

딥러닝 기반의 프린지 패턴 생성 네트워크 학습에 대한 최적화

*박선종 **김우석 ***서영호

광운대학교

*ok970601@kw.ac.kr **kws@kw.ac.kr ***yhseo@kw.ac.kr

Training Optimization for Fringe Pattern Generation Network Based on Deep Learning

*Sun-Jong Park **Woosuk Kim ***Young-Ho Seo

Kwangwoon University Electronic Material Engineering

요 약

본 논문에서는 프린지 패턴을 생성하는 딥러닝 기반의 WGAN-GP 네트워크의 최적화 방법을 제안한다. 기존의 복소 프린지 패턴 생성을 위한 GAN 모델은 생성의 정확도뿐만 아니라 학습의 안정성이 다소 부족하였다. 이에 따라 WGAN-GP 등의 업그레이드 된 방법을 사용하였지만, 네트워크 구조 및 파라미터에 따른 최적화가 필요하다. 보다 정확도 높은 정확도를 가진 프린지 패턴 생성을 위해 learning rate decay 사용하여 학습된 결과를 epoch 별 그래프로 최적화 전의 결과와 비교하고, 홀로그램과 복원 결과에 대한 PSNR 을 비교한다.

1. 서론

홀로그램은 주파수와 위상이 같은 참조파와 물체로부터 반사된 물체파 사이의 간섭현상을 기록하는 방법으로써 3 차원 정보를 기록할 수 있는 특징 때문에 많은 분야에서 연구와 개발이 이루어져 왔다. 더불어 아날로그 방식의 단점을 극복할 수 있는 디지털 홀로그램에 대한 연구가 활발하게 이루어지고 있으며[1], 현대에 컴퓨터의 급격한 발전과 딥러닝 분야의 발전에 힘입어, 딥러닝 네트워크를 통해서 홀로그램을 생성하는 연구도 진행되고 있다[2]. 위 연구에서는 딥러닝 네트워크 중에서도 생성 알고리즘인 GAN 모델에서 성능이 업그레이드된 WGAN-GP[3]를 통해서 생성한다. 하지만, GAN 모델 자체의 학습 안정성에 대해서는 아직 많은 연구가 필요하고, 활발하게 이루어지고 있다. 더불어 사용된 딥러닝 모델의 원래 목표는 홀로그램 생성이 아니었기 때문에, 홀로그램 데이터 셋에 대한 최적화 연구가 필요하다. 본 논문에서는 기존의 홀로그램 생성을 위한 딥러닝 네트워크의 학습에 대한 최적화 방법을 제안한다. 2 장에서 제안하는 방법론을 설명하고, 3 장에서 실험 결과를 보이고 분석한다. 마지막으로 4 장에서 결론을 맺는다.

2. 네트워크 최적화 방법

기존 딥러닝 기반 홀로그램 생성 연구[2]에서는 다소 불안한 train loss 로 인해 loss 가 발산하는 경우엔 학습율(Learning rate)를 감소시켜야 했다. 다만, loss 가 발산하는 것을 예측할 수 없기에, 사용자가 직접 조절하거나 저장된 epoch 별 가중치 중에 하나를 선택하여 전이 학습(Transfer learning) 을 할 수밖에 없다. 이를 step 또는 비선형적인 learning rate decay 방식을 사용하게 되면, 순간적으로 loss 의 변화가 증가하여 train loss 가 불안정해질 가능성이 높다. 따라서 비교적 선형적인 decay 기법 중에 cosine learning rate decay 방식을 적용하였다. 두 번째로 홀로그램의 복잡한 프린지 패턴을 더 많은 파라미터를 사용하여 좋은 성능을 보이기 위해 합성곱 층을 추가하였다.

3. 실험결과

홀로그램 데이터 세트구성은 다음과 같다. 객체 공간을 16x16x16 공간으로 설정하였고, 생성한 홀로그램의 크기는 128x128 의 가로 세로로 설정하였다. 홀로그램의 Pixel Pitch 는

6.4um, 객체의 각 포인트들 간의 간격은 200um 으로 설정하였다. 수학적 모델링을 통해 생성된 홀로그램인 CGH(Computer-Generated-Hologram)과의 정확도를 확인하기 위해서 PSNR 를 이용하였다. 합성곱 층을 증가시키는 실험에서는 기존의 네트워크 구조에서 개를 8 개로 증가시켰다.

그림 1 은 학습이 진행함에 따른 loss 와 PSNR 의 그래프이다. 그림 1(a)는 learning rate decay 를 적용하지 않은 결과이며, 그림 1(b)는 cosine decay 를 적용한 결과이다. 적용하지 않은 결과에서는 PSNR 이 점점 낮아지며, 학습이 불안정한 것을 볼 수 있다. 반면 cosine decay 를 사용한 것은 부족했던 학습의 안정성을 보완하여 PSNR 이 유지 및 증가되는 것을 볼 수 있다.

