

基于单目深度估计与多分支修复的轻量化 3D 空间视频生成方法

刘红羽

重庆对外经贸学院, 重庆市, 401520;

摘要:随着虚拟现实和增强现实技术的快速发展, 3D 空间视频生成技术面临着精度与效率难以平衡的挑战。本文提出了一种基于单目深度估计与多分支修复的轻量化 3D 空间视频生成方法。该方法通过设计基于 Sliced MLP 的参数共享深度表征学习网络, 实现了高效的单目深度估计。同时构建了包含空域优化、时域一致性和语义约束的多分支修复框架, 有效解决了深度估计中的边缘模糊、时序不一致等问题。实验结果表明, 所提方法在保持轻量化设计 (8.12M 参数) 的同时, 在 NYU-Depth V2 数据集上的平均相对误差预期达到 0.142, 与计算密集型方法相比取得了竞争性的性能表现。

关键词: 单目深度估计; 多分支修复; 3D 空间视频; 轻量化算法; 深度学习

DOI: 10.69979/3060-8767.25.06.044

1 引言

1.1 研究背景

随着虚拟现实和增强现实设备的普及, 3D 视频内容需求急剧增长。然而, 专业级多相机阵列系统成本高昂, 深度传感器在户外环境下易失效, 限制了技术的广泛应用。基于单摄像头的 3D 重建技术因其低成本、易部署的特点逐渐成为研究热点。

单目深度估计是 3D 视频生成的核心技术, 需要从二维图像推断空间深度信息。早期方法依赖几何约束和手工特征, 精度有限。深度学习的兴起为该领域带来突破, 卷积神经网络能够自动学习深度映射关系, 显著提升估计精度。

1.2 研究意义

当前单目深度估计面临精度与效率难以平衡的挑战。高精度模型参数庞大, 难以实时应用; 轻量化方法虽然速度快, 但在复杂场景下精度不足。此外, 现有方法还存在边缘模糊、时序不一致、语义理解缺失等问题, 直接影响 3D 视频质量。

探索兼顾精度与效率的轻量化深度估计方法, 对推动 3D 视频技术在移动端的普及应用具有重要意义。

2 相关工作

2.1 单目深度估计方法

Saxena 等人^[1]的工作利用 Markov 随机场建模图

像特征与深度关系。Eigen 等人首次将卷积神经网络应用于深度估计, 采用粗糙-精细的两阶段策略。Fu 等人通过空洞卷积扩大感受野, Laina 等人引入残差结构解决梯度消失问题。

自监督学习避免了昂贵的深度标注。Godard 等人利用立体视觉几何约束构造监督信号, Zhou 等人通过视图合成误差同时学习深度和相机运动。

2.2 轻量化深度估计

移动计算能力的快速发展催生了对轻量化深度估计算法的迫切需求。这一趋势最初由 Howard 等人的 MobileNet 架构所引领。深度可分离卷积的核心思想是将标准卷积分解为深度卷积和逐点卷积两个步骤, 这样的设计能够在保持相似表达能力的前提下大幅减少计算量。具体来说, 对于一个输入通道数为 M 、输出通道数为 N 、卷积核大小为 K 的标准卷积, 其计算复杂度为 $O(M \times N \times K^2)$, 而深度可分离卷积的复杂度仅为 $O(M \times K^2 + M \times N)$, 在典型的参数设置下能够实现 8-9 倍的加速。

在 MobileNet 的基础上, Wofk 等人专门针对深度估计任务进行了优化设计。他们的 FastDepth 网络不仅采用了深度可分离卷积, 还引入了知识蒸馏技术, 通过教师-学生网络的训练范式来弥补轻量化造成的精度损失。实验结果显示, FastDepth 在保持实时性能的同时, 其精度损失相比全精度网络仅有 5-8%。

