

# Dynamic Gaussian Splatting 기반 4차원 장면 복원 및 압축 기법 분석

□ 이윤규, \*박재식 / 포항공과대학교, \*서울대학교

## 요약

최근 3D Gaussian Splatting 기술이 발전함에 따라 4차원 복원에도 가우시안 기반 기법이 적용되고 있다. 가우시안을 동적 장면 복원에 적용하는 Dynamic Gaussian Splatting (Dynamic GS) 기술은 높은 품질과 빠른 속도를 제공하지만 많은 저장 공간을 소모한다. 따라서 실용화와 배포를 위해서는 저장 공간 소모량을 줄이는 압축 기술이 필수적이다. 본 글에서는 4 차원 복원을 위한 Dynamic GS 기술 전반을 소개하고, Dynamic GS 모델의 효율적인 저장 및 전송을 위한 기술을 분석한다.

## I. 서론

3차원 복원 기술은 컴퓨터 비전과 그래픽스 분야의 중요한 연구 대상이다. 이 기술은 사진으로부터 3차원 공간의 구조와 외관을 복원하는 것을 목표로 하며, 임의 시점 이미지 합성을 가능하게 한다. 현실 세계를 디지털화하여 모델링하는 3차원 공간 복원 기술은 VR/AR, 방송, 실감형 미디어 등 분야에 광범위하게 적용할 수 있다. 정적인 3차원 장면을 넘어, 동적인 장면을 복원하는 4차원 복원 기술에 대한 연구도 활발히 진행되고 있다.

최근 기계학습이 발전함에 따라 장면 복원 기술 역시 큰 발전을 이루었다. NeRF (neural radiance field, 신경 방사장)는 공간의 3차원 방사장을 인공신경망으로 표현한

다[Mildenhall et al., 2020]. 인공신경망은 공간상 한 점의 3차원 좌표와 관측 각도를 입력받아 해당하는 색상과 밀도를 출력하며, 출력값을 사용한 부피 렌더링을 통해 이미지가 합성된다. NeRF는 높은 품질의 복원을 가능케 하지만, 두 가지 한계를 가진다. 첫째, 부피 렌더링 과정에서 많은 양의 인공신경망 연산이 필요하여 학습 속도 및 렌더링 속도가 느린다. 둘째, 인공신경망을 사용하는 암시적 표현법(implicit representation)이므로 학습 후 수정과 후 처리에 제약이 있다. NeRF의 문제점을 개선하기 위한 연구[Müller et al., 2022]가 뒤따랐고 4차원 복원으로의 확장[T. Li et al., 2022]도 이루어졌지만, 인공신경망 기반 표현법 자체의 한계는 여전히 존재한다.

3D Gaussian Splatting[Kerbl et al., 2023] (3DGS)은

NeRF의 한계점을 개선한 명시적(explicit) 3차원 복원 기법이다. 이 기술은 공간을 수십~수백만 개의 3차원 가우시안 기본 요소로 표현한다. 각 가우시안은 위치, 크기, 방향, 색상, 투명도의 매개변수를 가지며, 가우시안의 중심을 나타내는 위치 매개변수로부터의 거리에 따라 투명도가 감소한다. 반사와 광택 등의 시점 종속 색상은 구면조화 함수로 표현된 후 RGB 색상값으로 계산된다. 가우시안의 렌더링은 효율성을 위해 splatting 기반 래스터화(rasterization)로 진행한다. Splatting이란, 3차원 가우시안을 이미지 평면에 사영하여 2차원 가우시안으로 변환하고 이를 직접 픽셀로 그리는 방식이다. 모든 렌더링 과정은 미분 가능하게 설계되어 가우시안의 각 매개변수는 직접적으로 Adam[Kingma and Ba, 2015] 등의 그래디언트 기반 기법으로 최적화가 가능하다. 이때 렌더링 결과와 입력 사진 사이의 차이가 손실 함수로 이용되어 여러 시점에서의 입력 사진이 필요하다.

3DGS는 정적인 3차원 공간의 복원에만 적용이 가능하다. 3DGS를 확장한 Dynamic Gaussian Splatting(Dynamic GS) 기법은 시간별로 변화하는 가우시안을 사용하여 동적인 장면을 표현하며, 사진이 아닌 영상을 입력으로 학습된다. 본 글은 II장에서 초기 Dynamic GS 기술을 소개하고, III장에서 효율적인 저장과 전송이 가능한 Dynamic GS 모델을 분석하며, IV장에서 결론을 맺는다.

