

Inner Gaussian Splatting과 DropGaussian 기법을 이용한 특화된 3D Gaussian Splatting 재구성

(Specialized 3D Gaussian Splatting Reconstruction Using Inner Gaussian Splatting and Drop Gaussian Techniques)

정성원*, 권구락**

(Seong Won Jeong, Goo Rak Kwon)

요약

3차원 재구성 기술은 의료 영상 진단 분야에서 중요한 역할을 지니고 있다. 3차원 재구성 기술을 통해 복잡한 해부학적 구조를 직관적으로 파악할 수 있다. 최근 3D Gaussian Splatting(3DGS)이 높은 렌더링 품질과 속도로 주목받고 있으나, 이는 주로 객체의 표면 재구성에 특화되어 있어 내부 구조 정보가 중요한 자기공명영상(Magnetic Resonance Imaging, MRI) 데이터에 직접 적용하기에는 어려움이 있다. 또한, MRI의 슬라이스 방식은 3차원 재구성 관점에서 희소 시점 문제를 야기하여 3DGS 학습 시 과적합과 아티팩트를 발생시킨다. 본 논문에서는 이러한 문제를 해결하기 위해 MRI 데이터에 특화된 3DGS 재구성 기법을 제안한다. 제안 방법은 내부 구조 표현을 위한 InnerGS 기법과, 희소 시점에서의 과적합 방지를 위한 DropGaussian 기법을 결합하였다. ADNI 데이터셋을 활용한 실험결과, 제안 방법은 내부 구조를 효과적으로 재구성하였으며, 정량적·정성적 평가에서 유의미한 성능을 보였다.

■ **중심어** : 3D 가우시안 스플래팅 ; 자기공명영상 ; 3차원 재구성 ; 새로운 시점 합성

Abstract

Three-dimensional (3D) reconstruction technology plays a crucial role in the field of MRI image diagnosis. 3D reconstruction technology allows for the intuitive understanding of complex anatomical structures. Recently, 3D Gaussian Splatting (3DGS) has gained attention for its high rendering quality and speed, but it is primarily specialized in the surface reconstruction of objects. This makes it difficult to apply directly to MRI data, where internal structural information is vital. Furthermore, the slice-based acquisition of MRI data poses a sparse view problem from the perspective of 3D reconstruction, leading to overfitting and artifacts during 3DGS training. In this paper, we propose a 3DGS reconstruction method specifically tailored for MRI data to address these issues. The proposed method combines InnerGS technique for internal structure representation and DropGaussian technique to prevent overfitting in sparse views. Experimental results using the ADNI dataset show that the proposed method effectively reconstructs internal structures and demonstrates significant performance in both quantitative and qualitative evaluations.

■ **keywords** : 3D Gaussian Splatting ; Magnetic Resonance Imaging ; 3D Reconstruction ; Novel View Synthesis

I. 서론

의료 진단에서 MRI를 사용한 3차원 재구성 기술은 중요한 역할을 지니고 있다. 3차원 재구성 기술은 2차원 단층 영상으로는 파악하기 어려운

복잡한 해부학적 구조의 깊이를 시각화함으로써, 정밀한 진단, 수술 계획 수립, 환자와의 소통에 있어 편리함을 제공한다.

최근 몇 년간 새로운 시점 합성(Novel View Synthesis, NVS) 분야는 많은 발전을 이루었다.

* 준회원, 조선대학교 정보통신공학부

** 정회원, 조선대학교 정보통신공학부

이 논문은 2025학년도 조선대학교 학술연구비의 지원을 받아 연구되었음.

접수일자 : 2025년 11월 25일

수정일자 : 2026년 01월 07일

게재확정일 : 2026년 01월 19일

교신저자 : 권구락 e-mail : grkwon@chosun.ac.kr

그 중심 기술 중 하나는 3DGS이다. 이는 3차원 공간에 3D 가우시안(Gaussian)의 집합으로 표현하여 장면을 명시적으로 나타낸다[1]. 또한, 고품질의 실시간 렌더링이 가능하다. 하지만, 3DGS의 경우 입력 데이터의 특성상 내부 정보보다는 표면을 복원하는 데 집중되어 있다. MRI의 경우 인체의 내부 구조를 촬영하고 내부 정보를 활용하기 때문에 직접 3DGS를 적용하기에는 무리가 있다. MRI는 복셀(Voxel)로 구성되며 슬라이스 단위로 나누어 활용한다. 3DGS는 조밀한(dense) 시점 입력을 요구한다. 여러 영상 간 특징을 추출하고 정합하면서 기하학적인 구조를 구성한다. 그러나 MRI에서는 슬라이스별로 다른 위치의 장면을 보기 때문에 영상 간에 중복되는 특징들이 없어 희소 시점 환경(sparse-view)이라 볼 수 있다. 희소 시점에서는 3DGS가 주어진 3D 장면을 이해하기 위한 충분한 기하학적 구조와 장면의 표면을 만들기 어려우며, 과적합 문제가 발생하거나 기하학적 구조가 제대로 생성되지 않을 수 있다.

