

홀로그램 데이터에 따른 딥 러닝 기반 홀로그램 워터마킹의 성능 분석

*이주원 이재은 서영호 김동욱

광운대학교

*chagogo9@kw.ac.kr

Performance analysis of deep learning based hologram watermarking according to hologram data

*Lee, Ju-Won Lee, Jae-Eun Seo, Young-Ho Kim, Dong-Wook

Kwangwoon University

요약

본 논문에서는 홀로그램 영상 콘텐츠의 지적재산권 보호를 위하여 워터마킹을 딥 러닝을 기반으로 하는 네트워크로 수행한다고 가정하고, 이 네트워크를 학습시킬 때 학습 데이터 세트를 어떻게 구성하는 것이 워터마킹 네트워크에 가장 효율적인지에 대해, JPEG Pleno에서 표준 데이터 세트로 제공하고 있는 홀로그램들을 사용하여 분석한다. 이 홀로그램들의 표준편차에 따라 학습 데이터세트의 구성을 달리하여 동일한 워터마킹 네트워크에 학습시킨 후 학습에 사용되지 않은 시험 데이터세트를 시험하여 나온 결과의 비가시성과 워터마크, 데이터의 추출률을 비교함으로써 학습 데이터세트 구축 방식에 대해 분석한다.

1. 서론

영상 콘텐츠의 응용분야의 증가로 영상콘텐츠가 고부가가치의 콘텐츠가 되어가고 있다. 따라서 고부가가치 콘텐츠인 영상 콘텐츠의 지적재산권을 보호하는 방법이 매우 중요해지고 있다. 이러한 지적재산권을 보호하는 방법으로 가장 활발하게 연구되고 있는 분야가 디지털 워터마킹이다[1].

광학시스템을 이용한 홀로그램 획득은 다양한 제약이 수반되기 때문에 주로 수학적 모델을 이용한 연산적 방법(CGH, computer-generated hologram)으로 디지털 홀로그램을 획득하게 된다. 이때, 방대한 계산량 때문에 많은 컴퓨팅 자원이 필요하고 제작된 홀로그램의 편집이 어려울 뿐 아니라 2차원 데이터인 홀로그램이 3차원의 정보를 포함하고 있기 때문에 홀로그램은 어느 영상 콘텐츠보다 고부가가치의 콘텐츠이다. 또한, 홀로그램은 입체 영상시스템의 최종 목표로 평가되고 있기 때문에 홀로그램의 지적재산권을 보호하는 방법이 필요하며, 그 방법으로 디지털 워터마킹이 활발하게 연구되고 있다. 기존에는 결정론적 알고리즘 기반의 홀로그램 워터마킹 방법이 많이 연구되어 왔다[2]. 홀로그램 영상이 아닌 일반 2D영상의 워터마킹의 경우에는 결정론적 알고리즘 기반의 워터마킹 방법보다 딥러닝 기반의 워터마킹 방법이 더 좋은 성능을 보이고 있다[3-4]. 그래서 홀로그램 워터마킹 분야에서도 딥러닝 기반의 워터마킹이 좋은 성능을 기대할 수 있을 것이라 생각한다.

본 논문에서는 디지털 홀로그램을 딥 러닝을 기반으로 하는 뉴럴 네트워크로 워터마킹을 수행하는 방법을 제안한다. 여기에는 JPEG Pleno에서 제공하는 홀로그램 표준 데이터세트를 사용하며, 이 데이터들의 표준편차가 학습에 미치는 영향을 분석하여 최적의 학습조건을

찾는다. 그 방법으로는 표준편차에 따라 분류하여 학습 데이터세트를 구축하고 딥 러닝 기반 워터마킹 네트워크에 학습시킨 후 학습에 사용되지 않은 테스트 데이터세트를 시험해서 나온 결과의 비가시성과 추출률을 비교하여 학습 데이터세트 구축 방식에 대해 분석한다.

2. JPEG Pleno 데이터세트

JPEG Pleno가 제공하는 표준 데이터세트는 만들어진 방식과 기관에 따라 크게 세 가지의 종류(ERC, B-com, UBD)로 분류할 수 있다 [5]. 이 세 가지 종류의 분류에서 총 46종류의 서로 다른 홀로그램 데이터를 제공하고 있다. 이 홀로그램들은 실수부와 허수부 그리고 컬러 영상의 R, G, B 채널을 구분하여 172개의 홀로그램으로 구성되어 있다. 홀로그램 원본영상의 경우 146개의 데이터는 [0, 1]의 범위의 표준편차를 가지고 있었지만, 나머지 26개의 데이터들은 값이 제한되어 있지 않아 큰 Dynamic Range를 가져 상대적으로 큰 표준편차들을 가진다. 그래서 이를 그대로 사용하지 않고 정규화(normalization)를 수행했다. 그림 1은 172개의 홀로그램을 [-1, 1]의 실수 값으로 정규화를 수행하여 표준편차 순서대로 나열한 histogram이다. 가장 큰 표준편차를 가지고 있는 데이터는 0.2982의 표준편차를 가지고 있고, 가장 작은 표준편차를 가지고 있는 데이터는 0.035의 표준편차를 가지고 있다. 표준편차가 워터마킹의 학습에 미치는 영향을 알아보기 위해 전체 홀로그램 데이터를 표준편차에 따라 상위 22개(High_std), 하위 22개(Low_std), 중간 22개(Middle_std), 데이터 전체를 등 간격으로 22개(Global_std)를 각각 추출하여 총 4종류의 데이터세트를 구축하였다. 네트워크에 학습시키는 데이터세트는 홀로그램을 128×128의 크기로 잘라서 각 데이터세트의 종류 22개중 18개는 학습 데이터(128×128 5000장)로 4개

