

딥러닝을 이용한 광학적 프린지 패턴의 생성

강지원¹ · 김동욱² · 서영호^{2*}

Generation of optical fringe patterns using deep learning

Ji-Won Kang¹ · Dong-Wook Kim² · Young-Ho Seo^{2*}

¹Undergraduate Student, Department of Electronic Material Engineering, Kwangwoon University, Seoul, 01897 Korea

^{2*}Professor, Department of Electronic Material Engineering, Kwangwoon University, Seoul, 01897 Korea

요약

본 논문에서는 심층신경망(deep neural network, DNN)을 이용하여 디지털 홀로그램을 생성하는 신경망의 학습을 위한 데이터 균형 조정 방법에 대하여 논의한다. 심층신경망은 딥러닝(deep learning, DL) 기술에 기반을 두고 있고, 생성형 적대적 네트워크(generative adversarial network, GAN) 계열을 이용한다. 심층 신경망을 통하여 생성 하고자 하는 홀로그램의 기본 단위인 프린지 패턴은 홀로그램 평면과 객체의 위치에 따라 데이터의 형태가 매우 다르다. 하지만 데이터의 분류 기준이 명확하지 않기 때문에 학습 데이터의 불균형이 생길 수 있다. 학습 데이터의 불균형은 곧 학습의 불안정 요소로 작용한다. 따라서 분류 기준이 명확하지 않은 데이터를 분류하고 균형을 맞추는 방법을 제시한다. 그리고 이를 통하여 학습이 안정화됨을 보인다.

ABSTRACT

In this paper, we discuss a data balancing method for learning a neural network that generates digital holograms using a deep neural network (DNN). Deep neural networks are based on deep learning (DL) technology and use a generative adversarial network (GAN) series. The fringe pattern, which is the basic unit of a hologram to be created through a deep neural network, has very different data types depending on the hologram plane and the position of the object. However, because the criteria for classifying the data are not clear, an imbalance in the training data may occur. The imbalance of learning data acts as a factor of instability in learning. Therefore, it presents a method for classifying and balancing data for which the classification criteria are not clear. And it shows that learning is stabilized through this.

키워드: 생성형 적대적 네트워크, 홀로그램, 데이터 전처리, 불균형 학습, 오버 샘플링

Keywords: GANs, Hologram, Data preprocessing, Imbalance training, Oversampling

Received 5 October 2020, Revised 13 October 2020, Accepted 20 October 2020

*Corresponding Author Young-Ho Seo (E-mail: yhseo@kw.ac.kr, Tel: +82-2-940-8362)

Professor, Department of Electronic Material Engineering, Kwangwoon University, Seoul, 01897 Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.12.1588>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

홀로그래프를 획득하는 방법은 크게 광학적으로 촬영하는 방법과 수치적으로 생성하는 방법으로 분류된다. 광학적 촬영은 고가의 장비가 필요할 뿐만 아니라 실험 환경에 매우 민감하다. 또한 높은 에너지를 갖는 레이저를 이용하기 때문에 모든 물체에 조사할 수 없다. 따라서 수치적으로 생성하는 방법이 사용되고 있다. 이렇게 수치적으로 생성하는 홀로그래프를 컴퓨터 생성 홀로그래프(Computer-generated-hologram, CGH)이라고 한다. 현재까지 매우 많은 CGH 기법이 연구되어 왔다. 가장 고품질의 홀로그래프를 생성하기 위해서는 공간을 부동소수점의 고정밀도로 표현하고, 포인트 클라우드(Point cloud) 기반의 레이 트레이싱(Ray-tracing)을 이용하여 홀로그래프를 생성하는 홀로그래프 수치 계산 방법이다 [1][2]. 객체와 홀로그래프 면 간의 공간을 근사화 시킨다면 계층 기반(Layer-based) 홀로그래프 생성 방식에 해당한다. 이 방식을 사용할 경우에는 양자화된 레이저에 대한 홀로그래프를 한 번에 생성할 수 있기 때문에 고속화가 가능하다[3-6]. 레이 트레이싱 방식에 기반을 두면서 고속화하기 위한 방법으로 WRP(wavefront recoding plane) 방식도 있다. 이는 가상의 면을 위치시킴으로써 연산을 가속화한다[7][8]. 이와 같이 고속화를 위해서는 데이터의 정밀도를 일정 부분 포기함으로써, 정밀도와 고속화 사이에는 트레이드 오프(Trade-off) 관계가 존재한다.