본 논문에서는 MRI 데이터에 최적화된 3DGS 재구성 기법을 제안한다. 제안 방법은 내부 단면 렌더링에 특화된 InnerGS[2]와, 희소 시점에서의 과적합을 방지하는 DropGaussian[3]을 결합하였다. 이를 통해 기존 3DGS가 MRI 데이터에서 보이는 내부 구조 재구성 한계 및 아티팩트 발생 문제를 해결하고자 한다.

II. 관련 연구

이 절에서는 NVS 기술의 개요와 희소 시점 환경에 대해 서술하고, CT나 MRI와 같은 의료 영상 기기에 적용된 연구를 설명한다.

1. Novel View Synthesis

NVS는 주어진 3D 장면에 대한 2D 이미지 집합으로부터 새로운 시점의 이미지를 생성하는 것을 목표로 한다. 초기 연구들은 기하학적 재구성을 기반으로 새로운 시점 이미지를 생성했으나 복잡한 재질, 조명 특성을 표현하는 데 한계

가 있었다. 이후 등장한 NeRF는 3D 장면을 Multi-Layer Perceptron (MLP)를 사용하여 장면을 연속적인 방사 필드로 학습하여 암시적으로 표현한다[4]. 고품질의 장면을 렌더링할 수 있지만, 학습 속도와 렌더링 속도가 느리다는 단점이 존재한다.

3DGS는 이러한 한계를 극복하기 위해 새로운 접근 방식으로 제안되었다. 3DGS는 장면을 N개의 3D 가우시안 집합으로 표현한다. 각 가우시안은 위치 $\mu \in \mathbb{R}^3$, 크기 $\sigma \in \mathbb{R}^3$, 불투명도 α , 색상 C , 회전 $q \in \mathbb{R}^4$ 등의 파라미터를 가지며 최적화한다. 렌더링 단계에서는 가우시안을 2차원으로 투영한 뒤 해당하는 픽셀에 대해서만 기여도를 계산한다. 이후 깊이 순으로 정렬하고 알파 블렌딩을 이용해 누적합을 수행하여 미분이 가능한 렌더링을 구현한다.

학습 과정에서는 Structure from Motion (SfM)을 이용하여 이미지 간 특징을 추출하고 정합하여 포인트 클라우드를 생성하고[5], 이를 초기 가우시안으로 초기화한 뒤 위치, 공분산, 색상, 불투명도, 회전을 반복하여 최적화한다.

2. Sparse View

3DGS의 뛰어난 성능은 조밀한 다중 시점 입력을 전제로 한다. 입력 시점이 희소할 경우 과적합과 아티팩트(artifacts)가 발생한다. 이를 해결하기 위해 추가적인 사전 정보나 정규화 전략을 도입하는 연구들이 진행되었다.

CoR-GS는 co-pruning과 pseudo-view 정규화를 도입하여 기하학적으로 일관된 가우시안을 학습하도록 설계했다[6]. 반면, DropGaussian은 학습 과정에서 일정 확률에 따라 렌더링을 할 때 가우시안이 제외시켜 매 반복마다 활성화되는 가우시안 집합이 달라지면서 특정 가우시안에 과도하게 의존하는 것을 방지하여 전체 가우시안 집합에 대한 기여도를 균형 있게 분산하여 과적합 문제를 해결한다. 다른 연구와 달리 추가적인 사전 정보를 사용하지 않고 희소 시점 조건에서도 아티팩트를 줄이고 기존 사전 정보에 의존적인 연구들과 비슷한 성능을 달성