는 검증데이터(128×128 1000장)로 구성했다. 시험 데이터세트는 학습에 사용하지 않은 전체 홀로그램들을 등 간격으로 34종류의 홀로그램으로 데이터세트를 구성하였다.

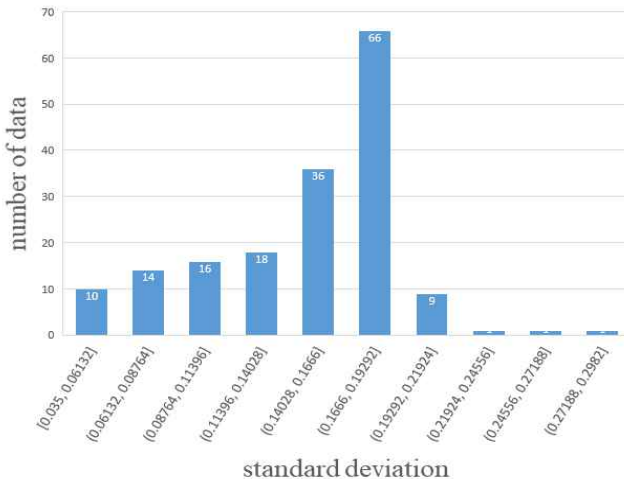


그림 1. 정규화된 JPEG Pleno 데이터세트의 표준편차 히스토그램

3. 워터마킹 네트워크

본 논문에서는 [6]의 네트워크 구조를 사용하여 워터마킹을 진행했다. 그림 2는 전반적인 워터마킹 네트워크의 구조이고, 표 1은 이 네트워크의 세부적인 구조이다. 이 네트워크는 호스트 영상과 워터마크 영상을 각각 전처리하는 전처리네트워크와 워터마크를 호스트 영상에 삽입하는 네트워크, 공격 시뮬레이션을 진행하는 네트워크, 마지막으로 워터마크를 추출하는 네트워크로 구성되어 있다. 전처리 네트워크에서 호스트영상의 특징을 보존하면서 워터마크에 적합한 특징을 추출하고, 워터마크를 업샘플링(up-sampling)하여 호스트영상과 같은 해상도를 가지도록 변형한다. 두 전처리 네트워크의 출력을 정합(concatenate)하여 워터마크를 삽입하는 네트워크를 거치며 워터마킹된 영상을 출력한다. 이 출력을 이용해 비가시성을 확인하고, 이 출력을 공격 시뮬레이션을 통과시키고, 그 결과를 워터마크 추출 네트워크의 입력으로 넣어 삽입했던 워터마크를 추출한다. 추출된 워터마크로 추출률을 확인한다.

4. 실험 및 결과

이전에 설명한 학습 데이터세트와 검증 데이터세트를 사용하여 워터마킹 네트워크를 학습하고, 시험 데이터세트를 이용하여 네트워크의 성능을 검증했다. 표 2와 그림 3은 시험 데이터세트를 시험한 결과이다. 표 2은 4가지의 다른 데이터세트로 학습시킨 네트워크의 시험 데이터세트로 시험하여 나온 PSNR과 BER의 Best, Worst case 그리고 Average를 표로 정리한 것이다. 그림 3의 경우 (a)는 PSNR (b)는 identity BER에 대한 그래프이다. 횡축의 오른쪽으로 갈수록 표준편차가 작은 데이터를 의미한다.

표 2과 그림 3의 결과를 보면 표준편차에 따라 구성된 학습데이터에 따라 결과의 편차가 많이 나는 것을 볼 수 있다. 당연히 학습 데이터세트를 구성한 표준편차 그룹에서는 높은 비가시성과 추출률을 보이지만, 그 반대의 표준편차를 갖는 데이터에서는 좋은 결과를 유지

하지 못하였다. 표준편차가 낮은 데이터들로 학습데이터를 구성한 경우가 이런 현상을 가장 두드러지게 보였다.

