

딥러닝을 이용한 홀로그램 생성 기술과 현황

□ 홍지수, 이병호 / 한국전자기술연구원

요약

딥러닝 기반의 홀로그램 생성 기술을 통해 홀로그램 화상 회의 서비스 등 기존에 불가능했던 서비스가 가능해졌으며, 홀로그래픽 디스플레이를 통해 가시화되는 영상 품질의 극적인 향상이 가능해지고 있다. 본고에서는 홀로그램 생성 및 가시화를 위한 전체 파이프라인의 여러 부분에 딥러닝 기술을 적용함으로써 홀로그래픽 디스플레이에 기반한 다양한 서비스를 구현한 사례들에 대해 살펴본다.

1. 서론

실사 물체에 대한 홀로그램의 직접 취득을 위해서는 레이저 광원을 조명으로 사용해야 하기 때문에, 실사 물체에 대한 홀로그램 직접 취득은 실험실 등 통제된 상황이 아닌 어려운 것으로 알려져 있다. 따라서 보통 실사 물체에 대한 홀로그램 취득은 깊이지도 카메라, 라이트필드 카메라 등 다양한 방법을 통해 대상 물체의 3차원 정보를 먼저 획득한 다음, 레이저 광원을 통한 홀로그램 기록의 물리적 과정을 컴퓨터 시뮬레이션을 통해 계산적으로 취득하게

된다[1]. 이러한 과정은 크게 두 가지 한계점을 가지게 된다. 먼저 3차원 정보의 취득 과정에서 surface reflectance 등 실사 물체의 photorealistic한 표현에 영향을 미칠 수 있는 정보들의 소실이 일어나기 때문에, 가시화된 홀로그램 영상의 사실적 표현에 한계가 있게 된다. 또한 홀로그램 기록 과정에 대한 컴퓨터 시뮬레이션 과정은 매우 높은 연산량을 요구하기 때문에 일반적인 데스크탑 컴퓨터 수준으로는 video rate의 홀로그램 생성이 불가능하다. 이는 홀로그램 영상의 실시간 스트리밍 및 이를 통한 다양한 응용 시나리오의 실현을 어렵게 한다. 최근 이러한 홀로그램

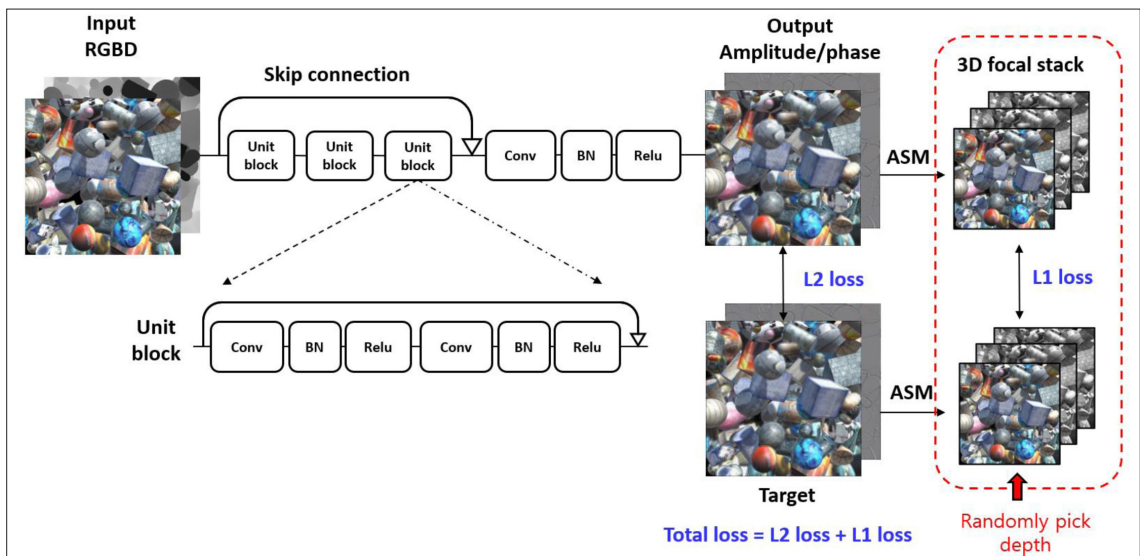
생성 과정을 딥러닝을 통해 추론하는 기술이 개발되었으며[2], 이를 통해 홀로그래프를 video rate으로 실시간 생성하는 것이 가능하게 되었다. 추론된 홀로그래프를 광학적으로 가시화하였을 때 인지적 영상 품질에 큰 문제가 없었으며, 기존의 홀로그래프 생성을 대체할 수 있을 것으로 기대되고 있다. 또한 최근 컴퓨터 그래픽스 분야에서는 실사 물체의 시점 영상을 딥러닝을 통해 implicit하게 추론하여 렌더링하는 Neural Radiance Field(NeRF) 기술이 활발히 연구되고 있는데, 이를 통해 실사 물체의 임의의 시점 영상에 대한 photorealistic한 렌더링이 가능해졌다[3]. 본고에서는 이와 같은 딥러닝 기반의 홀로그래프 실시간 생성 기술을 이용한 홀로그래프 영상의 실시간 스트리밍 구현 사례를 살펴보고, NeRF를 이용해 photorealistic한 홀로그래프 영상의 가시화를 실현하는 등 딥러닝 기술을 적용한 홀로그래프 영상 생성의 새로운 접근법들에 대해 소개하고자 한다.

