

2D diffusion based NeRF to Transformer based NeRF



Sogang University

Vision & Display Systems Lab, Dept. of Electronic Engineering



Presented By

이혜빈

Outline

- Paper
 - One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization (NeurIPS 2023)
 - LRM: Large reconstruction model for single image to 3D (ICLR 2024)


One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Overview

- 2D diffusion(각도별 이미지 생성) + 3D reconstruction module



Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Intro

- Single image to 3D reconstruction
- 기존의 방법들
 - ⌘ 2D diffusion model + 3D reconstruction module
 - ⌘ Vision-language model + 3D reconstruction module
 - ✓ ex) DreamField, DreamFusion, Magic3D
- 기존 방법들의 한계
 - ⌘ optimization time 오래 걸림
 - ⌘ 메모리 집약적
 - ⌘ 3D 불일치 결과들(야누스 문제)
 - ⌘ geometry 열악함

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Intro

- 논문이 제안하는 것

⚡ view-conditioned 2D diffusion model(Zero123) + 3D reconstruction module

✓ multi-view 이미지들 생성 → 3D

✓ 3D reconstruction module: SDF-based 생성 Neural Surface Reconstruction

⚡ 세 가지 모듈을 합성

✓ multi-view 합성

✓ elevation estimation

✓ 3D reconstruction


⚡ 과도한 3D 인식 regularization, fine-tuning 없이 새로운 뷰에서 렌더링된 이미지, 실제 이미지 간 차이 최소화하며 학습

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- Multi-views 생성



⚡ View-conditioned 2D diffusion model인 Zero123을 사용

✓ 2 stage 방법으로 Multi-view images 생성


⚡ Zero123의 input은 single image와 상대적인 camera transformation을 포함

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- Pose estimation



∴ Zero123에 의해 생성된 가까운 4개의 뷰들에 기초한 input 이미지의 elevation angle 측정


- ✓ elevation angle: 해당 이미지에서 특정 지점이나 물체의 상대적인 높이를 나타내는 각도

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 3D reconstruction



※ multi-view posed images를 SDF 기반의 생성형 neural surface reconstruction module에 넣음

- ✓ SDF: 3D 공간에서 각 점까지의 부호 있는 거리 나타내는 함수
- ✓ 해당 방법은 SDF 함수를 사용하여 3D 객체의 표면 추정, 모델 재구성함

※ 단일 feed forward pass로 3D mesh를 재구성하도록 학습 가능한 Cost Volume 기반 neural surface reconstruction 모듈 사용했음

Paper Review

- **One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization**

- Method

- 3D reconstruction

⌘ Cost Volume 기반 neural surface reconstruction 모듈

- ✓ Cost Volume

서로 다른 시점에서 촬영된 두 개의 이미지 비교하여 각 위치에 대한 대응점 찾는 데 필요한 정보를 저장, 관리하는 데 사용되는 데이터 구조

1. 각 이미지 픽셀 위치에서 대응되는 깊이 후보들에 대한 일치도 계산 (각 위치에 대한 모든 가능한 깊이 값에 대한 일치도 나타내는 볼륨)
2. Cost volume은 depth map을 생성하는 데 사용될 수 있음. 가장 낮은 비용을 갖는 깊이 선택하여 가능함

- ✓ Neural Surface Reconstruction

Cost Volume 활용하여 딥러닝 모델 학습. CNN이 사용되며 이 모델은 Cost Volume을 입력으로 받아 3D 공간에서의 표면을 예측하는 데 사용됨

Paper Review

- **One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization**

- **Method**

- 제안된 방법과 다른 시도: Zero123 + NeRF 나 SDF 기반 방법 실험(최적화 기반)



⚡Zero123

- ✓ Input: object의 하나의 RGB image, relative camera transformation
- ✓ Output: diffusion model을 컨트롤해서 변형된 카메라 뷰 조건의 새로운 이미지를 생성