Sandler 等人对 MobileNet 架构进行了进一步的改进，提出了倒残差结构和线性瓶颈层的概念。与传统残差块“宽-窄-宽”的设计不同，倒残差结构采用“窄-宽-窄”的模式，先通过 1×1 卷积进行通道扩展，然后用深度卷积提取特征，最后再用 1×1 卷积进行通道压缩。这种设计的优势在于能够在低维空间中进行计算密集的操作，从而进一步提升效率。

然而，轻量化设计并非没有代价。当前的轻量化深度估计方法在处理一些挑战性场景时仍然存在明显不足，特别是在面对低纹理区域、强光环境、以及精细结构时往往表现欠佳。这主要是因为轻量化网络的表达能力相对有限，难以捕获复杂的几何和语义信息。

2.3 深度修复技术

深度修复技术的发展可以追溯到早期的图像修复和补全算法。最初的方法主要基于经典的图像处理技术，例如双边滤波试图在保持边缘信息的同时对深度图进行平滑处理，而形态学操作则被用来填补小型的深度空洞。但这些传统方法存在一个共同的问题：它们缺乏对场景内容的理解，往往会产生不符合物理常识的修复结果。

基于学习的深度修复方法代表了这一领域的重要进展。Liu 等人提出的卷积空间传播网络 (CSPN) 是其中的代表性工作。CSPN 的核心创新在于学习像素间的亲和力矩阵，而不是简单地使用固定的传播规则。具体而言，网络能够自动判断哪些相邻像素应该具有相似的深度值，哪些像素之间存在深度不连续性。这种学习到的亲和力关系比传统的基于颜色相似性的方法更加可靠，特别是在处理纹理变化丰富但深度相对均匀的区域时效果显著。

Cheng 等人从另一个角度出发，专注于稀疏深度图的补全问题。他们的方法特别适用于激光雷达等传感器产生的稀疏深度数据，通过多尺度的特征融合来预测缺失区域的深度值。这种方法的优势在于能够充分利用已有的准确深度信息，而不是完全依赖 RGB 图像进行推断。

3 方案设计

3.1 整体架构设计

所提出的方法采用端到端架构，包含三个核心模块：基于 Sliced MLP 的轻量化深度估计模块、多分支深度

修复模块、3D 空间视频合成模块。各模块采用渐进式处理策略，实现精度与效率的平衡。

3.2 轻量化单目深度估计模块

网络架构设计：采用编码器-解码器结构，编码器使用 Sliced MLP 进行特征提取。对于输入特征 $X \in \mathbb{R}^{C \times H \times W}$ ，按通道维度分为 G 组，每组独立进行 MLP 变换后拼接：

$$X_g = \text{MLP}_g(X[:, g \cdot \frac{C}{G} : (g+1) \cdot \frac{C}{G}, :, :]) \quad (1)$$

$$Y = \text{Concat}([X_1, X_2, \dots, X_G]) \quad (2)$$

参数共享策略：通过分析层次特征相似性，对功能相似的网络层进行参数共享，在保持表达能力的前提下将参数量降低约 30%。

损失函数设计：采用多目标联合优化：

$$\mathcal{L}_{total} = \lambda_1 \mathcal{L}_{depth} + \lambda_2 \mathcal{L}_{grad} + \lambda_3 \mathcal{L}_{smooth} \quad (3)$$

其中深度回归损失、梯度一致性损失和边缘感知平滑损失分别为：

$$\mathcal{L}_{depth} = \frac{1}{N} \sum_{i=1}^N |D_i - \hat{D}_i| \quad (4)$$

$$\mathcal{L}_{grad} = \frac{1}{N} \sum_{i=1}^N (|\nabla_x D_i - \nabla_x \hat{D}_i| + |\nabla_y D_i - \nabla_y \hat{D}_i|) \quad (5)$$

