

## 심층 학습 기반 위상 홀로그램 생성

차준영, 반현민, 김휘용†

경희대학교

{cyj8922, hmban1996, hykim.v}@khu.ac.kr

†: 교신저자 (Corresponding author)

### Deep Learning-based Phase-only Hologram Generation

Junyeong Cha, Hyunmin Ban, Hui Yong Kim†

Kyung Hee University

#### 요약

본 논문에서는 기존 이미지를 통해 위상 홀로그램을 생성하는 네트워크를 학습 및 최적화하여, 기존에 사용하는 알고리즘 방식인 GS 알고리즘(Gerchberg-Saxton algorithm)을 대체하는 것을 목표로 한다. GS는 반복 최적화 기법으로 한 장의 이미지에서 위상 홀로그램을 생성하는데 많은 시간이 걸리지만, 심층 학습 기반으로 학습된 모델을 통해 위상 홀로그램을 생성할 경우, 반복 최적화 과정 없이 짧은 시간 안에 위상 홀로그램을 생성할 수 있다. GS와 심층 학습 기반으로 각각 생성한 위상 홀로그램을 ASM (Angular Spectrum Method)을 통해 수치적으로 재복원하여 PSNR로 원본 이미지와 비교한 결과, 심층 학습 기반으로 생성한 위상 홀로그램에서 더 좋은 화질의 이미지를 짧은 시간 안에 얻을 수 있었다.

#### 1. 서론

홀로그래피(Holography)는 3차원 물체에서 나오는 빛의 진폭과 위상 정보를 제어하는 기술로, 홀로그램(Hologram)은 두 개의 레이저 광이 서로 만나서 일으키는 빛의 간섭 현상을 이용해 입체 정보를 기록한 결과물을 의미한다. 컴퓨터 생성 홀로그램(Computer Generated Hologram)은 아날로그 홀로그램과 달리 실존하는 물체가 아닌 가상의 물체에서 나오는 빛의 정보를 컴퓨터로 계산하여 기록한 결과물을 의미하며, 이렇게 생성된 홀로그램은 디지털 공간광변조기(Spatial Light Modulator)를 통해 디스플레이 할 수 있다. 컴퓨터로 생성한 홀로그램을 완벽히 복원하기 위해서는 빛의 위상과 진폭 정보를 모두 표현할 수 있는 공간광변조기가 요구되지만, 현재 기술적 한계로 빛의 진폭 혹은 위상만 기록할 수 있기 때문에, 빛의 정보를 보다 효율적으로 표현할 수 있는 위상 공간광변조기를 주로 사용한다. 따라서 위상 공간광변조기에서 홀로그램 영상을 잘 복원할 수 있도록, 빛의 위상만 기록한 홀로그램인 위상 홀로그램(Phase-only Hologram)을 잘 만들기 위한 연구가 지속되고 있다.

위상 홀로그램을 만드는 대표적인 방법으로는 GS 알고리즘(Gerchberg-Saxton algorithm)[1]이 있다. GS 알고리즘은 반복 최적화 기법으로, 원본 이미지를 Hologram plane으로 전파했을 때 얻어지는 진폭과 위상 정보를 최대한 담을 수 있도록 위상을 최적화하는 기법이다. GS 알고리즘을 통해 많이 반복하면 이미지를 수치적으로 복원했을 때 원본 이미지와 유사한, 충분히 좋은 화질의 위상 홀로그램 이미지를 얻을 수 있다. 하지만, 좋은 화질의 위상 홀로그램 한 장을 얻기까지 상당한 시간이 걸리며, 이는 홀로그램 상용화 관점에서 실시간으로 홀로그램 영상을 만들고 송수신하는 데 어려운 점이 발생할 수 있다.

