

文章编号 1004-924X(2026)12-1928-12

解耦漫反射与镜面反射光的可编辑神经纹理映射

曾 升^{1*}, 武向娟¹, 耿国华²

(1. 宁夏大学 信息工程学院, 宁夏 银川 750021;

2. 西北大学, 计算机学院, 陕西 西安 710127)

摘要:解耦三维物体几何与纹理的数据驱动的深度学习能够进行外观编辑,但在局部纹理编辑后通过网络渲染的视图保真度仍有不足,并且由于隐式神经网络端到端的进行视图渲染可控性仍不强,为了像传统方法一样能够灵活编辑物体的外观,提出解耦漫反射与镜面反射光的可编辑外观的神经纹理映射方法。首先,基于物理光照模型构建漫反射、镜面反射及纹理映射三个独立的阶段学习框架。接着,以球状空间采样构建神经辐射场,建立漫反射分量损失函数,在进行真实数据监督学习的同时学习漫反射光照能量分布。然后,基于 3D 高斯泼溅的神经壳网络方法使用多分辨率哈希编码可学习的颜色信息,加入漫反射分量后使用真实图像进行监督学习实现视角相关的镜面反射建模。最后,使用循环一致性纹理映射网络建立独立于颜色空间的位置得到显式的 2D 纹理,并将视角无关的漫反射颜色分量一一对应于纹理贴图,实现编辑纹理图片逆操作神经纹理。实验结果表明:在 DTU 公共数据集上,相较于先进的可编辑纹理的 NeuTex 与 Texture-GS 方法,新视角合成测试集上定量指标的峰值信噪比方面平均提升了 5.6%,感知图像损失平均降低了 18%,在 NeRFSyn 数据集上的结构相似性也具有优势,并且在显式编辑纹理再通过神经网络渲染多视角视图后明显更加清晰。本方法实现了神经纹理的构建与可控的编辑,能够显式地在 2D 纹理上灵活修改神经隐式表达的 3D 模型的外观,且保证了多视角外观的一致性。

关键词:基于物理的渲染;神经辐射场;3D 高斯泼溅;纹理映射

中图分类号:TP394.1;TH691.9 **文献标识码:**A

doi:10.37188/OPE.20263412.1928

CSTR:32169.14.OPE.20263412.1928

Editable neural texture mapping for decoupling diffuse and specular reflections

ZENG Sheng^{1*}, WU Xiangjuan¹, GENG Guohua²

(1. School of Information Engineering, Ningxia University, Yinchuan 750021, China;

2. School of Computer Science, Northwest University, Xi'an 710127, China)

* Corresponding author, E-mail: zengsheng@nxu.edu.cn

Abstract: Data-driven deep learning methods that decouple the geometry and texture of 3D objects enable appearance editing. However, the view fidelity rendered by neural networks remains insufficient after local texture editing, and controllability is still weak due to implicit end-to-end view rendering. To flexibly edit object appearance as in traditional methods, this paper proposed an editable appearance neural texture mapping method that decoupled diffuse and specular reflections. First, a three-stage independent learning

收稿日期:2026-03-27; **修订日期:**2026-05-10.

基金项目:宁夏自然科学基金优秀青年项目项目(No. 2024AAC05032);宁夏重点研发计划引才专项项目项目(No. 2023BSB03020);国家自然科学基金地区科学基金项目(No. 62362056)

framework was constructed based on the physical illumination model, including diffuse reflection, specular reflection, and texture mapping. Next, a neural radiance field was built via spherical spatial sampling, and a loss function for the diffuse reflection component was established to learn the diffuse illumination energy distribution while conducting supervised learning on real-world data. Then, the neural shell network method based on 3D Gaussian splatting employed multi-resolution hash encoding for learnable color information; after incorporating the diffuse reflection component, supervised learning with real images was performed to achieve view-dependent specular reflection modeling. Finally, a cycle-consistent texture mapping network was used to establish position mappings independent of the color space to obtain explicit 2D textures, and the view-independent diffuse color components were mapped one-to-one to texture atlases, realizing the inverse operation of editing texture images for neural textures. Experimental results show that on the public DTU dataset, compared with the state-of-the-art editable texture methods NeuTex and Texture-GS, the peak signal-to-noise ratio (PSNR) on the novel view synthesis test set is improved by an average of 5.6%, and the perceptual image loss is reduced by an average of 18%. It also achieves superior structural similarity on the NeRFSyn dataset. Moreover, the multi-view images rendered by the neural network after explicit texture editing are significantly clearer. The proposed method realizes the construction and controllable editing of neural textures, enabling flexible modification of the appearance of 3D models with neural implicit representations directly on 2D textures while ensuring multi-view consistency of appearance.

