

# 딥러닝 기반 CGH 기술

□ 양대호 / 가천대학교

## 요약

컴퓨터 생성 홀로그래피(computer generated holography, CGH)는 기존의 간섭을 이용해 기록하고 재생하던 홀로그램과는 다르게 3차원 물체에서 방출되는 빛 파동의 전파를 계산하여 홀로그램을 생성하는 기술이다. 이로 인해 임의의 물체를 자유롭게 생성할 수 있게 되었고 디스플레이에서 홀로그램의 활용도가 높아지게 되었다. 그러나 CGH 기술은 계산에 필요한 컴퓨팅 파워가 매우 크고 이미지 품질이 제한되는 등 한계를 드러내고 있다. 본 기고문에서는 기존 CGH 기술들의 한계를 설명하고 어떻게 딥러닝이 이러한 한계를 극복할 수 있는지 연구자들에게 관련 정보를 제공하고자 한다.

## 1. 서론

홀로그래피는 1947년에 물리학자 데니스 가보르(Dennis Gabor)가 최초로 제안한 기술이다. 홀로그래피 기술은 최초에는 전자 현미경의 이미지 품질을 향상시키려는 목표를 가지고 개발하였으며, 빛의 간섭과 회절을 이용하여 3차원 이미지를 만들어내는 방법을 연구하였다. 이후 레이저의 발달로, 가간섭성 광원을 3차원 물체에 조사하고 간섭을 기록하는 광학적 아날로그 홀로그래피 기술이 등장하게 되었다.

컴퓨터의 성능이 크게 발전하면서, 아날로그 홀로그래피 기술이 아닌 3차원 물체에 레이저가 조사될 때 예상되는 빛의 전파를 계산하는 CGH 기술이 등장하게 된다. CGH 기술은 실제 물체의 기록을 바탕으로 한 홀로그램으로는 생성하기 어려운 다양한 장면을 자유롭게 다룰 수 있다는 장점을 가지고 있다. 또한 이를 통해 실제와 구분하기 어려운 수준의 3차원 경험을 제공하는 디스플레이 기술로 주목받았다.

그러나 3차원 공간상의 방대한 양의 정보를 계산해야 한다는 특징 때문에 연산량이 매우 많아 실시간으로 홀로

그램을 생성하기 어려웠다. 또한, 가간섭성이 있는 광원을 이용해 재생한다는 특징 때문에 스펙클 노이즈가 중요한 문제로 대두되었다. 이러한 한계를 극복하기 위해 새로운 알고리즘 개발 뿐 아니라 딥러닝이 어떻게 활용될 수 있는지에 대한 연구가 활발히 진행되고 있다. 본 기고문에서는 딥러닝을 이용한 CGH 생성 방법들에 대해 설명하고, 어떻게 딥러닝이 기존 CGH 방법들의 한계를 극복할 수 있는지에 대해 논의하려 한다. 이를 통해 연구자들에게 딥러닝을 활용한 CGH의 이해를 돕고, 이 분야의 연구를 촉진하는데 도움을 주려 한다.

## II. 딥러닝 CGH의 생성 방법

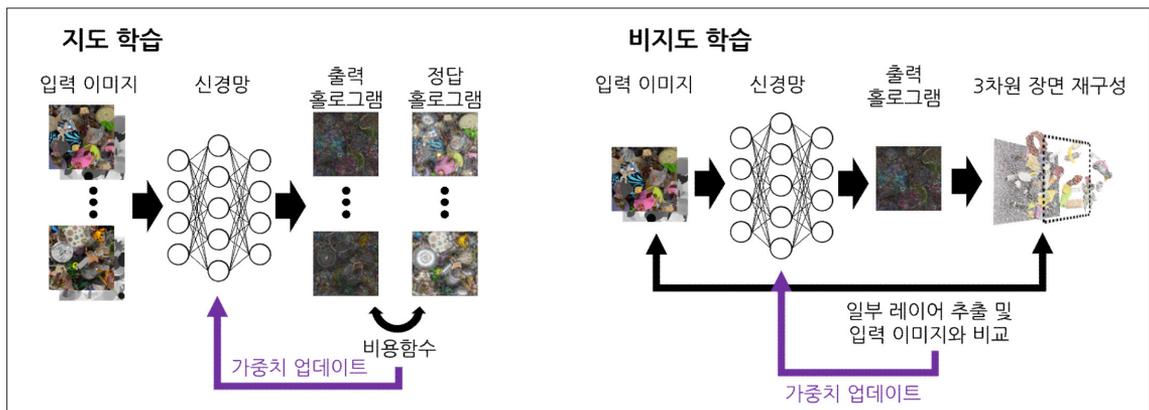
1998년, 최초로 신경망을 이용하여 홀로그래름을 생성한 연구가 진행되었다. 해당 연구에서는 16 x 16 픽셀의 매우 간단한 데이터셋을 이용해 신경망을 훈련시켰다. 비록 컴퓨팅 자원이 부족하여 현재의 깊은 인공신경망 구조를 채택할 수 없었지만, 해당 연구는 신경망이 기존 최적화 방법보다 빠르게 홀로그래름을 최적화할 수 있음을 보여주었다. 이후 그래픽 처리 장치(GPU)를 연산에 본격적으로 채용하게 되면서, 2018년 이후로는 딥러닝 기반의 CGH 기술이 빠르게 발전하였다. 이 과정에서 홀로그래름을 생성하