최근에 딥러닝 기술이 급속도로 발전하면서 지금까지 해결하기 어려운 다양한 문제들을 이전과는 다른 방식으로 접근하는 방법론들이 등장하고 있다. 홀로그래프 생성 또한 생성형 적대적 네트워크(generative adversarial network, GAN)나 가변형 자동 인코더(Variational Auto Encoder, VAE)와 같은 심층 신경망(deep neural network, DNN)을 이용한 연구가 이루어지고 있다[9][10]. 본 연구실에서는 딥러닝 기술 중 높은 공간 주파수 표현력을 가지고 있는 GAN을 이용하여 홀로그래프 생성기를 만들었다. 이러한 생성형 모델들은 학습이 어렵다. 특히 홀로그래프와 같은 데이터들은 형태도 매우 다양하다. 하지만 어떠한 기준으로 데이터의 형태를 분류해야 할지 기준이 명확하지 않다. 균형을 부적절하게 맞추거나 고려하지 않는 경우 학습의 불안정성이 높아진다. 따라서 이에 대한 연구가 필요하다.

본 논문은 다음과 같이 구성된다. 2장에서는 학습과

평가에 사용하는 홀로그래프 데이터의 생성 방법과 GAN 네트워크의 학습방법을 설명한다. 3장에서는 홀로그래프 데이터의 균형을 맞추기 위한 기준 분류법을 제안한다. 4장에서는 제안한 방법을 적용하여 데이터의 균형을 맞추고 학습이 안정화됨을 보인다. 그리고 5장에서 결론을 맺는다.

II. 관련 연구

본 논문에서는 딥러닝 네트워크를 트레이닝 할 때 홀로그래프의 성분 분석을 통하여 분류하고, 데이터의 균형을 맞추어주는 방법을 제안하고 학습의 안정화를 이룸을 보인다. 이 때 쓰는 홀로그래프 데이터 생성과 GAN 네트워크의 학습 방법을 아래에서 설명한다.

2.1. 홀로그래프 생성

식 (1)은 완전 복소 홀로그래프의 생성을 위한 CGH 수식을 나타내었다. $I(u, v)$ 는 홀로그래프 평면의 좌표 (u, v) 에서의 밝기이고, $A_j(x, y, z)$ 는 객체 점인 (x, y, z) 좌표에서의 밝기이다. N 은 객체 점의 개수이고, λ 는 홀로그래프 생성에 사용한 참조파(Reference wave)의 파장이고, p 는 홀로그래프와 광원의 화소의 크기인데, 여기에서는 편의상 동일한 값으로 취급하였다.

$$I(u, v) = \sum_j^N A_j(x, y, z) \exp\left(\frac{2\pi}{\lambda} \sqrt{(pu - px)^2 + (pv - py)^2 + z^2}\right) \quad (1)$$

사용한 네트워크의 데이터 세트는 식 (1)에서 한정된 객체 공간 안의 점을 하나씩 샘플링하여 이에 해당하는 프린지 패턴을 생성하여 구성한다.

2.2. GAN

본 논문에서는 프린지 패턴을 생성할 때 다른 네트워크와 비교하였을 때 높은 공간 주파수의 표현력이 높은 GAN 네트워크를 사용한다. 이 네트워크는 서로 경쟁하는 두 개의 네트워크 시스템에 의해 구현된다.

GAN의 구조는 생성기(Generator)와 판별기(Discriminator)로 구성되어 있으며, 생성기와 판별기는 서로 상반된 목적을 가지고 두 신경망 모델의 경쟁을 통해 학습하고 결

과물을 생성해낸다. 생성기는 실제에 가까운 거짓 데이터를 생성하는 것을 목적으로 하고 있으며, 실제 데이터를 학습하여 데이터의 분포를 캡처하고 이를 바탕으로 거짓 데이터를 생성한다. 판별기는 생성자의 거짓 데이터를 구분하는 것이 목적으로 생성기가 생성한 데이터가 실제인지 거짓인지 판별하도록 학습한다.