Key words: physically based rendering; neural radiance field; 3D Gaussian splatting; texture mapping

1 引言

计算机视觉和图形学研究的真实感场景渲染技术发展对VR,AR等应用提供有力支持。传统渲染管道中使用多边形网格表示3D模型,2D图像存储物体纹理,能够灵活进行外观编辑。近年来,数据驱动的学习方法相较于费时费力的传统方法逐渐成为新的研究范式,但在编辑外观时保真度与实用性仍显不足。可控的灵活编辑隐式表达的物体外观值得深入研究,尤其在文物数字化留存与虚拟展示方面也很有价值。

三维文物的纹理建模对文物虚拟修复与展示十分重要^[1],其纹理映射是传统场景绘制的核心环节,目的是计算3D表面和合适的参数域之间的双射映射,通常需要艺术家基于3D形状进行外观建模。近几年已提出许多基于神经渲染技术的高保真纹理映射方法,能够通过深度学习实现外观建模^[2-4]。基于神经辐射场(Neural Radiance Fields, NeRF)^[5]和3D高斯泼溅(3D Gaussian Splatting, 3DGS)^[6]的纹理建模最具有研究前景。NeuTex^[7]提出一种纹理映射方法,使用解纠缠的三个子网络分别表示场景几何、纹理

映射函数和2D纹理,其中循环映射损失用来正则化纹理映射和逆映射网络,能够得到均匀覆盖物体表面的纹理图,实现了直接在2D纹理空间中进行物体表面外观的编辑。Nuvo使用多个图表分配网络扩展了NeuTex,通过多块纹理图提高纹理映射的精度^[8]。NGF提出统一神经规范场的一般框架,联合优化规范变换和神经场,以较小计算量实现实时变换并保留场景信息^[9]。Iso-UVField着重研究高效的表面参数化学习,基于IDR重建物体的几何形状并通过NeRF获取3D表面位置与2D纹理空间坐标之间的连续双射映射^[10]。Auv-net等专注于特定的人类头部的可编辑神经参数化^[11-12]。基于NeRF的方法在获取物体真实颜色时保真度较高,但由于需要沿着每个观察视角的所有像素光线上的上百个采样点进行最终颜色的计算,训练过程相对缓慢,3D-GS技术的提出为高效的实时神经渲染提供了新的研究方向。

3D高斯泼溅方法中3D高斯的位置、形状、方向、不透明度及颜色等属性都可以进行学习,通过泼溅3D高斯进行渲染极大地提升了执行效率。Textured-GS为每个高斯增加透明通道、

RGB 或 RGBA 纹理贴图,在高斯内部建模空间变化的颜色与不透明度^[13]。Gaussian Grouping 为每个高斯分布添加紧凑的身份编码,使其能够根据 3D 场景中所属的类别进行分组,支持在开放场景中进行细粒度编辑^[14]。Point'n Move 利用 3DGS 快速且显式的特性,实现交互式的 3D 高斯选择和实时编辑^[15]。Feature 3DGS 通过模型蒸馏实现了在任意维度语义特征上的 3D 高斯泼溅,实现了新视角语义分割、语言引导编辑^[16]。PhysGaussian 自定义材质点进行物理模拟来研究 3D 高斯的物理特性,将 3D 高斯视为孤立的着色元素,实现物理模拟和视觉渲染的统一,能够支持变形后的渲染^[17]。NeST-Splatting 引入了神经外壳纹理,使用 2DGS 替换 3DGS 并使用可训练特征向量的多分辨率哈希表来增强神经网络,实现了高效率、精细纹理细节的重建^[18]。Texture-GS 侧重研究物体外观和几何结构分离方法,在以对象为中心的场景中将纹理参数化后用于纹理编辑,实现了高保真的外观编辑^[19]。还有一些外观编辑方法专注于语义编辑,然而它们无法执行细节小于 3D 高斯的细粒度编辑^[20-21]。