기 위한 방법은 크게 지도 학습(Supervised Learning) 방법과 비지도 학습(Unsupervised Learning) 방법으로 나뉘어지게 되었다(<그림 1>).

### 1. 지도 학습(Supervised Learning)

딥러닝 기반 CGH에서 지도 학습이란 미리 생성된 홀로그래름 데이터셋을 이용해 신경망을 학습시키는 방법을 의미한다. 따라서 신경망 학습 이전에 기존에 알려진 알고리즘으로 CGH 데이터셋을 제작해야 한다. 일반적으로 신경망을 학습시키기 위해서는 많은 숫자의 데이터셋이 필요하기 때문에 비교적 데이터를 구하기 쉬운 2차원 이미지를 기반으로 홀로그래름을 생성하게 된다. 예를 들어, 2D 컬러 이미지나, 컬러 이미지와 깊이 이미지를 포함한 RGB-D 이미지를 기반으로 홀로그래름을 생성한다.

홀로그래름 데이터셋을 생성할 때 주로 이용되는 방법은 레이어 기반 홀로그래름 생성 방법이다. 레이어 기반 홀로그래름 생성은 연속적인 깊이를 몇 장의 레이어로 양자화시키고 각 레이어를 평면 광파 진행시켜 연산하게 된다. 이렇게 각 레이어를 평면 광파 진행한 파동장을 중첩시켜 최종적인 홀로그래름을 생성하는데, 화질 향상을 위해 occlusion(가려짐)을 고려하거나 전파 거리에 따른 위상을 보정하는 등의 방법을 추가할 수 있다. 또한, 특정 깊이에 신경망



<그림 1> 지도 학습과 비지도 학습

이 과적합하는 현상을 방지하기 위해 깊이의 분포가 일정해야 하는 등, 데이터셋의 생성에 주의를 기울여야 한다.

데이터셋이 준비되면, 신경망이 해당 홀로그램 데이터셋을 생성할 수 있도록 비용 함수를 설정해 훈련시킨다. 즉, RGB-D 이미지를 신경망 입력으로 받고 내놓은 출력을 홀로그램 데이터셋과 비교하여 신경망의 가중치를 업데이트한다. 비용 함수로는 일반적으로 평균제곱오차를 사용하나 목적에 따라 L1 손실 함수나 LPIPS(Learned Perceptual Image Patch Similarity)와 같은 신경망 기반의 손실 함수를 사용할 수 있다.

## 2. 비지도 학습(Unsupervised Learning)

딥러닝 기반 CGH에서 비지도 학습이란 미리 생성된 홀로그램 데이터셋을 이용하지 않고 신경망의 가중치를 업데이트하는 방법을 의미한다. 홀로그램 데이터셋을 이용하지 않는 대신, 신경망에서 출력된 파동장이 3차원 장면을 성공적으로 재구성하는지 확인하고, 목표로 하는 3차원 장면과 비교하여 신경망의 가중치를 업데이트한다. 3차원 장면을 성공적으로 재구성하는지 확인하는 방법에는 여러 가지가 있지만, 신경망으로 생성된 홀로그램을 평면 광과 진행시켜 각 깊이별로 비교하는 방법이 일반적으로 사용된다.

지도 학습과 다르게 비지도 학습은 홀로그램 데이터셋을 준비하지 않아도 되기 때문에 데이터셋 준비에 시간이 걸리지 않는다는 장점이 있다. 따라서 데이터셋 준비에 시간이 오래 걸리는 경우에 사용하면 좋다. 예를 들어 하나의 홀로그램 생성을 위해 반복적인 방법(iterative method)이 필요한 경우, 데이터셋 준비에 긴 시간이 필요하지만 이를 생략 가능하다. 그러나, 신경망 학습 과정에서 3차원 장면을 평면 광과 진행으로 재구성해야 하기 때문에 학습 시간이 길어지게 된다. 또한, 생성할 홀로그램의 정답을 모르거나 정답을 계산하는데 시간이 오래 걸릴 경우에도 유용한 방법이다.