본 논문에서는 GS 알고리즘의 단점을 극복하기 위해 딥러닝 기반으

로 위상 홀로그램을 생성하는 데 주목했다. 단순히 이미지를 통해 위상 홀로그램을 생성하는 것이 아닌 Hologram plane에서 진폭과 위상 정보를 최대한 활용할 수 있도록 DPAC (Double Phase Amplitude Coding)[2] 방법을 이용해 위상을 초기화했고, 초기화된 위상을 네트워크의 입력으로 주어 위상 홀로그램을 생성하였다. 논문의 구성은 다음과 같다. 첫째, 위상 홀로그램을 생성하는 GS 알고리즘과 DPAC를 소개한다. 둘째, 이미지를 통해 위상 홀로그램을 생성하는 네트워크와 네트워크 학습 전략에 대해 소개한다. 셋째, GS 알고리즘으로 만든 위상 홀로그램과 학습된 네트워크를 통해 만든 위상 홀로그램의 화질 및 생성 시간을 비교한다. 마지막으로 결론을 지으면서 향후 연구 과제를 도출한다.

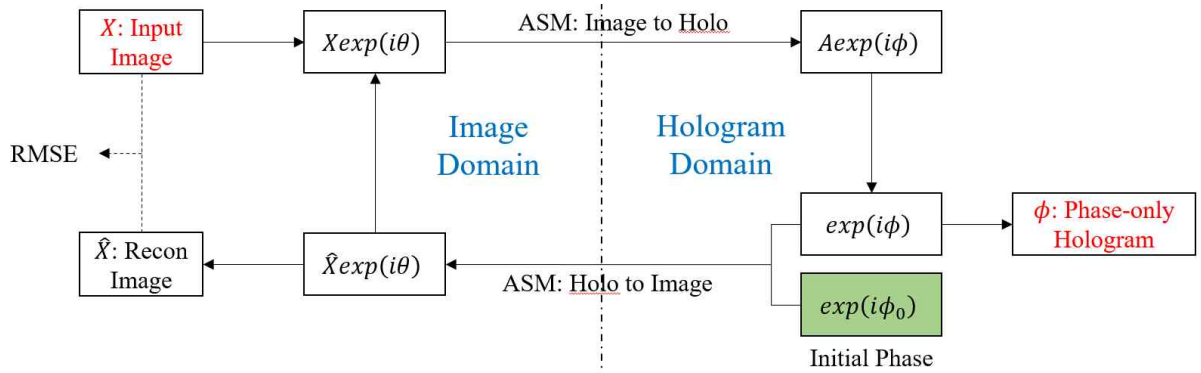
#### 2. 위상 홀로그램 생성 알고리즘

##### 1) Gerchberg-Saxton (GS) algorithm

GS 알고리즘은 다음과 같은 방법으로 위상을 최적화한다. 첫째, 초기 위상을 생성한 후, ASM (Angular Spectrum Method)를 통해 Image plane으로 전파한다. 둘째, Image domain으로 전파된 빛의 위상 및 진폭 중 위상 정보만을 취한 후, 진폭 정보를 원본 이미지로 대체한다. 셋째, 재구성된 이미지를 ASM을 통해 다시 Hologram plane으로 전파한다. 넷째, Hologram의 위상값만 취한 후, 진폭 정보를 1로 제한한다. 그리고 둘째부터 넷째까지의 순서를 반복적으로 적용한 결과, 위상 홀로그램을 생성할 수 있다.

##### 2) Double Phase Amplitude Coding (DPAC)

DPAC는 빛의 위상과 진폭을 두 개의 위상값으로 부호화하여 위상 홀로그램을 생성하는 방법이다. 위상이  $\theta$ , 진폭이  $a$ 인 복소수 값  $c$ 가



<Figure 1> GS algorithm

진다고 하면,  $c$ 는 아래와 같은 수식을 통해 2개의 위상으로 부호화할 수 있다.

$$c = ae^{i\theta} = 0.5e^{i(\theta + \psi)} + 0.5e^{i(\theta - \psi)}$$

$$\psi = \cos^{-1} a$$

이때, 진폭  $a$ 는  $[0, 1]$ 의 범위를 가진다. 하지만 위상 공간광변조기는 하나의 위상 이미지만 복원할 수 있으므로, 두 위상을 바둑판 모양으로 배치하여 위상 이미지를 생성한다.

