

Adaptive Digital Watermarking Based on Multi-Rendering Signals: Perceptual Quality Enhancement through JND Model Integration

Ji-Hoon Kim*, Dong-Heon Cho**, Seung-Kwan Choi***

*MS. Student, Dept. of Metaverse Technology, Sogang University, Seoul, Korea

**Ph.D. Student, Dept. of Metaverse Technology, Sogang University, Seoul, Korea

***Professor, Dept. of Metaverse Entertainment, Sogang University, Seoul, Korea

[Abstract]

In digital watermarking for 3D content protection, existing methods fail to exploit intermediate rendering signals and apply uniform embedding strength, leading to inevitable perceptual quality degradation. To overcome this limitation, we propose an adaptive watermarking method that combines rendering signals with a JND model. By analyzing correlations between five rendering signals and JND via Mutual Information, we identify Normal Map (0.073 nats) as the optimal guide signal and design two pixel-wise strength adaptation strategies: Product and Gated. Experiments on 960 samples from six 3D models demonstrate a PSNR improvement of 5.47dB and SSIM enhancement of 0.0059 over the baseline while maintaining 100% message recovery. The computational overhead is 19.4%, making it practical for real-time applications.

▶ **Key words:** Digital Watermarking, 3D Rendering, Normal Map, Just Noticeable Difference (JND), Adaptive Embedding

[요 약]

3D 콘텐츠의 저작권 보호를 위한 디지털 워터마킹에서, 기존 방법들은 렌더링 파이프라인의 중간 신호를 활용하지 못하고 균일한 강도로 워터마크를 삽입하여 시각적 품질 저하가 불가피하였다. 본 연구는 이러한 한계를 극복하기 위해 렌더링 신호와 JND 모델을 결합한 적응형 워터마킹 방법을 제안한다. 5가지 렌더링 신호와 JND 간의 상관관계를 Mutual Information으로 분석하여 Normal Map(0.073 nats)을 최적 가이드 신호로 선정하고, Product와 Gated 두 가지 픽셀별 강도 조절 전략을 설계하였다. 6개 3D 모델의 960개 샘플에 대한 실험 결과, 비교 대상 대비 PSNR 5.47dB 향상과 SSIM 0.0059 개선을 달성하면서 32비트 메시지 복원율 100%를 유지하였다. 추가 계산 비용은 19.4%로 실시간 적용이 가능하다.

▶ **주제어:** 디지털 워터마킹, 3D 렌더링, 법선 맵, JND 모델, 적응형 임베딩

- First Author: Ji-Hoon Kim, Corresponding Author: Seung-Kwan Choi
- *Ji-Hoon Kim (jhkim1009@sogang.ac.kr), Dept. of Metaverse Technology, Sogang University
- **Dong-Heon Cho (davidcho@sogang.ac.kr), Dept. of Metaverse Technology, Sogang University
- ***Seung-Kwan Choi (csk0123@sogang.ac.kr), Dept. of Metaverse Entertainment, Sogang University
- Received: 2025. 12. 16, Revised: 2026. 01. 16, Accepted: 2026. 02. 10.
- Ji-Hoon Kim and Dong-Heon Cho contributed equally to this work.

I. Introduction

1.1 Background and Motivation

최근 3D 컴퓨터 그래픽스 기술의 급속한 발전과 함께 게임, 영화 VFX, 메타버스 플랫폼, 가상현실(VR) 및 증강 현실(AR) 등 다양한 응용 분야에서 고품질 3D 디지털 콘텐츠의 생산과 유통이 폭발적으로 증가하고 있다. 이러한 디지털 자산의 경제적 가치가 증대됨에 따라, 무단 복제 및 불법 배포로부터 콘텐츠를 보호하기 위한 디지털 워터마킹 기술의 중요성이 더욱 부각되고 있다[1], [2].

디지털 워터마킹은 멀티미디어 콘텐츠에 인지 불가능한 형태로 저작권 정보나 인증 데이터를 삽입하는 기술로서, 두 가지 상충되는 요구사항을 동시에 만족해야 하는 근본적인 도전 과제를 안고 있다: (1) 비가시성(Imperceptibility)-워터마크가 원본 콘텐츠의 시각적 품질을 저하시키지 않아야 하며, (2) 견고성(Robustness)- 다양한 신호처리 공격이나 압축 변환 후에도 워터마크를 안정적으로 추출할 수 있어야 한다[3].

최근 딥러닝 기술의 발전과 함께 end-to-end 학습 기반 워터마킹 방법들이 활발히 연구되고 있다. 특히 Zhu et al.의 HiDDeN [4]과 Sander et al.의 Watermark Anything Model(WAM) [5]은 신경망 기반 인코더-디코더 아키텍처를 통해 우수한 비가시성과 견고성을 동시에 달성하였다. 그러나 이러한 최신 방법들은 3D 렌더링 파이프라인에서 최종적으로 출력되는 RGB 픽셀값만을 활용한다는 근본적인 한계를 공유한다. 즉, 렌더링 과정에서 생성되는 풍부한 기하학적 및 광학적 중간 신호들이 워터마크 삽입 전략에 반영되지 못하고 있다.