II. 홀로그래프 실시간 생성 및 스트리밍

1. 딥러닝 기반 홀로그래프 실시간 생성

홀로그래프는 대상 3차원 물체로부터 회절된 파면이 홀로그래프 면에 도달하여 만들어지는 복소 홀로그래프를 기반으로 만들어지며, 이는 Rayleigh-Sommerfeld diffraction formula를 통해 계산할 수 있다[4]. Rayleigh-Sommerfeld diffraction formula는 그 계산 과정이 사실상 convolution과 유사하여, CNN(Convolutional Neural Network)을 통한 추론으로 대체할 수 있을 것이라는 기대를 가질 수 있다. Shi 등은 최근 이러한 CNN 기반 딥러닝 네트워크를 이용한 tensor holography 알고리즘을 개발하였으며, 이를 통해 video-rate의 홀로그래프 생성이 가능함을 보여주었다[2]. 따라서 이를 이용하면 홀로그래프 영상의 실시간 스트리밍이 가능하다.

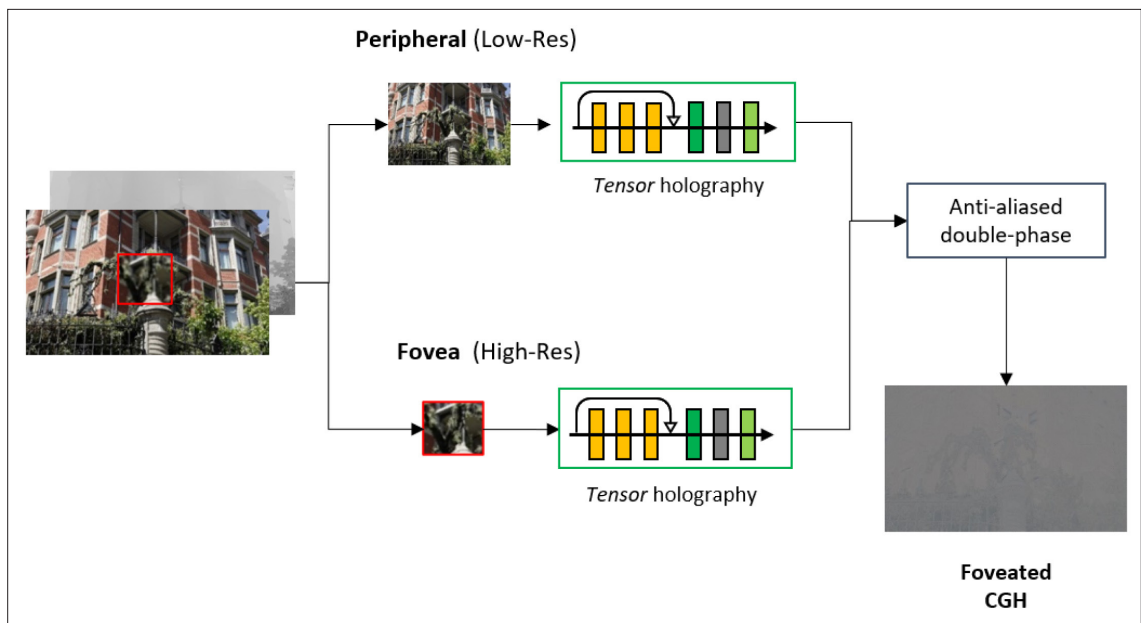
홀로그래프 생성을 위한 딥러닝 네트워크 구조는 <그림 1>과 같이 여러 개의 연속한 unit block들로 이루어져 있으며, 각 unit block은 두 개의 convolution layer와 batch normalization layer, 그리고 ReLU activation layer로 이루어져 있으며, short cut을 포함하도록 구성되어 있다. 이 네트워크는 RGB 이미지 및 깊이도 영상을 입력으로 받아 진폭 영상과 위상 영상으로 이루어진 복소 홀로그래프를 추론하는 것을 목표로 삼고 있다. 이 네트워크



