



# 面向自动驾驶仿真的动态街景重建技术

---



彭思达

浙江大学CAD&CG全国重点实验室

## 基于路采数据的动态街景高精建模与重渲染



路采数据



动态三维街景

# 自动驾驶仿真的价值

## 自动驾驶训练

### Imitation Learning


支撑数据增强，实现车型泛化、长尾训练等

### Reinforcement Learning


在关键场景上大量采样训练，提升安全性

收集仿真结果

## 自动驾驶仿真




# 三维重建在自动驾驶仿真中的位置





## 对于自动驾驶的价值：短期

- 车厂面临的问题：在小轿车训练的感知模型，无法泛化到其他车型。
- 目标：采集一次数据，实现多种车型的训练。



# 对于自动驾驶的价值：中期


- 车厂面临的问题：长尾数据难以收集。
- 目标：通过行车记录仪采集的视频构建自动驾驶训练数据。






# 对于自动驾驶的价值：长期

- 车厂面临的问题：真实环境下训练和测试成本高。
- 目标：构建虚拟环境训练和测试自动驾驶系统。




# 自动驾驶仿真中的动态街景重建需要哪些能力



**需求：依赖动态街景重建技术提供高质量街景资产**



# 自动驾驶仿真中的动态街景重建需要哪些能力



# 实验室已有研究积累

## 自动驾驶仿真

需求：依赖动态街景重建技术提供高质量街景资产

关键问题1：  
提升渲染质量

相关工作：  
StreetGaussians、  
StreetCrafter、  
FreeTimeGS等

关键问题2：  
提升解耦能力

相关工作：  
StreetGaussians、  
Split4D

关键问题3：  
降低输入要求

相关工作：  
MatchAnything、  
D-SfM、Murre等

关键问题4：  
提升重建速度

相关工作：  
PromptDA、  
ADGaussian

**论文发表：**在CVPR、ICCV、ECCV等发表多篇Oral、Highlight论文，谷歌引用量数百次。

**代码开源：**论文GitHub stars累积数千次，数次被集成进知名算法库kornia和transformers。

**竞赛获奖：**获得谷歌举办的全球三维重建挑战赛冠军。

# 关键问题1: 提升仿真质量





# 关键问题1.1: 小视角渲染质量

原先方法存在的问题: 小视角渲染质量低



Block-NeRF: Scalable Large Scene Neural View Synthesis. CVPR 2022.

# 关键问题1.1: 小视角渲染质量

## 为什么这个问题重要


- 小视角可以满足自动驾驶仿真的短期价值 -> 车型泛化能力。
- 小视角质量先能做好，才有机会搞大视角渲染。

# 关键问题1.1: 小视角渲染质量

## 已有技术范式


范式1:  
基于Feature Grids的场景表征

代表性工作: UniSim



范式2:  
基于3D Gaussians的场景表征

代表性工作: Street Gaussians




实验室成果



# Street Gaussians (实验室成果)

- 基于**组合式的三维高斯**表示动态三维场景





# 与EmerNeRF的可视化比较



# 更多的渲染结果





# 关键问题1.2: 大视角渲染质量

## 原先方法存在的问题



相邻视角



变道视角

## 关键问题1.2: 大视角渲染质量

### 为什么这个问题重要

- 大视角渲染对自动驾驶仿真的短、中、长期目标都很有价值。
- 大视角渲染是闭环仿真的必要条件。




# 关键问题1.2: 大视角渲染质量

## 已有技术范式


范式1:  
基于逐场景优化

代表性工作: GaussianPro




范式2:  
引入SDS Loss约束

代表性工作: VEGS



范式3:  
Video model生成新视角


代表性工作: StreetCrafter



实验室成果

# StreetCrafter (实验室成果)

利用雷达点云控制视频生成模型输出新视角的图片，作为StreetGS的监督。





# 实验结果：变车道新视角渲染



Ours-G



Street Gaussians



# 实验结果：变车道新视角渲染



Ours-G



Street Gaussians

## 关键问题1.3: 非刚性建模能力

原先方法存在的问题：无法高质量表征非刚性运动物体。



Real-time Photorealistic Dynamic Scene Representation and Rendering with 4D Gaussian Splatting. ICLR 2024.