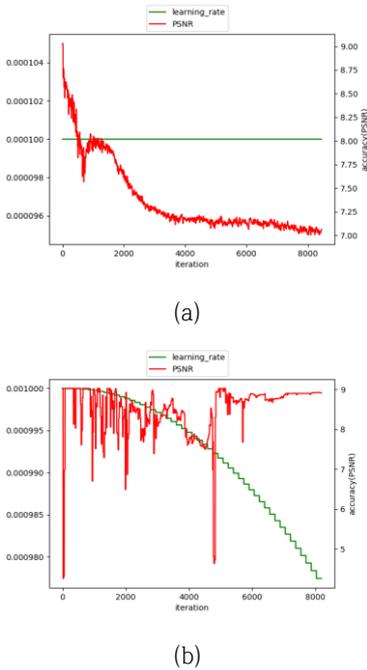


그림 1. 학습 결과 (a) learning rate decay 미사용, (b) cosine decay 사용
Fig. 1. Training results (a) disable learning rate decay, (b) using cosine decay

그림 2 는 합성곱 층을 증가시킨 것과 비교한 결과이다. 그림 2(a)는 기존의 층을 가지는 네트워크의 결과이고, 그림 2(b)는 합성곱 층을 증가시킨 결과이다. PSNR 과 loss 를 비교하였을 때, 합성곱 층을 증가시킨 쪽이 오히려 결과가 좋지 않은 것을 볼 수 있다. 이는 단순히 합성곱 층만 증가시켰을 때 발생할 수 있는 vanishing gradient, 파라미터 숫자 증가에 따른 필요 학습 수 증가 등이 이유가 될 수 있으며, 단순히 층을 늘리는 것이 아닌, 최적화된 모델 구조가 추가적으로 필요하다는 것을 알 수 있다.

4. 결론

본 연구에서는 learning rate decay 와 합성곱 층의 증가를 통해 홀로그램 생성을 위한 딥러닝 네트워크의 최적화 방법을 제안하였다. 제안한 방법 중에 학습률을 조정하는 방법은 홀로그램 생성을 위한 딥러닝 학습에 효과가 있음을 입증하였다. 합성곱 층을 증가시킨 결과는 비록 결과가 좋지 않았지만, 단순히 가중치를 증가시키는 것은 홀로그램을 학습하는데 좋은 영향을 보일 수 없으며, 보다 정확한 프린지 패턴을 생성하기 위한 네트워크 구조 관련 연구가 필요하다는 것을 증명하였다. 위 실험결과를 기반으로 이후에 진행될 딥러닝 기반의 홀로그램 생성 연구에 많은 도움을 줄 수 있을 것으로 기대한다.

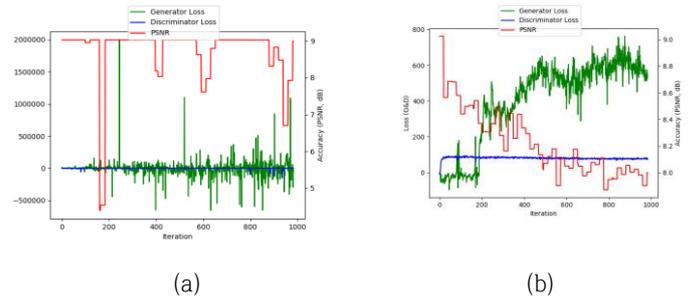


그림 2. 학습 결과 (a) 합성곱 층 = 4 개, (b) 합성곱 층 = 8 개
Fig. 2. Training results (a) convolution layer = 4, (b) convolution layer = 8

ACKNOWLEDGEMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임. (2020-0-00922, 다시점 영상기반의 홀로그래픽 스테레오그램 프린팅 기술 개발)

References

- [1] W. Osten, A. Faridian, P. Gao, K. Körner, D. Naik, G. Pedrini, Al. Kumar Singh, M. Takeda, and M. Wilke, "Recent advances in digital holography [Invited]," *Appl. Opt.* 53, pp. G44-G63, 2014.
- [2] J.W Kang, J.K. Kim, D.W. kim, Y.H. Seo, 24(1), "Optical Fringe Pattern Generation using Deep Learning", *The Korea Institute of Information and Communication Engineering*, 214-215, 7, 2020
- [3] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, and A. Courville, "Improved training of wasserstein GANS," *Advances in Neural Information Processing Systems*, pp. 5769-5779, 2017