1.2 Research Objective and Approach

3D 렌더링 파이프라인에서는 Normal Map, Depth Map, Albedo, Shading, Roughness 등 풍부한 중간 렌더링 신호들이 생성되는데 불구하고, 이러한 기하학적 및 광학적 정보를 워터마킹에 체계적으로 활용한 연구는 극히 제한적이다.

본 연구는 3D 렌더링 과정에서 생성되는 기하학적 신호가 인간의 시각 특성과 관련이 있을 수 있다는 가설에서 출발한다. 일반적으로 표면의 기하학적 변화가 큰 영역(모서리, 굴곡)과 평활한 영역에서 인간의 시각적 민감도가 다르다고 알려져 있다. Just Noticeable Difference (JND) 모델 [6], [7]은 각 픽셀에서 인간이 감지할 수 있는 최소 변화량을 예측한다.

본 연구의 목표는 렌더링 신호와 JND 간의 관계를 체계

적으로 분석하고, 이를 활용하여 픽셀별로 워터마크 강도를 조절하는 적응형 워터마킹 방법을 개발하는 것이다.

1.3 Contributions

본 논문의 주요 기여는 다음 네 가지로 요약된다. 첫째, 5가지 렌더링 신호(Normal Map, DepthMap, Albedo, Shading, Roughness)와 JND 간의 Mutual Information을 측정하여 상관관계를 정량 분석하였다. 그 결과, Normal Map이 평균 MI 0.073 nats로 가장 높은 상관관계를 보여 적응형 워터마크 임베딩을 위한 최적의 가이드 신호임을 입증하였다. 둘째, 렌더링 신호와 JND를 결합한 두 가지 픽셀별 워터마크 강도 조절 전략(Product, Gated)을 제안하고 최적 파라미터를 도출하였으며, Normal Map 기반 Product 전략은 기준선(WAM) 대비 PSNR 5.47 dB 향상과 SSIM 0.0059 개선을 달성하면서 32비트 메시지 복원을 100%를 유지하였다. 셋째, 기하학적 복잡도가 상이한 6개 3D 모델의 960개 샘플에 대해 대응표본 t-검정($t(959) = 23.47, p < 0.001, \text{Cohen's } d = 2.35$)으로 통계적 유의성을 확인하였다. 넷째, 추가 계산 비용이 19.4%(이미지 당 0.65초 \rightarrow 0.78초)에 불과하여 실시간 적용이 가능함을 입증하였다.

II. Related Work

2.1 Deep Learning Watermarking on RGB Images

디지털 워터마킹은 전통적으로 주파수 영역 변환[1]이나 공간 영역 조작 [8]을 기반으로 발전해왔다. 최근에는 딥러닝 기반 방법들이 주목받고 있다. Kandi et al.[9]은 CNN 기반 인코더-디코더 구조를 제안했으나, 균일강도로 임베딩하여 시각적 최적화가 부재하다. Zhu et al. [4]의 HiDDeN은 adversarial training으로 견고성을 향상시켰으나, 역시 콘텐츠 특성을 고려하지 않는 전역 균일 임베딩 방식을 사용한다. 최근 Sander et al.[5]의 WAM은 영역 선택적 워터마크 삽입이 가능하나, 강도 조절은 여전히 스케일 상수에 의존한다. 이러한 방법들은 공통적으로 최종 렌더링된 RGB 이미지만 활용하며, 3D 렌더링 과정의 중간 신호를 활용하지 않는다는 근본적 한계가 있다.

2.2 3D and Neural Rendering Watermarking

WaterRF [10]는 radiance field 자체에 워터마크를 삽입했으나, NeRF 전용 구조로 일반 렌더링 파이프라인에

적용할 수 없다. NeRF Protector [11]은 다양한 NeRF 변형에 적용 가능하나, 워터마크 강도가 뷰에 따라 불균일한 문제가 있다. 3D mesh 워터마킹은 기하학적 변형 [12]이나 스펙트럴 분석 [13]을 활용해 왔으나, mesh 구조를 직접 수정하므로 시각적 품질 저하가 불가피하다.

Table 1. Approaches and Limitations

Study	Approach	Limitation
HiDDeN [4]	DL Enc-Dec	Only used RGB
WAM [5]	Selective region	No rendering signals
WaterRF [10]	NeRF embedding	Specific NeRF, limited generality
Ohbuchi [12]	Mesh deformation	Direct mesh modification
Chou [6]	Adaptive JND	No 3D geometry utilization
DIBR [14]	Adaptive Depth	No multisignal comparison
Ours	Rendering + JND	Multisignal fusion

2.3 JND Models and Watermarking

JND 모델 [6], [7]은 인간 시각 특성을 반영하여 워터마크 강도를 최적화하는 데 활용되어 왔다. 그러나 기존 JND 기반 방법은 휘도와 텍스처 등 2D 이미지 특징만 사용하며, 3D 기하학적 정보를 고려하지 않는다.