### 3. Deep learning-based Hologram Generator

#### 1) 위상 홀로그램 생성 네트워크<sup>3)</sup>

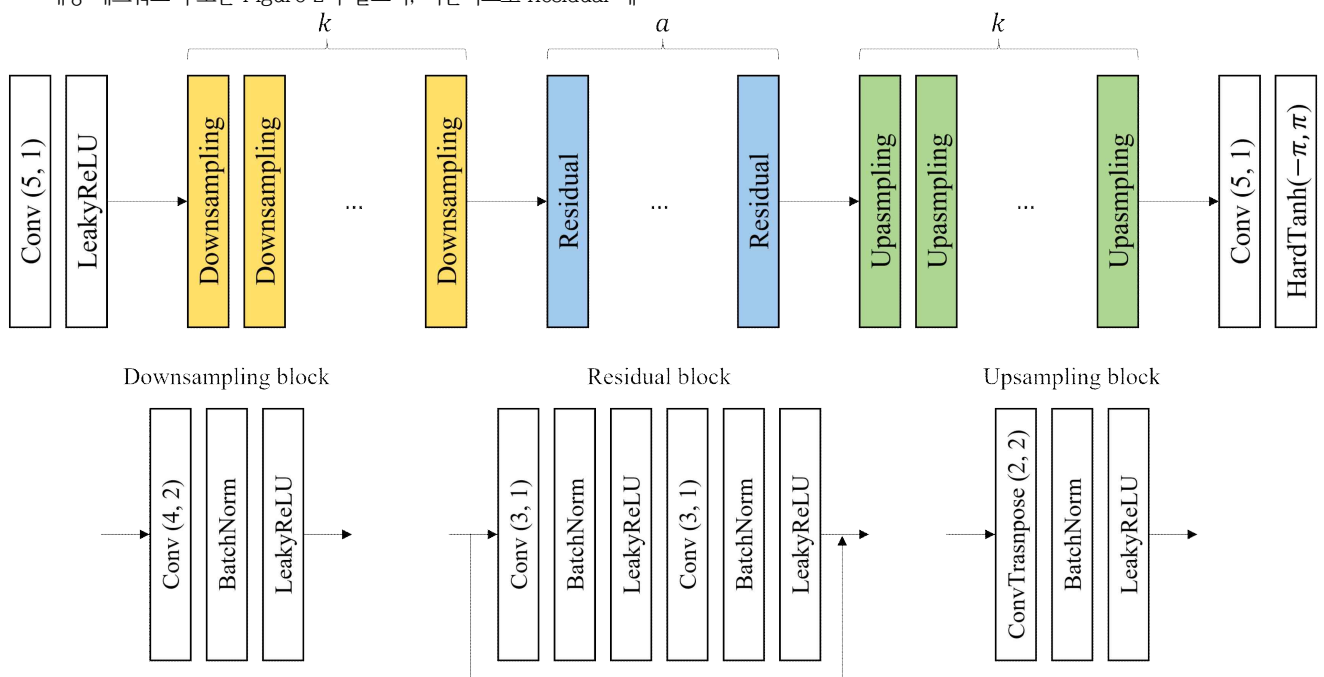
본 논문에서 사용한 위상 홀로그램 생성 모델은 앞서 소개한 GS 알고리즘의 단점을 보완하기 위해 만들어진 가벼운 네트워크 모델로 GS 알고리즘을 대체할 수 있을 만한 화질을 지닌 위상 홀로그램 이미지를 생성하는 것이 핵심이다.