<그림 1> Tensor holography 네트워크 구조

의 학습을 위한 학습 데이터로는 RGB 및 깊이지도 영상과 그에 대응하는 복소 홀로그램 1000쌍을 사용하였으며, 복소 홀로그램 ground truth 데이터는 기존의 레이어 기반 홀로그램 생성 방법을 이용해 생성하였다. 또한 RGB 및 깊이지도 영상은 충분한 임의성을 가질 수 있도록 임의의 장면을 자동으로 구성해 주는 random scene generator를 구현한 후 이를 통해 생성하였다. 학습을 위한 loss는, 복소 홀로그램 ground truth 값과의 L2 loss 및 복소 홀로그램을 angular spectrum method를 통해 임의의 거리에 전파시킨 영상과의 L1 loss를 구하고, 이 두 가지 loss의 합인 total loss로 정의하였다. 이렇게 학습된 딥러닝 네트워크는 RTX4090 GPU를 장착한 일반 데스크탑 PC에서 1920 x 1080 x 3 해상도의 복소 홀로그램을 20 ms 미만에 계산하는 성능을 보여주었으며, 따라서 50 fps 이상의 속도로 홀로그램 실시간 생성이 가능하다. 이는 기존의 홀로그램 생성 방식 대비 25배 이상의 속도 향상이며, 결과적으로 딥러닝 네트워크의 도입을 통해 video-rate의 홀로그램 생성이 가능함을 확인하였다.

최근에는 NED(Near-Eye Display)를 위한 영상 렌더링에 있어서, 인간 시각 시스템의 분해능이 전체 FOV(Field of View)에 대해서 일정하지 않고, 중심시로 갈수록 분해능이 높다는 점에 착안하여 중심시에 대해서는 높은 품질로 렌더링하고 주변시에 대해서는 낮은 품질로 렌더링하는 Foveated Rendering 기법이 많이 활용되고 있다[5]. 이와 같은 접근법은 렌더링의 품질 제어 설계가 잘 되었을 경우 영상의 인지적인 품질에는 큰 문제가 없으면서도 렌더링 시간을 크게 단축할 수 있는 장점을 가진다. 현재의 공간광변조기의 기술 수준으로 구현 가능한 홀로그래픽 디스플레이는 10° 미만의 작은 회절각을 가지며, 이로부터 기인한 제한적 eye box 크기로 NED의 형태로 구현할 수밖에 없다. 따라서 foveation의 개념을 적용한다면 홀로그램 영상 생성 시간을 더욱 단축할 수 있을 것으로 기대할 수 있다. 따라서 홀로그램 영상의 생성시 중심시와 주변시로 나누어 주변시는 낮은 해상도로 추론 후 upscaling하는 방식으로 접근하게 되면 전체적으로 홀로그램 추론 시간을 더욱 단축할 수 있



<그림 2> Foveated tensor holography의 구성 및 동작 파이프라인

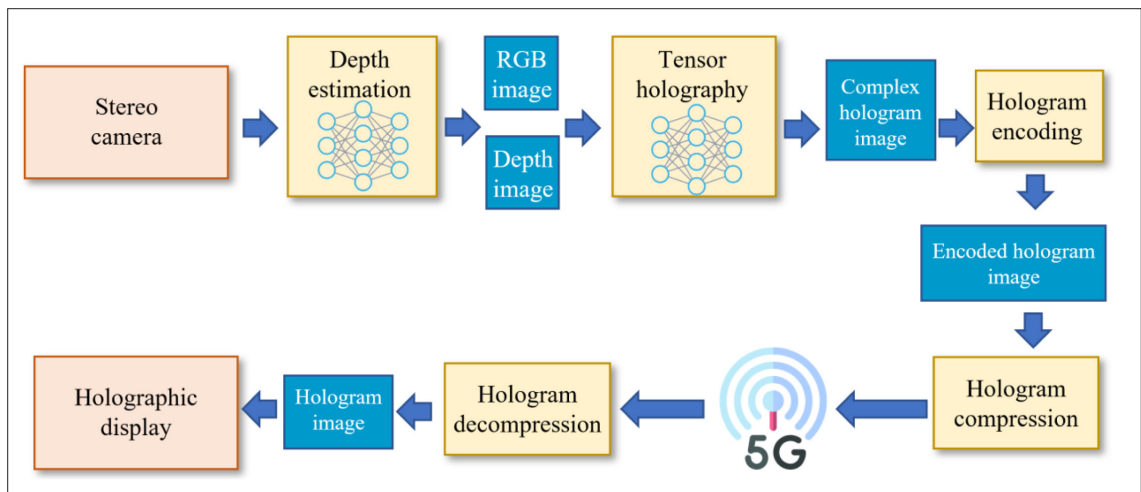
다. 저자들은 이러한 접근법을 적용한 foveated tensor holography를 구현하였으며, 이의 구성 및 동작 파이프라인은 <그림2>와 같다. 이때 CNN 기반의 홀로그램 생성 네트워크는 입력 영상의 해상도에 무관하게 적용 가능하기 때문에 저해상도와 고해상도를 위한 딥러닝 홀로그램 생성 네트워크를 따로 학습시킬 필요 없이 한 가지 네트워크를 사용하여 중심시 및 주변시 홀로그램 영상을 모두 생성할 수 있다.