传统数字化建模时通过多边形网格表示形状,二维纹理贴图表示外观,几何与外观的分离支持灵活的编辑。近年来,随着三维场景重建深

度学习方法的发展,基于 Nerf 和 3D 高斯泼溅的纹理映射方法越来越受到关注。然而,缺乏显式信息的神经网络模型虽然在重建结果上越来越精细,但由于其内部的不可解释性难以按照所见即所得的方式进行编辑。NeuTex 首次基于 NeRF 解耦了模型几何和纹理,提出循环一致性损失以保证纹理映射的双射性,但不同视角需要建立不同的 2D 纹理图进行建模。Texture-GS 基于高斯泼溅方法完全分离几何和纹理,分别在不同阶段进行学习,但由于单个高斯覆盖的像素具有不同的 UV 坐标,在进行纹理编辑时通过训练后的网络计算最终结果会产生伪影,难以维持一一映射带来的编辑优势。为了与传统方法灵活的三维建模工作方式一样,提出解耦漫反射与镜面反射光的可编辑神经纹理映射方法,使用三阶段学习策略,将显式信息融合到学习过程中,支持保证多视角一致的 3D 模型外观编辑的深度学习方法。

2 解耦漫反射与镜面反射光的可编辑神经纹理映射方法

2.1 总体架构

本文方法架构如图 1 所示,输入为多视角真




图 1 解耦漫反射与镜面反射光的可编辑神经纹理映射的整体框架

Fig. 1 Overall framework of editable neural texture mapping for decoupling diffuse and specular reflected light

实图像,分离物体的几何与外观分别用于构建纹理映射学习网络与漫反射-镜面反射解耦学习网络。几何部分通过循环一致性损失构建纹理映射并添加显式的控制中心点实现灵活编辑。外观部分基于 Cook-Torrance 模型将物体外观作为漫反射与镜面反射光叠加后的效果,通过基于 NeRF 和 3D 高斯泼溅的方法分别进行漫反射及镜面反射的学习,最终获取保持多视角一致的神经纹理,并实现灵活的外观编辑。

NeuTex 基于 NeRF 使用多层感知机网络编码场景几何,提出正逆映射网络学习空间位置与纹理之间的映射关系,再通过渲染损失进行训练形成完整的端到端学习网络,实现了显式的编辑 2D 纹理修改隐式网络模型从而推理得到多视角一致的渲染视图。Texture-GS 基于 3D 高斯泼溅方法将几何与外观完全分离进行学习以实现高效的外观编辑,其纹理映射模块也通过循环一致约束实现 3D 空间和 UV 纹理域之间的映射关系学习,然后使用光度损失和泰勒展开的 MLP 近似学习 2D 纹理值,并允许单个高斯覆盖的像素具有不同的 UV 坐标从而避免纹理退化。然而,真实图像是在特定光照射在物体上进行相互作用的结果,不同角度看到的外观并不相同,不同角度产生不同的 2D 纹理或者从 2D 纹理查询高斯颜色属性后通过可微高斯泼射获取纹理值限制了纹理编辑的灵活性与适用性。本文解耦的学习漫反射与镜面反射,2D 纹理为显式的漫反射纹理保证了不同观察角度颜色的一致性,镜面反射使用基于 3D 高斯泼溅的神经纹理来表达不同角度的镜面反射分量,纹理映射网络沿用循环一致约束方式进行学习,构建自适应中心点权重计算方法建立空间位置与 2D 纹理的关联以支持纹理编辑的可控性,通过三阶段独立的学习网络完成纹理映射,能够灵活编辑 2D 纹理达到隐式神经网络多视角渲染视图编辑的效果。

