

단일 Reverse Inception 기반의 딥러닝을 사용한 홀로그램 Super-Resolution

*김우석 **김동욱 ***서영호

광운대학교 전자재료공학과

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

Hologram Super-Resolution Using a Single Reverse Inception-based Deep Learning

*Kim, Woo-Suk **Kim, Dong-Wook ***Seo, Young-Ho

Dept. of Electronic Materials Eng., Kwangwoon University

요약

저해상도의 홀로그램을 Bilinear 및 Bicubic 등의 알고리즘을 이용하여 업 스케일링을 하는 방법도 있다. 하지만, 홀로그램 데이터의 손실이 매우 크게 발생하며, 이로 인한 화질 저하가 발생하게 된다. 본 논문에서는 기존에 요구되던 파라미터와 연산량, 메모리를 대폭 감소시키면서도 준수한 성능을 보이는 RCI 구조를 제안한다. 제안한 네트워크 구조는 준수한 성능을 보이면서도 기존 2D 이미지에 대한 SISR 네트워크보다 더 빠르고 더 적은 메모리를 사용하였다.

1. 서론

디지털 홀로그램에 대한 많은 연구가 진행되고 있지만, 고해상도의 홀로그램을 생성하기 위해선 여전히 많은 연산량과 메모리가 요구된다. 이러한 부분을 해결하기 위해 저해상도의 홀로그램을 Bilinear, Bicubic 등의 알고리즘을 이용하여 업 스케일링을 하는 방법도 있다. 하지만, 홀로그램 데이터의 손실이 매우 크게 발생하며, 이로 인한 화질 저하가 발생하게 된다. 이러한 부분을 SISR(Single Image Super-Resolution)에서 높은 성능을 보이는 딥러닝 모델을 사용하여 개선할 수 있다. 비교적 성능이 높은 모델들의 많은 파라미터, 연산량, 그리고 메모리는 여전히 큰 문제이다.

본 논문에서는 기존에 요구되던 파라미터와 연산량, 메모리를 대폭 감소시키면서도 준수한 성능을 보이는 RCI(Reverse Convolution Inception) 구조를 제안한다. 2장에서 제안하는 구조에 대하여 설명하고, 3장에서 진행한 환경과 학습 결과에 대하여 설명한다. 그리고 4장에서 결론을 맺는다.

2. RCI(Reverse Convolution Inception)

그림 1(a)는 기존에 제안되었던 Inception v4 네트워크의 앞단에서 사용된 Inception-A 블록 구조이다[1]. 기존 2D 이미지를 대상으로 하는 네트워크들은 가장 앞에 3x3 컨볼루션 레이어만을 사용하였으며, 인셉션 구조 또한 네트워크의 가장 처음부터는 사용되지 않았다. 하지만, 입력인 LR(Low Resolution)으로부터 홀로그램의 회절 패턴과 랜덤 위상 등의 다양한 특성을 추출하기 위해선 단순한 3x3 컨볼루션 구조로는 한계가 있을 것이며, 본 연구에서는 이를 극복하고자 그림 1(b)와 같은 구조를 제안한다. 먼저 입력을 4가지 3x3 컨볼루션 연산을 진행한다. 그리고 마지막에 1x1 컨볼루션을 출력의 채널 수를 절반으로 감소시킨다. 마지막으로 4개의 결과를 연결하고 1x1 컨볼루션 연산을 사용하여 최종적으로 업샘플링 레이어의 입력으로 사용한다. 업샘플링

레이어의 구조는 RCAN[2]에서 사용된 ESPCN의 Pixel-shuffle layer를 사용하였다[3].




그림 1. 네트워크 구조 (a) Inception-A 블록 (b) RCI 구조

Fig. 1. Network structure (a) Inception-A block (b) RCI structure

3. 실험 및 결과

실험에 사용된 홀로그램 데이터는 JPEG Pleno의 Hologram dataset이 사용되었으며, 각각의 홀로그램으로부터 512x512의 크기로

sub-hologram을 생성하여 총 800개의 training set과 8개의 validation set을 사용하였다. LR은 원본인 HR(High Resolution)으로부터 bicubic 다운 샘플링을 사용하여 생성하였다. 네트워크의 입력 사이즈는 48×48이고, 미니 배치는 16개를 사용하였다. 실험환경은 PYTORCH 1.1 버전과 CUDA 10.0이 사용되었으며, GPU는 NVIDIA의 RTX2080 2개를 사용하였다.




그림 1. 학습결과 (a) RCAN (b) RCI
Figure 1. Training result (a) RCAN (b) RCI

그림 2는 각 epoch에서 training set의 Loss와 validation set의 PSNR 평균을 측정한 결과이다. 그림 2(a)는 RCAN 네트워크를 학습시킨 결과이다. 약 60 epoch까지는 PSNR이 상승하였으며, 이후에는 PSNR이 감소하는 문제가 발생하였다. 그림 2(b)는 제안한 네트워크 구조의 학습 결과이며, RCAN보다 높은 PSNR을 유지하는 결과를 보였다. 표 1은 각 네트워크 별로 학습에 요구되는 시간과 메모리이다. RCAN은 8GB 이상의 메모리 사용량과 많은 연산량으로 인한 문제가 있으며, 실제로 성능대비 더 좋은 결과를 보이지 않는다. 반면 RCI 구조는 RCAN 대비 적은 메모리 사용과 빠른 연산을 진행할 수 있으면서, 좋은 결과를 보인다.

표 1. 학습시간 및 메모리 사용량
Table 2. Learning time and memory usage

	RCAN	RCI
Learning average time (sec/epoch)	112	4
GDDR(Training)	≒ 9GB	≒ 1GB

4. 결론

본 논문에서는 고해상도 홀로그램을 위한 딥러닝 기반의 Super-Resolution 네트워크 구조를 제안하였다. 준수한 성능을 보이면서도 기존 2D 이미지에 대한 SISR 네트워크보다 더 빠르고, 간단한 네트워크 구조를 보이며, 이를 기반으로 딥러닝 기반의 해상도 홀로그램 연구의 가능성과 이후 연구에 많은 도움이 될 것으로 기대된다.

5. 감사의 글

이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(2018R1D1A1B07043220)

6. 참고문헌

[1] C. Szegedy, S. Ioffe, and V. Vanhoucke, "Inception-v4, inception-resnet and the impact of residual connections on learning," *In ICLR Workshop*, 2016.

[2] Y. Zhang, K. Li, K. Li, L. Wang, B. Zhong, Y. Fu, "Image super-resolution using very deep residual channel attention networks," *In ECCV*, 2018.

[3] W. Shi, J. Caballero, F. Huszár, J. Totz, A. P. Aitken, R. Bishop, D. Rueckert and Z. Wang, "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network," *In CVPR*, 2016.