## II. 초기 Dynamic Gaussian Splatting 기술

Dynamic GS 기술은 3DGS와 동일하게 가우시안을 기본 요소로 사용하여 공간을 표현한다. 따라서 동적인 장면을 표현하기 위해서는 가우시안 매개변수를 시간에 따라 변화시키는 기술이 핵심적이다. 본 장에서는 기본적인 Dynamic GS 표현법을 변형 기반 방법과 궤적 기반 방법, 두 가지로 나누어 살펴본다.

### 1. 변형 기반 방법

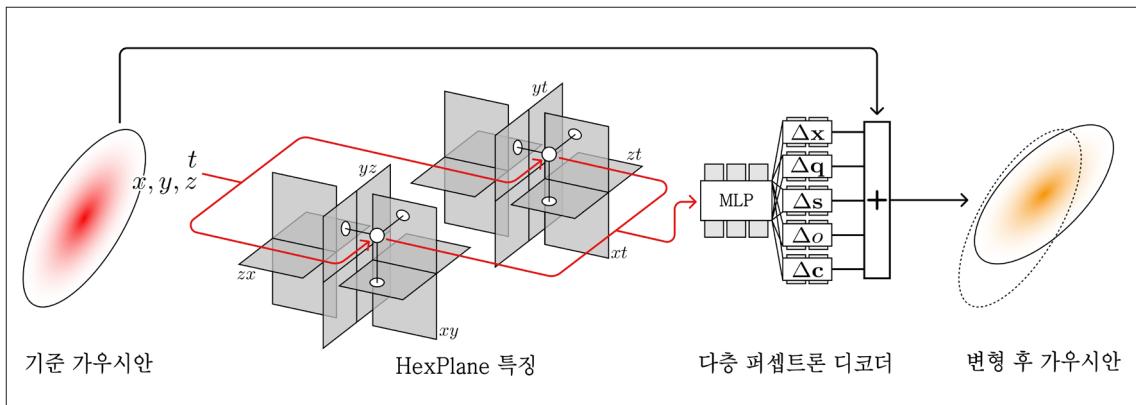
변형 기반 방법(deformation-based method)은 하나의 가우시안 집합을 시간에 따라 변형하여 움직임을 나타낸다. 이 방법에 속하는 모델은 가우시안과, 가우시안을 시간에 따라 변형시키는 변형 모델로 구성된다. 변형을 통한 운동의 표현은 이전 NeRF 기반 방법[Park et al., 2021]에서도 연구되었다.

[G. Wu et al., 2024] 연구는 변형을 사용한 4D Gaussian Splatting (4DGS) 방법을 제안하였다. 이 표현 방법은 기준(canonical) 가우시안을 기반으로 한다. 시간에 따른 변형은 기준 가우시안의 위치와 특정 시간을 변형 모델에 입력하여 얻은 변화량을 기준 가우시안의 매개변수에 더하는 방식으로 이루어진다. 변형 모델은 학습 가능한 특징(feature)과 특징 디코더로 구성되어 있다. 효율적인 구현을 위해 4차원 공간을 6개의 2차원 평면으로 분해하는 HexPlane[Cao and Johnson, 2023][Fridovich-Keil et al., 2023] 구조로 특징을 저장한다. 각 특징 벡터는 다층 퍼셉트론(multilayer perceptron)을 통해 변화량으로 디코딩된다. 모델 학습 시 기준 가우시안과 변형 모델을 동시에 최적화하여 복원 성능을 높인다.

4DGS[G. Wu et al., 2024] 방식은 기존 NeRF 기반 방법에 비해 높은 복원 품질을 보이고, 학습과 렌더링 속도를 크게 향상시켰다. 하지만 하나의 가우시안 집합만을 변형시키는 변형 기반 방법의 특성상, 새로 등장하거나 사라지는 물체가 존재하는 경우 복원 품질 저하가 발생한다. 또한, 매개변수에 작은 변화량을 더하여 움직임을 나타내므로 움직임이 빠른 물체의 복원에 적합하지 않다. 변형 기반 방법은 영상 전체에 하나의 모델만을 학습시켜, 수천 프레임 길이의 긴 영상의 복원에도 품질이 저하된다[Xu et al., 2024].