2. 홀로그램 영상 실시간 스트리밍

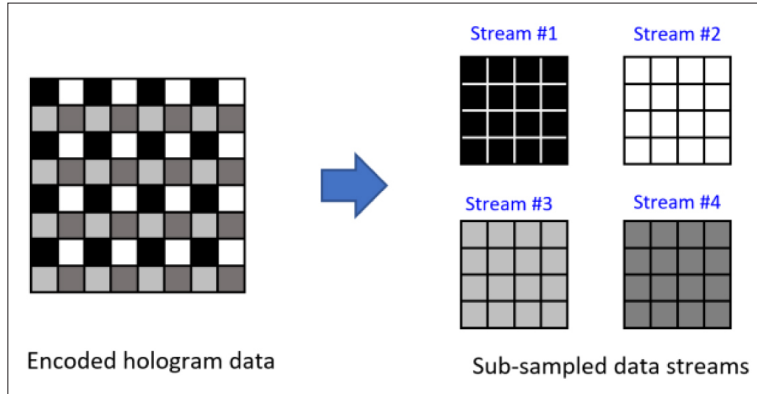
딥러닝 기반의 홀로그램 영상 생성 알고리즘은 진폭과 위상을 모두 포함하는 복소 홀로그램을 추론하는 것으로 써, 이를 진폭 혹은 위상만 변조 가능한 일반적인 공간 광변조기에 표시하기 위해서는 진폭 혹은 위상만을 가지는 영상 정보로 변환하는 인코딩 과정이 필요하다. 이렇게 진폭 정보만을 가지는 영상 정보로 인코딩된 홀로그램을 amplitude-only hologram, 위상 정보만을 가지는 영상 정보로 인코딩된 홀로그램을 phase-only hologram이라고 한다. 이 중 phase-only hologram으로 인코딩하기 위해 대표적으로 사용되는 인코딩 방법은 double phase

encoding 방법이 있다[6]. 이는 인접한 두 개 이상의 픽셀을 superpixel로 취급하고, 각각의 subpixel이 렌즈 광학계를 통해 이미징된 후 가지는 위상 차이를 이용하여 진폭과 위상을 모두 표현하는 방법이다. 이렇게 인코딩된 phase-only hologram을 스트리밍하고자 하면 <그림3>과 같이 압축·전송을 포함한 네트워크 파이프라인을 이용해야 한다. 이때 전체 시스템 구성을 보다 편리하게 하기 위해서는 기존의 압축·전송 방법을 최대한 활용하는 것이 바람직하다.

하지만 일반적으로 amplitude-only 또는 phase-only hologram으로 인코딩된 홀로그램은 superpixel 내의 subpixel들의 값에 큰 차이가 존재하게 되므로, 보통 고주파 성분을 최소화하는 방향으로 설계되어 있는 기존의 압축 방법을 인코딩된 홀로그램 영상에 그대로 적용하면 이러한 subpixel 사이의 차이가 사라지게 되고 결과적으로 전송 후 홀로그램 영상을 복원하였을 때 제대로 된 홀로그램 영상의 가시화가 불가능하게 된다. 따라서 이러한 superpixel 내부의 정보 손실을 막기 위해서는 <그림4>와 같이 subpixel별로 모은 서브영상 세트로 구성하여 각 서브영상에 대해서 압축을 수행하는 것이 필요하다.



<그림 3> 홀로그램 스트리밍 파이프라인




<그림 4> 홀로그램 서브영상 세트 구성 방법

이렇게 압축된 서브영상 세트를 수신단에서 받아 다시 원래의 superpixel 구조를 재구성하면 원래의 홀로그램 영상을 얻을 수 있는데, 이를 위해 필요한 정보를 담고 서브영상 세트를 구조화하기 위한 파일 포맷의 표준이 필요하다. 최근 TTA에서는 이러한 방식의 스트리밍을 위한 파일 포맷 표준화가 이루어졌으며, 파일 포맷의 구조

는 <그림 5>와 같다[7]. 이 파일 포맷에서 이러한 홀로그램 서브영상 구성을 하기 위한 중요 정보들이 담겨 있는 Hologram Info 영역은 <표 1>과 같이 구성되어 있다. 이와 같은 파일 포맷을 채택한다면 인코딩된 홀로그램 영상 정보의 손실을 최소화하고 홀로그램의 실시간 스트리밍이 가능하다.