Cook-Torrance 反射模型是基于物理渲染的双向分布函数模型,描述了光线与物体表面的交互过程,适合作为基于深度学习方法光照模型的理论依据^[22]。反射的几何关系如图 2 所示, p 表示表面上的点, v 代表观察者方向单位矢量, l 是光源方向单位矢量, n 是垂直于表面的法线。入射光的能量为反射表面每单位时间每单位面积




图 2 光照反射几何关系

Fig. 2 Geometric Relationship of Light Reflection

的能量,入射能量为 $E_i = I_i(nl)d\omega_i$,反射方向上的反射强度与另一方向的入射能量之比为双向反射率 R 。将每个光源到达观察者的反射强度分为漫反射分量与镜面反射分量,则可以得到入射光强和反射光强的关系,如式(1)所示:

$$I_r = I_i(sR_s + dR_d)(nl)d\omega_i, \quad (1)$$

其中: I_r 是出射光强, I_i 是入射光强, R_s 是双向反射率的漫反射分量, R_d 是镜面反射分量, $s + d = 1$, n 是单位法线, l 是光照方向单位向量, $d\omega$ 是入射光束的立体角微元。设定出射光强由入射光经漫反射分量与镜面反射分量线性叠加后计算得到,其中漫射分量在半球方向上均匀地反射光,镜面分量在不同方向上反射不同强度的光。依据此物理模型进行漫反射及镜面反射网络及损失函数的构建,不仅可以在纹理编辑后保证多视角渲染视图的一致性还可以进行光照的修改替换。

2.2 漫反射纹理学习模型

2.2.1 神经网络结构

漫反射纹理学习模型基于 NeRF 进行构建,隐式地学习三维空间辐射场,有效生成物体任意视角的图像,每个像素的颜色通过体渲染进行计算,如式(2)所示:

$$I = \sum_i \exp\left(-\sum_{j=1}^{i-1} \sigma_j \delta_j\right) (1 - \exp(-\sigma_i \delta_i)) c_i, \quad (2)$$

其中: I 是辐射强度, σ 是体积密度, δ 是两个连续采样点之间的距离, c 是辐射光线上点的辐射值,

$\exp\left(-\sum_{j=1}^{i-1}\sigma_j\delta_j\right)$ 为透射率。

在光线上采样的空间点 (x, y, z) 和射线方向 (θ, ϕ) 都进行正弦余弦位置编码后输入全连接网络中进行预测。与 NeuTex 不同, 本文仅对空间采样点进行编码, 将立方体采样区域改为球体区域进行采样, 增加散射项与高光项的 MLP 进行学习, 并依据漫反射视角无关的特性构建损失函数。其中 $F_o(x)$ 编码几何预测体积密度, $F_s(x, d)$ 预测高光项, $F_d(x, d)$ 预测散射项, x 是空间坐标, d 是视线方向。在球体区域内进行空间点采样, 每个神经网络都使用 10 层 MLP, ReLU 作为激活函数, 最终预测的颜色 RGB 由散射项和高光项叠加获得, 记录散射项与高光项的能量比值用于后续自适应中心点散射纹理计算, 再计算密集近邻点位置权重后导出 2D 散射纹理。由于高光项高频信息难于准确估计, 此部分重点获取散射项并存储为显式纹理便于快速查询获取, 高光项部分进行近似估计, 合并计算时由后续基于 3D 高斯泼溅的方法进行预测, 既提升了高频信息的预测效果又大幅提升了推理效率。

2.2.2 损失函数

在训练网络模型时使用渲染损失、漫反射损失和掩码损失。渲染损失使用真实图像的像素值来监督光线体渲染计算后得到的颜色, 如式(3)所示:

$$L_r = \|I_{\text{gt}} - I\|_2^2, \quad (3)$$

其中: I_{gt} 为真实像素值, I 为渲染图像像素值, 该损失是训练网络预测最终数据与真实数据差距减小的关键。

漫反射损失根据漫反射出射光辐射强度向各个方向均匀反射的特点进行设计, 依据反射模型将光线辐射强度拆解为漫反射光与镜面反射光强的叠加, 漫反射光在以反射方向为中心的半球上随机取反射方向, 预测光照强度时构建的损失如式(4)所示:

$$L_d = \|I_d - I_{\text{random}}\|_2^2, \quad (4)$$

其中: I_d 是漫反射网络预测的光辐射强度特征, I_{random} 是此反射方向半球范围内的随机方向预测结果, 该损失保证此部分网络预测的反射的辐射强度在各个方向是一致的。