⚡TensorRF

- ✓ single 이미지가 주어지면 3D로 reconstruction 해주는 NeRF 기반 모델

⚡NeuS


- ✓ 특정 지점에서 표면까지의 거리와 방향을 포함하는 함수(SDF) 기반 3D reconstruction 모델

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 제안된 방법과 다른 시도: Zero123 + NeRF 나 SDF 기반 방법 실험(최적화 기반)



☞ View transformation마다 Objaverse dataset으로부터의 100개의 shapes의 PSNR, mask IoU, CLIP 유사도

☞ input relative pose가 크거나 target pose가 일반적이지 않은 위치들에 있을 때, 전체적인 PSNR이 높지 않음을 알 수 있음


- ✓ PSNR이 높을수록 loss가 작고 퀄리티가 높음
- ✓ Input view에서 각도가 커질수록 잘 안 됨

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 제안된 방법과 다른 시도: Zero123 + NeRF 나 SDF 기반 방법 실험(최적화 기반)



⚡ 그러나 mask IoU와 CLIP 유사도는 상대적으로 좋음

- ✓ Zero123가 gt와 시각적으로 유사하고 윤곽이나 경계가 유사한 예측을 생성
- ✓ 그러나 픽셀 수준의 외관이 완전히 동일하지 않을 수 있음

⚡ Source Views 간의 이러한 불일치는 이미 기존의 최적화 기반 방법에 치명적


- ✓ 최적화에 시간이 많이 걸림

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 논문이 제안한 3D reconstruction 방식



※ 일반화 가능한 SDF reconstruction 방법인 SparseNeuS를 기반

※ Input: m개의 포즈 소스 이미지


※ 2D feature 네트워크를 사용하여 m개의 2D feature map을 추출

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 논문이 제안한 3D reconstruction 방식



※ 각 3D voxel을 m 개의 2D feature 평면에 project → m 개의 project된 2D 위치에서 feature의 분산을 가져옴

※ 콘텐츠가 계산되는 3D cost volume을 구축


※ cost volume은 sparse 3D CNN을 사용하여 처리되어 입력 모양의 기본 geometry를 인코딩하는 geometry volume을 얻음

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 논문이 제안한 3D reconstruction 방식



※ 임의 3D 포인트에서 SDF를 예측하기 위해 MLP 네트워크는 3D 좌표와 geometry volume에서 보간된 feature를 입력으로 사용


※ 3D 포인트의 색상을 예측하기 위해 다른 MLP 네트워크는 project된 위치의 2D feature, geometry volume에서 보간된 feature, 소스 이미지의 뷰 방향을 기준으로 한 쿼리 광선의 뷰 방향을 입력으로 사용

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Method

- 논문이 제안한 3D reconstruction 방식



- ※ 네트워크는 각 소스 뷰의 혼합 가중치를 예측하고, 3D 포인트의 색상은 project된 색상의 가중치 합으로 예측
- ※ RGB 및 깊이 렌더링을 위해 두 개의 MLP 네트워크 위에 SDF 기반 렌더링 기술이 적용

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

• Method

- 2-Stage Source View Selection and Ground truth-Prediction Mixed Training

- ※ Zero123 을 freeze, 3D 객체 데이터셋에 대해 학습
- ※ 구형 카메라 모델 사용
- ※ n개의 카메라 포즈의 n개의 ground-truth RGB, depth 이미지 렌더링
- ※ Zero123으로 4개의 near view 예측
- ※ 학습 중 ground-truth pose가 포함된 $4 \times n$ 개의 예측 모두 reconstruction module에 input으로 넣음
- ※ n개의 ground-truth RGB 이미지 뷰 중 하나를 target view로 선택
- ※ 학습 중에 더 나은 supervision을 위해 첫 번째 단계에서 n개의 ground-truth 렌더링 사용 → depth loss 활성화
- ※ Inference 중에는 n개의 gt 렌더링을 zero123의 예측으로 대체 가능함
- ※ texture가 있는 mesh를 추출하려면 marching cube 사용 → SDF field에서 mesh 추출
→ mesh 정점의 색상을 쿼리함
 - ✓ Marching cube: 3차원 공간 내 점에 대한 density → 3D mesh 생성