<표 1> 홀로그램 영상 전송을 위한 파일 포맷의 Hologram Info 영역의 구성

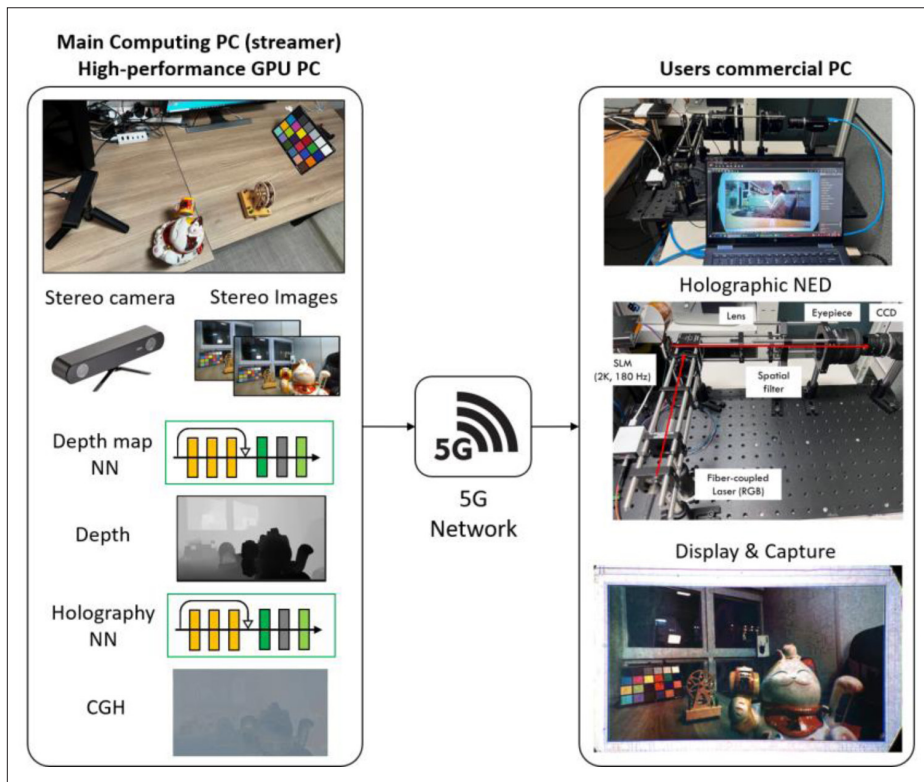
필드 이름	형식	상세 설명
WAVELENGTH_NUMBER	unit8	홀로그램 표현 파장의 갯수
WAVELENGTH	double[2]	홀로그램 표현 파장 (nm 단위)
WAVELENGTH_INTENSITY	double[2]	홀로그램 표현 파장별 세기의 비율
PIXEL_PITCH	double[2]	홀로그램 가로 및 세로 픽셀 크기 (um 단위)
DEPTH_RANGE_FLAG	bool	홀로그램 깊이 범위 (DEPTH_RANGE) 제공 유무
DEPTH_RANGE	double[2]	(Optional) 홀로그램 깊이 범위의 near, far 값 (mm 단위)
HOLOGRAM_TYPE	unit8	홀로그램 타입 (0: amplitude-phase, 1: real-imaginary, 2: amplitude-only, 3: phase-only)
HOLOGRAM_BIT_DEPTH	unit8	홀로그램 영상의 bit depth 값
PHASEMAP_TYPE	unit8	Phase 매핑값 기술 방법 (0: 매핑값 제공 안함, 1: Linear 매핑, 2: Custom 매핑)
PHASEMAP	double[2]	(Optional) 홀로그램 영상의 계조별 Phase 매핑값 (실제 phase값을 π 로 나눈 비율로 기술) - PHASEMAP_TYPE = 0: Null - PHASEMAP_TYPE = 1: (double[2]) 계조가 0일때의 값과 (HOLOGRAM_BIT_DEPTH-1)일 때의 값을 정의하고 이 사이 값을 선형적으로 보간하여 사용. - PHASEMAP_TYPE = 2: (double HOLOGRAM_BIT_DEPTH) 계조가 0일때부터 (HOLOGRAM_BIT_DEPTH-1)일때까지의 값을 순차적으로 정의.
INTERWEAVE_FLAG	bool	저장된 홀로그램 스트림 데이터를 interweaving 하여 사용할 것인지 여부
INTERWEAVE_SHAPE	unit8[2]	(Optional) Interweaving 매핑 정보 행렬의 크기 (행, 열의 순서)
INTERWEAVE_MAP	unit8[2]	(Optional) Interweaving 매핑 정보 행렬
STREAM_TYPE	string	홀로그램 스트림 저장 형식
STREAM_NUMBER	unit8	저장된 홀로그램 스트림의 개수
STREAM_SIZE	unit32[2]	홀로그램 스트림별 용량 (byte값)




<그림 5> 홀로그램 영상 전송을 위한 파일 포맷의 구조

<그림 6>은 이와 같은 홀로그램 실시간 스트리밍 기술을 이용하여 홀로그램 화상 회의 시스템을 구현한 사례를 보여주고 있다. 이 시스템에서는 단안 1920 x 1080