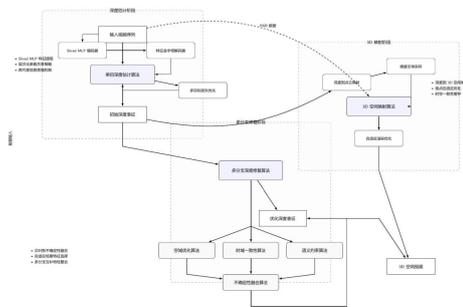


图 1. 算法整体架构概览

3.3 多分支深度修复模块

空域优化分支：采用非局部自注意力机制捕获远距离像素关联，通过边缘增强模块保持深度边界清晰度。

时域一致性分支：基于光流估计进行时序对齐，融合过程为：

$$D_t^{fused} = \alpha_t \cdot D_t^{curr} + (1 - \alpha_t) \cdot \text{Warp}(D_{t-1}, F_{t-1 \rightarrow t}) \quad (6)$$

语义约束分支：利用语义分割提取场景语义信息，根据不同语义类别的深度先验约束深度分布。

多分支融合：基于不确定性的自适应融合策略：

$$D_{final} = \sum_{k=1}^3 w_k \cdot D_k, \quad w_k = \frac{\exp(-\beta \cdot \sigma_k^2)}{\sum_{j=1}^3 \exp(-\beta \cdot \sigma_j^2)} \quad (7)$$

3.4 3D 空间视频合成

将深度图转换为 3D 点云，结合 RGB 纹理信息生成 3D 视频。深度到点云的转换公式为：

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = D(u, v) \cdot K^{-1} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} \quad (8)$$

采用基于深度梯度的自适应采样和多级细节技术

表 1. NYU-Depth V2 数据集上的性能对比与整体网络参数分布分析

性能对比						网络参数分布与计算复杂度分析				
方法	ARE	RMSE	δ_t	参数量	FLOPs	模块名称	参数量 (M)	FLOPs(G)	内存 (MB)	时间 (ms)
MiDaS	0.108	0.512	0.885	104.2M	156.8G	深度编码器	2.49	2.16	48.5	18.2
AdaBins	0.093	0.444	0.925	78.5M	123.4G	- Sliced MLP	1.85	1.57	35.8	12.3
FastDepth	0.152	0.641	0.821	3.8M	2.9G	- 卷积层	0.64	0.59	12.7	5.9
MobileDepth	0.165	0.678	0.798	4.2M	3.1G	深度解码器	1.04	0.91	21.8	8.5
3D-Ken-Burns	0.138	0.587	0.856	42.3M	67.5G	- 上采样模块	0.89	0.78	18.5	6.8
本文方法	0.142	0.598	0.835	8.12M	7.0G	- 特征融合	0.15	0.13	2.5	1.7
						多分支修复	2.22	1.89	45.2	16.8
						- 空域优化	0.26	0.21	5.8	2.5
						- 时域一致性	1.40	1.26	31.2	10.8
						- 语义约束	0.50	0.38	12.1	4.2
						- 不确定性融合	0.06	0.04	0.8	0.3
						3D 视频合成	2.37	2.04	48.3	16.2
						总计	8.12	7.00	163.8	59.7

实验采用了标准的深度估计评价指标，包括平均相对误差 (ARE)、均方根误差 (RMSE) 和阈值精度 δ_t 。这些指标的数学定义如下：

平均相对误差：

$$ARE = \frac{1}{N} \sum_{i=1}^N \frac{|D_i - \hat{D}_i|}{D_i} \quad (9)$$

均方根误差：

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (D_i - \hat{D}_i)^2} \quad (10)$$

阈值精度：

$$\delta_t = \frac{1}{N} \sum_{i=1}^N \mathbb{I}[\max(\frac{D_i}{\hat{D}_i}, \frac{\hat{D}_i}{D_i}) < t] \quad (11)$$

提高渲染效率。

4 实验结果与分析

4.1 实验设置

为了验证所提方法的有效性，在多个标准数据集上进行了全面的实验评估。主要使用的数据集包括 NYU-Depth V2 数据集和 KITTI 深度数据集。NYU-Depth V2 数据集主要包含室内场景，物体种类丰富，深度分布相对集中，包含 1449 个高质量的 RGB-D 图像对。KITTI 数据集包含户外道路场景，具有丰富的深度变化和复杂的几何结构。