Paper Review

- **One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization**

- Method

- Camera Pose Estimation

- ※ $4 \times n$ 개의 소스 이미지에 대한 카메라 포즈가 필요
- ※ 표준 구면 좌표계 (θ, ϕ, γ) 에서 카메라를 parameterize함
- ※ 카메라마다 구면 좌표를 가지고 있는데 적어도 하나의 카메라의 고도각이 절대값이어야 다른 값들을 알 수가 있음
- ※ 입력 이미지의 고도각을 추론하기 위한 고도각 추정 모듈을 제안 (elevation estimation) → 이미지, 카메라 포즈 간 reprojection loss 가장 적은 고도각 선택

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization


▪ Experiments

- Dataset: Objaverse-LVIS
- 3D models: 46k
- 카테고리 수: 1,156
- 방법:
 - ※ Zero123 을 freeze하여 학습
 - ※ 구의 표면에 위치한 camera poses를 선택함으로써 각각의 input image에 대해 8개의 이미지들을 생성함
 - ※ 각 8개의 views에 대해 4개의 local images(10도 간격) 를 생성
- gt RGB와 depth images를 render하기 위해 BlenderProc를 사용
 - ※ BlenderProc: 사실적인 렌더링을 위한 프로시저 블렌더 파이프라인
- Background 이미지들 때문에 SAM과 bounding-box prompts 를 사용
 - ※ SAM: Segment Anything
 - ✓ Prompt Encoder + Image Encoder + lightweight mask Encoder 구조로 text로 이미지 Segment가 되게 하는 모델(<https://arxiv.org/pdf/2304.02643v1.pdf>)

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

- Experiments: 다른 3D diffusion model 과의 정성적 비교



Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

- Experiments: 야누스 문제, 환각 문제 해결



- 기존 diffusion model의 문제 원인

- input 과 계속 가깝게 하려고 학습하다 보니 피규어 같은 경우 앞 뒤가 똑같이 구현되는 경우가 생김
→ 얼굴이 2개 → 야누스 문제

- One-2-3-45

- View Conditioned 2D diffusion model을 활용하여 본질적으로 3D 일관성을 향상시킴

Paper Review

• One-2-3-45: Any Single Image to 3D Mesh in 45 Seconds without Per-Shape Optimization

▪ Experiments: F-Score

	Prior Source	F-Score			CLIP Similarity			Time
		GSO	Obj.	avg.	GSO	Obj.	avg.	
Point-E [52]	internal	81.0	81.0	81.0	74.3	78.5	76.4	78s
Shap-E [29]	3D data	<u>83.4</u>	<u>81.2</u>	<u>82.3</u>	79.6	82.1	80.9	27s
Zero123+SD [36]	2D diffusion models	75.1	69.9	72.5	71.0	72.7	71.9	~15min
RealFusion [43]		66.7	59.3	63.0	69.3	69.5	69.4	~90min
3DFuse [68]		60.7	60.2	60.4	71.4	74.0	72.7	~30min
Ours		84.0	83.1	83.5	<u>76.4</u>	<u>79.7</u>	<u>78.1</u>	45s

- F-Score:

※ 다른 모델들에 비해 가장 좋은 성능 보임

- CLIP 유사도:

※ Geometry 유사도보다는 색상 유사도에 민감한 편이라 Shap-E에 비해 낮은 수치를 보임

- Time:

※ One-2-3-45는 약 5초 만에 3D mesh를 재구성

※ 나머지 시간은 주로 A100 GPU에서 이미지당 약 1초가 걸리는 Zero123 예측에 사용됨


LRM: Large reconstruction model for single image to 3D

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Overview

- Transformer + NeRF



Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Intro

- 임의 개체의 single 이미지 → 3D 이미지
- 기존의 방법들
 - ※ 3D geometry의 ambiguity 로 인해 특정 class 범주 내에서 잘 수행되었음
 - ※ 형태별 NeRF 최적화 → 일관된 geometry 구성
- 기존 방법들의 한계
 - ※ 비현실적임
 - ※ pretrained model을 사용해왔음 → 새로운 type의 데이터의 경우 3D image 변환 불가능
 - ※ 생성 모델, CLIP 같은 multi modal model에 의존

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Intro


- 논문이 제안하는 것
 - ⌘ Transformer Encoder-Decoder Architecture
 - ⌘ Image Encoder: DINO
 - ⌘ Decoder: Image-triplane Transformer Decoder
 - ⌘ cross attention, self attention → 공간적으로 구조화된 3차원 토큰 간 관계 modeling
 - ⌘ MLP 사용 → 각 점의 삼면 특성 디코딩 → 색상, 밀도 얻음 → 볼륨 렌더링 수행 → 이미지 렌더링
- Data driven 방식, pretrained multi modal, diffusion model에 의존하지 않음
- 과도한 3D 인식 regularization, fine-tuning 없이 새로운 뷰에서 렌더링된 이미지, 실제 이미지 간 차이 최소화하며 학습

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- Method

- Encoder: DINO (ViT/B-16)



⌘ input: RGB 이미지

⌘ 패치별 feature token으로 인코딩

⌘ 이미지에서 두드러진 구조, 질감에 대해 해석 가능한 attention을 학습하는 self-diffusion model DINO 사용


⌘ DINO > ResNet, CLIP

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Method

- Decoder: Image-To-Triplane Decoder



※ 2D image feature, camera feature → 학습 가능한 임베딩 space에 투영

※ cross-attention: image features, camera features 간 관계 모델링

※ Camera Features


- ✓ 2D → 3D projection 위해서는 camera features를 이미지와 잘 매칭시켜야 함
- ✓ intrinsic parameters, extrinsic parameters
- ✓ 주요 layer 앞단에서 modulation 연산

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Method

- Decoder: Image-To-Triplane Decoder



⚡ Triplane Representation


- ✓ 3차원 Transformer Decoder에서 각 레이어마다 cross-attention, modulation 통해서 2d 이미지 feature를 3D 이미지 feature로 변환
- ✓ image feature와 camera feature를 사용하는 이유
 - camera feature: 카메라 전체 모양, 방향, 왜곡 제어
 - image feature: 색상 정보, 기하학적 정보
 - 두 정보를 통해 3D projection을 하기 위함

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Method

- Decoder: Image-To-Triplane Decoder



⚡ Modulation with Camera features

✓ DiT로부터 영감을 받음

• DiT = **Transformer** + Diffusion + **AdaLN**

⚡ ModLN

$$\gamma, \beta = \text{MLP}^{\text{mod}}(\tilde{c})$$

$$\text{ModLN}_c(\mathbf{f}_j) = \text{LN}(\mathbf{f}_j) \cdot (1 + \gamma) + \beta$$

✓ camera features를 LayerNorm, MLP 연산을 통해 output 을 γ, β 로 받음

✓ r은 scale, b는 shift factor

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- Method

- Decoder: Image-To-Triplane Decoder

- ⚙️ ModLN


- ✓ AdaLN의 방식 + Modulation
- ✓ AdaLN (Adaptive Layer Normalization)
 - DiT 같은 이미지 생성 모델에서 사용하는 Normalization 기법
 - 각 채널에 독립적으로 학습 가능한 scale, shift parameter 도입
 - 입력 데이터의 특성에 따라 동적으로 조절 가능
 - 생성된 이미지의 품질과 안정성 향상시킴

