지만, 선생 생성자와 학생 판별자간 지식 증류에 대한 연구는 아직 부족한 상황이다. 본 연구에서는 선생 생성자와 학생 판별자간 지식 증류의 필요성에 대해 논의하고, 해당 증류기법이 GAN 압축 성능을 향상시킬 수 있음을 실험적으로 보였다.

1. 서론

생성적 적대 신경망(GANs)[1]은 뛰어난 생성능력으로 이미지 생성[6,7,8,10], 이미지 변환[2,3,4,5,9], 이미지 편집[11,12] 등 컴퓨터 비전 분야 전반에서 최상위의 성능을 보였다. 그들의 고유한 성능과 범용성으로 인해 휴대전화나 폐쇄회로 텔레비전, 위성과 같은 엣지 장치(Edge devices)에 탑재하는 것에 대한 관심이 높아지고 있다. 하지만 최신 생성적 적대 신경망은 높은 연산량 및 메모리 요구량, 큰 모델 사이즈를 필요로 하여, 현장에서의 실사용이 크게 제한되고 있는 상황이다.

신경망의 효율적 사용을 위한 신경망 압축 기술 연구(Neural network compression)는 오랫동안 관심 받아온 분야로써, 분류 모델을 위한 가중치 양자화[13,14], 모델 경량화[15,16], 지식 증류법[17,18] 등 다양한 연구가 진행되었다. 하지만, 분류 모델에서의 신경망 압축 기술은 생성적 적대 신경망의 고유의 적대적 학습기법(Adversarial training)을 특성을 고려하지 못하기 때문에 생성적 적대 신경망에 적용시 좋지 못한 성능을 내지 못하는 경우가 많다.

이러한 배경에서 생성적 적대 신경망의 특성을 고려한 다양한 연구들이 소개되었다. GAN Slimming[19]은 모델 경량화(Model pruning)와 지

식 증류(Knowledge distillation)를 위해 인지 손실 함수(Perceptual loss) 도입 및 손실 함수를 통합하였고, GCC[20], DCD[21]은 선생 생성자(Teacher generator) 및 판별자(Teacher discriminator)의 지식을 효과적으로 학생 생성자(Student generator)에게 증류하기 위해 신경망의 중간 특성 맵(Intermediate feature maps)을 활용하여 손실 함수를 구축하였다. GCC의 경우 추가로 학생 생성자와 학생 판별자의 모델 성능 격차를 줄이기 위해 선택적 활성화 판별자(Selective activation discriminator)를 도입하였다. CAGC[22]은 영상 분할 모델(Image segmentation network)을 활용하여 선생 생성자의 결과의 의미론적 정보(Semantic contents)를 우선적으로 학생 생성자에게 증류하였다.

하지만 이 연구들은 대부분 선생 생성자 및 판별자의 지식을 학생 생성자에게 직접적으로 증류하는 방법에 초점을 맞추었을 뿐, 선생 생성자와 학생 판별자(Student discriminator)간 지식 증류에 대한 연구는 거의 이루어지지 않았으며, 생성자의 학습 성능은 판별자와의 관계에서 크게 좌우된다는 사실을 간과한다.

이 문제들을 해결하기 위해, 본 연구에서는 판별자의 특성을 분석한 뒤, 선생 생성자와 학생 판별자간 지식 증류의 필요성에 대해 논의한다. 또한, 선생 생성자와 학생 판별자간 지식 증류가 GAN 압축 성능 향상에 기여함을 실험적으로 보인다.

2. 관련 연구

2.1 생성적 적대 신경망(GANs)

생성적 적대 신경망은 생성자(Generator) G 와 판별자(Discriminator) D 간의 경쟁(Min-max game)을 통해 생성자를 학습시킨다. 생성적 적대 신경망의 최적화 문제는 다음과 같이 표현된다.

$$\min_G \max_D \mathcal{L}_{GAN} = \mathbb{E}_{x \sim P_{data}} [\log D(x)] + \mathbb{E}_{z \sim P(z)} [1 - \log(G(z))]$$

여기서, P(z)는 표준 정규 분포와 같은 사전 분포이며, 생성자 G는 새로운 샘플을 생성하고, 판별자 D는 실제 데이터와 생성된 샘플을 구분하도록 학습된다. 생성자와 판별자가 이상적으로 최적화되었을 때, 판별자는 생성자가 생성하는 영상과 실제 영상을 구분하지 못하고, 판별자가 두 영상에 대해 동일한 점수를 부여하는 내쉬 균형(Nash equilibrium)에 도달한다. 생성자와 판별자가 경쟁하는 과정에서 생성적 적대 신경망은 [30,31]와 같은 다른 생성모델보다 뛰어난 생성능력을 보여왔다.