### 2. 궤적 기반 방법

하나의 가우시안 집합을 변형시키는 변형 기반 방법과



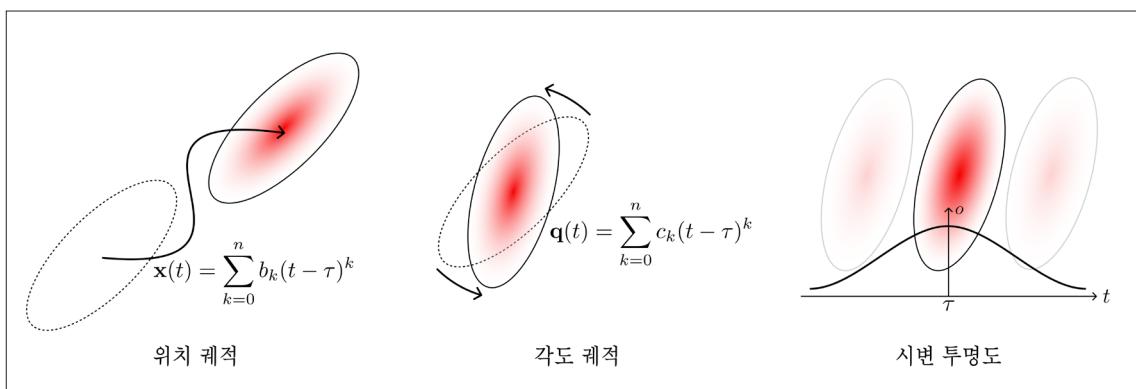
&lt;그림 1&gt; 4DGS 방법 모식도

달리, 궤적 기반 방법(trajectory-based method)은 각 가우시안에 독립적인 궤적을 부여함으로써 움직임을 표현한다. 이때 각 가우시안은 공간축뿐만 아니라 시간축 상의 위치도 가져, 투명도가 위치와 시간에 따라서 변화한다. 이 범주에 속하는 방법으로는 STG[Li et al., 2024]와 4DGS[Yang et al., 2024] 등이 있다.

STG는 가우시안의 각 매개변수를 직접적으로 시간에 따른 함수로 나타내는 방법이다. 물체의 운동을 표현하는 가우시안의 위치와 방향 궤적을 다항함수로 나타낸다. 가우시안의 생성과 소멸은 시간에 따라 투명도를 1차원 가

우시안 함수로 변화시켜 표현한다. 외관의 표현을 위해서는 각 가우시안에 RGB 색상이 아닌 특징 벡터를 부여하여, 렌더링 시 splatting된 특징 벡터를 다중 퍼셉트론으로 디코딩해 최종 색상을 출력한다.

STG 방법은 각 가우시안을 시간에 따라 직접 변화시켜, 변형 기반 방법인 4DGS[G. Wu et al., 2024]보다 높은 복원 품질을 보인다. 그러나 각 가우시안이 독립적인 궤적과 특징 벡터를 가지므로 많은 수의 매개변수가 필요하고, 이는 높은 저장 공간 소모량으로 이어진다.



&lt;그림 2&gt; STG 방법 모식도

### 3. 초기 방법의 한계점

초기 Dynamic GS 기술은 기존 방법에 비해 복원 품질, 학습 속도, 그리고 렌더링 속도를 크게 향상시켰다. 이에 따라 4차원 복원 연구의 패러다임은 NeRF 기반 방법으로부터 Dynamic GS 방법으로 옮겨갔지만, 초기 Dynamic GS 기술은 실용화에 한계가 있다. 초기 기술의 가장 큰 한계는 모델의 강건성(robustness) 부족으로, 복원 결과의 품질이 입력 영상에 큰 영향을 받는다. 특히 크고 빠른 물체의 운동, 긴 영상, 적은 입력 영상 시점 수

에 취약하다. 연구가 몇 개의 표준 데이터셋[T. Li et al., 2022]에 집중되며 해당 데이터셋에는 복원이 원활하지만, 일반적인 입력에 대해서는 복원 품질이 저하된다. <그림 3>은 움직임이 빠른 장면[Zitnick et al., 2004]에 대해 변형 기반 방법인 4DGS[G. Wu et al., 2024]의 복원 결과와 원본 사진의 비교이다. 빠른 물체의 경우 복원 품질의 저하가 발생하는 것을 확인할 수 있다. <그림 4>는 궤적 기반 방법인 4DGS[Yang et al., 2024]의 복원 결과와 원본 사진의 비교로, 마찬가지로 빠른 대상의 복원에 한계가 존재한다.