지도 학습과 비교했을 때 비지도 학습의 가장 큰 장점

은, 동일한 목적을 수행하도록 훈련한다면 일반적으로 성능 향상을 기대해 볼 수 있다는 점이다. 지도 학습에서는 신경망의 가중치 업데이트가 홀로그램 데이터셋을 이용해서 계산되기 때문에 홀로그램 데이터셋을 생성할 때 이용했던 알고리즘 이상의 성능을 내는 것이 불가능하다. 그러나 홀로그램 데이터셋을 생성할 때 사용한 알고리즘이 일반적으로 가장 이상적인 형태가 아니기 때문에 비지도 학습에서는 이를 개선시킬 여지가 존재한다. 또한 데이터셋 생성 시 사용한 알고리즘은 계산의 편의성을 위해 가정한 부분들이 존재하는데, 비지도 학습에서는 해당 부분들도 최적화하여 성능을 개선한다. 예를 들어, 레이어 기반 홀로그램에서 전역 위상(global phase)은 0으로 가정하지만, 비지도 학습에서는 전역 위상 역시 최적화된다.

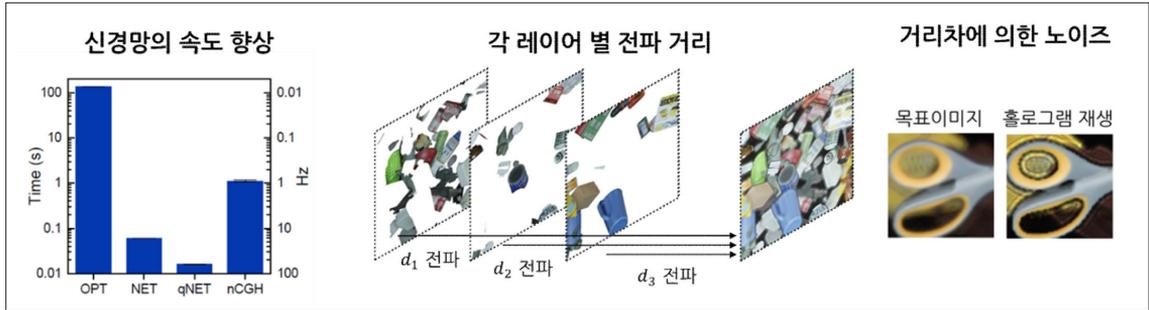
## III. 딥러닝 CGH 기술의 응용

딥러닝 기술을 CGH 기술에 응용할 경우 기존 CGH 기술의 단점들을 극복할 수 있다. 대표적으로, 연산 속도 향상을 통해 실시간 홀로그램 생성이 가능하며 기존 CGH에 비해 화질을 향상시키는 것 역시 가능하다. 또한 그 밖에도 홀로그램의 깊이 표현 향상이나 효율 향상 등 다양한 응용이 가능하다.

### 1. 연산 속도 향상

딥러닝을 CGH 기술에 응용할 때 가장 크게 기대하는 것은 속도 향상이다. 기존의 CGH 생성은 점 기반 방법, 폴리곤 기반 방법, 그리고 레이어 기반 방법으로 크게 세 가지 방법을 이용해서 이루어진다. 이들 중 레이어 기반 방법이 깊이 정보를 양자화하여 다른 방법에 비해 속도가 빠른 것으로 알려져 있으나, 해당 방법의 경우에도 실시간으로 CGH를 생성하지는 못한다.

반면, 딥러닝 기술로 홀로그램을 생성하는 경우 최대 60Hz 이상의 속도로 홀로그램을 생성할 수 있다. 또한 그



<그림 2> 신경망의 속도 향상과 거리에 따라 생긴 노이즈

래픽 연산 장치뿐 아니라 신경망 가중치 양자화를 통해 모바일 기기에서 실행하거나 추론 전용 가속기 등에서 실행하는 등, 기존 서버 기반의 연산에서 벗어나 엣지 디바이스에서 홀로그램을 생성하는 연구들도 이루어지고 있다. 다만 홀로그램 생성의 경우 다른 딥러닝 응용에 비해, 입출력 해상도가 높기 때문에, 신경망의 구조를 간단하게 하더라도 연산량이 크다. 따라서 아직까지 실시간으로 모바일에서 연산은 구현된 적이 없으며, 해당 구조를 개선하기 위해 활발히 연구가 진행되고 있다(<그림 2>).