2.2 GAN 압축 기술(GAN compression)

GAN 압축 기술은 크게 생성자 축소(Generator pruning)와 지식 증류(Knowledge distillation)으로 이루어져 있다. 생성자 축소는 원본 생성자의 생성능력을 최대한 유지한 채 생성자를 축소하는 것을 목표로 하고[19,21], 지식 증류[19,20,21,22]는 축소된 생성자를 학생 생성자, 원본 생성자를 선생 생성자로 취급하여 선생 생성자의 지식을 학생 생성자에게 효과적으로 증류하는 것을 목표로 한다. 선생 생성자와 학생 생성자간 지식 증류는 다음과 같이 표현된다.

$$\min_{G_S} \mathcal{L}_{KD} = \mathbb{E}_{z \sim P(z)} [d(g(f(G_S(z))), g(G_T(z)))]$$

G_S : 학생 생성자, G_T : 선생 생성자

여기서 $d(\cdot, \cdot)$ 는 두 값을 비교하는 거리함수, $g(\cdot)$ 는 추가적인 조작 함수, $f(\cdot)$ 는 학생 생성자의 축소된 채널을 선생 생성자에 맞추기 위한 함수(주로 1x1 합성곱(Convolution))이다. 예를 들어, CAGC[22]의 경우 $g(\cdot)$ 는 선생 생성자의 의미론적 정보를 추출하는 이미지 분할 마스크이며, $d(\cdot, \cdot)$ 는 L1 손실 함수와 LPIPS 인지 손실 함수[23]로 이루어져 있다.

하지만 기존 GAN 압축 기술들은 선생 생성자의 지식을 학생 생성자에게 증류하는 것만을 고려할 뿐, 학생 생성자의 학습 성능에 크게 영향을 끼치는 학생 판별자와의 관계에는 고려하지 않는다.

따라서 본 연구에서는 선생 생성자와 학생 판별자간 지식 증류에 대해 분석 및 실험을 진행하였다.

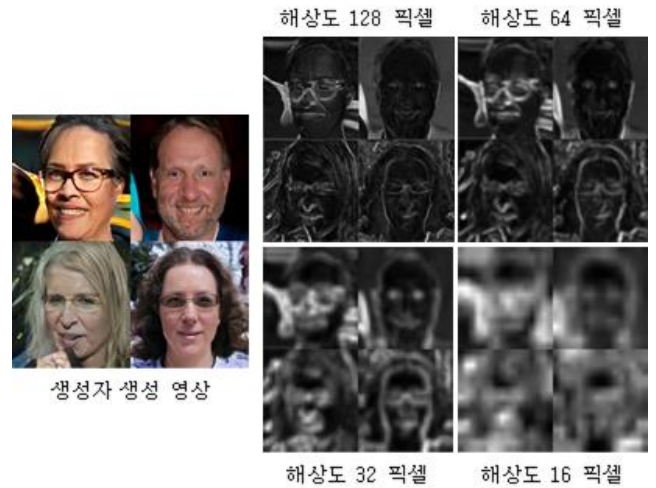


그림 1. 판별자 중간 특성 맵 해상도별 경사 클래스 활성화 맵. 생성자 생성 영상과 판별자의 경사 클래스 활성화 맵을 비교해 보았을 때, 판별자가 영상의 경계면에 집중하는 것을 확인할 수 있다.