<그림 3> (좌) 4DGS[G. Wu et al., 2024] 복원 결과. (우) 원본 사진



<그림 4> (좌) 4DGS[Yang et al., 2024] 복원 결과. (우) 원본 사진

&lt;표 1&gt; NeRF 기반 방법과 초기 Dynamic GS 방법의 복원 품질, 학습 시간, 렌더링 속도, 저장 공간 비교

기술	PSNR	DSSIM	학습 시간	렌더링 FPS	저장 공간
DyNeRF [T. Li et al., 2022]	29.58	0.0197	1344 hrs	0.015 FPS	28 MB
4DGS [G. Wu et al., 2024]	31.15	0.016	0.67 hrs	30 FPS	90 MB
STG [Li et al., 2024]	32.05	0.014	3 hrs	140 FPS	200 MB

복원 품질 이외의 문제로는 저장 공간의 문제가 있다. 수십만 개가 넘는 가우시안을 사용하는 Dynamic GS 기술은 높은 복원 품질을 달성하지만, 많은 저장 공간을 소모한다. 3차 구면 조화 함수를 사용하는 경우, 각 가우시안은 59개의 32비트 부동소수점 값으로 저장되어 해당 200바이트를 넘게 차지한다. 반면 NeRF에서 사용하는 암시적 신경망은 연속함수를 직접 표현하므로 가우시안과 같은 불연속 명시적 표현법보다 적은 용량을 소모한다 [Sitzmann et al., 2020]. 가우시안이 도입되며 NeRF 기반 방법에 비해 복원 품질과 속도는 향상되었지만, 저장 공간 소모량은 오히려 회귀하였다.

하고 벡터 양자화를 통해 가우시안의 매개변수를 압축한다. 시공간 마스킹을 위해서 각 가우시안에 학습 가능한 마스크 변수를 추가하고, 해당 변수를 0 또는 1로 이진화하여 가우시안의 투명도와 크기에 곱하여 가우시안을 유지 또는 소멸시킨다. 학습 시 불필요한 마스크 값은 0이 되도록 유도하여 복원에 필요한 가우시안만을 유지하고, 저장 및 전송에 필요한 가우시안의 개수를 줄인다. 개수가 줄어든 가우시안의 매개변수는 잔여 벡터 양자화를 통해 압축된다. 가우시안은 높은 시공간적 지역성을 가지며 [Shin, Park and Cho, 2025] 중복된 정보가 많아 벡터 양자화에 유리하다. 압축을 제외한 전반적인 학습과 렌더링 방법은 STG를 따른다. C3DGS는 STG와 유사한 복원 품질을 유지하는 동시에 저장 용량을 1/10 수준으로 크게 낮추었다.

### III. Dynamic Gaussian Splatting 모델의 효율적인 저장과 전송

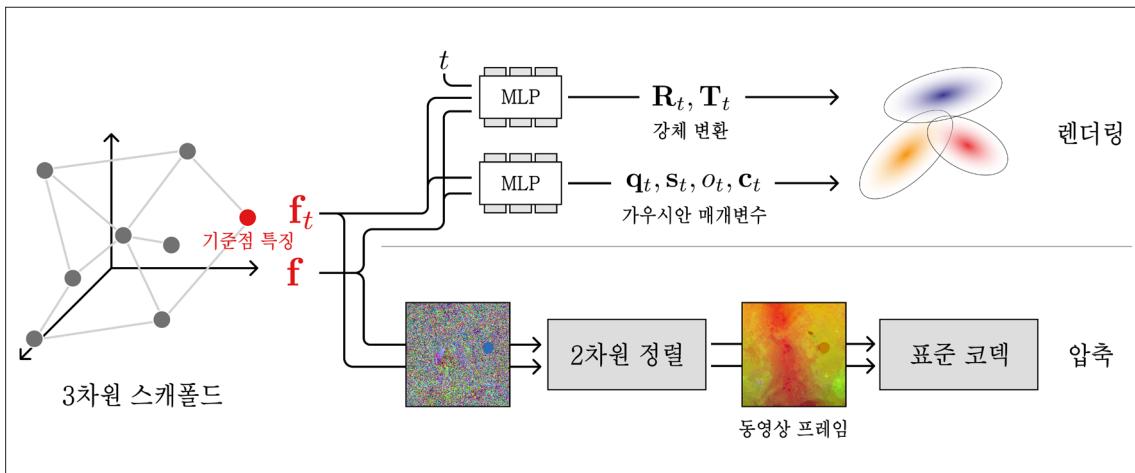
초기 Dynamic GS 방법은 각 프레임당 수백 킬로바이트(KB)의 저장 공간을 소모한다. 이를 전송을 위한 대역폭으로 환산하면 초당 수백 메가비트(Mbps) 수준으로, 실용화를 위해서는 개선이 필요한 수치이다. 상기한 초기 기술 이후에 제안된 연구 중 일부는 가우시안의 효율적인 저장과 전송을 목표로 한다. 본 장에서는 저장과 전송 효율을 높인 Dynamic GS 방법 중 일부를 살펴본다.