DIBR 워터마킹 [14]은 깊이 정보를 부분적으로 활용했으나, 단일 신호에 국한되어 다중 렌더링 신호 간의 체계적 비교가 이루어지지 않았다.

표 1은 기존 연구들의 접근 방식과 한계를 본 연구와 비교하여 정리한 것이다. 본 연구는 다중 렌더링 신호와 JND를 체계적으로 결합한 시도로, 기존 연구들의 한계를 해결한다.

III. Preliminaries

3.1 Digital Watermarking

디지털 워터마킹은 멀티미디어 콘텐츠에 감지 불가능한 정보를 삽입하는 기술이다. 인코더가 원본 이미지에 메시지를 삽입하고, 디코더가 워터마킹된 이미지에서 메시지를 추출한다. 핵심 과제는 워터마크 강도(α)를 조절하여 비가시성(눈에 안 보이게)과 견고성(공격에 강하게)의 균형을 맞추는 것이다.

3.2 JND Model

Just Noticeable Difference(JND) 모델은 인간 시각 시스템의 특성을 반영하여, 각 픽셀에서 인간이 감지할 수 있는 최소 변화량을 예측한다. JND는 두 가지 마스킹 효과를 고려한다: (1) 휘도 마스킹 - 밝은 영역에서 변화를 덜 인지, (2) 대비 마스킹 - 복잡한 텍스처 영역에서 변화를 덜 인지. JND 값이 높을수록 해당 픽셀에 더 강한 워터마크를 삽입해도 눈에 띄지 않는다.

3.3 Rendering Signals

3D 렌더링 파이프라인은 최종 이미지 외에도 다양한 중간 신호를 생성한다. 본 연구에서는 5가지 신호를 활용하며, 표 2에 각 깊이 맵(Depth Map), 법선 맵(Normal Map), 알베도(Albedo), 음영(Shading), 거칠기(Roughness) 신호의 특성을 정리하였다.

3.4 Mutual Information

상호정보량(Mutual Information, MI)은 두 변수 간의 통계적 의존성을 측정한다. MI 값이 높을수록 두 변수가 서로 관련이 깊다는 의미이다. 본 연구에서는 MI를 사용하여 어떤 렌더링 신호가 JND와 가장 관련이 있는지 분석한다. MI 추정은 히스토그램 기반 이산화 방식을 사용하며, 각 신호와 JND 맵의 픽셀값을 256개 균등 구간(bin)으로 양자화한 후 결합 확률 분포 $p(r, j)$ 와 주변 분포 $p(r), p(j)$ 를 추정한다. 로그 함수는 자연로그(nats)를 사용하며, 확률이 0인 구간은 계산에서 제외한다.

Table 2. Five Rendering Signals Used in This Study

Rendering Signal	Description
Depth Map	Per-pixel distance from camera
Normal Map	Surface orientation; varies sharply at edges and creases
Albedo	Intrinsic surface color excluding lighting
Shading	Brightness change due to light-surface angle
Roughness	Degree of surface smoothness

IV. The Proposed Scheme

4.1 System Overview

본 연구는 Watermark Anything Model (WAM) [5]을 확장하여 렌더링 신호를 통합한 적응형 워터마킹 프레임

워크를 제안한다. 그림 1은 제안 시스템의 전체 구조를 보여준다. 시스템은 다음 세 단계로 구성된다.

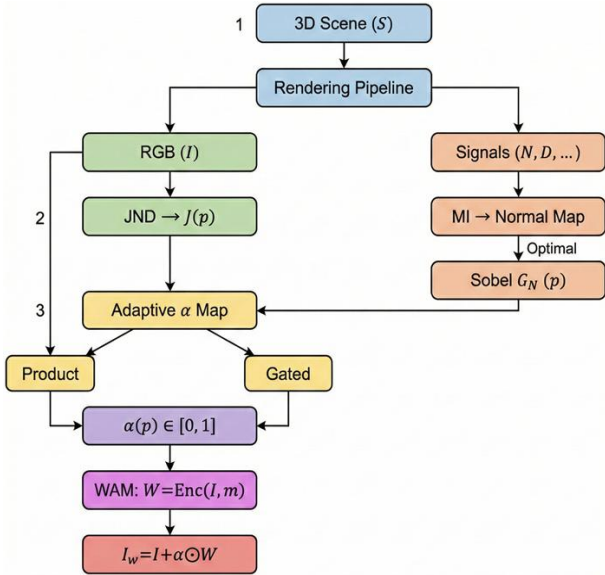


Fig. 1. Overall Processing Flow of the Proposed System.