해상도의 스테레오 카메라(ZED 2i)로 인물의 컬러 및 깊이도 영상을 실시간으로 촬영하고 이를 딥러닝 홀로그램 생성을 이용, 1920 x 1080 해상도의 double-phase encoding된 phase-only 홀로그램 영상을 획득한다. 이 홀로그램 영상을 Subimage 변환하여 압축 후 5G 네트워크를 통해 전송하고, 수신단에서는 전송된 홀로그램 영상의 superpixel 재구성 후 홀로그래픽 디스플레이 시스템을 통해 가시화하였다. <그림 7>은 구현된 홀로그램 화상 회의 시스템을 통해 실시간 스트리밍한 홀로그램을 광학적으로 가시화한 영상을 카메라로 촬영한 것을 보여준다. 두 이미지는 카메라의 초점 거리를 가까운 쪽(Near focus)과 먼 쪽(Far focus)으로 바꾸어가며 촬영한 것이며, Near focus 이미지는 가까운 곳에 초점이 맞고(파란색 동그라미 부분), Far focus 이미지는 먼 쪽에 초점이 맞은(초록색 동그라미 부분) 것을 확인할 수 있다. 따라서 이



<그림 6> 홀로그램 실시간 스트리밍 시스템의 구성



<그림 7> 홀로그램 화상 회의 시스템의 홀로그램 가시화 영상

러한 초점 표현을 통해 홀로그램의 가시화가 잘 이루어진 것을 확인할 수 있다. 전송된 홀로그램 영상은 일반적인 5G 네트워크망에서 30 fps 이상의 속도로 재생이 되었으며, 전송에 약 1초의 latency가 존재하였다. 이러한 실험 결과를 통해 딥러닝 기반 홀로그램 생성 알고리즘을 적용하면 5G 네트워크 상에서 실시간 홀로그램 영상의 스트리밍이 가능함을 확인하였다.

III. Neural Radiance Filed(NeRF)를 이용한 photorealistic 홀로그램 영상 가시화

1. NeRF 기반 극사실적 홀로그램 프린팅

홀로그램 프린팅은 넓은 시야각의 홀로그램 영상 가시화에 요구되는 높은 해상도에 대응하기 위하여 전체 홀로그램을 프린팅을 통해 구현하는 방법이다[8]. 일반적으로 홀로그램을 넓은 시야각으로 표현하기 위해서는 수백 K 이상의 해상도가 필요하게 되며, 이는 일반적인 SLM으로 표현이 불가능하다. 따라서 이러한 높은 해상도를 갖는 홀로그램 영상을 일반적인 SLM 장치에 표현 가능한 수 K 정도의 해상도를 갖는 단위 영상으로 나누면, 각각

의 단위 영상은 SLM에 표시가 가능하다. 이후 이를 홀로그램 필름에 아날로그 홀로그래피의 방식으로 기록할 수 있다. 이때 단위 영상들을 마치 프린팅을 하듯이 홀로그램 필름 상에서 연속적으로 이어지도록 기록을 하게 되면 최종적으로 의도했던 수백K급 해상도의 홀로그램 영상을 가시화할 수 있으며, 이러한 기록 방식을 홀로그램 프린팅이라 한다. 이는 비록 동적인 영상의 가시화는 불가능하지만, 자유롭게 편집 및 재가공이 가능한 디지털 홀로그램 영상 데이터를 넓은 시야각을 가지도록 가시화 가능한 기술이다. 하지만 앞서 설명한 바와 같이, 실제 프린팅된 홀로그램 결과물은 입체 표현은 뛰어나나 실사 물체의 3차원 정보를 취득하는 과정에서 소실되는 정보들에 의해 photorealistic한 표현은 어려운 문제가 있었다.

이를 해결하기 위해 다시점 카메라 시스템을 통해 대상 물체를 촬영하고, 촬영된 결과를 NeRF 네트워크로 학습시켜 놓으면 photorealistic한 입체의 시점 영상 정보를 획득할 수 있기 때문에, 홀로그램 생성에 필요한 시점 영상들을 이를 통해 확보하면 계산된 영상들을 홀로그램 프린팅으로 기록할 경우 photorealistic한 홀로그램 영상을 가시화할 수 있다[9]. 저자들은 <그림 8>과 같이 25대의 4000 x 3000급 해상도의 스마트폰 카메라로 다시점 카메라 시스템을 구성하였으며, 이로부터 촬영된 영상들을 통해 NeRF 네트워크를 학습할 수 있었다. <그림 9>는 이와