#### 1. C3DGS

C3DGS[Lee et al., 2024]는 STG[Li et al., 2024] 표현법에 대한 압축 방법을 제안하였다. 이 기법은 시공간 마스킹으로 불필요한 가우시안을 삭제하여 모델을 경량화

#### 2. GIFStream

HEVC, VVC 등의 동영상 코덱은 성숙한 기술로, 높은 성능을 가지며 소프트웨어와 하드웨어에서 널리 지원된다. 이에 따라 동영상 코덱을 Dynamic GS 압축에 적용하려는 연구가 진행되었다. 그중 GIFStream[Li et al., 2025]은 가우시안의 특징 벡터를 영상 코덱으로 압축하는 방법을 제안하였다. GIFStream은 Scaffold-GS[Lu et al., 2024]의 스캐폴드 표현 방법을 기반으로 한다. 스캐폴드 표현 방법은 가우시안의 매개변수를 직접 저장하는 대신, 3차원 기준점(anchor point)에 위치한 특징 벡터를 디코딩하여 가우시안을 표현한다. 각 기준점의 특징 벡터는 시변 특징 벡터와 시불변 특징 벡터로 이루어져 있으며, 다층 퍼셉트론을 사용하여 여러 가우시안의 매개변수로 디



&lt;그림 5&gt; GIFStream 방법 모식도

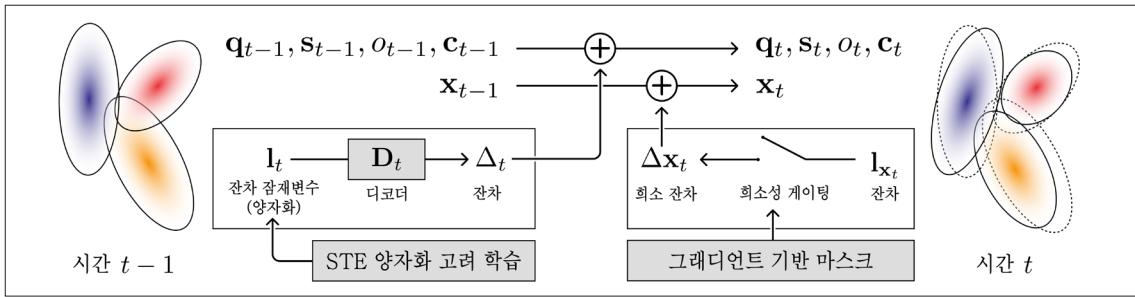
코딩된다. 각 가우시안의 움직임은 기준점을 중심으로 하는 평행이동과 회전으로 표현한다.

스캐폴드 표현법의 효율적인 저장 및 전송을 위해서는 3차원 기준점의 특징 벡터를 압축해야 한다. GIFStream은 이를 위해 특징 벡터를 동영상으로 저장하는 방식을 제안하고, 3차원상의 특징을 2차원 영상 프레임으로 표현하기 위해서 정렬 기반 방법[Morgenstern et al., 2025]을 사용한다. 2차원 정렬을 통해 영상 프레임의 고주파 성분을 최소화하여 코덱의 압축 효율을 높인다. 또한, 코덱 효율 향상을 위해 종단간 학습을 적용한다. 합성곱 신경망을 사용하여 자기회귀적으로 영상의 다음 프레임의 분포를 예측하고, 예측된 분포의 엔트로피를 최소화하는 정규화 항을 손실 함수에 추가하여 부호율-변형(rate-distortion)을 종단간으로 최적화한다. 그 결과, GIFStream은 C3DGS를 뛰어넘는 부호율-변형 성능을 보이는 동시에 표준 동영상 코덱을 활용하는 장점을 갖는다.

### 3. QUEEN

Dynamic GS의 효율적인 전송을 위해서는 단순 압축 뿐만 아니라 스트리밍도 필요하다. 기존 기술[G. Wu et

al., 2024][Li et al., 2024][Lee et al., 2024]은 입력 영상 전체 또는 영상 블록에 대한 모델이므로 프레임 단위 스트리밍이 불가능하며, 모델 전체를 전송해야 한다. 또한 학습 시 입력 영상의 모든 프레임이 필요한 오프라인 학습 방식이므로 방송, 스포츠, 화상회의 등 입력 영상이 실시간으로 수신되는 상황에는 적합하지 않다. QUEEN[Girish et al., 2024]은 온라인 학습과 프레임 단위 스트리밍이 가능한 방식으로, 위 문제에 대한 해결책을 제시한다. 이 방법은 각 프레임에서 이전 프레임의 가우시안과의 잔차를 학습하고 저장하여 가우시안의 변화를 나타낸다. 이때 양자화를 통해 잔차를 효율적으로 저장하며, 양자화 과정에서 발생하는 오차를 줄이기 위해 양자화 고려 학습을 진행한다. 효율을 더욱 높이기 위해 가우시안의 그레디언트의 크기를 기반으로 동적 가우시안과 정적 가우시안을 분리하여, 장면의 움직이는 물체에 해당하는 적은 개수의 일부 가우시안만을 업데이트한다. QUEEN은 높은 품질과 렌더링 속도를 가지는 동시에 프레임 단위 학습과 전송을 가능하게 한다. 하지만 학습에 프레임당 수 초가 소요되어 실시간 응용에는 적합하지 않으며, 스트리밍이 불가능한 표현법과 비교하면 많은 저장 공간을 소모한다.