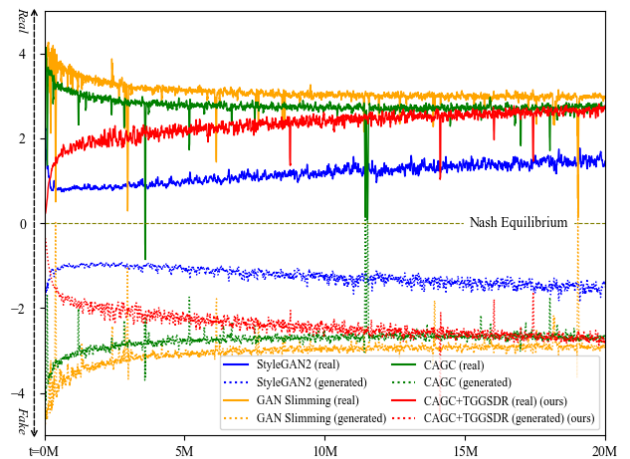


그림 2. GAN 압축 기법별 판별자 점수 도식. 이상적인 경우 생성된 영상과 실제 영상에 대해 판별자의 점수가 0이 되는 내쉬 균형에 도달한다. 압축된 생성자의 경우 판별자가 원본 생성자보다 생성된 영상과 실제 영상을 쉽게 구분하면서 실제 영상과 생성된 영상에 대한 판별자의 점수차가 커지는 내쉬 균형의 악화가 일어나는 것을 확인할 수 있다 (GAN Slimming, CAGC). 선생 생성자 학생 판별자 정규화를 도입할 경우 실제 영상과 생성된 영상에 대한 판별자의 점수 차가 줄어들면서 상대적으로 내쉬 균형이 개선된 것을 확인할 수 있다.

3. 선생 생성자 - 학생 판별자간 지식 증류

이 문단에서는 선생 생성자와 학생 판별자간 지식 증류의 필요성과 구체적인 기법을 묘사한다.

3.1 판별자의 집중 영역 분석

우리는 효과적인 선생 생성자와 학생 판별자간 지식 증류를 위해 먼저 판별자가 입력 영상의 진위 여부를 판단하기 위해 집중하는 정보에 대해 클래스 활성화 맵(Class activation map, CAM)[24]을 분석하였다. 클래스 활성화 맵은 분류 모델에서 특정 클래스 분류에 기여하는 신경망 중간 특성 맵(Intermediate features)을 추출하기 위한 기법으로 해당 클래스에 대한 중간 특성 맵의 가중합을 구한다. 가중합의 가중치를 구하는 방법에 따라 다양한 연구가 소개되었으며, 본 연구에서는 가장 범용적인 경사 클래스 활성화 맵(GradCAM)[25]을 사용하여 판별자의 진위여부에 기여하는 중간 특성 맵을 시각화하였다 (그림 1). 판별자의 경사 클래스 활성화 맵에서 볼 수 있듯이 판별자는 입력 영상의 진위 여부 판단을 위해 입력 영상의 경계면에 집중하는 것을 관찰할 수 있다. 이러한 판별자의 특성은 압축으로 인해 성능 저하로 인해 영상 경계면 생성에 취약해진 학생 생성자에게 불리하게 작용한다. 이 결과, 판별자는 생성자가 생성한 영상과 실제 영상을 더욱 잘 구분하게 되며, 판별자가 실제 영상에는 더 높은 점수를, 생성된 영상에는 더 낮은 점수를 주게 되며, 두 점수간의 격차가 커지는 내시 균형(Nash equilibrium)의 악화가 일어나는 것을 확인할 수 있다 (그림 2).

3.2 선생 생성자 유도 학생 판별자 정규화 (Teacher generator-guided student discriminator regularization)

판별자가 입력 영상의 경계면에 집중한다는 사실과 영상의 전반적인 정보는 영상의 의미론적 정보에 기반한다는 사실을 기반으로 우리는 학생 판별자가 입력 영상의 의미론적 정보를 학습할 수 있도록 선생 생성자 유도 학생 판별자 정규화를 도입하였다. 최근 OASIS[26] 및 GGDR[27]은 생성자의 중간 특성 맵이 생성되는 영상의 의미론적 정보를 대략적으로 보유하고 있음을 보였다. 여기서 더 나아가 GGDR은 판별자에 U-Net[28] 기반 업샘플링을 통해 마지막 계층 특성 맵으로부터 생성자의 중간 특성 맵을 복원하도록 하여 판별자가 생성자의 의미론적 부분에도 집중할 수 있도록 하였다.