<그림 8> NeRF 학습용 이미지 촬영을 위한 다시점 카메라 시스템



<그림 9> NeRF를 이용한 인물의 홀로그램 프린팅 가시화 결과

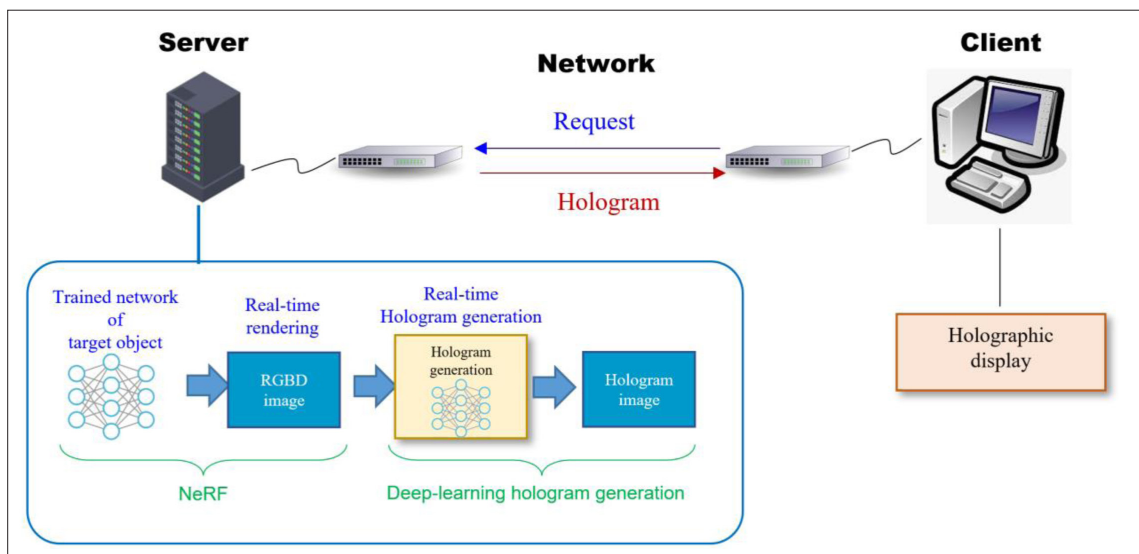
같은 과정을 통해 인물을 촬영하여 홀로그램 프린팅을 통해 가시화한 예시이다. 프린팅된 홀로그램 영상은 5인치 크기의 홀로그램 필름에 360K x 360K의 해상도를 가지도록 기록되었다. 이 결과에서 볼 수 있듯이 NeRF를 활용할 경우 실사 물체의 photorealistic한 홀로그램 영상의 가시화가 가능한 것을 확인할 수 있다.

2. NeRF 기반 홀로그램 온라인 전시 가시화 서비스

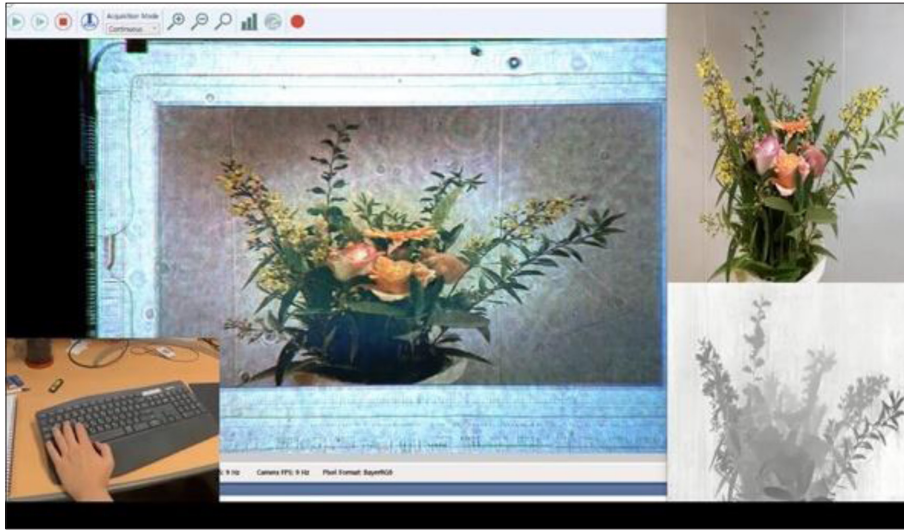
NeRF는 극사실적 시점 영상을 렌더링할 수 있으나, 학습 및 렌더링에 필요한 시간이 매우 길어 실시간 영상에 적용하기 어려운 단점이 있다. 최근에는 이러한 학습 및 렌더링 시간을 줄이기 위해 활발한 연구가 이루어지고 있으며, 특히 렌더링에 있어서는 video-rate으로 렌더링 가능한 접근법들이 다수 보고되고 있다[10, 11]. 따라서 이러한 기술은 학습은 오래 걸리지만 렌더링은 실시간으로 가능하기에 온라인 쇼룸, 온라인 전시 등 사용자가 서버에 접속하여 사전에 저장된 전시 영상 정보를 확인하는 형태의 응용처에서 활용이 가능하다. 전시하고자 하는 물체를

사전에 NeRF로 학습하여 서버에 데이터베이스화하여 저장해 두면, 클라이언트의 사용자가 서버에 접속하여 전시품의 다양한 시점을 실시간으로 photorealistic한 영상으로 가시화하여 향유하는 시나리오가 가능하다. 이때, 렌더링된 시점 영상 및 그에 대응하는 깊이지도를 앞의 2장에서 소개한 딥러닝 기반의 실시간 홀로그램 스트리밍 파이프라인의 입력으로 활용하면, 클라이언트에 있는 사용자가 온라인상의 전시품의 다양한 시점을 photorealistic한 홀로그램 영상으로 향유하는 시나리오로 개발할 수 있다.