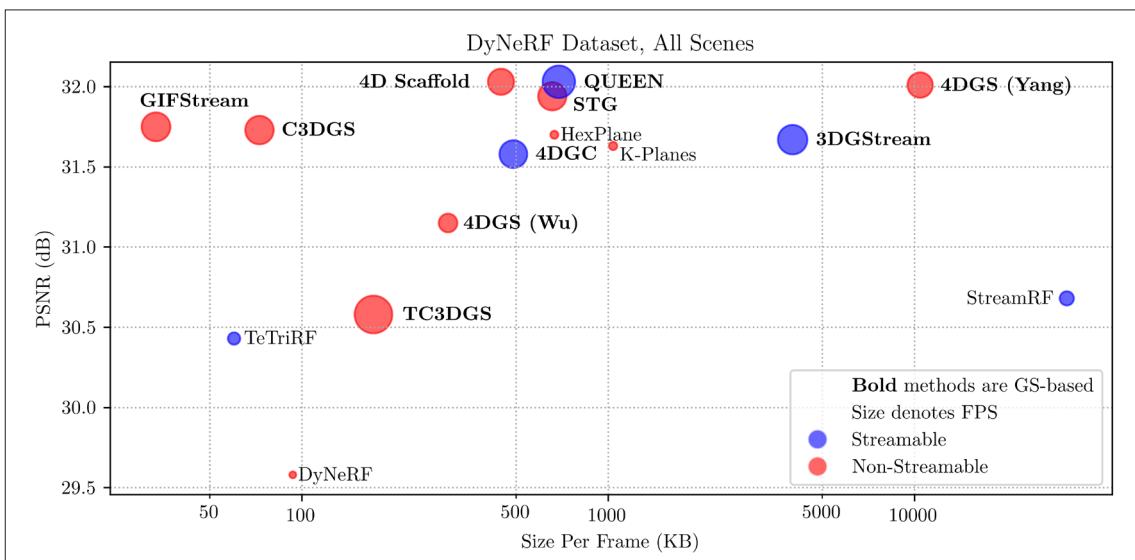


<그림 6> QUEEN 방법 모식도

#### 4. 압축 성능 비교

본 글에서는 4차원 복원 방법의 압축과 렌더링 성능 비교를 수행하였다. <그림 7>은 Dynamic GS 및 NeRF 기반 방법(DyNeRF[T. Li et al., 2022], 4DGS[G. Wu et al., 2024], HexPlane[Cao and Johnson, 2023], K-Planes[Fridovich-Keil et al., 2023], STG[Li et al., 2024], 4DGS[Yang et al., 2024], C3DGS[Lee et al., 2024], GIFStream[Li et al., 2025], QUEEN[Girish et al., 2024], 4D Scaffold[Cho et al., 2024], 4DGC[Hu et al.,

2025], 3DGStream[Sun et al., 2024], TeTriRF[M. Wu et al., 2024], TC3DGS[Javed et al., 2024], StreamRF[L. Li et al., 2022])의 정량적인 부호율-변형 성능을 PSNR 지표로 나타낸다.  $1352 \times 1014$  화질, 300 프레임 길이의 DyNeRF[T. Li et al., 2022] 데이터셋을 기준으로 비교하였다. 가우시안 기반 방법이 NeRF 기반 방법보다 우수한 성능을 보이는 것을 확인할 수 있다. 그중 GIFStream 방법은 프레임당 용량 33KB에서 평균 PSNR 31.75dB를 가져 파레토 최적 압축 성능을 보인다. 분석한 모든 Dynamic GS 기반 방법은 실시간 렌더링이 가능한 렌더



<그림 7> 대표적인 4차원 복원 기법의 부호율-변형 성능 비교

링 속도(30FPS 이상)를 갖는다.