본 논문에서는 이 GAN 네트워크 중에서도 convolution을 이용하여 이미지의 특징을 추출해내고 이를 통해 훨씬 디테일한 이미지를 생성해내는 DCGAN (Deep Convolutional Generative Adversarial Networks)의 판별기와 생성기를 사용한다. 기존 DCGAN 논문에서 사용하는 Jensen-Shannon divergence 대신 연속적인 값을 가지는 식 (2)의 Wasserstein distance를 손실 함수로 적용하여 그림 1과 같은 흐름으로 홀로그래프 데이터를 학습한다[11][12].

$$W(P_r, P_g) = \inf_{r \in \Pi(P_r, P_g)} E_{(x,y) \sim y} [\|x - y\|] \quad (2)$$

홀로그래프를 생성하고자 하는 좌표를 입력으로 넣어 주면 CGH 알고리즘을 통하여 해당 프린지 패턴(f)가 생성되고 이와 동시에 생성기를 이용하여 가짜 프린지 패턴(\tilde{f})을 생성한다. 판별기는 이 식 (2)를 이용해 두 결과를 비교하여 진짜와 가짜가 얼마나 비슷한지에 대한 점수를 출력한다. 이 계산결과를 바탕으로 판별기는 진짜 프린지 패턴이 들어왔을 때의 점수가 더 크게 나올 수 있도록 내부 파라미터들이 갱신된다. 또한 생성기는 판별기가 가짜 프린지 패턴의 점수를 더 크게 만드는 방향으로 내부 파라미터들을 갱신하는 과정을 거친다. 이러한 상반된 목표를 가진 네트워크가 상호 경쟁하며 이와 같은 과정을 반복 수행하면 판별기가 진짜와 가짜를 구별할 수 없을 정도로 유사해지게 되는데, 이것은 생성기가 프린지 패턴을 출력할 수 있는 상태가 되었다는 것을 의미하고 이것을 학습의 목표로 한다.

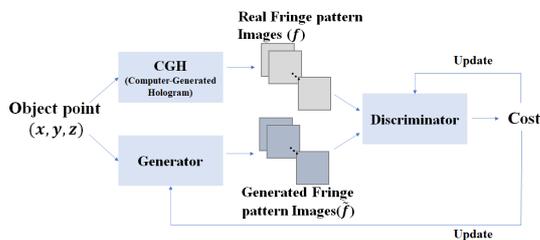


Fig. 1 Flow chart of Conditional GAN generating optical fringe pattern[13]

III. 홀로그래프 생성기 학습 안정화 방법

디지털 홀로그래프의 기본 구성요소인 프린지 패턴은 홀로그래프 평면의 위치와 객체가 존재 하는 공간의 위치에 따라서 그림 2에 나타난 것과 같이 형태가 매우 다양하다. 이런 다양한 형태의 프린지 패턴은 네트워크 입장에서 데이터의 불균형으로 작용하여 상대적으로 다수인 특징이 비슷한 형태의 데이터에 치중된 파라미터 갱신을 할 가능성이 높아진다. 이는 곧 네트워크 학습의 안정성을 떨어트리는 요소로 작용하게 된다.

하지만 균형이 맞지 않은 데이터의 균형을 맞추어 주기 위해서는 데이터의 적절한 분류법이 필수적이다.