- 1) 렌더링 신호 추출 및 전처리: 3D 렌더링 파이프라인에서 RGB 이미지와 함께 Normal Map, Depth Map 등 중간 렌더링 신호를 동시에 추출하고, 각 신호를 [0, 1] 범위로 정규화한다.
- 2) 상관관계 분석 및 신호 선택: 각 렌더링 신호와 JND 맵 간의 상호정보량(MI)을 계산하여, 인간 시각 특성과 가장 높은 상관관계를 보이는 신호를 선택한다.
- 3) 적응형 알파 맵 생성 및 임베딩: 선택된 렌더링 신호와 JND를 결합하여 픽셀별 워터마크 강도 맵(alpha map)을 생성하고, 이를 WAM 인코더에 적용하여 적응형 워터마크를 삽입한다.

4.2 Signal Extraction and Selection

3D 렌더링 파이프라인에서 추출된 중간 신호 중, 본 연구에서는 두 가지 후보를 가이드 신호로 고려한다. 법선 맵 Gradient(G_N)는 표면의 기하학적 복잡도를 정량화하며, Eq. (1)과같이 Sobel 필터를 적용하여 계산한다.

$$G_N(p) = \sqrt{\left(\frac{\partial N}{\partial x}(p)\right)^2 + \left(\frac{\partial N}{\partial y}(p)\right)^2} \quad (1)$$

여기서 $N(p)$ 는 Eq. (2)와 같이 $n(p) \in [-1, 1]^3$ 을 [0,1]범위로 정규화한 값이다.

$$N(p) = \frac{n(p) + 1}{2} \quad (2)$$

G_N 값이 높은 모서리/굴곡 영역은 시각적 민감도가 낮아 워터마크 삽입에 유리하며, 역 깊이($D_{i.nv}$)는 Eq. (3)과 같이 전경 객체에 우선순위를 부여한다.

$$D_{i.nv}(p) = 1 - \frac{z(p) - z_{near}}{z_{far} - z_{near}} \quad (3)$$

최적 신호 선택을 위해 Eq. (4)와 같이 각 렌더링 신호 R과 JND 맵 J간의 상호정보량(MI)을 계산한다.

$$I(R;J) = \sum_{r \in R} \sum_{j \in J} p(r,j) \log \frac{p(r,j)}{p(r) \cdot p(j)} \quad (4)$$

MI가 높을수록 해당 신호가 시각적 민감도를 잘 반영하며, 이를 통해 데이터 기반으로 가이드 신호를 선택한다.

4.3 Adaptive Embedding Strategies

기존 WAM이 균일 강도 $\alpha = 0.5$ 를 적용하는 것과 달리, 렌더링 신호와 JND를 결합하여 픽셀별 $\alpha(p)$ 를 결정하는 두 가지 전략을 제안한다.

4.3.1 Product Strategy

Eq. (5)에 기반하여, JND와 렌더링 신호의 곱으로 두 조건이 동시에 충족되는 영역에 집중한다.

$$\alpha(p) = \alpha_o + \lambda \cdot J(p)^\gamma \cdot R(p)^\beta \quad (5)$$

$J(p)$ 는 정규화된 JND 값, $R(p)$ 는 렌더링 신호, α_o 는 최소 강도, λ 는 스케일링 계수, γ/β 는 영향력 지수이다. JND가 높고 기하학적 복잡도가 높은 영역에 워터마크를 강하게 삽입한다

4.3.2 Gated Strategy

렌더링 신호가 임계값 τ 를 초과하는 영역에서만 선택적으로 강도를 증가시켰으며 다음 수식 Eq. (6)과 같다.

$$\alpha(p) = \alpha_o + \lambda \cdot J(p) \cdot \sigma(a \cdot (R(p) - \tau)) \quad (6)$$

$\sigma(\cdot)$ 는 시그모이드 함수, 게이팅 함수, a 는 전환 경사도, τ 는 임계값이다. $R(p) < \tau$ 인 평활 영역에서는 최소 강도 α_0 만, $R(p) > \tau$ 인 복잡 영역에서만 JND에 비례하여 강도가 증가한다.

4.4 Overall Algorithm

제안 방법의 전체 처리 과정을 Algorithm 1에 요약한다.

Algorithm 1 Adaptive Watermarking Based on Rendering Signals

Require: 3D scene S , watermark message m (32-bit), strategy $\phi \in \{\text{Product, Gated}\}$