## 2. 화질 향상

딥러닝 기술을 응용하여 홀로그램의 화질을 향상하는 방법은 크게 두 가지로 구분 가능하다. 첫 번째 방법은 기존 알고리즘의 한계를 극복해 이론적으로 고화질의 홀로그램을 생성하는 방법이며, 두 번째 방법은 실험적으로 들어오는 노이즈 등을 극복하여 화질을 높이는 방법이다. 먼저 이론적으로 고화질의 홀로그램을 생성하는 방법에 대해 살펴보자. 이를 이해하기 위해서는 기존 CGH 방법에서 발생하던 노이즈를 이론적으로 이해할 필요가 있다.

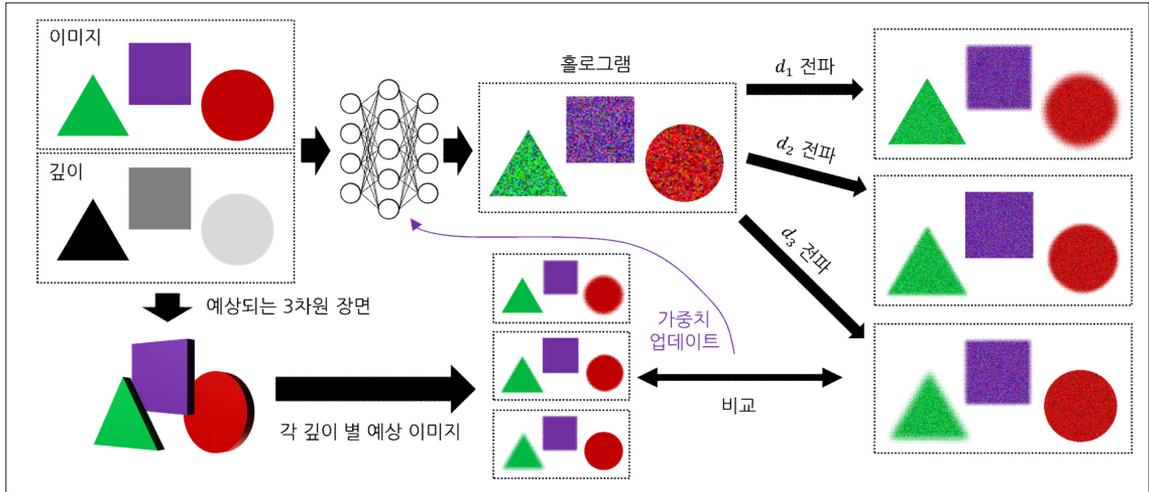
레이어 기반 방법에서 거리  $d$  만큼 떨어진 평면으로 광파를 진행할 경우 주파수 성분에 따른 위상과  $e^{ikd}$  만큼의 위상이 생긴다(<그림 2>). 따라서 홀로그램 생성을 위해 평면 광파 전파한 서로 다른 깊이의 레이어를 중첩시키면 거리에 따라 해당 위상만큼 차이가 나게 된다. 서로 다른 깊이

의 레이어가 인접하는 경우, 해당 경계에서는 거리차에 의한 위상차이( $e^{ik\Delta d}$ )가 발생하는데, 거리가 일반적으로 파장보다는 매우 크기 때문에  $k\Delta d \gg 2\pi$ 가 성립한다. 따라서 해당 위상차이는 무작위하게 보이고, 해당 무작위 위상에 의해 노이즈가 발생한다. 노이즈를 감소시키기 위해서 일부 CGH 방법에서는 깊이에 따라  $e^{ikd}$ 의 위상을 추가해서 거리에 따른 위상차이를 상쇄시키기도 하지만, 평면 광파 전파 거리가 멀어지는 경우 주파수 성분에 따른 위상의 영향이 커져 무작위 위상 노이즈는 억제 불가능하다(<그림 2>).

경계면에서 발생하는 해당 노이즈는 아직까지 분석적인 방법으로 해결할 수 있는 방법이 알려지지 않았기 때문에, 경계면 노이즈를 억제하기 위해 딥러닝 방법을 응용할 수 있다. 이 경우, 정답을 알지 못하기 때문에 신경망 학습을 위해서는 비지도 학습을 이용해야 한다. 즉, 신경망에서 출력된 파동장을 원하는 깊이까지 평면 광파 전파하고 해당 레이어의 목표 이미지와 비교한다. 다만, 비지도 학습으로 신경망 학습 속도가 느려질 수 있기 때문에 지도 학습을 통해 먼저 어느 정도 학습한 뒤, 비지도 학습으로 노이즈를 줄이는 방법을 사용할 수도 있다.