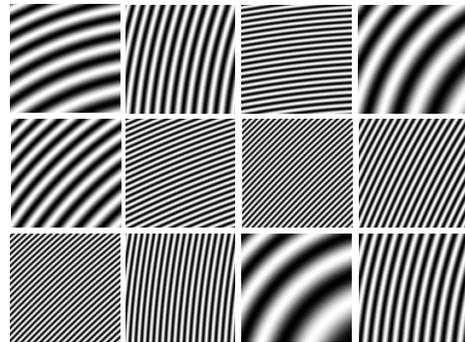


Fig. 2 Various types of fringe patterns

프린지 패턴의 데이터 분류에 이산 코사인 변환 (Discrete Cosine Transform, DCT) 알고리즘을 사용한다. 프린지 패턴에 DCT를 수행하고, 변환 후 주파수 영역에서 에너지 집중도를 분석하여 프린지 패턴을 분류한다. DCT는 전역 변환보다는 지역 변환에 대해서 더 좋은 특성을 나타내기 때문에 8×8 의 블록 단위로 나누어서 변환을 수행한다.

수행하는 방법은 그림 3에 나타내었다. 프린지 패턴 공간영역을 8×8 블록 단위로 나눈다. 각 블록의 동일 좌표의 에너지를 더해 하나의 블록으로 나타낸다. 식 (3)은 크기가 $N \times N$ 일 때 입력 블록 좌표의 DCT 계수 $B_n(x, y)$ 와 전체 블록 수 M 에 대한 에너지 $E(x, y)$ 에 대한 식이다.

$$E(x, y) = \sum_{x=1}^N \sum_{y=1}^N \sum_{n=1}^M (B_n(x, y))^2 \quad (3)$$

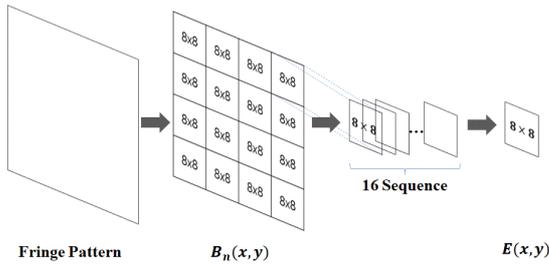


Fig. 3 8x8 Block based DCT energy calculation [14]

이 과정은 모든 블록에 대한 동일 좌표의 에너지를 합하여 공간 주파수 계수의 개수에 따른 에너지 집중도를 산출한 것이기 때문에 이는 해당 데이터의 주파수의 특징을 담고 있는 데이터이다. 8x8블록 크기의 에너지 맵을 14개의 구역으로 나누어 홀로그래프의 데이터 분류 기준을 정한다. 이 구역 정보는 그림 4에 나타났다. 에너지의 대부분이 분포하는 DC영역을 제외한 AC영역을 14개의 구역으로 나누고 각 구역의 에너지 평균을 구한다. 그리고 가장 높은 에너지 평균을 가지는 구역을 해당 데이터를 대표하는 구역으로 정하고 이 구역을 level이라고 부르기로 한다.

이와 같이 데이터의 주파수 성분에 기반한 분류를 진행하고 나면 데이터 세트가 편중되어 있는 level과 희소한 level이 생기게 된다.

이 때 재 샘플링(Re-sampling)을 이용한다. 재 샘플링은 소수 클래스 샘플을 생성하는 오버 샘플링(Over-sampling)과 다수 클래스 샘플을 제거하는 언더 샘플링(Under-sampling)으로 나눈다. 언더 샘플링은 데이터 크기를 줄이기 때문에 학습 시간 등을 줄이는데 도움이 되지만, 자칫 유용한 정보를 담고 있는 샘플을 제거해서 우수하지 못한 모델을 학습할 위험이 있다. 반대로 오버 샘플링은 데이터 크기를 늘리기 때문에 학습 시간이 늘어난다는 단점이 있으나, 데이터의 유용한 정보를 그대로 사용할 수 있어 우수한 모델을 만들 가능성이 높다. 대표적인 오버 샘플링 방법으로는 소수 클래스의 샘플을 임의로 복제하여 그 수를 늘리는 랜덤 오버 샘플링(Random Oversampling, ROS) 방법이 존재한다[15].

모든 데이터는 학습 시 무작위로 불러오지만, 데이터의 무작위 호출 시 랜덤 오버 샘플링 방법을 사용하여 상대적으로 적은 데이터 구역에 가중치(Weight)를 부여하여 더 많은 학습이 이루어질 수 있게 하는 방법을 제안한다.