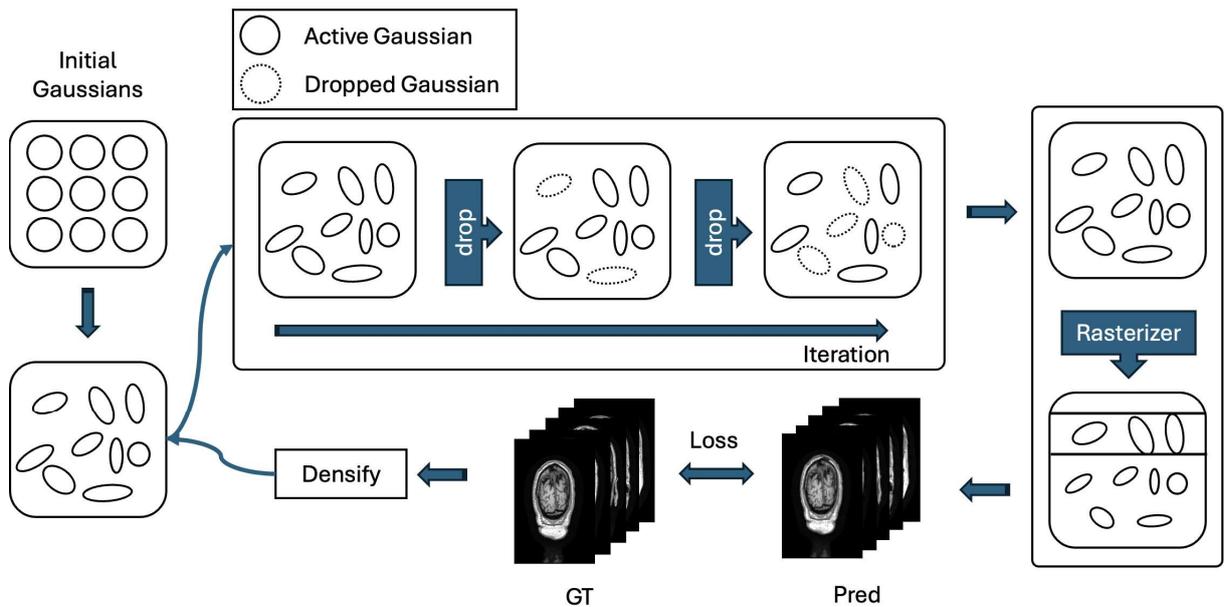


그림 1. 제안된 시스템의 구성도

했다.

3. NVS for Medical

의료 영상은 표면이 아닌 내부 구조를 다룬다는 점에서 기존 NVS와는 다른 접근 방식을 요구한다.

R^2 -Gaussian[7]은 3DGS의 알파 블렌딩과 X-ray 물리적 차이를 보정하여 빠른 CT 재구성 속도를 달성했다. 한편, 3DGSMD[8]은 3DGS를 복소수 영역으로 확장하고 자기지도 학습을 적용하여, 언더샘플링된 k-space 데이터로부터 고품질의 MRI 볼륨을 재구성했다.

InnerGS는 3DGS의 렌더링 파이프라인을 MRI 슬라이스와 같이 내부 단면 렌더링을 할 수 있도록 제안한 연구이다. 기존 3DGS는 3D 가우시안을 2D 카메라 평면에 투영한다. InnerGS의 경우 평면 방향과 깊이 방향으로 인수분해한(factorized) 방식을 도입한다. 각 가우시안은 특정 슬라이스가 주어졌을 때 화면 평면에서의 2D 분포, 깊이 축을 따라 나타나는 1D 분포에 의해 픽셀에 대한 기여도가 결정된다. 이때 깊이에 따른 조건부 스플래팅(Conditional Splatting)을 사용하여, 가우시안 중심과 슬라이스 간 거리가 멀어질수록 스플래트의 크기를 점진적으로 감소시키고, 슬라이스와 가까운 영역에 위치한 가우시안이 크게 기여하도록 설계했다.

III. 제안 방법

본 논문에서는 MRI의 슬라이스 데이터로부터 내부 구조를 복원하기 위한 방법을 제안한다. 제안된 방법의 전체적인 구성도는 그림 1과 같다. 제안된 방법은 MRI의 단면 특성을 반영하기 위해 InnerGS의 렌더링 방식을 사용했다. 이는 3D 가우시안을 화면 평면과 깊이 축으로 분해하고, 슬라이스 깊이에 따른 조건부 스플래팅을 적용하여 단면 내부를 표현한다. 또한 희소 시점으로 인한 문제를 방지하기 위해 DropGaussian 전략을 적용했다. 이는 매 학습마다 무작위로 가우시안을 드롭아웃하여 특정 시점에 대한 의존도를 낮추고 모델의 일반화 성능을 높였다. 전체 과정은 초기화된 가우시안이 DropGaussian 모듈을 거쳐 활성화되고, InnerGS 렌더링을 통해 예측된 슬라이스를 생성한 뒤, 원본 MRI와의 손실을 최소화 하는 방향으로 가우시안 집합을 최적화하는 반복 구조를 가진다.

초기 3D 가우시안 생성은 SfM 기반 포인트 클라우드 초기화 방식을 MRI 데이터에 직접 적용하기 어렵기 때문에 격자 형태로 생성했다. 정규화된 좌표계 $[-1,1]^3$ 에서 $32 \times 32 \times 32$ 격자를 생성하고 각 점에 무작위 잡음을 추가했다. 초기 가우시안은

크기 $\sigma \in \mathbb{R}^3 = (0.02, 0.02, 0.02)$, 색상 $C = 0.8$, 불투명도 $\alpha \in [0, 1] = 0.2$ 로 설정했다.