Ensure: Watermarked image I_w

```

1: // Step 1: Rendering and Signal Extraction
2:  $I, N, D, A, Sh, Rg \leftarrow \text{Render}(S)$ 
3:  $J \leftarrow \text{ComputeJND}(I)$   $\triangleright$  Compute JND map
4:  $G_N \leftarrow \text{SobelGradient}(N)$   $\triangleright$  Normal map gradient
5:  $R \leftarrow \text{Normalize}(G_N, [0, 1])$   $\triangleright$  Min-max normalization
6: // Step 2: Adaptive  $\alpha$  Map Generation
7: for each pixel  $p \in I$  do
8:   if  $\phi = \text{Product}$  then
9:      $\alpha(p) \leftarrow \alpha_0 + \lambda \cdot J(p)^\gamma \cdot R(p)^\beta$ 
10:  else
11:     $\alpha(p) \leftarrow \alpha_0 + \lambda \cdot J(p) \cdot \sigma(a \cdot (R(p) - \tau))$ 
12:  end if
13: end for
14:  $\alpha \leftarrow \text{Clip}(\alpha, [0, 1])$   $\triangleright$  Clamp to valid range
15: // Step 3: WAM-based Adaptive Embedding
16:  $W \leftarrow \text{WAM\_Encoder}(I, m)$   $\triangleright$  Generate watermark residual
17:  $I_w \leftarrow I + \alpha \odot W$   $\triangleright$  Apply pixel-wise strength
18: return  $I_w$ 
    
```

Algorithm 1의 핵심은 기존 WAM의 균일 임베딩 $I_w = I + \alpha \cdot W$ (α : 스칼라)를 픽셀별 2D 맵으로 확장한 $I_w = I + \alpha \odot W$ (\odot : 원소별 곱)에 있다. 이를 통해 지각적으로 둔감한 영역에는 강한 워터마크를, 민감한 영역에는 약한 워터마크를 삽입한다.

V. Experiments

5.1 Experimental Setup

5.1.1 Dataset

일반화 성능 검증을 위해 기하학적 복잡도가 다른 6개의 표준 벤치마크 3D 모델을 선정하였다. 본 연구의 핵심 가설(“기하학적 복잡도가 높을수록 Normal Map gradient와 JND의 상관관계가 강하다.”)을 검증하기 위해 단순 평면(Cube)부터 정교한 조각(Buddha)까지 넓은 복잡도 스펙트럼을 포함하였으며, 표준 모델 사용으로 재현성을 보장한다.

표 3은 선정된 6개 3D 모델의 기하학적 특성을 요약한다.

렌더링 조건은 10개 카메라 시점(방위각 5개 \times 고도각 2개), 8개 조명 조건(위치 4개 \times 강도 2개), 2개 워터마크 시드로 구성되어 총 960개의 512×512 해상도 테스트 표

본을 생성하였다. 모든 렌더링은 PyVista를 사용하여 물리 기반 음영으로 수행되었다.

5.1.2 Evaluation Metrics

성능 평가를 위해 PSNR (Peak Signal-to-Noise Ratio, 객관적 품질), SSIM (Structural Similarity Index, 지각적 품질), BAR (Bit Accuracy Rate, 32비트 메시지 복원), MI (Mutual Information, 신호-JND 상관관계)의 네 가지 지표를 사용하였다.

Table 3. Geometric Characteristics of 3D Models Used in Experiments

Model	Complexity	Geometric Characteristics
Cube	Simple	Flat surfaces, minimal gradient
Teapot	Low-mid	Smooth continuous curves
Bunny	Medium	Localized curvature variation
Dragon	Complex	Sharp changes from wings and scales
Suzanne	Complex	Detailed facial features
Buddha	Very complex	Fine sculptural details

5.1.3 Baselines and Parameters

균일 워터마크 강도($\alpha = 0.5$)를 사용하는 WAM[5]을 비교 대상으로 설정하였다. 공정한 비교를 위해, 기준선과 제안 방법은 동일한 WAM 인코더디코더 구조, 동일한 32비트 메시지, 동일한 입력 이미지 및 마스크를 사용하며, 유일한 차이점은 임베딩 강도 맵(α 맵)이다. 즉, 비교 대상은 모든 픽셀에 $\alpha = 0.5$ 를 균일 적용하고, 제안 방법은 렌더링 신호와 JND 기반의 적응형 α 맵을 사용하므로 강도 조절 전략의 효과만을 분리하여 평가할 수 있다. JND 맵은 Chou [6]와 Wu [7]의 모델을 기반으로 휘도 마스크와 텍스처 마스크를 결합하여 계산하였다. MI 추정에는 256 bin 히스토그램 이산화를 적용하였다. 전체 데이터셋에 대한 그리드 서치를 통해 Product 전략의 최적 파라미터는 $\alpha_0 = 0.05$, $\lambda = 10.0$, $\gamma = 1.0$, $\beta = 1.0$ 으로, Gated 전략은 $\alpha_0 = 0.05$, $\lambda = 10.0$, $a = 5.0$, $\tau = 0.5$ 로 결정하였다. Sobel 필터는 3×3 커널을 사용하며, 모든 신호는 min-max 정규화로 $[0, 1]$ 범위에 맞추었다.

5.2 Results and Analysis

5.2.1 Correlation Analysis

표 4는 렌더링 신호와 JND 간의 상호정보량을 보여준다. Normal Map이 모든 모델에서 일관되게 가장 높은

MI 값을 보였으며, 특히 기하학적으로 복잡한 Buddha 모델에서 $MI = 0.107$ 로 최댓값을 기록했다. Depth Map과 Albedo는 중간 수준의 상관관계를 보였고, Roughness는 상관관계가 없는 것으로 나타났다.