## 关键问题1.3: 非刚性建模能力

### 为什么这个问题重要

- 日常街道场景中，除了汽车，还有很多非刚性物体：行人、骑行者、动态灯光等。
- 扩展场景的丰富性必须建模好这些非刚性物体。




# 关键问题1.3: 非刚性建模能力

## 已有技术范式

范式1:  
基于Neural Scene Graph

代表性工作: OmniRe



范式2:  
基于native 4DGS

代表性工作: FreeTimeGS



# FreeTimeGS (实验室成果)


不再区分前后背景，使用四维高斯建模整个动态场景。



静态背景




动态前景



动态光照

基于四维高斯的统一建模

# FreeTimeGS: 基于四维高斯的建模动态场景




三维高斯

+

随时间的运动

+


时序窗口





# 遇到的难点：如何建模快速运动的物体


已有四维高斯使用[R; T]建模motion，难以优化，导致复杂运动物体效果不好。



# 解决思路：基于线性运动的四维高斯

在任意时刻任意位置定义高斯，为每个高斯赋予线性运动，用4DSH建模外观。

实验发现，FreeTimeGS可以很好地建模复杂的运动物体。



# 实验结果






# 实验结果



路边的人群



变换的灯光

# 实验结果



## 关键问题1.4: 雷达仿真能力

### 为什么这个问题重要

- 一些自动驾驶算法的输入包括雷达。
- 为了在闭环仿真器中训练这些自驾算法，必须实现雷达仿真。




# 关键问题1.4: 雷达仿真能力

## 已有技术范式


范式1:  
基于Rasterization Rendering

代表性工作: GS-LiDAR




范式2:  
基于Ray Tracing Rendering

代表性工作: LiDAR-RT




# LiDAR-RT (实验室成果)

- Ray Tracing可以支持雷达柱面成像方式







# 如何实现Ray Tracing

1. 构建加速结构以计算Ray Interaction。
2. 对于Intersection points, 计算GS的值, 再做Volume Rendering。






# Novel view LiDAR point clouds




# Novel view LiDAR range images


Depth




Intensity



Depth




Intensity






# Qualitative comparisons on Waymo dataset


Ground Truth



LiDAR-NeRF




LiDAR4D



DyNFL



Ours





## 关键问题2: 提升解耦能力

### 自动驾驶仿真



**需求：依赖动态街景重建技术提供高质量街景资产**

关键问题1:  
提升渲染质量

关键问题2:  
提升解耦能力


关键问题3:  
降低输入要求

关键问题4:  
提升重建速度

## 关键问题2: 提升解耦能力

### 为什么这个问题重要

- 世界模型由**静态背景**和**可互动前景物体**组成。
- 因此，输入路采视频，我们需要将背景和前景分解开来，让前景物体可以自由移动或被编辑。



# 关键问题2: 提升解耦能力

## 已有技术范式


范式1:  
基于物体三维框

代表性工作: StreetGaussians



范式2:  
基于自监督

代表性工作: EmerNeRF



范式3:  
基于逐帧实例分割


代表性工作: Split4D





# 范式1：Street Gaussians（实验室成果）

- 基于**组合式的三维高斯**表示动态三维场景



# StreetGaussian的解耦效果

Rendering




Decomposition



# StreetGaussian的问题


- 日常路采数据中存在大量动态物体。难以准确标注全部物体的三维框，且标注成本高。





## 范式2: EmerNeRF

- 分别定义Dynamic Field和Static Field, 再组合为最终图片。




## 仍存在的问题：解耦不够准确



## 范式3: Split4D (实验室成果)


- 基于额外标注的方法面临的问题：
  - 输入的标注大多是三维框、Video segmentation, 标注成本昂贵。
  - 如果采取自动化标注, 很难准确。





# Split4D解决问题的思路

- 只使用**逐帧Segmentation**作为额外输入的标注：
  - 即使采取自动化标注，大部分情况下也足够准确。






# 使用逐帧Segmentation面临的问题

- 如何将2D segmentation转变为4D segmentation?