MRI 데이터는 일반적인 8비트 영상과 달리 $[0, 255]$ 정수 값이 아닌 연속적인 강도(intensity) 값을 가진다. 이를 화면에 표시하기 위해서는 $[0, 255]$ 구간으로 양자화(quantization)하는 정규화 과정이 필요하지만, 이 과정에서 미세한 손실이 발생할 수 있다. 본 연구에서는 이러한 정보를 최대한 활용하기 위해 각 복셀의 강도를 $[0, 1]$ 구간으로 정규화한 연속 값을 그대로 사용했다. 또한, 기존 3DGS는 시점에 의존적인 색 표현을 위해 구면 조화 계수(spherical harmonics, SH)를 사용하지만 MRI의 경우 동일 위치의 강도 값이 시점에 따라 변하지 않는다. 그래서 본 연구에서는 SH 계수를 사용하지 않고 각 Gaussian에 대해 회색조 색상을 유지함으로써 불필요한 연산을 줄였다.

InnerGS와 달리, 본 연구에서는 미니배치 학습 전략을 사용하여 3D 가우시안을 최적화했다. 각 반복에서 배치 크기 k 로 하여, 크기에 맞는 슬라이스 집합을 선택하기 위해 라운드 로빈(round-robin) 기반의 축 균형 샘플링 방식을 적용했다. 라운드 로빈 방식은 여러 집합에서 데이터를 순환하여 할당해 공평하게 분배하는 고전적인 스케줄링 기법이다. 본 연구에서는 세 축의 전체 슬라이스 수 비율에 따라 축별로 슬라이스를 배정한 뒤, 남은 슬라이스는 반복 인덱스를 기준으로 축 순서를 순환시키는 라운드 로빈 방식으로 나누어 갖도록 하였다. 이를 통해 항상 배치 크기 k 를 유지하면서도 세 축의 데이터 분포를 균형 있게 했다.

학습을 3단계로 나누어, 배치 크기 k 를 단계적으로 조절하여 학습했다. 1단계에서는 초기 배치 크기인 k_s 를 4로 설정하여 MRI의 전체적인 기하학적 구조를 학습하도록 했다. 2단계에서는 배치 크기 스케줄링 함수를 이용하여 반복 횟수에 따라 배치 크기 k 를 초기 배치 크기 k_s 에서 최종 배치 크기인 k_e 까지 비선형으로 점진적으로 증가하도록 설계했다. 마지막 단계에서는 최종 배치 크기인 k_e 를 64로 하여 MRI의 세부 정보를 학습하도록 했다. 각 단계에서

는 서로 다른 가우시안 밀도화 주기(densification interval)와 불투명도 초기화 주기(opacity interval)를 가지고 있다.

렌더링을 진행하기 전 특정 슬라이스나 특정 가우시안에 과적합되지 않도록 DropGaussian 기법을 적용했다. 무작위로 선택된 가우시안을 렌더링을 수행할 때 제거했다. 이때 가우시안 제거에 관한 식 제거율 r_t 은 다음 수식1과 같이 계산된다.

$$r_t = \gamma \times \frac{t}{t_{total}}, \quad (1)$$

여기서 $\lambda \in [0, 1]$ 제거율의 가중치이다. t_{total} 은 전체 학습 횟수이고 t 는 현재 학습 횟수이다. 학습이 진행될수록 드롭아웃을 점점 강하게 적용하여, 초기에는 큰 구조를 잡고 후반에는 과적합을 방지하기 위해 많은 가우시안들을 드롭아웃 시킨다.

선택된 이미지에서 3D 가우시안들을 2D로 투영하여 렌더링을 수행한다. InnerGS에서 제안한 방법과 유사하게, 특정 슬라이스 위치를 t 라 할 때 t 에서의 픽셀(u, v)에서 이미지 강도 I 는 다음 수식 2와 같이 계산된다.

$$I(u, v, t) = \sum_{i=1}^N P_{i(u, v, t)} \alpha'_i(t) c_i \times \prod_{j=1}^{i-1} (1 - p_{j(u, v, t)} \alpha'_j(t)), \quad (2)$$

여기서 $p_{i(u, v, t)}$ 는 슬라이스 위치 t 에서 i 번째 가우시안의 기여도를 나타낸다. N 은 전체 가우시안의 수이다. 또한, 불투명도 $\alpha'(t)$ 는 선택된 슬라이스 t 에 따라 조정되며 다음 수식 3과 같다.

$$\alpha'(t) = \alpha \times \exp(-t\lambda), \quad (3)$$

거리에 기반하여 멀리 떨어져 위치한 가우시안일수록 작은 크기와 낮은 불투명도를 가져, 해당 슬라이스 위치 t 에서 렌더링할 때 영향력을 줄인다.

마지막으로 렌더링이 진행된 이미지와 실제 MRI 슬라이스 간의 차이를 최소화하기 위해 다중 손실 함수를 사용하며 L_1 손실, D-SSIM의 조합으로 구성된 손실 L_{total} 이며 다음 수식 4와 같이 계산된다.