掩码损失监督是为了背景区域不影响视图

区域训练, 保证计算像素值在有效的范围, 通过真实的掩膜来进行监督, 如式(5)所示:

$$L_{\text{mask}} = \|M_{\text{gt}} - (1 - T_N)\|_2^2, \quad (5)$$

其中: M_{gt} 是真实的掩膜数据, T_N 是最后一个着色点的透射率, 以判断辐射光线是否在背景区域。训练时的总损失如式(6)所示:

$$L_{\text{total}} = L_r + L_d + L_{\text{mask}}. \quad (6)$$

2.3 镜面反射纹理学习模型

基于 NeRF 的方法具有连续性, 但光线辐射强度预测速度慢, 通过查询来获取视角无关的漫反射纹理可以提升速度, 但多视角相关的光线辐射强度等高频信息预测效果不佳。基于 3D 高斯泼溅的场景表示与渲染方法可以大幅提升多视角图像训练的效率, NeST-Splatting 引入高分辨率哈希表有效的编码了高频信息, 非常适合实现镜面反射纹理学习模型, 通过联合漫反射数据进行训练可以得到保真的渲染图像。3D 高斯点一般用中心位置、缩放、旋转、透明度及与方向相关的球谐函数 SH 来进行表达, NeST-Splatting 使用 2DGS 替代 3DGS 表达, 渲染每个像素颜色的计算公式如下:

$$c(x) = \sum_{i=1}^n T_i \alpha_i G_i^{2D}(x) c_i, \quad (7)$$

其中: $T_i = \prod_{j=1}^{i-1} (1 - \alpha_j G_j^{2D}(x))$, α 是不透明度, $G_j^{2D}(x)$ 是由高斯点缩放与旋转参数的 3D 协方差矩阵投影到 2D 平面的矩阵, c 是视角相关的球谐颜色 SH。本方法为了建立漫反射与镜面反射分别建模的目的, 在沿用 NeST-Splatting 方法时, 将镜面反射项看作真实图像除去散射光强产生的颜色的残差进行学习。

损失函数由颜色损失、深度失真损失与掩膜损失组成, 计算公式如下:

$$L = L_c + L_d + L_{\text{mask}}, \quad (8)$$

其中: L_c 计算去除散射的残差视图的损失, 使用 L_1 与 L_{ssim} 联合, 其中 $L_1 = \|I_{\text{gt}} - I_d - I\|_2^2$, L_{ssim} 通过 $\text{SSIM}(I_{\text{gt}}, I_d + I)$ 计算, L_d 损失沿用 2DGS 的深度失真损失^[23], 以及与式(5)一致的掩码损失组成为总损失进行训练。

2.4 纹理映射学习模型

2.4.1 神经网络模型

NeuTex 提出使用正向和逆向网络保证 3D-

2D 映射网络的一一映射关系,并联合渲染网络进行训练,Texture-GS 完全独立出此正逆向网络对约束于基础表面附近的点进行 uv 映射,类似的,本文 uv 映射学习模型也利用循环一致性约束来学习网络。但为了结合散射纹理灵活编辑外观,离线的计算射线与近似表面交点,并将 3D 点映射到 2D 空间以存储对应的纹理。 $F_{uv}(x)$ 是映射 3D 表面点到二维 uv 坐标的多层感知机网络, $F_{uv}^{-1}(u)$ 是二维 uv 坐标逆向映射到 3D 点的多层感知机网络,使用立方体贴图将球面纹理对应到平面图像。由 3D 映射到 2D 的损失计算式子如下:

$$L_{3D} = \frac{1}{N_d} \sum_{i=1}^{N_d} \|x_i - F_{uv}^{-1}(F_{uv}(x_i))\|, \quad (9)$$