GGDR 을 기반으로 우리는 학생 판별자가 선생 생성자의 중간 특성 맵을 복원하도록 하여 학생 판별자를 정규화 하였다. 정규화 식은 다음과 같다.

$$\max_{D_S} \mathcal{L}_{TGGSDR} = \mathbb{E}_{z \sim P(z)} \left[d_{\cos} \left(D'_S(G_T(z)), G'_T(z) \right) \right],$$

$d_{\cos}(\cdot, \cdot)$: 코사인 유사도

여기서 $D'(G(z))$ 는 판별자의 마지막 특성 맵으로부터 복원된 중간 특성 맵이며, $G'(z)$ 는 생성자의 중간 특성 맵이다. 학생 판별자로부터 복원된 중간 특성 맵과 선생 생성자의 중간 특성 맵 사이의 코사인

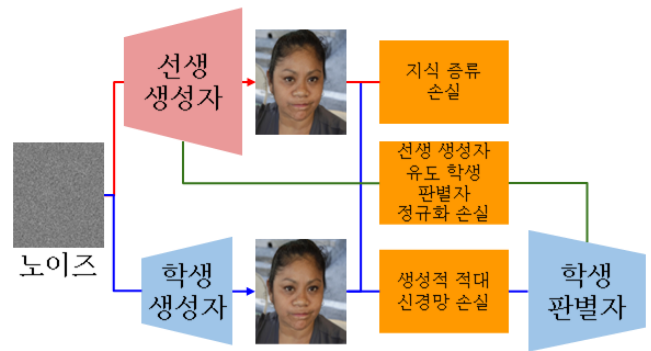


그림 3. 선생 생성자 유도 학생 판별자 정규화를 포함한 GAN 압축 학습 도식. 학생 생성자는 학생 판별자와의 기존의 생성적 적대 신경망 손실과 선생 생성자와의 지식 증류 손실을 통해 학습된다. 한편, 학생 판별자는 생성적 적대 신경망 손실 및 선생 생성자와의 선생 생성자 유도 학생 판별자 정규화 손실을 통해 학습된다.

표 1. 채널 압축률 70%에서의 GAN 압축 기법 별 FID 점수.

기법	FID (↓)
StyleGAN2 (Full Size)	5.322
압축된 생성자	
GAN Slimming	10.013
CAGC	9.967
CAGC+TGGSDR (Ours)	8.655

유사도를 높여 나감으로써 학생 판별자는 선생 생성자의 의미론적 정보를 학습할 수 있다. 우리는 이 정규화 기법을 선생 생성자 유도 학생 판별자 정규화(Teacher generator-guided student discriminator regularization, TGGSDR)이라고 명명하였다. 선생 생성자 유도 학생 판별자 정규화를 포함한 GAN 압축 기법의 전체 학습 과정은 그림 3. 에 묘사되었으며, 최적화 문제는 다음으로 표현된다.

$$\min_{G_S} \max_{D_S} \mathcal{L}_{total} = \mathcal{L}_{GAN} + \alpha \mathcal{L}_{KD} + \beta \mathcal{L}_{TGGSDR}$$

4. 실험 결과 및 분석

제시된 선생 생성자 유도 학생 판별자 정규화 기법의 실험 환경 설정은 다음과 같다. 데이터셋은 256 픽셀 해상도의 고품질의 얼굴 영상으로 이루어진 FFHQ[6] 데이터셋에서 실험하였다. 압축할 생성적 적대 신경망은 StyleGAN2[6]를 활용하였으며, 학습률(Learning rate)를 포함한 생성적 적대 신경망의 학습 환경은 StyleGAN2의 환경을 따랐다. 선생 생성자 유도 학생 판별자 정규화를 위한 손실 함수는 CAGC[22]에 추가되었으며 하이퍼파라미터 α 는 3, β 는 10으로 설정되었다. 모든 실험에서 생성자의 계층별 채널의 압축률은 70%이며,



그림 3. StyleGAN2 와 선생 생성자 유도 학생 판별자 정규화를 사용한 GAN 압축 생성자 생성 이미지.

모든 실험에서 총 20000k 개의 영상을 학습시켰다. 실험된 GAN 압축 기법의 성능은 FID(Fr chet inception distance)[29]로 측정되었으며, 실험 결과는 표 1.에 기재되었다.