반면, 실험적으로 들어오는 노이즈 등을 극복하여 화질을 높이는 방법은, 실험 셋업에 의해 구현된 광파 전파 모델과 홀로그램 생성 시 이용한 광파 전파 모델이 달라서 생기는 문제를 보정해서 화질을 높인다. 대표적으로 camera-in-the-loop(CITL) 방법이 이에 해당하는데, 이 방법에서는 실험에 의한 광파 전파 모델을 먼저 학습시킨





<그림 4> CGH의 깊이 표현 향상을 위한 딥러닝

생하는 홀로그램을 생성한다면, 깊이 표현을 보다 강화할 수 있다. 따라서, 렌더링 혹은 알고리즘으로 깊이마다 이미지가 다른 가변 초점 데이터셋을 준비하고, 해당 데이터셋을 바탕으로 비지도 학습을 통해 신경망을 훈련시켜 깊이 표현이 강화된 홀로그램을 생성할 수 있다.

또 다른 응용으로 효율 향상이 존재한다. 홀로그램을 재생하기 위해서는 복소 변조기가 필요한데, 아직까지 상용화된 복소 위상 변조기가 존재하지 않기 때문에 일반적으로 위상 변조기 혹은 진폭 변조기를 이용해 홀로그램을 재생한다. 따라서 해당 과정에서 복소 홀로그램을 위상 혹은 진폭 홀로그램으로 변환해야 하는데, 해당 과정을 인코딩 과정이라고 한다. 복소 홀로그램에 비해 위상 및 진폭 홀로그램은 포함할 수 있는 정보가 적기 때문에, 인코딩을 거친 홀로그램을 재생하면 효율과 화질이 떨어지게 된다. 만약 인코딩 과정을 딥러닝을 통해 수행하게 되면, 비용함수

에 따라 효율 향상을 포함한 다양한 목적을 달성 가능하다.

## IV. 결론

지금까지 딥러닝 기반 CGH 기술의 신경망 훈련 방법과 응용에 대해 살펴보았다. 지난 십 년간 컴퓨팅 기술의 발전과 CGH 기술의 발전으로 보다 사실적이고 노이즈가 적은 홀로그램이 생성될 수 있었다. 딥러닝 기반 CGH 기술은 더 나아가 기존의 CGH 기술의 한계를 극복하고 다양한 가능성을 제시한다. 특히, 실시간 홀로그램 생성은 기존 CGH 기술의 한계로 지적되던 계산 속도 문제를 크게 완화시켜 CGH 기술 상용화의 가능성을 보여주었다. 딥러닝 기술의 도입으로 CGH 기술이 앞으로도 크게 발전할 수 있을 것으로 예상된다.

## 참 고 문 헌

- [1] Gabor, D. Holography, 1948-1971. *Science* 177, 299-313 (1972).
- [2] Shimobaba, T. et al. Deep-Learning Computational Holography: A Review. *Front. Photon*, 3, (2022).
- [3] Eybposh, M. H., Caira, N. W., Atisa, M., Chakravarthula, P. & Pégard, N. C. DeepCGH: 3D computer-generated holography using deep learning. *Opt. Express*, OE 28, 26636-26650 (2020).
- [4] Shi, L., Li, B., Kim, C., Kellnhofer, P. & Matusik, W. Towards real-time photorealistic 3D holography with deep neural networks. *Nature* 591, 234-239 (2021).
- [5] Maimone, A., Georgiou, A. & Kollin, J. S. Holographic near-eye displays for virtual and augmented reality. *ACM Trans. Graph*, 36, 85:1-85:16 (2017).
- [6] Peng, Y., Choi, S., Padmanaban, N. & Wetzstein, G. Neural holography with camera-in-the-loop training. *ACM Trans. Graph*, 39, 185:1-185:14 (2020).
- [7] Yang, D. et al. Diffraction-engineered holography: Beyond the depth representation limit of holographic displays. *Nat Commun* 13, 6012 (2022).
- [8] Yang, D. Enhancing efficiency of complex field encoding for amplitude-only spatial light modulator based on a neural network. *Opt. Express*, OE 31, 40741-40747 (2023).

## 저 자 소 개



### 양 대 호

- 2013년 : 서울대학교 화학교육학 전공/물리학 전공 학사
- 2019년 : 서울대학교 물리학과 박사
- 2019년 ~ 2023년 : 삼성전자 종합기술원
- 2023년 ~ 현재 : 가천대학교 물리학과 교수
- 주관심분야 : 홀로그래프, 딥러닝, 양자광학