Table 4. Mutual Information Between Rendering Signals and JND (nats) \uparrow

Rendering Signal	Buddha	Teapot	Suzanne	Avg.
Normal Map	0.107	0.047	0.065	0.073
Depth Map	0.092	0.031	0.043	0.055
Albedo	0.093	0.030	0.043	0.055
Shading	0.054	0.021	0.024	0.033
Roughness	0.000	0.000	0.000	0.000

5.2.2 Watermarking Performance Comparison

표 5는 960개 전체 표본에 대한 평균 성능을 보여준다. N_product 방법이 Baseline 대비 5.47dB PSNR 개선과 0.0059 SSIM 향상으로 최고 성능을 달성했으며, 일관된 메시지 복원을 유지했다. Normal Map 기반 방법들이 역깊이(Inverse depth) 기반 접근법보다 일관되게 우수한 성능을 보였다.

Table 5. Average Performance Metrics (960 Samples)

Method	PSNR \uparrow	SSIM \uparrow	BAR \uparrow	Δ PSNR
Baseline (WAM)	43.96	0.9924	1.00	-
N_product	49.43	0.9983	1.00	+5.47
N_gated	46.36	0.9975	1.00	+2.40
invD_product	45.13	0.9949	1.00	+1.17
invD_gated	45.21	0.995	1.00	+1.25

5.2.3 Per-Model Analysis

표 6은 제안된 N_product 전략의 3D 모델별 성능을 보여준다.

기하학적으로 복잡한 모델이 우리 접근법으로부터 가장 큰 혜택을 받았으며, Buddha가 8.84dB 개선을 달성했다. 이는 표 4의 MI 분석과 일관된 결과로, Normal Map MI가 가장 높은 Buddha(0.107 nats)가 Δ PSNR도 가장 크며, MI가 상대적으로 낮은 모델일수록 개선폭이 감소하는 경향을 보인다. 이러한 양의 상관관계는 기하학적 복잡도가 높을수록 렌더링 신호와 JND 간의 상관관계가 강해져 적응형 α 맵이 더 효과적으로 작동함을 정량적으로 뒷받침한다. 단순한 Cube 모델조차도 3.86dB 향상을 보여 방법의 일반화 가능성을 입증했다.

Table 6. Per-Model PSNR (dB) of N_product \uparrow

Model	Baseline	N_product	Δ PSNR
Buddha	43.61	52.45	+8.84
Teapot	44.4	50.51	+6.11
Suzanne	44.14	49.2	+5.06
Bunny	43.73	48.46	+4.73
Dragon	43.43	47.62	+4.19
Cube	44.46	48.32	+3.86

5.2.4 Statistical Significance

통계적 유의성을 검증하기 위해 대응표본 t-검정을 수행한 결과, t-통계량 $t(959) = 23.47$ ($p < 0.001$)과 Cohen's $d = 2.35$ (매우 큰 효과 크기)를 얻었으며, Δ PSNR의 95% 신뢰구간은 [5.01, 5.93] dB로 나타나 개선이 통계적으로 유의하고 일관됨을 확인하였다.

5.2.5 Computational Overhead

렌더링 신호 추출 및 적응형 강도 계산에 따른 평균 시간 오버헤드는 19.4%(이미지 당 0.65초에서 0.78초로 증가)이며, 렌더링 버퍼 저장을 위한 메모리 오버헤드는 12.5MB이다. 512×512 해상도 이미지를 0.8초 이내에 처리할 수 있어 실시간 적용이 가능한 수준이다.

5.3 Visual Quality Analysis

그림 2는 비교 대상(균일 강도)과 제안 방법(적응형 강도)의 시각적 비교를 보여준다. 적응형 접근법은 기하학적으로 복잡한 영역에 워터마크 에너지를 집중시켜 왜곡이 자연스럽게 마스킹 된다.

5.4 Ablation Study

제안 시스템은 렌더링 신호 선택, 결합 파라미터, JND 모델의 세 가지 핵심 요소로 구성된다. 각 요소의 기여도를 독립적으로 평가하기 위해 하나의 요소를 변경하고 나머지를 고정하는 방식으로 ablation 연구를 수행하였다.