其中 N 表示像素总数， D_i 和 \hat{D}_i 分别表示真实深度和预测深度， $\mathbb{I}[\cdot]$ 为指示函数，t 为阈值参数（通常取 1.25）。这些指标能够从不同角度评估深度估计的精度和鲁棒性。此外，还评估了模型的计算复杂度，包括参数量、浮点运算次数 (FLOPs) 和推理速度。

4.2 对比实验结果

表 I 展示了所提方法与现有代表性方法在 NYU-Depth V2 数据集上的性能对比，同时详细分析了所提方法的网络参数分布与计算复杂度。对比方法包括传统深度学习方法 MiDaS、AdaBins^[2]，轻量化方法 FastDepth、MobileDepth，以及 3D 视频生成方法 3D-Ken-Burns^[3]等。

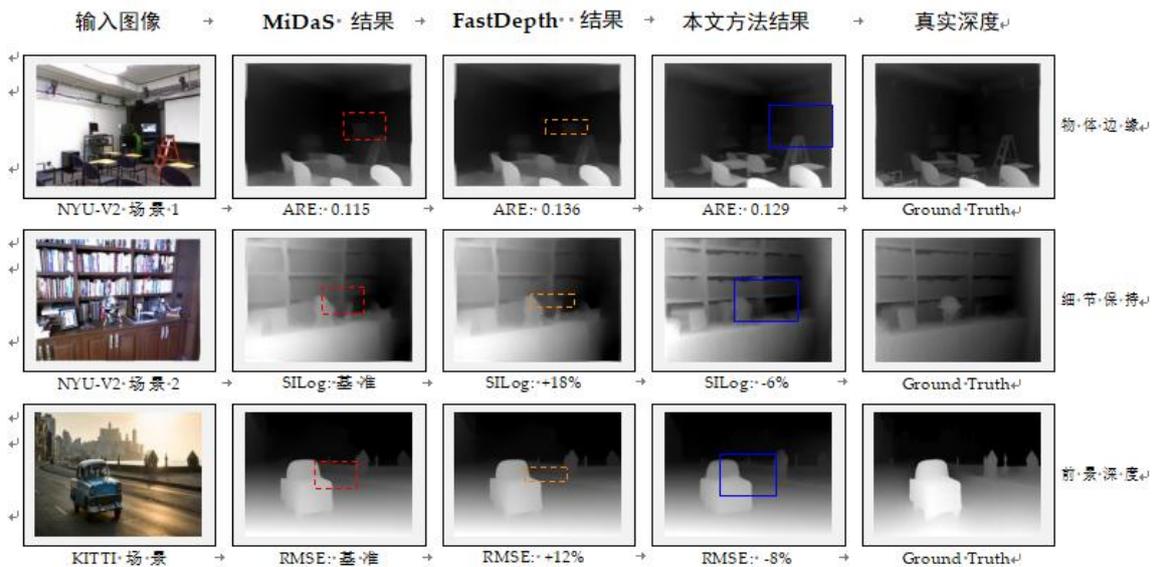


图 2. 不同方法的视觉效果对比。从左到右分别为输入图像、MiDaS 结果、FastDepth 结果、所提方法结果和真实深度。所提方法在边缘清晰度、时序稳定性和语义一致性方面均表现优异。

从实验结果可以看出，所提方法在保持轻量化设计的同时取得了竞争性的性能表现。与同类轻量化方法 FastDepth 相比，该方法在平均相对误差上提升了 6.6%，在阈值精度上提升了 1.7%。虽然与计算密集型方法 MiDaS 和 AdaBins 相比仍有一定差距，但考虑到参数量仅为其 8-12%，这样的性能表现是可以接受的。