해당 네트워크 구조는 Figure 2와 같으며, 기본적으로 Residual 네

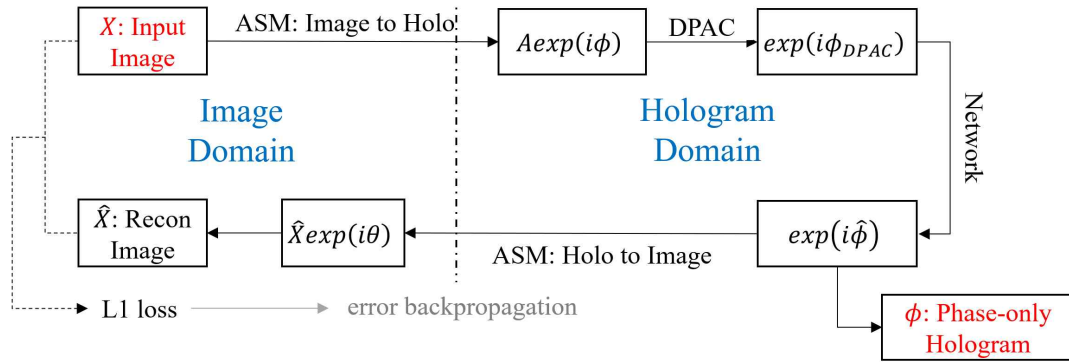
트워크 구조를 따른다. 크게 Feature Extraction, Downsampling block, Upsampling block, Residual block, Reconstruction으로 나누어져 있다. Feature Extraction에서는 CNN 연산 및 LeakyReLU를 통해 이미지의 비선형적 특징을 추출한다. Downsampling block에서는 이미지의 크기는 줄이고 feature map의 크기를 늘리면서 이미지에 포함된 비선형적 위상 정보를 학습한다.  $k$ 개의 Downsampling block을 지난 후,  $a$ 개의 Residual block으로 이미지의 비선형적 특징을 잔차 학습한다. Upsampling block에서는 Downsampling block과는 반대로 이미지의 크기는 늘리고 feature map의 크기는 줄이면서 위상 홀로그램 이미지를 재구성한다. 마지막으로 Reconstruction에서는 CNN 연산 및 Hard hyperbolic tangent를 통해 모든 픽셀을  $[-\pi, \pi]$  사이의 값을 가지도록 한다.

#### 2) 네트워크 학습 전략

입력 이미지를 통해 바로 위상 홀로그램 이미지를 생성하도록 학습하는 것은 쉽지 않다. ASM을 통해 Hologram plane으로 빛이 전파하는 과정을 학습해야 하는 것뿐만 아니라, 전파된 빛의 정보가 모두 위상



<Figure 2> Model Network



<Figure 3> Model Training Process

에 담기도록 만들어야 하기 때문이다. 따라서, 입력 이미지에서 바로 위상 홀로그램을 만들지 않고, Hologram plane으로 먼저 전파한다. 그 후, 전파된 빛의 위상 정보를 통해 위상 홀로그램을 새롭게 생성한다. 이때, 단순히 진폭 정보를 버리고 위상 정보만을 취할 수 있다. 하지만, 위상은 이미지의 고주파수 성분을 많이 가지고 있으므로, 저주파수 성분을 많이 가지고 있는 자연 이미지의 위상 홀로그램을 생성할 초기 위상 이미지로 적절하지 않다.<sup>[4]</sup> 따라서 진폭과 위상 정보를 적절히 가져올 수 있는 DPAC 방법을 통해 초기 위상을 만든 후, 네트워크에 입력하여 입력 이미지의 위상 홀로그램을 생성한다. 네트워크를 통해 생성된 위상 홀로그램은 다시 ASM을 통해 수치적으로 재복원되며, 재복원된 결과와 입력 이미지의 L1 Loss를 통해 네트워크를 학습한다.

4. 실험 결과

실험에 앞서, DIV2K 데이터 셋<sup>5</sup>으로 학습에 사용할 데이터를 새롭게 생성하였다. 훈련 데이터와 검증 데이터 모두 이미지마다 256×256의 크기로 임의의 위치에서 3장씩 잘라내 생성하였다. 따라서 학습에 사용한 데이터는 총 2,400개, 검증 데이터로는 총 300개를 사용했으며, 이때 이미지 간 픽셀값의 편차를 줄이기 위해 0과 1 사이로 정규화하였다.

홀로그램 이미지 생성을 위해 ASM을 통해 전파할 때, 공간광변조기의 화소 크기는 8μm로 설정했으며, propagation distance는 1cm, 파장의 길이는 520nm로 Green 단일 채널에 대해 실험하였다. GS 알고리즘으로 위상 홀로그램 영상을 생성할 때 초기 위상은 [0, 1)사이의 Uniform distribution으로 생성했으며, 총 500 반복 최적화하였다. 위상 홀로그램 생성 네트워크를 학습할 때 역시 같은 파라미터를 사용하여 ASM으로 전파하였다. Downsampling block과 Residual block을 각각 2개, 5개씩 쌓아 총 네트워크 파라미터는 약 1.7M개이며, 학습에 사용한 손실함수로 L1 손실함수를 사용하였고, 최적화 방법으로는 Adam 알고리즘을 사용하였다. 이때, 학습률(Learning Rate)은 0.001로, 매 100epoch 마다 0.1배씩 줄어든다 하여 총 200epoch 학습하였다.