먼저, 렌더링 신호의 효과를 분석하였다. Normal Map을 다른 신호로 교체한 결과, invD_product는 Δ PSNR +1.17 dB로 N_product(+5.47 dB)의 21% 수준에 그쳐, MI가 높은 신호일수록 적응형 강도 조절이 효과적임을 확인하였다. 다음으로, 결합 파라미터의 효과를 검증하였다. γ 와 β 에 대해 [0.5, 2.0] 범위의 그리드 서치 결과, $\gamma = 1.0$, $\beta = 1.0$ (선형 동등 가중치)이 최적이었다. 이를 벗어나면 강도 맵의 과도한 대비 또는 정보원 간 불균형으로 성능이 저하되었다. 마지막으로, JND 통합의 효과를 분석하였다. Normal Map만 단독 사용시 Δ PSNR은 2.3 dB에

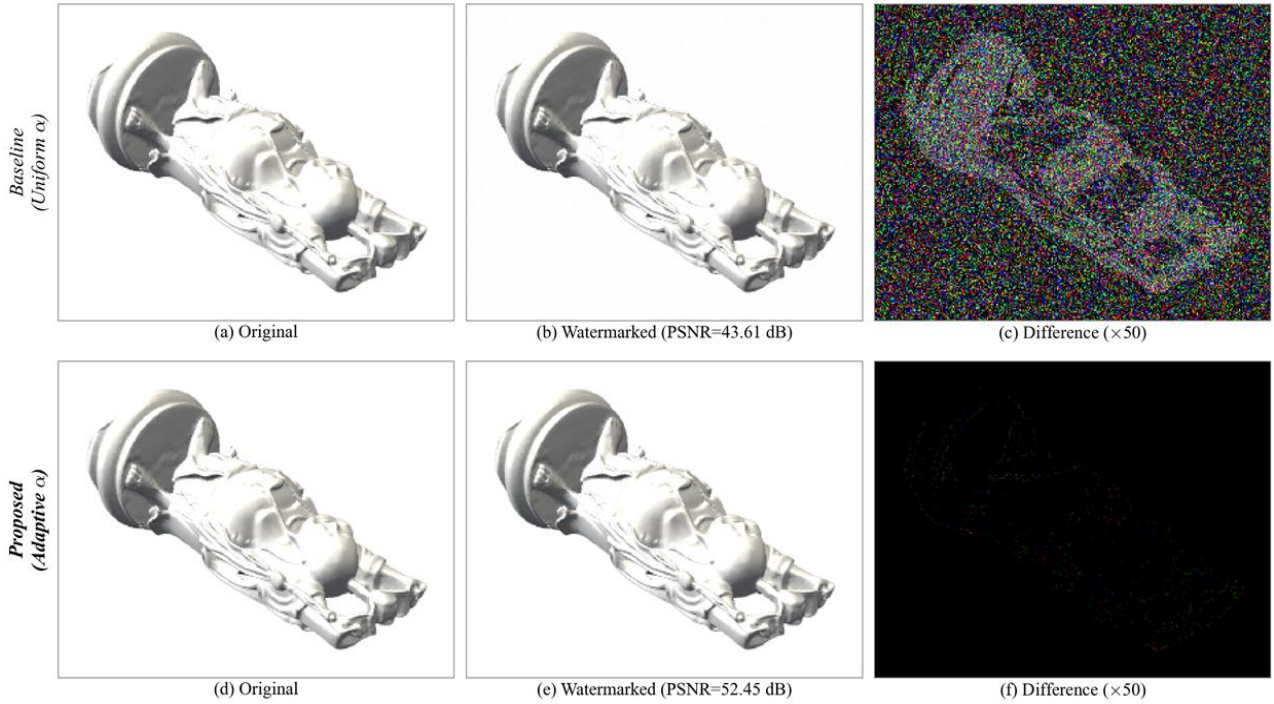


Fig. 2. Visual Comparison of Baseline (top) and N_product (bottom). Difference maps ($\times 50$) show reduced distortion in sensitive regions.

불과하나, JND를 결합하면 5.47dB(약2.4배)로 향상되어, 기하학적 정보와 지각적 허용 한계의 결합이 필수적임을 입증하였다.

VI. Conclusions

본 논문은 기존 워터마킹이 최종 RGB 이미지에 균일 강도로 삽입하는 한계를 극복하기 위해, 3D 렌더링 중간 신호와 JND를 결합한 적응형 프레임워크를 제시하였다.

본 연구의 핵심 기여는 세 단계로 요약된다. 첫째, Normal Map, Depth Map, Albedo, Shading, Roughness 5가지 렌더링 신호와 JND 간의 상관관계를 Mutual Information으로 체계적으로 분석하여, Normal Map이 평균 0.073 nats로 가장 높은 상관관계를 보이는 최적의 가이드 신호임을 정량적으로 확인하였다. 둘째, 이를 기반으로 렌더링 신호와 JND를 결합하는 Product 및 Gated 두 가지 픽셀별 강도 조절 전략을 설계하고, 6개 3D 모델의 960개 샘플에 대한 실험을 통해 Product 전략이 기존(WAM) 대비 PSNR 5.47dB 향상과 SSIM 0.0059 개선을 달성하면서도 32비트 메시지 복원율 100%를 유지함을 검증하였다. 셋째, 대응표본 t-검정($p < 0.001$, Cohen's $d = 2.35$)을 통해 이러한 개선이 통계적으로 유의하며, 추가 계산 비용이 19.4%에 불과하여 실시간 적용이 가능함을 입증하였다.