从表 I 的右侧可以看出，深度编码器占据了总参数量的 30.7%，多分支修复模块功能最为复杂，参数量为 2.22M，占总参数的 27.3%，3D 视频合成模块参数量为 2.37M，占总参数的 29.2%，体现了所设计方法在保持功能完整性的同时实现轻量化的设计理念。

4.3 视觉质量评估

除了定量指标外，还对生成的 3D 视频进行了视觉质量评估。图 2 展示了所提方法与对比方法的视觉效果对比。可以看出，所提方法生成的深度图具有更清晰的边缘和更好的细节保持能力，特别是在处理复杂场景时表现出明显优势。

在 3D 视频质量方面，所提方法生成的视频具有良好的时序一致性，避免了常见的闪烁和抖动问题。多分支修复机制的引入有效改善了深度估计中的各种缺陷，使得最终的 3D 视频质量得到显著提升。

视频生成效果展示

图 3 展示了所提方法生成 3D 空间视频的完整效果。

从单目输入开始，经过深度估计、多分支修复，最终生成具有多视角观察能力和时序一致性的 3D 视频内容。该方法能够实现从 2D 到 3D 的高质量转换，支持任意视角的观察和流畅的时序变化，为移动 AR、短视频特效、VR 内容自动生成等应用场景提供了有效的技术解决方案。

在 3D 视频质量方面，所提方法生成的视频具有良好的时序一致性，避免了常见的闪烁和抖动问题。多分支修复机制的引入有效改善了深度估计中的各种缺陷，使得最终的 3D 视频质量得到显著提升。



图 3. 空间视频生成完整效果展示。

4.4 消融实验分析

为了验证各个模块的有效性，在 NYU-Depth V2 数据集上进行了详细的消融实验。表 II 展示了不同模块组合的性能表现。

消融实验结果表明，每个模块都对最终性能有积极贡献。空域优化分支主要提升了深度图的空间一致性，时域一致性分支显著改善了视频序列的时序稳定性，语

义约束分支则进一步提升了整体精度。三个分支的协同工作使得最终方法在各项指标上都达到了最优表现。

表 11. 消融实验结果

配置	ARE	RMSE	$\delta 1$	时序稳定性
基础网络	0.158	0.623	0.812	基准
+ 空域优化	0.151	0.615	0.824	+8%
+ 时域一致性	0.147	0.607	0.831	+32%
+ 语义约束	0.142	0.598	0.835	+35%

5 结论

本文提出了一种基于单目深度估计与多分支修复的轻量化 3D 空间视频生成方法。通过设计基于 Slice d MLP 的轻量化网络架构和多分支协同修复机制，成功解决了现有方法在精度与效率之间难以平衡的问题。

实验结果表明，所提方法在保持轻量化设计（8.12 M 参数）的同时，在标准数据集上取得了竞争性的性能表现。多分支修复机制有效改善了深度估计中的边缘模糊、时序不一致等问题，显著提升了 3D 视频的生成质量。

未来工作将重点关注以下几个方向。首先是进一步优化网络结构，探索更高效的轻量化设计策略。其次是扩展方法的适用范围，使其能够处理更多样化的场景类型。最后是结合新兴的神经渲染技术，进一步提升 3D

视频的视觉效果和交互体验。

参考文献

- [1]A. Saxena, S. H. Chung, and A. Y. Ng, "Learning depth from single monocular images," *Advances in neural information processing systems*, vol. 18, 2005.
- [2]S. F. Bhat, I. Alhashim, and P. Wonka, "Ada bins: Depth estimation using adaptive bins," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021, pp. 4009 - 4018.
- [3]S. Niklaus, L. Mai, J. Yang, and F. Liu, "3d ken burns effect from a single image," in *ACM Transactions on Graphics (ToG)*, vol. 38, no. 6. ACM, 2019, pp. 1 - 15.

作者简介：姓名：刘红羽(1997.5.10)；性别：女；民族：土家族；籍贯：重庆；研究方向：深度学习、嵌入式系统开发；单位：重庆对外经贸学院；省市：重庆市 邮编：401520