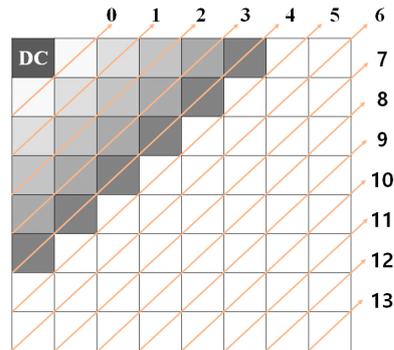


Fig. 4 DCT energy divided by data frequency characteristics

제안하는 방법의 전체적인 흐름도는 그림 5에 나타내었다. 학습하고자하는 데이터세트에 대하여 8x8 블록 기반의 DCT 에너지 맵을 구한다. 그리고 나온 8x8 크기의 에너지 맵에서의 level을 각 데이터들에 대하여 구하고 각 level에 해당하는 데이터의 개수를 저장한다. 전체 데이터 세트에 대하여 이러한 과정을 거쳐 나온 각 level별 데이터 개수로 데이터 비율을 구하고 이 비율을 역수 취하여 가중치로써 사용한다. 이후 네트워크 학습에 필요한 데이터를 무작위 샘플링 할 때 이 가중치를 사용하여 데이터를 샘플링한다. 이렇게 샘플링을 진행하면 무작위로 샘플링을 진행하되 데이터의 개수가 작은 level 일수록 샘플링이 될 확률이 높아지면서 결과적으로 네트워크에 전달되는 데이터의 균형이 맞게 된다.

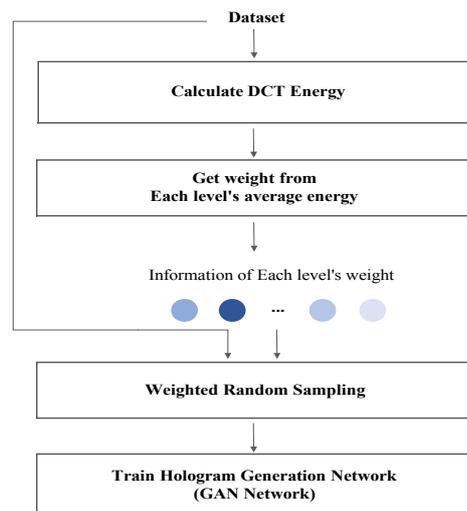


Fig. 5 Flowchart of hologram generator training stabilization method

IV. 실험 결과

16×16×16 공간에 대한 데이터 세트들은 표 1과 같은 파라미터들로 생성되어 학습에 사용되었다. 16×16×16 공간에 대한 데이터는 총 4,096개로 이루어져있다. 앞에서 제시했던 방법과 같이 블록 단위의 에너지 계산을 진행하고, 해당 데이터를 분류하면 그림 6(a)와 같이 분류된다. 실험에 사용한 데이터의 불균형은 약 51 : 31 : 14 : 1로 매우 차이가 매우 크다. 따라서 데이터의 무작위 호출 시 상대적으로 적은 level 3의 데이터에 대해서는 51만개의 가중치를, 가장 많은 level 0의 데이터에는 1의 가중치를 두는 방식으로 균형을 맞추었다.

제시한 방법으로 균형을 맞추어 학습을 진행한 경우 학습의 안정화를 보인다. 학습의 완성도를 판별하는 기준으로는 구조적 유사도 (Structural Similarity, SSIM)를 사용하였다. level별 SSIM 학습 추이는 그림 6 (b)에, 균형을 맞추지 않고 기존의 데이터로 학습한 경우의 level별 SSIM의 정확도 추이는 그림 6 (c)에 나타내었다. 두 네트워크는 각각 200 에폭까지 학습을 진행하고 추이를 관찰하였다.