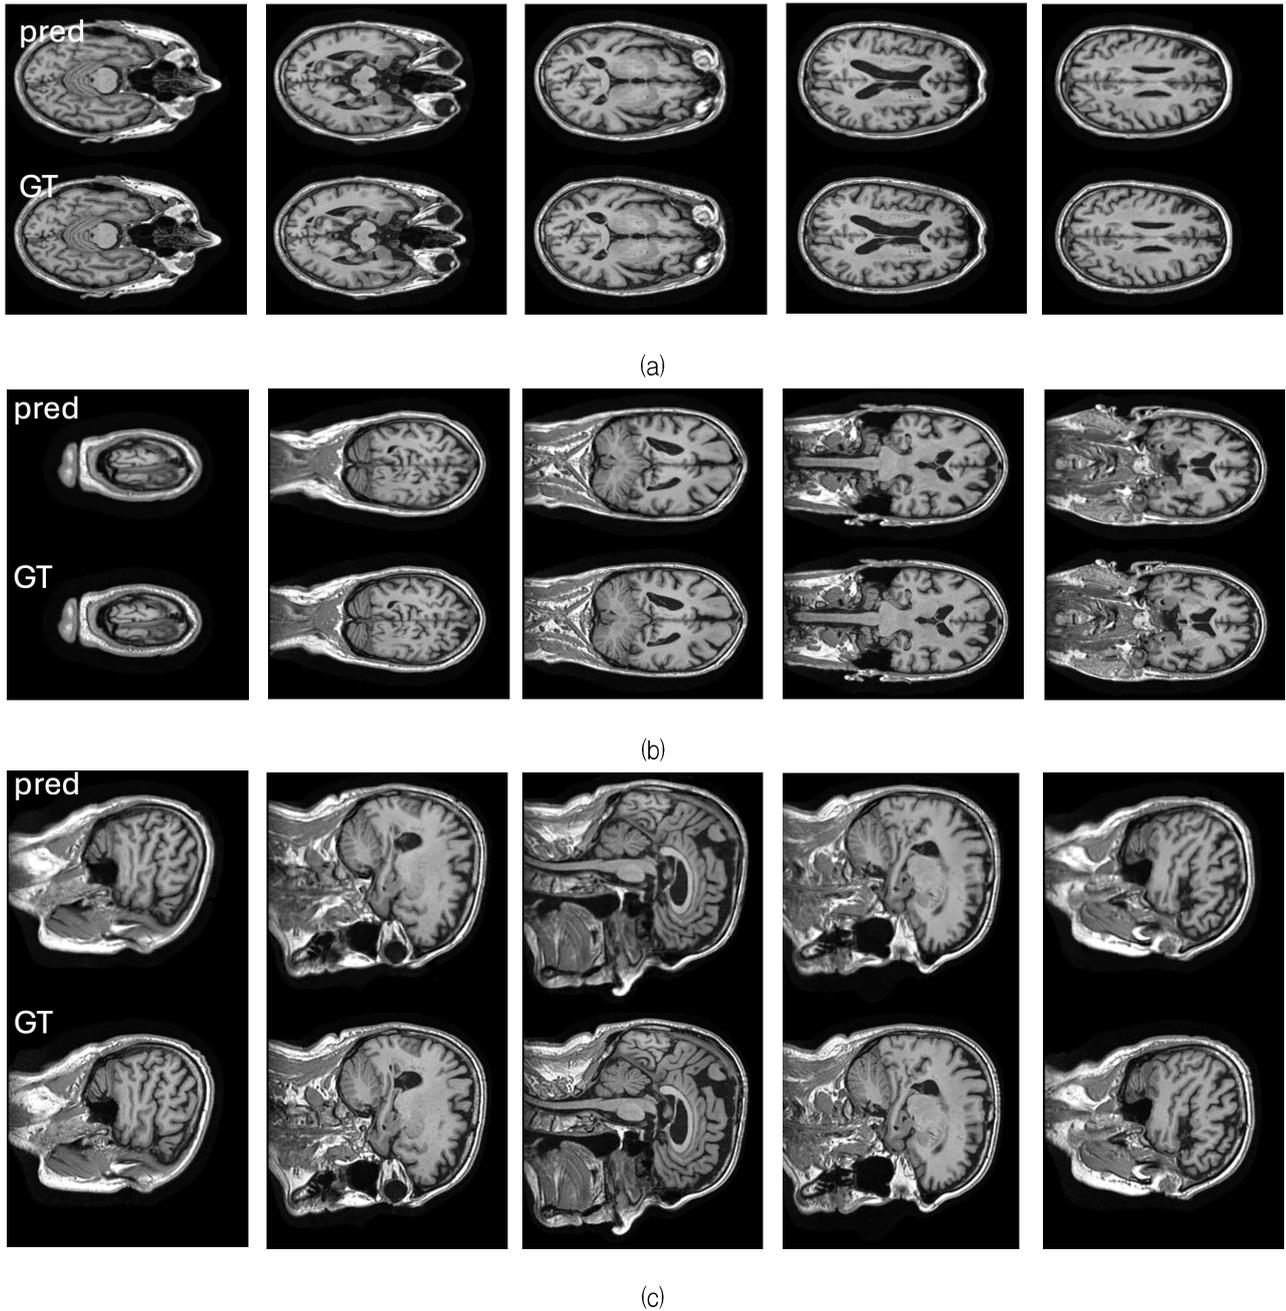


그림 2. 해부학적 단면별 재구성 결과 비교. (a) axial, (b) coronal, (c) sagittal

$$L_{total} = L_1 + \lambda L_{D-SSIM} \quad (4)$$

여기서 λ 는 가중치로 0.2로 설정하였다. D-SSIM은 렌더링이 진행된 이미지와 원본 이미지 사이의 구조적 유사성을 측정한다.