실험 결과는 선생 생성자 유도 학생 판별자 정규화 기법이 기존의 GAN 압축 기법에 성능을 더욱 향상시켜줄 수 있음을 보여준다. 이는 학생 판별자가 선생 생성자의 의미론적 부분을 학습함으로써 학생 생성자가 학생 판별자를 통해 선생 생성자의 지식을 간접적으로 증류 받을 수 있으며, 학생 자가 학생 생성자에 비해 과도하게 강해지는 것을 방지하고, 그림 2. 에서 볼 수 있듯이, 기존의 GAN 압축 기법에 비해 판별자의 실제 영상-생성된 영상간 점수차가 줄어들어 내시 균형이 향상되었으며, 학생 생성자와 학생 판별자가 균형 있게 학습되는 것으로 볼 수 있다. 각 GAN 압축 기법을 통해 압축된 생성자로부터 생성된 영상은 그림 3.에서 확인할 수 있다.

5. 결론

본 논문에서는 선생 생성자의 의미론적 정보가 학생 판별자를 효과적으로 정규화 할 수 있음을 보였으며, 이를 통해 기존 GAN 압축 기법의 성능을 향상시켜줄 수 있음을 확인하였다.

감사의 글

이 논문은 2022 년도 정부(과학기술정보통신부)의

재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2020-0-01336, 인공지능대학원지원(울산과학기술원), No.2022-0-00959, (2 세부) 의 사결정 지원을 위한 퓨샷 학습 기반 시각 및 언어에 대한 인과관계 추론기술개발)

참고문헌

- [1] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2014). Generative Adversarial Nets. In Z. Ghahramani, M. Welling, C. Cortes, N. Lawrence, & K. Q. Weinberger (Eds.), *Advances in Neural Information Processing Systems* (Vol. 27).
- [2] P. Isola, J. -Y. Zhu, T. Zhou and A. A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 5967-5976, doi: 10.1109/CVPR.2017.632.
- [3] J. -Y. Zhu, T. Park, P. Isola and A. A. Efros, "Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks," 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017, pp. 2242-2251, doi: 10.1109/ICCV.2017.244.
- [4] K. Baek, Y. Choi, Y. Uh, J. Yoo and H. Shim, "Rethinking the Truly Unsupervised Image-to-Image Translation," 2021 IEEE/CVF International Conference on Computer Vision (ICCV), Montreal, QC, Canada, 2021, pp. 14134-14143, doi: 10.1109/ICCV48922.2021.01389.
- [5] J. Park et al., "LANIT: Language-Driven Image-to-Image Translation for Unlabeled Data," 2023

- IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, BC, Canada, 2023, pp. 23401-23411, doi: 10.1109/CVPR52729.2023.02241.
- [6] T. Karras, S. Laine and T. Aila, "A Style-Based Generator Architecture for Generative Adversarial Networks," 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019, pp. 4396-4405, doi: 10.1109/CVPR.2019.00453.
- [7] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen and T. Aila, "Analyzing and Improving the Image Quality of StyleGAN," 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 8107-8116, doi: 10.1109/CVPR42600.2020.00813.
- [8] Karras, T., Aittala, M., Laine, S., Härkönen, E., Hellsten, J., Lehtinen, J., & Aila, T. (2021). Alias-Free Generative Adversarial Networks. In M. Ranzato, A. Beygelzimer, Y. Dauphin, P. S. Liang, & J. W. Vaughan (Eds.), *Advances in Neural Information Processing Systems* (Vol. 34, pp. 852–863).
- [9] Y. Choi, Y. Uh, J. Yoo and J. -W. Ha, "StarGAN v2: Diverse Image Synthesis for Multiple Domains," 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 8185-8194, doi: 10.1109/CVPR42600.2020.00821.
- [10] Andrew Brock, Jeff Donahue, & Karen Simonyan (2019). Large Scale GAN Training for High Fidelity Natural Image Synthesis. In *International Conference on Learning Representations*.
- [11] R. Abdal, Y. Qin and P. Wonka, "Image2StyleGAN: How to Embed Images Into the StyleGAN Latent Space?," 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), 2019, pp. 4431-4440, doi: 10.1109/ICCV.2019.00453.
- [12] R. Abdal, Y. Qin and P. Wonka, "Image2StyleGAN++: How to Edit the Embedded Images?," 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 8293-8302, doi: 10.1109/CVPR42600.2020.00832.
- [13] Hubara, I., Courbariaux, M., Soudry, D., El-Yaniv, R., & Bengio, Y. (2016). Binarized Neural Networks. In D. Lee, M. Sugiyama, U. Luxburg, I. Guyon, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 29).
- [14] B. Jacob et al., "Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 2704-2713, doi: 10.1109/CVPR.2018.00286.
- [15] Han, S., Pool, J., Tran, J., & Dally, W. (2015). Learning both Weights and Connections for Efficient Neural Network. In C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 28).
- [16] Zhuang Liu, Mingjie Sun, Tinghui Zhou, Gao Huang, & Trevor Darrell (2019). Rethinking the Value of Network Pruning. In *International Conference on Learning Representations*.
- [17] Geoffrey Hinton, Oriol Vinyals, & Jeff Dean. (2015). Distilling the Knowledge in a Neural Network.
- [18] Adriana Romero, Nicolas Ballas, Samira Ebrahimi Kahou, Antoine Chassang, Carlo Gatta, & Yoshua Bengio. (2015). FitNets: Hints for Thin Deep Nets.
- [19] Wang, H., Gui, S., Yang, H., Liu, J., Wang, Z. (2020). GAN Slimming: All-in-One GAN Compression by a Unified Optimization Framework. In: Vedaldi, A., Bischof, H., Brox, T., Frahm, JM. (eds) *Computer Vision – ECCV 2020*. ECCV 2020. Lecture Notes in Computer Science(), vol 12349. Springer, Cham. https://doi.org/10.1007/978-3-030-58548-8_4
- [20] Li, S., Wu, J., Xiao, X., Chao, F., Mao, X., & Ji, R. (2021). Revisiting Discriminator in GAN Compression: A Generator-discriminator Cooperative Compression Scheme. In M. Ranzato, A. Beygelzimer, Y. Dauphin, P. S. Liang, & J. W. Vaughan (Eds.), *Advances in Neural Information Processing Systems* (Vol. 34, pp. 28560–28572).
- [21] T. Hu, M. Lin, L. You, F. Chao and R. Ji, "Discriminator-Cooperated Feature Map Distillation for GAN Compression," 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, BC, Canada, 2023, pp. 20351-20360, doi: 10.1109/CVPR52729.2023.01949.
- [22] Y. Liu, Z. Shu, Y. Li, Z. Lin, F. Perazzi and S. Y. Kung, "Content-Aware GAN Compression," 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, TN, USA, 2021, pp. 12151-12161, doi: 10.1109/CVPR46437.2021.01198.
- [23] R. Zhang, P. Isola, A. A. Efros, E. Shechtman and O. Wang, "The Unreasonable Effectiveness of Deep Features as a Perceptual Metric," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 586-595, doi: 10.1109/CVPR.2018.00068.
- [24] M. Oquab, L. Bottou, I. Laptev and J. Sivic, "Is object localization for free? - Weakly-supervised learning with convolutional neural networks," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015, pp. 685-694, doi: 10.1109/CVPR.2015.7298668.
- [25] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh and D. Batra, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization," 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017, pp. 618-626, doi: 10.1109/ICCV.2017.74.
- [26] Edgar Schönfeld, Vadim Sushko, Dan Zhang, Juergen Gall, Bernt Schiele, & Anna Khoreva (2021). You Only Need Adversarial Supervision for Semantic Image Synthesis. In *International Conference on Learning Representations*.
- [27] Lee, G., Kim, H., Kim, J., Kim, S., Ha, JW., Choi, Y. (2022). Generator Knows What Discriminator Should Learn in Unconditional GANs. In: Avidan, S., Brostow, G., Cissé, M., Farinella, G.M., Hassner, T. (eds) *Computer Vision – ECCV 2022*. ECCV 2022. Lecture Notes in Computer Science, vol 13677. Springer, Cham. https://doi.org/10.1007/978-3-031-19790-1_25

- [28] Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28
- [29] Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), Advances in Neural Information Processing Systems (Vol. 30).
- [30] Kingma, D. P., & Welling, M. (2013). Auto-Encoding variational Bayes. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1312.6114>
- [31] Kingma, D. P., & Dhariwal, P. (2018). Glow: Generative Flow with Invertible 1x1 Convolutions. In S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi, & R. Garnett (Eds.), Advances in Neural Information Processing Systems (Vol. 31)