〈그림 7〉에서 스트리밍 가능 기법은 파란색, 불가능 기법은 빨간색을 사용해 나타내었다. 스트리밍 가능 기법은 복원 후 모델을 스트림 형태로 전송하여, 사용자가 스트림의 일부 프레임만 수신한 후 곧바로 렌더링이 가능하다. 반면 스트리밍 불가능 기법은 사용자가 모델 전체를 수신해야만 렌더링이 가능하다. 스트리밍 가능 기법은 불가능 기법보다 비교적 많은 저장 공간을 소모한다. 프레임 단위 스트리밍과 온라인 학습을 지원하는 QUEEN 방법은 그렇지 않은 GIFStream에 비해 약 20배의 용량을 갖는다. 또 다른 스트리밍 가능 기법인 4DGC는 GIFStream에 비해 약 15배의 용량을 갖는다. QUEEN과 4DGC는 프레임 단위 스트림으로 정보를 전송한다는 장점이 있지만, 프레임 간 중복성을 활용하지 못해 많은 저장 공간을 소모한다.

## IV. 결 론

본 글에서는 4차원 복원을 위한 Dynamic GS 기술에 대해 소개하였고, Dynamic GS 모델의 효율적인 저장과 전송을 위한 방법을 분석하였다. 4차원 복원 기술의 발전으로 적은 저장 공간과 낮은 대역폭으로 실감 미디어를 저장하고 전송하는 것이 가능해졌다. 최신 기술들은 제어된 환경에서 촬영된 영상에 대해서는 높은 복원 품질을 보이지만, 여전히 빠른 움직임과 적은 수의 입력 영상 시점에 대해서는 취약하다[Liang et al., 2024]. 복원 속도 또한 제한적이어서, 온라인 학습 기법의 경우에도 복원에 프레임당 수 초가 소요되어 실시간 복원 및 전송이 불가능하다[Girish et al., 2024]. 4차원 복원의 강건성 문제를 해결하고, 단일 시점 복원과 실시간 복원 및 압축 등 고도화된 기술의 개발을 위해서는 추가적인 연구가 필요할 것으로 사료된다.

## 참 고 문 헌

- 
- [Cao and Johnson, 2023] A. Cao and J. Johnson (2023) ‘HexPlane: A Fast Representation for Dynamic Scenes’, in 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). CVPR 2023, Vancouver, BC, Canada: IEEE, pp. 130-141.
- [Cho et al., 2024] W.O. Cho et al. (2024) ‘4D Scaffold Gaussian Splatting for Memory Efficient Dynamic Scene Reconstruction’, arXiv.
- [Fridovich-Keil et al., 2023] S. Fridovich-Keil et al. (2023) ‘K-Planes: Explicit Radiance Fields in Space, Time, and Appearance’, in 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). CVPR 2023, Vancouver, BC, Canada: IEEE, pp. 12479-12488.
- [Girish et al., 2024] S. Girish et al. (2024) ‘QUEEN: QUantized Efficient ENcoding of Dynamic Gaussians for Streaming Free-viewpoint Videos’. arXiv.
- [Hu et al., 2025] Q. Hu et al. (2025) ‘4DGC: Rate-Aware 4D Gaussian Compression for Efficient Streamable Free-Viewpoint Video’, CoRR, abs/2503.18421.
- [Javed et al., 2024] S. Javed et al. (2024) ‘Temporally Compressed 3D Gaussian Splatting for Dynamic Scenes’, arXiv.
- [Kerbl et al., 2023] B. Kerbl et al. (2023) ‘3D Gaussian Splatting for Real-Time Radiance Field Rendering’, ACM Transactions on Graphics, 42(4).
- [Kingma and Ba, 2015] D.P. Kingma and J. Ba (2015) ‘Adam: A Method for Stochastic Optimization’, in Y. Bengio and Y. LeCun (eds) 3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings.
- [Lee et al., 2024] J.C. Lee et al. (2024) ‘Compact 3D Gaussian Splatting for Static and Dynamic Radiance Fields’, arXiv.
- [Li et al., 2025] H. Li et al. (2025) ‘GIFStream: 4D Gaussian-based Immersive Video with Feature Stream’. arXiv.
- [L. Li et al., 2022] L. Li et al. (2022) ‘Streaming Radiance Fields for 3D Video Synthesis’, in S. Koyejo et al. (eds) Advances in Neural Information Processing Systems 35: Annual Conference on Neural Information Processing Systems 2022, NeurIPS 2022, New Orleans, LA, USA, November 28 - December 9, 2022.