IV. 실험 결과

1. 실험 방법

실험은 PyTorch 프레임워크를 사용했으며, NVIDIA RTX 3090 GPU를 사용했다. ADAM 옵

티마이저를 사용하여 모델의 파라미터들을 학습했다. 제안된 방법은 10,000번의 반복으로 학습된다. 자세한 학습 파라미터는 표 1과 같다.

표 1. 학습 파라미터

	반복 횟수	밀도화 주기	투명도 초기화 주기
1단계	2,000	80	1,000
2단계	7,000	60	1,000
3단계	1,000	-	-

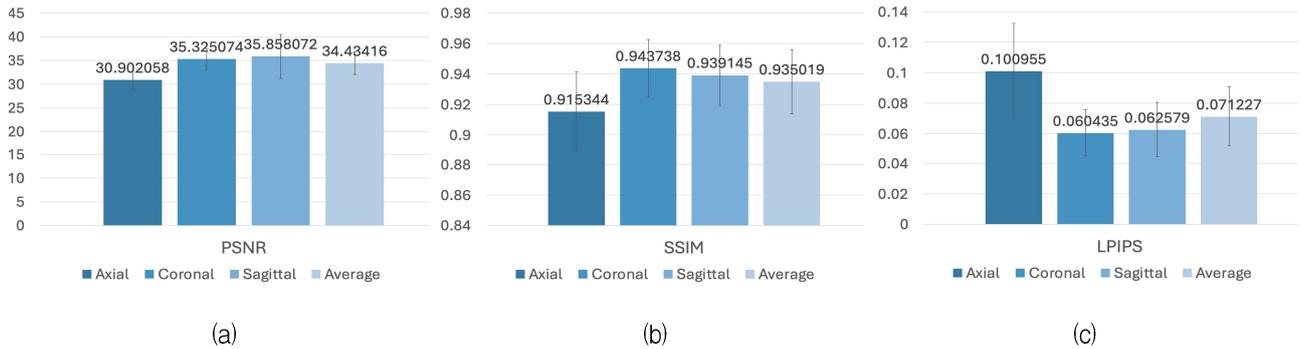


그림 3. 해부학적 단면 별 평가지표 막대그래프 및 오차 막대 (a) PSNR, (b) SSIM, (c) LPIPS

표 2. 성능 비교

방법	기반	데이터셋	PSNR ↑	SSIM ↑	LPIPS ↓
InnerGS	이미지 슬라이스	BrainWeb	32.43	0.9676	-
3DGSMR	주파수 도메인	자체 수집 데이터 (7명)	32.87	0.942	0.095
ours	이미지 슬라이스	ADNI	34.43	0.935	0.071

가우시안 밀도화는 100번째 반복에서부터 시작하고 6,000번째 반복에서 종료된다. 3단계에서는 밀도화 주기가 이미 종료되어 가우시안 밀도화와 투명도 초기화는 하지 않고, 최적화만 진행된다.

2. 데이터 셋과 평가지표

제안된 방법의 데이터 셋은 ADNI (Alzheimer’s Disease Neuroimaging Initiative)을 사용했다. ADNI는 알츠하이머 병을 연구하는 연구자들에게 공개된 뇌 MRI 데이터 셋이다. 본 실험에 사용된 각 데이터는 255 X 255 X 166의 해상도를 가지며, ADNI의 표준 전처리인 GradWarp, B1 Correction, N3, Scaled가 적용된 상태에서 실험을 진행하였다. MRI 데이터의 일부를 검증 및 테스트 셋으로 분리할 경우 3D 구조의 연속성이 훼손되므로, 본 연구는 별도의 데이터 분할 없이 전체 슬라이스를 학습에 활용하여 3D 구조를 재구성하였다.

성능 평가를 위해 다음 세 가지 평가지표를 사용했다. 평가지표는 Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), Learned Perceptual Image Patch Similarity (LPIPS)를 사용하여 실험을 평가했다. PSNR은 원본 이미지와 픽셀 단위 차이를 측정하는 오류 기반 지표이다. SSIM은 밝기, 대비, 구조를 나

누어서 원본 이미지와의 구조적 유사도를 나타내는 지표이다. 마지막으로 LPIPS는 사전 학습된 특징을 활용하여 원본 이미지와 지각적 유사도 지표이다.