# 如何将2D segmentation转变为4D segmentation?

- 解决问题的思路:
  - 借助FreeTimeGS的Short-range 3D correspondence.
  - 3D correspondence + 2D segmentation = 4D segmentation.





## 具体做法（1）：构建Freetime FeatureGS


Freetime FeatureGS：在FreeTimeGS上定义可学习特征。



## 具体做法 (2) : 对特征做contrastive loss

1. 渲染Freetime FeatureGS得到特征图。
2. 在特征图上采样像素点。


属于同一个mask的特征相互拉近，否则相互变远。





## 具体做法 (3) : 利用3D correspondences传播特征

因为不同时刻的Gaussians相关联，因此可以得到时序一致的特征。





# 实验结果：整体重建效果



# 实验结果：前后背景分离





# 实验结果：场景编辑





# 实验结果：整体重建效果



# 实验结果：场景编辑





# 实验结果：通用场景编辑






## 实验结果：通用场景编辑




# 关键问题3: 降低输入要求



# 关键问题3.1: 无物体三维框输入

## 为什么这个问题重要

- 日常路采数据中存在大量动态物体。难以准确标注全部物体的三维框，且标注成本高。






# 关键问题3.1: 无物体三维框输入

## 已有技术范式

范式1:  
基于Dynamic NeRF

代表性工作: EmerNeRF



范式2:  
基于native 4DGS

代表性工作: FreeTimeGS



## 关键问题3.2: 无自车位姿输入

### 为什么这个问题重要

- 行车记录仪采集的视频，不是由数据采集车传回，而是由量产车辆传回，不带有相机位姿高精标注设备。要重建行车记录仪视频，必须要有自车位姿。
- 即使是数据采集车，有时候传回的自车位姿也不够准确。