워터마킹의 비가시성과 추출률을 모두 고려하면 모든 표준편차 데이터에서 고루 학습데이터를 구성한 global_std가 가장 좋은 성능을 보였다. 그러나 표준편차의 전 영역에서 가장 작은 성능편차를 보인 것은 High_std이었다. 이 경우 비가시성을 판단하는 척도인 PSNR의 worst case에서 가장 높은 값을 가졌고 추출률을 판단하는 척도인 BER의 worst case에서도 가장 좋은 결과를 나타내었다. 평균 비가시성 또한 40.45dB로 꽤 높은 수치를 유지하였고, 평균 추출률 또한 0.568%로 낮은 값을 유지하였다.

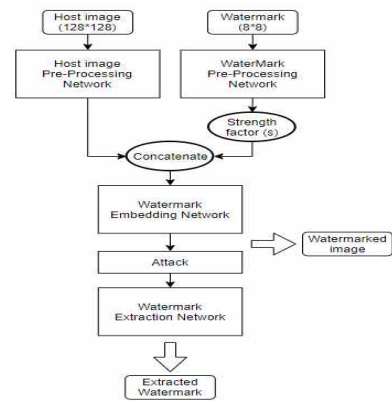


그림 2. 워터마킹 네트워크 구조

표 1. 워터마킹 네트워크 구조

Network	Kernel size	number of kernels	stride	Batch Normalization	Activation function	average-pooling
Pre-processing Network(Host)	3×3	64	1	X	X	X
Pre-processing Network(WM)	3×3	512	1/2	○	ReLU	○
	3×3	256	1/2	○	ReLU	○
	3×3	128	1/2	○	ReLU	○
	3×3	1	1/2	○	-	○
WM embedding Network	3×3	64	1	○	ReLU	X
	3×3	64	1	○	ReLU	X
	3×3	64	1	○	ReLU	X
	3×3	64	1	○	ReLU	X
	3×3	1	1	X	tanh	X
WM Extraction Network	3×3	128	2	○	ReLU	X
	3×3	256	2	○	ReLU	X
	3×3	512	2	○	ReLU	X
	3×3	1	2	X	tanh	X


5. 결론

본 논문에서는 디지털 홀로그램의 워터마킹을 딥 러닝을 기반으로 하는 네트워크로 수행하는 방법을 제안하고, 학습 데이터세트를 홀로그램의 표준편차에 따라 구성하여 각 데이터세트로 학습한 결과의 성능이 어떻게 달라지는지를 분석하였다. 그 결과 전 표준편차 영역에서 골고루 데이터를 추출하여 학습 데이터세트를 구성한 경우 가장 좋은 성능을 보였으며, 높은 표준편차 데이터들로 학습 데이터세트를 구성한 경우 홀로그램의 표준편차에 따른 성능의 편차가 가장 적었음을 확인하였다.


향후 딥 러닝 기반 홀로그램의 워터마킹에 대한 연구가 활발히 진행될 것으로 예상되며, 이 경우 본 논문에서 제안하고 분석한 결과가 매우 유용하게 참고 될 것으로 사료된다.

표 2. 비가시성과 추출률 실험 결과

Items	Detailed items	High_std	low_std	middle_std	global_std
Invisibility	PSNR_best	42.54dB	46.85dB	45.31dB	46.54dB
	PSNR_worst	39.34dB	37.04dB	37.83dB	39.16dB
	PSNR_average	40.45dB	41.27dB	41.82dB	42.16dB
Extraction ratio	BER_best	0%	0%	0%	0%
	BER_worst	0.586%	12.508%	3.785%	3.106%
	BER_average	0.167%	2.288%	0.218%	0.175%



(a)



(b)

그림 3. 시험 결과: (a) 시험 데이터세트의 PSNR (b) 시험 데이터세트의 BER(identity = no attack) 한국방송미디어공학회, 19(5), pp. 606 - 615. doi: 10.5909/JBE.2014.19.5.606., 2014.

감사의 글

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(NRF-2019R1F1A1054552)

참고문헌

[1] I. J. Cox, et al., "Digital watermarking and steganigraphy," Morgan Kaufmann Publisher, 2008.
 [2] Lee, Yoon-Hyuk, Seo, Young-Ho and Kim, Dong-Wook "Fresnel 회절 모델을 이용한 홀로그램 워터마킹," 방송공학회논문지, 25(2), 166-175. 2020.

[3] J. Zhu, R. Kaplan, J. Johnson, and L. Fei-Fei, "HiDDeN: hiding data with deep networks," arXiv:1807.09937, July, 2018.
 [4] M. Ahmadi, A. Norouzi, S. M. Reza Soroushmehr, N. Karimi, K. Najarian, S. Samavi, and A. Emami, "RedMark: framework for residual diffusion watermarking on deep networks," arXiv:1810.07248, Dec. 2018.
 [5] JPEG Pleno <https://jpeg.org/jpegpleno/>
 [6] 이재은, 서영호, 김동욱, "워터마크 및 해상도 적응적인 영상 워터마킹을 위한 딥 러닝 프레임워크," 방송공학회논문지, 25(2), 166-175. 2020.