이러한 홀로그램 온라인 전시 서비스를 구현하기 위해 저자들은 <그림 10>과 같은 시스템을 구현하였으며, 전시품의 실시간 시점 영상 및 깊이지도 렌더링을 위해 TensorRF 알고리즘을 통해 네트워크 학습 및 렌더링을 수행하였다[11]. 클라이언트의 사용자는 키보드 입력을 통해 서버에 저장된 전시품의 렌더링 시점을 변화시킬 수 있으며, 시점 영상은 2K급 컬러 및 깊이지도 영상으로 렌더링되어 tensor holography 알고리즘의 입력으로 제공된다. 이때 홀로그램 영상은 약 1 fps의 속도로 생성되었으며, 이렇게 생성된 홀로그램 영상은 네트워크를 통해 전송 후 클라이언트단에 있는 홀로그래픽 디스플레이를 통



<그림 10> NeRF를 이용한 홀로그램 온라인 전시 시스템



<그림 11> NeRF를 이용한 홀로그램 온라인 전시 시스템 가시화 영상

한 가시화를 하여 <그림 11>과 같이 사용자가 홀로그램 영상으로 전시품의 다양한 시점을 관찰할 수 있도록 제공이 가능함을 확인하였다.

IV. 결론

본고에서는 기존 홀로그램 영상 생성에 있어 불가능했던 홀로그램의 실시간 생성 및 photorealistic한 표현을 딥러닝 알고리즘을 통해 실현하는 기술에 대해서 살펴보았다. CNN 기반의 딥러닝 네트워크를 이용해 video-rate

의 홀로그램 생성이 가능해졌고, 이러한 알고리즘을 이용해 홀로그램 화상 회의 등의 응용처에 적용할 수 있음을 확인하였다. 또한 NeRF를 통해 실사 물체의 시점 영상 생성 과정에서 정보 손실을 최소화할 수 있게 됨으로써 이를 통해 생성된 홀로그램 영상이 photorealistic한 표현이 가능해졌기 때문에 극사실적 홀로그램 프린팅 및 홀로그램 기반의 온라인 전시 서비스가 가능함을 보여주었다. 추후에 NeRF 알고리즘의 학습 속도가 향상된다면 극사실적 홀로그램 영상의 실시간 스트리밍도 가능할 수 있을 것으로 전망된다.

※ 이 논문은 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2020-0-00548, (세부3) 딥러닝 기반의 5G 서비스 실시간 홀로그램 획득 및 전처리 기술 개발)

참 고 문 헌

- [1] T. Shimobaba and T. Ito, "Computer Holography: Acceleration Algorithms and Hardware Implementations," CRC Press (2019).
- [2] L. Shi, B. Li, C. Kim, P. Kellnhofer, and W. Matusik, "Towards Real-Time Photorealistic 3d Holography with Deep Neural Networks," Nature 591, 234-239 (2021).
- [3] B. Mildenhall, et al., "NeRF: Representing scenes as neural radiance fields for view synthesis," In ECCV (2020).
- [4] J. Goodman, "Introduction to Fourier Optics," (3rd Ed) Roberts and Company Publishers (2004).
- [5] B. Guenter, M. Finch, S. Drucker, D. Tan, and J. Snyder, "Foveated 3D graphics," ACM Trans. Graph. 31, 164 (2012).
- [6] C. K. Hsueh and A. A. Sawchuk, "Computer-generated double-phase holograms," Appl. Opt. 17, 3874-3883 (1978).
- [7] TTA 국문표준, TTAK,KO-10.1479, "홀로그램 스트리밍을 위한 홀로그램 파일 포맷" (2023).
- [8] H. Kang, E. Stoykova, and H. Yoshikawa, "Fast phase-added stereogram algorithm for generation of photorealistic 3D content," Appl. Opt. 55, A135-A143 (2016).
- [9] J. Hong, et al., "New approaches for hologram streaming and printing using deep learning," In DHIP (2023).
- [10] C. Reiser, S. Peng, Y. Liao, and A. Geiger, "KiloNeRF: Speeding up Neural Radiance Fields with Thousands of Tiny MLPs," In ICCV (2021).
- [11] A. Chen, Z. Xu, A. Geiger, J. Yu, and H. Su, "TensorRF: Tensorial Radiance Fields," In ECCV (2022).

저 자 소 개



홍 지 수

- 2004년 ~ 2008년 : LG전자기술원 선임연구원
- 2012년 : 서울대학교 전기컴퓨터공학부 박사
- 2014년 ~ 현재 : 한국전자기술연구원 책임연구원
- 주관심분야 : 홀로그래픽 디스플레이, XR 디스플레이, 3차원 영상정보처리



이 병 호

- 2015년 : 서울대학교 전기정보공학부 학사
- 2021년 : 서울대학교 전자정보공학부 박사
- 2021년 ~ 현재 : 한국전자기술연구원 선임연구원
- 주관심분야 : 홀로그래픽 디스플레이, Computational 디스플레이