학습한 결과 이미지는 Figure 4와 같다. GS algorithm을 사용하여 위상 홀로그램 이미지를 생성하고, 이를 수치적으로 재복원했을 때 심한 Noise가 끼어있었으며 전반적으로 Ground Truth에 비해 Intensity가 많이 낮아진 모습을 확인할 수 있었다. 또한, 검증 데이터 셋 300개를 모두 최적화하여 위상 홀로그램을 생성하는데 평균적으로 5.92초가 걸렸으며, PSNR 결과로 11.89dB가 나온 모습을 확인할 수 있었다. 반면, 학습된 네트워크를 통해 위상 홀로그램 이미지를 생성하고 이를 수치적

으로 재복원했을 때는 Checkerboard artifact가 다소 끼어있었지만, GS algorithm에 비해 Intensity가 원본과 비슷하여 보다 선명한 이미지를 얻을 수 있었다. 또한, 검증 데이터 셋 300개를 모두 위상 홀로그램 이미지를 생성하는데 평균적으로 0.027초가 걸렸으며, PSNR 결과로 16.07dB가 나왔다. 결과적으로, GS 알고리즘으로 생성한 위상 홀로그램 이미지보다 월등히 빠르고 좋은 화질의 홀로그램 이미지를 생성할 수 있었다.

5. 결론

본 논문에서는 GS 알고리즘의 단점을 보완하기 위해, 위상 홀로그램 이미지를 생성하기 위한 프레임워크와 네트워크 모델을 함께 제안한다. 반복 최적화 기법인 GS 알고리즘과 딥러닝 기반 네트워크로 각각 생성한 위상 홀로그램의 생성 시간과 수치적으로 재복원한 이미지의 화질



<Figure 4>

(a) Ground Truth, (b) GS-500, (c) Proposed network

	Time(s)	PSNR(dB)
GS-500	5.92	11.89
Proposed network	0.027	16.07

<Table 1> Hologram Generating Time & PSNR

을 비교해보았을 때, 본 논문에서 제안한 방식의 성능이 월등히 우수함을 보였다. 2D 이미지를 이용해 위상 홀로그램을 짧은 시간 안에 생성할 수 있음은, 향후 3D 모델의 위상 홀로그램 이미지 역시 딥러닝을 통해 짧은 시간 안에 생성할 수 있을 것이다. 또한, 단순히 좋은 화질의 홀로그램 영상을 얻는 것뿐만 아니라 GS 알고리즘을 통해 달성하기 어려운 압축 최적화된 위상 홀로그램 생성 모델로 발전 가능성을 기대할 수 있을 것이다.

## Acknowledgement

이 논문은 삼성전자미래기술육성센터의 지원을 받아 수행된 연구임 (과제번호 SRFC-IT2202-03)

## 6. 참고문헌

- [1] GERCHBERG, Ralph W. "A practical algorithm for the determination of phase from image and diffraction plane pictures." *Optik*, 1972, 35: 237-246.
- [2] HSUEH, Chung-Kai; SAWCHUK, "Alexander A. Computer-generated double-phase holograms." *Applied optics*, 1978, 17.24: 3874-3883.
- [3] LEE, Juhyun, et al. "Deep neural network for multi-depth hologram generation and its training strategy." *Optics Express*, 2020, 28.18: 27137-27154.
- [4] MAIMONE, Andrew; GEORGIU, Andreas; KOLLIN, Joel S. "Holographic near-eye displays for virtual and augmented reality." *ACM Transactions on Graphics (Tog)*, 2017, 36.4: 1-16.
- [5] AGUSTSSON, Eirikur; TIMOFTE, Radu. Ntire 2017 challenge on single image super-resolution: Dataset and study." In: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2017. p. 126-135.