其中: N 是 3D 点数量, x_i 是空间 3D 点。由 2D 映射到 3D 的损失计算式子如下:

$$L_{2D} = \frac{1}{N_u} \sum_{i=1}^{N_u} \|u_i - F_{uv}(F_{uv}^{-1}(u_i))\|, \quad (10)$$

其中: N 是 2D 纹理坐标的采样数量, u_i 是 2D 空间坐标。为了让 2D 纹理坐标能够均匀地覆盖表面,还需要将均匀分布的 uv 坐标通过网络映射到 3D 空间,与物体近似几何表面点云数据计算倒角距离损失,计算公式如下:

$$L_{CD} = \frac{1}{S_u} \sum_{i=1}^{N_u} \min_{p_j \in P} \|p_j - (F_{uv}^{-1}(u_i))\| + \frac{1}{S_p} \sum_{j=1}^{N_p} \min_{u_i \in U} \|p_j - (F_{uv}^{-1}(u_i))\|, \quad (11)$$

其中: S_u 是均匀采样 uv 坐标集合, S_p 是真实表面采样 3D 点集合。总损失计算公式如下:

$$L_{UV} = L_{3D} + L_{2D} + L_{CD}. \quad (12)$$

2.4.2 自适应中心点

为了提升在显式 2D 纹理上编辑以修改多视角渲染视图的细节精度且降低算力的使用,构建自适应中心点选取及纹理查询计算方法。物体近似表面可以由几何预测网络获取或用传统的 Colmap 方法进行计算。基于微小邻近区域表面性质基本一致的考虑,通过大量的光线与物体表面的密集交点计算自适应体素中心点作为纹理插值的近邻权重依据,在使用 2D 纹理编辑 3D 外观时,将计算光线与表面的交点归类于中心点区域,再通过近邻点权重计算近邻颜色值作为散射项。中心点采样根据 3D 点云分布密度动态调整体素大小,依据算力条件选定体素大小后均匀划

分空间,并选取离体素中心最近的点作为采样点。每个原始点都可以用近邻的中心点进行表示,计算公式如下:

$$P_i = \sum_{j \in \Gamma(i)} \omega_{ij} C_j, \quad (13)$$

其中: Γ 是 P_i 点的邻接点集合, ω_{ij} 是邻接点距离的权重, C 是计算自适应体素得到的中心点。其他近似表面点都由中心点通过加权计算,将散射项输入镜面反射模块叠加多视角的高光项得到最终渲染视图。通过实验证明了本方法的有效性,能够在获取的平面纹理上进行文字添加和光照变化,并在通过模型进行渲染后保持多视角的一致性。

3 实验结果与分析

3.1 实验设置

本文在真实环境下采集文物图像进行纹理映射,并在公共的 DTU 与 NeRFSyn 数据集上进行实验。DTU 数据集与 NeuTex, Texture-GS 使用的实验数据一样,对单个对象场景进行定量实验,每个场景包含 49 个不同视角的图像,将其中 45 个视图作为训练数据,保留 4 个视图作为测试视图,通过新视角预测的结果进行评估。在 NeRF-Syn 数据集中,使用纹理丰富的 hotdog 与 chair、复杂形状的 lego 及薄结构的 mic 这 4 个场景进行实验,其训练集都为 100 个不同视角的图像,测试集为 200 个不同视角的图像。定性比较对比 2D 纹理编辑后的多角度渲染视图的效果,定量比较对比测试集上新视角合成的峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、学习感知图像块相似性(Learned Perceptual Image Patch Similarity, LPIPS)以及结构相似性(Structural Similarity Index Measure, SSIM)。在漫反射纹理学习模块,所有场景数据都归一化到单位球中,每个像素的光线都在球体内进行分层采样,每条射线采样点为 128,使用本文的损失函数训练迭代 600 000 次。镜面反射纹理学习模块训练迭代 30 000 次,uv 映射学习模块迭代 15 000 次。所有实验在 RTX4090GPU 上运行,每个场景数据的漫反射纹理学习部分平均需要 87 h,镜面反射纹理学习部分平均 1.8 h,uv 映射学习部分平均 0.5 h。