## 关键问题3.2: 无自车位姿输入

### 已有技术范式


范式1:  
**Structure from Motion**

代表性工作: COLMAP



范式2:  
**SLAM**

代表性工作: MegaSaM




范式3:  
**Learning-based Methods**

代表性工作: VGGT





- 使用Transformer网络直接回归camera poses和depth maps。



## 关键问题3.3: 输入图像质量低

### 为什么这个问题重要

- 即使是数据采集车传回的数据，也经常面临各种图像质量问题，包括：炫光、动态模糊、黑夜、镜头有污渍。
- 环视相机之间经常存在色调不一致的情况。




# 关键问题3.3: 输入图像质量低

## 常见低质量图像情况

### 图像模糊

相关工作: DeblurGS




### 多视角光照不一致

相关工作: BilaRF




### 黑夜炫光

相关工作: RawNeRF



### 摄像头在前车窗内

相关工作: DC-Gaussian



核心解决思路: 在渲染过程中显式建模 Image Degradation Model



## 关键问题3.4: 无雷达输入

### 为什么这个问题重要


- 行车记录仪采集的视频，不是由数据采集车传回，而是由量产车辆传回，不带有高精度激光雷达。
- 已有重建算法通常依赖激光雷达提供三维高斯初始位置和几何约束。

## 关键问题3.4: 无雷达输入

已有技术范式: 额外估计场景几何以初始化三维高斯

范式1:  
**SLAM**

代表性工作: MegaSaM



范式2:  
**Learning-based MVS**

代表性工作: VGGT



## 关键问题4: 提升重建速度





## 关键问题4: 提升重建速度

3DGS存在的问题: 即使是小场景, 重建也需5分钟



**Vanilla 3DGS**  
[Kerbl et al. 2023]

SSIM 0.98  
PSNR 33.36  
LPIPS 0.018  
Training 6:21



**AdR-Gaussian**  
[Wang et al. 2024]

SSIM 0.91  
PSNR 25.83  
LPIPS 0.083  
Training 4:11



**EAGLES**  
[Girish et al. 2025]

SSIM 0.96  
PSNR 29.03  
LPIPS 0.033  
Training 11:01

## 关键问题4: 提升重建速度

### 为什么这个问题重要


- 大多数车厂采集了几百万到几十亿公里的街道数据。
- 如果每公里重建需要2小时，那么所需时间成本和算力成本过大。

# 关键问题4: 提升重建速度

## 已有技术范式


范式1:  
二阶优化器

代表性工作: 3DGS2




范式2:  
基于学习的优化器

代表性工作: G3R



范式3:  
前向推理模型

代表性工作: PromptDA





# PromptDA (实验室成果)



- 根据Input LiDAR输出准确的绝对深度



24x24 points




**4K RGB &  
Low-res Metric Depth**



**4K Depth**

# 具体做法


## • 如何提示深度基础模型？



|                                          | ARKitScenes |          | ScanNet++ |        |           |
|------------------------------------------|-------------|----------|-----------|--------|-----------|
|                                          | L1 ↓        | AbsRel ↓ | Acc ↓     | Comp ↓ | F-Score ↑ |
| (a) Ours <sub>syn</sub> (synthetic data) | 0.0163      | 0.0142   | 0.0746    | 0.0666 | 0.7307    |
| (b) w/o prompting                        | 0.0605      | 0.0505   | 0.0923    | 0.0801 | 0.5696    |
| (c) w/o foundation model                 | 0.0194      | 0.0169   | 0.0774    | 0.0713 | 0.7077    |
| (d) AdaLN prompting                      | 0.0197      | 0.0165   | 0.0795    | 0.0725 | 0.6943    |
| (e) Cross-atten. prompting               | 0.0523      | 0.0443   | 0.0932    | 0.0819 | 0.5595    |
| (f) Controlnet prompting                 | 0.0239      | 0.0206   | 0.0785    | 0.0726 | 0.6899    |

# 实验结果

## • 厘米级误差的度量(Metric)深度估计





# 实验结果


- 大幅提升深度基础模型重建效果




Reference




Ours




Depth Any v2.




Metric 3D v2



ARKit Depth



Marigold\_align



Depth Any v2.\_align



Metric 3D v2\_align




# 实验结果

- 提示机制可泛化至Realsense L515、车载LiDAR等常用传感器




Image




Output




L515



Image





Output



Vehicle LiDAR

# 自动驾驶应用


- 基于街景雷达的室外大场景重建





# ADGaussian (实验室成果)

- PromptDA预测高斯位置, Gaussian Head预测高斯外观



# ADGaussian的效果：换车道



Ours

DepthSplat

MVSplat



# ADGaussian的效果：时序预测

Ours



DepthSplat






# 机器人应用

- 通用机器人抓取，抓取成功率超越Image及LiDAR作为输入




# 三维扫描应用

- PromptDA被集成进三维扫描App KIRI Engine




# 总结：自动驾驶仿真中的动态街景重建需要哪些能力





# 总结：三维重建在自动驾驶仿真中的位置



## 自动驾驶仿真

需求：依赖动态街景重建技术提供高质量街景资产

关键问题1：  
提升渲染质量

相关工作：  
StreetGaussians、  
StreetCrafter、  
FreeTimeGS等

关键问题2：  
提升解耦能力

相关工作：  
StreetGaussians、  
Split4D

关键问题3：  
降低输入要求

相关工作：  
MatchAnything、  
D-SfM、Murre等

关键问题4：  
提升重建速度

相关工作：  
PromptDA、  
ADGaussian

**论文发表：**在CVPR、ICCV、ECCV等发表多篇Oral、Highlight论文，谷歌引用量数百次。

**代码开源：**论文GitHub stars累积数千次，数次被集成进知名算法库kornia和transformers。


**竞赛获奖：**获得谷歌举办的全球三维重建挑战赛冠军。

# 自动驾驶仿真，优先级靠前的5个问题

## 基于动态三维重建的自动驾驶闭环仿真



路采数据



动态三维街景

问题1:  
闭环仿真强化  
学习效果

问题2:  
大视角渲染  
质量

问题3:  
前后景解耦  
质量

问题4:  
动态场景表征  
重建速度

问题5:  
街道级  
自车位姿标定





# 谢谢!

---

彭思达

浙江大学CAD&CG全国重点实验室