## 참 고 문 헌

- [T, Li et al., 2022] T. Li et al. (2022) ‘Neural 3D Video Synthesis from Multi-view Video’, in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. CVPR 2022, New Orleans, LA, USA: IEEE, pp. 5511-5521.
- [Li et al., 2024] Zhan Li et al. (2024) ‘Spacetime Gaussian Feature Splatting for Real-Time Dynamic View Synthesis’, in *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. CVPR 2024, Seattle, WA, USA: IEEE, pp. 8508-8520.
- [Liang et al., 2024] Y. Liang et al. (2024) ‘Monocular Dynamic Gaussian Splatting is Fast and Brittle but Smooth Motion Helps’, arXiv.
- [Lu et al., 2024] T. Lu et al. (2024) ‘Scaffold-GS: Structured 3D Gaussians for View-Adaptive Rendering’, in *IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2024, Seattle, WA, USA, June 16-22, 2024*. IEEE, pp. 20654-20664.
- [Mildenhall et al., 2020] B. Mildenhall et al. (2020) ‘NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis’, in A. Vedaldi et al. (eds) *Computer Vision - ECCV 2020*. Cham: Springer International Publishing (Lecture Notes in Computer Science), pp. 405-421.
- [Morgenstern et al., 2025] W. Morgenstern et al. (2025) ‘Compact 3D Scene Representation via Self-Organizing Gaussian Grids’, in *Computer Vision-ECCV 2024*. Cham: Springer Nature Switzerland, pp. 18-34.
- [Müller et al., 2022] T. Müller et al. (2022) ‘Instant Neural Graphics Primitives with a Multiresolution Hash Encoding’, *ACM Trans. Graph.*, 41(4), p. 102:1-102:15.
- [Park et al., 2021] K. Park et al. (2021) ‘Nerfies: Deformable Neural Radiance Fields’, in *2021 IEEE/CVF International Conference on Computer Vision, ICCV 2021, Montreal, QC, Canada, October 10-17, 2021*. IEEE, pp. 5845-5854.
- [Shin, Park and Cho, 2025] S. Shin, J. Park and S. Cho (2025) ‘Locality-aware Gaussian Compression for Fast and High-quality Rendering’, in *The Thirteenth International Conference on Learning Representations, ICLR 2025, Singapore, April 24-28, 2025*. OpenReview.net.
- [Sitzmann et al., 2020] V. Sitzmann et al. (2020) ‘Implicit Neural Representations with Periodic Activation Functions’, in *Proc. NeurIPS*.
- [Sun et al., 2024] J. Sun et al. (2024) ‘3DGStream: On-the-Fly Training of 3D Gaussians for Efficient Streaming of Photo-Realistic Free-Viewpoint Videos’, arXiv.
- [G. Wu et al., 2024] G. Wu et al. (2024) ‘4D Gaussian Splatting for Real-Time Dynamic Scene Rendering’, in *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. CVPR 2024, Seattle, WA, USA: IEEE, pp. 20310-20320.
- [M. Wu et al., 2024] M. Wu et al. (2024) ‘TeTriRF: Temporal Tri-Plane Radiance Fields for Efficient Free-Viewpoint Video’, in *IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2024, Seattle, WA, USA, June 16-22, 2024*. IEEE, pp. 6487-6496.
- [Xu et al., 2024] Z. Xu et al. (2024) ‘Representing Long Volumetric Video with Temporal Gaussian Hierarchy’, *ACM Transactions on Graphics*, 43(6).
- [Yang et al., 2024] Z. Yang et al. (2024) ‘Real-time Photorealistic Dynamic Scene Representation and Rendering with 4D Gaussian Splatting’, in *The Twelfth International Conference on Learning Representations, ICLR 2024, Vienna, Austria, May 7-11, 2024*. OpenReview.net.
- [Zitnick et al., 2004] C.L. Zitnick et al. (2004) ‘High-quality video view interpolation using a layered representation’, *ACM Trans. Graph.*, 23(3), pp. 600-608.

## 저자 소개

### 이윤규



- 2021년 ~ 현재 : 포항공과대학교 컴퓨터공학과 학사 재학
- 2024년 ~ 현재 : 서울대학교 시각 및 기하지능 연구실 학부연구원
- 연구분야 : Dynamic Scene Reconstruction, Computer Vision

### 박재식



- 2005년 ~ 2009년 : 한양대학교 미디어통신공학 졸업
- 2009년 ~ 2011년 : 한국과학기술원 전기 및 전자공학과 석사 졸업
- 2011년 ~ 2015년 : 한국과학기술원 전기 및 전자공학과 박사 졸업
- 2015년 ~ 2019년 : Intel Labs Research Scientist
- 2019년 ~ 2023년 : 포항공과대학교 컴퓨터공학과 조교수/부교수
- 2023년 ~ 현재 : 서울대학교 컴퓨터공학부 조교수
- 연구분야 : 3D Vision, Computer Vision