3. 성능평가

본 절에서는 제안 방법을 검증하기 위해 ADNI 데이터 셋에서 무작위로 선정한 약 100개의 3T MRI 데이터에 대해 개별적으로 재구성을 수행하였다.

그림 2와 같이 Axial, Coronal, Sagittal의 세 가지 해부학적 단면에서 각각 5개의 슬라이스를 추출하여 원본 이미지와 비교하였다. 제안 방법은 희소시점 환경임에도 불구하고 뇌의 전체적인 기하학적 구조를 재구성했다.

정량적 평가로, 평균 PSNR은 34.43dB로 측정되었다. 이는 일반적인 영상 재구성 연구에서 우수한 품질로 판단되는 30dB 수치보다 높으며, MRI의 강도 변화를 효과적으로 복원했음을 의미한다. SSIM은 0.935로 뇌의 복잡한 해부학적 구조의 특징이 원본과 유사하게 유지되고 있음을 나타낸다. 또한, LPIPS는 0.071의 수치를 기록하여 시각적 인지와 흡사한 재구성 결과를 확인하였다. 이는 제안 방법인 MRI 데이터에 3DGS를 통한 재구성이 데이터의 구조를 잘 복원하고 있음을 알 수 있다.

성능 검증을 위해 본 논문의 제안 방법과 최신 3DGS 기반 의료 영상 재구성 기법인 InnerGS,

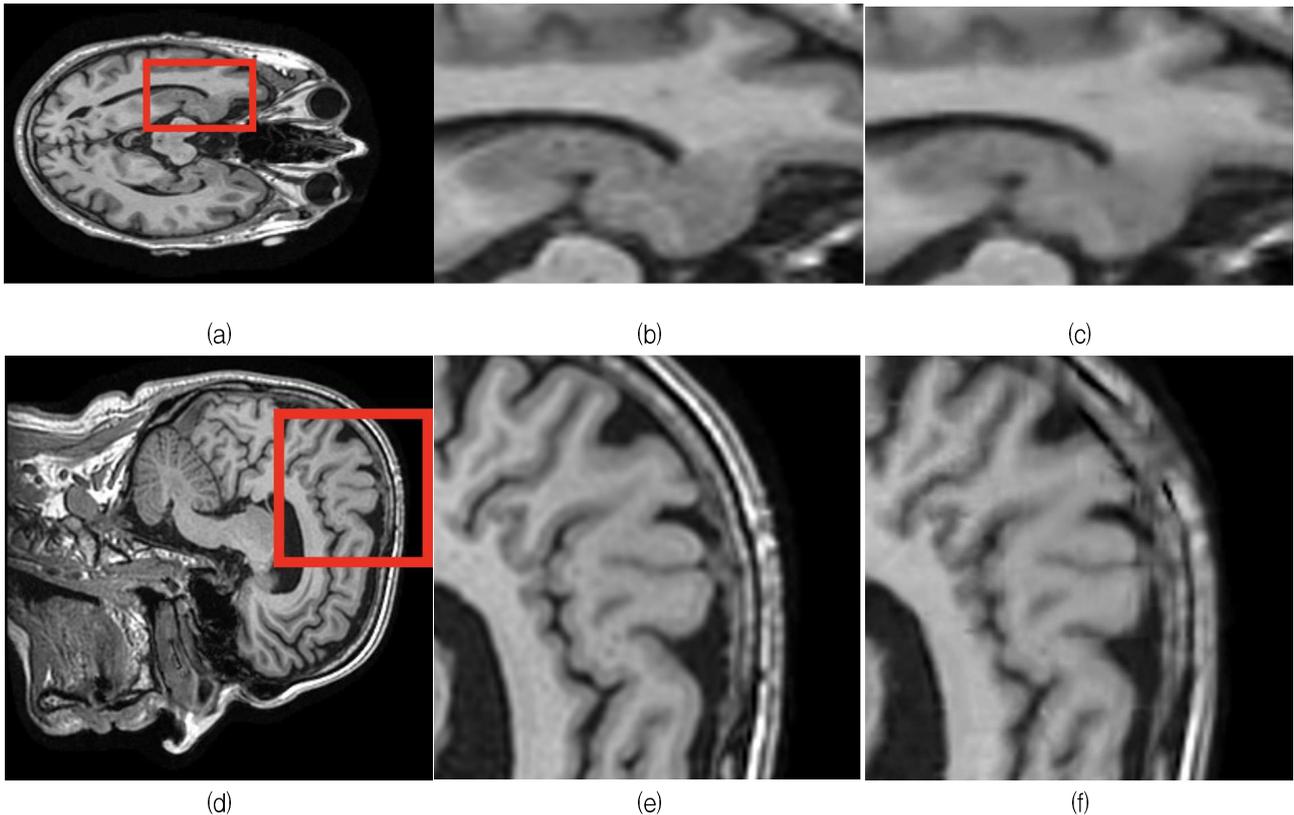


그림 4. 확대한 렌더링 이미지 및 원본 이미지. (a) axial 축의 원본 이미지, (b) 확대한 axial 축의 원본 이미지. (c) 확대한 axial 축의 렌더링 이미지. (d) coronal 축의 원본 이미지, (e) 확대한 coronal 축의 원본 이미지. (f) 확대한 coronal 축의 렌더링 이미지.