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- Method

- Decoder: Triplane-NeRF



3차원 representation T 에서 query된 point features로부터의 RGB, density를 예측

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- Method

- Training Objectives

$$\mathcal{L}_{\text{recon}}(\mathbf{x}) = \frac{1}{V} \sum_{v=1}^V (\mathcal{L}_{\text{MSE}}(\hat{\mathbf{x}}_v, \mathbf{x}_v^{GT}) + \lambda \mathcal{L}_{\text{LPIPS}}(\hat{\mathbf{x}}_v, \mathbf{x}_v^{GT}))$$

※ $\hat{\mathbf{x}}_v$: rendering 된 뷰들

※ \mathbf{x}_v^{GT} : input view들과 side view들

※ pixel 간의 L2 Loss + LPIPS Loss

✓ LPIPS Loss: 인지된 이미지 패치 유사도에 대한 Metric

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- Experiments

- Training Objectives

- ⌘ Dataset: Objaverse, MVImgNet (video)

- ⌘ GPU: batch 1024, 128개의 A100

- ⌘ epoch: 30

- ⌘ 학습시간: 3일

- ⌘ optimizer: AdamW

- ⌘ cosine scheduler 사용

- ⌘ learning rate: 4×10^{-4}

- Inference


- ⌘ GPU: A100

- ⌘ Camera feature: Objaverse 로 학습할 때의 feature

- ⌘ input single image → mesh (5초 미만)


Paper Review

- LRM: Large reconstruction model for single image to 3D
 - Experiments




Paper Review

- LRM: Large reconstruction model for single image to 3D
 - Experiments



Paper Review

- LRM: Large reconstruction model for single image to 3D
 - Experiments




- One-2-3-45와의 비교

※LRM이 훨씬 더 선명한 디테일, 일관된 표면 생성함

Paper Review

• LRM: Large reconstruction model for single image to 3D

▪ Limitation



- 폐색된 영역에 대해 흐릿한 텍스처 생성하는 경향
 - ∴원인: single image → 3D 자체가 확률론으로의 접근
 - ✓ 평균에 가까운 영역들만 잘 표현하고 그렇지 않을 경우 생성이 잘 안 됨
- 추론 시간 동안 고정된 camera intrinsic, extrinsic parameter set을 테스트 이미지에 할당함
 - ∴카메라 매개변수가 실제와 일치가 잘 되지 않게 됨 → 왜곡된 형태 재구성
- 배경이 없는 사물의 이미지만을 다룸
- 빛나는 금속, 세라믹 같은 뷰 의존적 외관 충실하게 재구성 못함
 - ∴NeRF의 뷰 종속 모델링을 생략함 (기존에 NeRF는 이것 잘 해서 정반사되는 사물들도 잘 표현했었음)

Paper Review

- **LRM: Large reconstruction model for single image to 3D**

- **Limitation**

- 개인적으로 생각했던 추가적인 문제점:

- ⚡ input image와 camera feature modulation

- ✓ input 이미지, 카메라 feature 간 연산으로 구도가 바뀌었을 때의 이미지는 잘 rendering됨
- ✓ 그러나 광원의 위치에 따른 색상 변화가 학습되지 않아서 input image의 색상과 거의 똑같이 이미지 색상이 결정됨
 - 그로 인해 자세한 feature들이 잘 반영되지 않음

Reference

- One-2-3-45 논문 리뷰
 - <https://kimjy99.github.io/%EB%85%BC%EB%AC%B8%EB%A6%AC%EB%B7%B0/one-2-3-45/>
- One-2-3-45 논문
 - <https://arxiv.org/pdf/2306.16928v1.pdf>
- LRM 논문
 - <https://arxiv.org/pdf/2311.04400.pdf>
- Cost Volume 관련
 - <https://velog.io/@chunjakim/Cost-Volume>
- Marching Cube 관련
 - <https://xoft.tistory.com/47>

감사합니다 😊