이러한 결과는 중간 렌더링 정보가 인간의 시각적 민감도와 밀접한 관련이 있으며, 이를 워터마킹에 체계적으로 활용하면 지각적 품질과 데이터 은닉 용량 간의 트레이드 오프를 효과적으로 개선할 수 있음을 시사한다. 다만, 현재 평가는 공격 없는 시나리오에 한정되어 있으며, 렌더링 신호의 가용성을 전제한다는 한계가 있다.

향후 압축, 노이즈 등 다양한 공격 조건에서의 견고성 평가와 Neural 렌더링 파이프라인(NeRF, 3D Gaussian Splatting)으로 연구 방향을 확장 수행할 예정이다.

ACKNOWLEDGEMENT

This research was supported by the Metaverse Convergence Graduate School(RS-2022-00156318) Project funded by the MSIT and the IITP, and the Development of Copyright Protection and utilization activation Technology in Metaverse(RS-2023-00219237) Project funded by the MCST and the KOCCA.

REFERENCES

- [1] Miller, Matthew, et al. Digital watermarking and steganography. Elsevier Science & Technology, 2008.

- [2] Barni, Mauro, and Franco Bartolini. Watermarking systems engineering: enabling digital assets security and other applications. Crc Press, 2004.
- [3] Voloshynovskiy, Sviatoslav, et al. "Attacks on digital watermarks: classification, estimation based attacks, and benchmarks." *IEEE communications Magazine* 39.8, 118-126, 2001
- [4] Zhu, Jiren, et al. "Hidden: Hiding data with deep networks." *Proceedings of the European conference on computer vision (ECCV)*. 2018.
- [5] Sander, Tom, et al. "Watermark anything with localized messages." *arXiv preprint arXiv:2411.07231* (2024).
- [6] Chou, Chun-Hsien, and Yun-Chin Li. "A perceptually tuned subband image coder based on the measure of just-noticeable-distortion profile." *IEEE Transactions on circuits and systems for video technology* 5.6, 467-476, (1995).
- [7] Wu, Jinjian, et al. "Enhanced just noticeable difference model for images with pattern complexity." *IEEE Transactions on Image Processing* 26.6, 2682-2693, (2017).
- [8] Van Schyndel, Ron G., Andrew Z. Tirkel, and Charles F. Osborne. "A digital watermark." *Proceedings of 1st international conference on image processing*. Vol. 2. IEEE, 1994.
- [9] Kandi, Haribabu, Deepak Mishra, and Subrahmanyam RK Sai Gorthi. "Exploring the learning capabilities of convolutional neural networks for robust image watermarking." *Computers & Security* 65, 247-268, (2017).
- [10] Jang, Youngdong, et al. "Water: Robust watermarks in radiance fields for protection of copyrights." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024.
- [11] Song, Qi, et al. "Protecting nerfs' copyright via plug-and-play watermarking base model." *European Conference on Computer Vision*. Cham: Springer Nature Switzerland, 2024.
- [12] Ohbuchi, Ryutarou, Hiroshi Masuda, and Masaki Aono. "Watermaking three-dimensional polygonal models." *Proceedings of the fifth ACM international conference on Multimedia*. 1997.
- [13] Kanai, Satoshi, Hiroaki Date, and Takeshi Kishinami. "Digital watermarking for 3D polygons using multiresolution wavelet decomposition." *Proc. Sixth IFIP WG*. Vol. 5. No. 2. 1998.
- [14] A. Al-Haj, M. E. Farfoura, and A. Mohammad, "Transform-based watermarking of 3d depth-imagebased-rendering images," *Measurement*, vol. 95, pp. 405-417, 2017.

Authors



Ji-Hoon Kim received the B.S. degree in Industrial Engineering from Dajin University, Korea, in 2021. He is currently pursuing the M.S. degree in Metaverse Technology at Sogang University, Korea.

His research interests include Computer Graphics, Computer Vision, and Optimization.



Dong-Heon Cho received the B.S. degree in Information Industrial Engineering and Computer Science from Yonsei University, Korea, in 2017, and the M.S. degree in Industrial Engineering from Yonsei University,

Korea, in 2019. He is currently pursuing the Ph.D. degree in Metaverse Technology at Sogang University, Korea. His research interests include Computer Vision and Optimization.



Seung-Kwan Choi received the M.S. degree in Electronic Computer Science from Hoseo University, Korea, in 2000, and the Ph.D. degree in Digital Contents from Sejong University, Korea, in 2010.

He served as a Teacher at Korea Animation High School from 2001 to 2008, and as a Professor at Sogang University Future Education Center from 2008 to 2021. He also served as a Development Director at Cake Therapy from 2014 to 2016. He is currently a Professor in the Graduate School of Virtual Convergence, Sogang University, Korea. His research interests include Virtual Convergence, XR, and Software Copyright.