Table. 1 CGH dataset generation condition

CGH Parameter	
Hologram pixel pitch	6.4μm
Size of Hologram Plane	128 × 128
Object pitch	400μm
Size of Object Space	16 × 16 × 16
Distance (distance between Hologram and Object)	15 cm
Wavelength	633nm

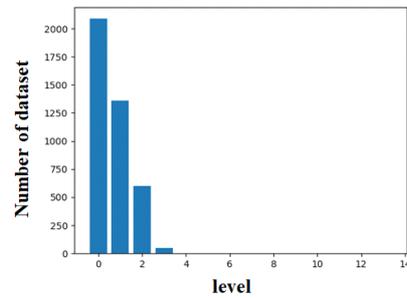
그림 6 (a)에서 볼 수 있듯이 level 0이 가장 많은 수의 데이터를, level 3이 가장 적은 수의 데이터를 가지고 있다. 제안하는 방법을 수행하지 않은 그림 6 (c)를 보면 level 0과 level 1이 가장 빠르게 학습이 되며 약 SSIM 0.9까지 학습이 된다. level 2는 level 0과 1에 비해서 학습속도가 느리지만 최종 SSIM 0.9를 달성하는 것은 같다. 하지만 level 3의 경우 학습도 느릴 뿐만 아니라 최종 SSIM 이 0.8이다.

이와 비교하여 그림 6 (b)는 150에폭 이후에는 모두 0.8 이상의 SSIM을 보인다. 또한 가장 학습이 잘 되지

않았던 Level 3에 속하는 데이터의 경우 가장 빨리 학습이 되는 것을 확인했다. 그리고 학습이 진행될 때 학습의 정확도 추이가 흔들리는 요동(Fluctuation) 현상이 줄어든 것으로 학습의 안정도가 높아졌음을 확인 했다.

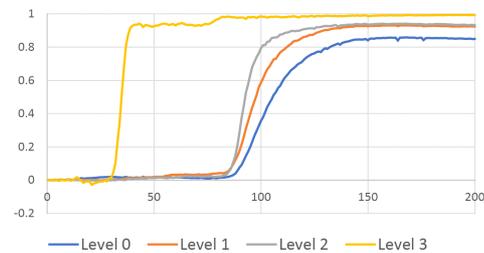
V. 결론

본 논문에서는 불안정한 홀로그래프 GAN학습을 개선하기 위하여 홀로그래프 데이터의 균형을 맞추고자 할 때 사용하는 데이터 분류 방법을 제안하고 가중치를 통한 오버 샘플링을 이용하여 데이터의 균형을 맞추는 방법을 제안했다. 본 방법을 사용하였을 때 학습의 안정성이 높아졌을 뿐만 아니라 정확도 또한 전반적으로 빠른 상승을 보이며 학습의 속도 또한 개선됨을 확인했다. 본 논문에서 제안한 방식은 홀로그래프에 국한되는 것이 아니라 라벨이 존재하지 않는 비지도 학습과 같은 상황의 데이터의 균형을 조정하고자 할 때에도 적용이 가능할 것이다.



(a)

Balanced dataset



(b)

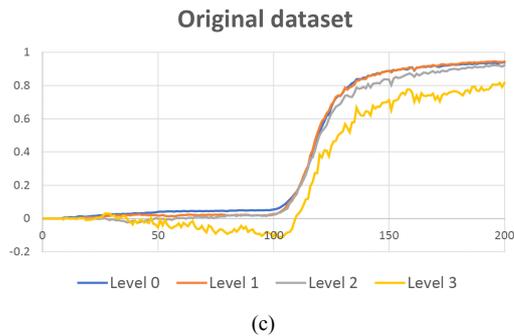


Fig. 6 (a) Frequency domain classification of data set through 2D DCT, (b) Transition of balanced dataset through SSIM, (c) Transition of unbalanced dataset through SSIM

ACKNOWLEDGEMENT

This work was supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) (2020-0-00922, Development of holographic stereogram printing technology based on multi-view imaging)

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education in 2020 (NRF-2020R1D1A1B07043220)