3DGSMR의 정량적 결과를 표 2에 비교하였다.

InnerGS는 가상 데이터인 BrainWeb을, 3DGSMR은 자체 데이터셋을 사용하였기에 본 연구의 ADNI 데이터셋과 특성이 달라 비교에는 한계가 있으나, 제안 방법은 실제 임상 데이터에서도 기존 연구 대비 향상된 PSNR 성능을 보였다. LPIPS에서도 3DGSMR에 비하여 좋은 결과를 보였다. SSIM의 경우 기존 기법들과 유사한 수준의 결과를 보였다. 이를 통해 전반적인 재구성 품질과 노이즈 억제 측면에서 뛰어난 성능을 입증하였다.

그림 4에서와 같이 확대한 영역에서 axial 방향의 슬라이스의 경우 원본 이미지에 비하여 기하학적 구조는 비슷하나 흐릿한 부분이 있는 것을 볼 수 있다. coronal 방향의 슬라이스의 경우 아티팩트가 발생하여 기하학적 구조가 완벽하게 생성되지 못했다. 이러한 부분들은 전체적인 구조 파악에는 큰 영향을 미치지 않으나, 고정밀 진단을 위해서는 화질 개선이 필요하다.

V. 결론

본 연구는 표면 렌더링에 특화된 3DGS를 의료 이미지 분야로 확장하여, MRI 데이터 내부 구조를 표현하는 방법을 제안했다. 제안된 방법은 학습 과정에서 과적합 문제를 완화하고 주요 해부학적 구조를 재구성하였다. 고배율로 확대 시 일부 경계에서 구조가 제대로 형성되지 않아 이미지의 품질이 저하되는 한계가 있다. 향후 연구에서는 세부 묘사를 더 잘 할 수 있도록 개선하고자 한다. 또한, 슬라이스 단위 렌더링이 아닌 NVS 기술의 장점을 살린 슬라이스 간 연속 렌더링 및 임의의 각도에서의 단면 재구성 등의 연구로 확장하고자 한다.

REFERENCES

- [1] B. Kerbl, G. Kopanas, T. Leimkühler, and G. Drettakis, "3D Gaussian Splatting for Real-Time Radiance Field Rendering," *ACM Trans. Graph.*, vol. 42, no. 4, article 139, 2023.
- [2] S. Liang, Y. Xiao, and W. Tang, "InnerGS: Internal Scenes Rendering via Factorized 3D

- Gaussian Splatting,” arXiv preprint arXiv:2508.13287, 2025.
- [3] H. Park, G. Ryu, and W. Kim, “DropGaussian: Structural Regularization for Sparse-View Gaussian Splatting,” in *Proc. of IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR)*, pp. 21600 - 21609, Nashville, TN, USA, Jun. 2025.
- [4] B. Mildenhall, P. P. Srinivasan, M. Tancik, J. T. Barron, R. Ramamoorthi, and R. Ng, “NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis,” *Communications of the ACM*, vol. 65, no. 1, pp. 99 - 106, 2022.
- [5] J. L. Schonberger and J.-M. Frahm, “Structure-from-Motion Revisited,” in *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pp. 4104 - 4113, Las Vegas, NV, USA, Jun. 2016.
- [6] J. Zhang, J. Li, X. Yu, L. Huang, L. Gu, J. Zheng, and X. Bai, “CoR-GS: Sparse-View 3D Gaussian Splatting via Co-Regularization,” in *Computer Vision - ECCV 2024: Proc. of the 18th European Conf. on Computer Vision (ECCV)*, pp. 335 - 352, Milan, Italy, Sept. - Oct. 2024.
- [7] R. Zha, T. J. Lin, Y. Cai, J. Cao, Y. Zhang, and H. Li, “R2-Gaussian: Rectifying Radiative Gaussian Splatting for Tomographic Reconstruction,” arXiv preprint arXiv:2405.20693, 2024.
- [8] T. Peng, R. Zha, Z. Li, X. Liu, and Q. Zou, “Three-Dimensional MRI Reconstruction with Gaussian Representations: Tackling the Undersampling Problem,” arXiv preprint arXiv:2502.06510, 2025.

 저 자 소 개



정성원 (준회원)

2025년 조선대학교 정보통신공학과
학사 졸업.

2025년~현재, 조선대학교 정보통신

<주관심분야 : 컴퓨터 비전, 영상처리,
딥러닝>

권구락 (정회원)



2007년 고려대학교 메카트로닉스학과
공학박사

2008년~현재, 조선대학교 정보통신공
학과 재직중

<주관심분야 : 의료영상처리, 디지털미디어컴퓨팅>