REFERENCES

- [1] Y. H. Lee, Y. H. Seo, J. S. Yoo, and D. W. Kim, "High-performance Computer-generated Hologram by Optimized Implementation of Parallel GPGPUs," *JOSK(Journal of the Optical Society of Korea)*, vol. 18, no. 6, Dec. 2014
- [2] Y. H. Lee, D. W. Kim, and Y. H. Seo, "High-speed CGH based on Resource Optimization for Block-based Parallel Processing," *Applied Optics*, vol. 57, no. 13, May. 2018.
- [3] M. Bayraktar and M. Ozcan, "Method to calculate the far field of three-dimensional objects for computer-generated holography," *Applied Optics*, vol. 49, pp. 4647-4654, 2010.
- [4] Y. Zhao, L. Cao, H. Zhang, D. Kong, and G. Jin, "Accurate calculation of computer-generated holograms using angular-spectrum layer-oriented method," *Optics Express*, vol. 23, pp. 25440-25449, 2015.
- [5] J. Chen and D. Chu, "Improved layer-based method for rapid hologram generation and real-time interactive holographic display applications," *Optics Express*, vol. 23, no. 14, pp. 18143-18155, 2015.
- [6] A. Symeonidou, D. Blinder, A. Munteanu, and P. Schelkens, "Computer-generated holograms by multiple wavefront recording plane method with occlusion culling," *Optics Express*, vol. 23, no. 17, pp. 22149-22161, 2015.
- [7] T. Shimobaba, N. Masuda, and T. Ito, "Simple and fast calculation algorithm for computer-generated hologram with wavefront recording plane," *Optics Letters*, vol. 34, no. 20, pp. 3133-3135, 2009.
- [8] P. W. M. Tsang and T. C. Poon, "Fast generation of digital holograms based on warping of the wavefront recording plane," *Optics Express*, vol. 23, no. 6, pp. 7667-7673, 2015.
- [9] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets," *Advances in Neural Information Processing Systems*, pp. 2672-2680, 2014.
- [10] D. P. Kingma and M. Welling, "Auto-encoding variational bayes," *2nd International Conference on Learning Representations*, 2014.
- [11] M. Arjovsky, S. Chintala, and L. Bottou. "Wasserstein GAN". arXiv preprint arXiv:1701.07875, 2017.
- [12] 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.
- [13] M. Mirza and S. Osindero, "Conditional generative adversarial nets," *arXiv Preprint*, arXiv:1411.1784, 2014.
- [14] J. K. Kim, K. J. Kim, W. S. Kim, Y. H. Lee, K. J. Oh, J. W. Kim, D. W. Kim, and Y. H. Seo, "Characteristic Analysis for Compression of Digital Hologram," *The Korean Society Of Broad Engineers*, vol. 24, no. 1, pp. 164-181, 2019.
- [15] A. Ghazikhani, H. S. Yazdi, and R. Monsefi, "Class Imbalance Handling Using Wrapper-Based Random Vversampling," *Proc. 20th Iranian Conf. on Electrical Engineering*, pp. 611-616, 2012.



강지원(Ji-Won Kang)

2019년 2월 : 광운대학교 전자재료공학과 졸업(공학사)
2019년 9월 ~ 현재 : 광운대학교 전자재료공학과(공학석사)
※관심분야 : 영상처리, 디지털 홀로그래, 딥 러닝



김동욱(Dong-Wook Kim)

1983년 2월 : 한양대학교 전자공학과 졸업(공학사)
1985년 2월 : 한양대학교 공학석사
1991년 9월 : Georgia 공과대학 전기공학과(공학박사)
1992년 3월 ~ 현재 : 광운대학교 전자재료공학과 정교수
※관심분야 : 3D 영상처리, 디지털 홀로그래, 디지털 VLSI Testability, VLSI CAD, DSP설계, Wireless Communication



서영호(Young-Ho Seo)

1999년 2월 : 광운대학교 전자재료공학과(공학사)
2001년 2월 : 광운대학교 일반대학원 졸업(공학석사)
2004년 8월 : 광운대학교 일반대학원 졸업(공학박사)
2005년 9월~2008년 2월 : 한성대학교 조교수
2008년 3월~현재 : 광운대학교 전자재료공학과 정교수
※관심분야 : 실감미디어, 2D/3D 영상 신호처리, 디지털 홀로그래, SoC설계