依据本文提出的方法,与视角无关的漫反射存储为 2D 纹理,视角相关的高频纹理通过镜面

反射纹理网络计算。图 2(a)是用相机拍摄的飞天图案石板文物的真实去除背景后的图像,图 2(b)是经过漫反射纹理学习网络渲染的视图,图 2(c)是使用 cubemap 算法导出自己拍摄文物场景数据的 2D 漫反射纹理。渲染图像与真实图像相比存在一些虚影,但不放大观察难以区分,映射的 2D 纹理也基本均匀地布满球体区域,验证了本方法在实际数据中的有效性。




图 3 飞天图案石板文物的纹理映射结果

Fig. 3 Texture mapping results of the cultural relic stone slab with flying apsaras pattern

3.2 对比实验

3.2.1 纹理编辑

为了验证本方法灵活编辑外观的效果,在 2D 纹理上增加点光源的光照以改变显式纹理,在 2D 纹理中查询散射项后经过镜面反射模块进行多视角渲染。

如图 4 所示,图上方是两个 2D 纹理在不同位置加了两个点光源后纹理的变化结果,图下方是本方法通过加载 2D 纹理后再进行渲染的效果。



图 4 2D 纹理添加不同点光源后的渲染效果

Fig. 4 Rendering effects of 2D textures with different point light sources added

红框处可以明显看到佛像右胸部分明显的光照加强,以及右侧佛像底座明显的亮度加大(彩图见期刊电子版)。实验说明了本方法能够灵活有效地通过显式信息控制隐式网络进行外观编辑。

在细粒度纹理编辑方面,本文的方法在导出的漫反射 2D 纹理上添加红色文字 OPE,经过镜面反射模块加入高光项进行多视角的渲染。如图 5 所示,在 DTU114 模型上与 Texture-GS 的方法进行对比,左侧的所有图是 Texture-GS 方法的实验结果,右侧图是本文方法的结果。图中最上一行的 2D 纹理都按本文方法进行局部修改,此时的纹理并不包含镜面反射项。图中下面两个图像是经过模型进行多视角渲染的结果,可以看出本文的方法与 Texture-GS 方法相比,明显在 2D 纹理编辑后渲染的视图的多视角一致性更好,新添加的文字并没有出现变弱及重影等情况,并且高光部分的真实感更强(彩图见期刊电子版)。

为了说明纹理编辑的适用性,在形状特征各异的 NeRFSyn 数据集上进行实验。由于正逆向纹理映射网络本身主要面向单个对象,并且对于形状变化尖锐,存在薄壁结构及孔洞的对象难以生成精确的 2D 坐标。如图 6 所示,上面一行为 hotdog 场景在 2D 纹理上添加 OPE 后,通过本方法渲染的 2 个不同视角的结果,下面一行为存在孔洞的 chair 场景纹理编辑的结果。可以看出,在 2D 纹理进行编辑后 3D 空间文字会根据物体 3D 表面的形状变形,在形状变化平缓的区域文字信息扭曲较小,但在形状突变或原模型存在孔洞的形状上应用编辑时,扭曲较为明显,图中椅子上的文字在 3D 空间中字母 O 变化尤为明显。原因是在进行纹理映射时,形状突变或大孔洞造成原空间位置无法均匀地映射到纹理空间,多分块纹理是潜在的解决方案,但又会存在割缝过多难以对齐的问题,这也是后续值得深入研究的问题。

为了进一步说明应用本方法进行纹理编辑的时间开销,进行时效性分析。如表 1 所示,在 DTU 与 NeRFSyn 数据集上分别统计本方法中不同阶段的耗时,这两个数据集的时间差异是由训练和测试图像的数量差异造成的。在训练阶段漫反射网络非常耗时,镜面反射网络训练速度明显较快,这是由于 NeRF 方法和 3D 高斯方法的差异造成的。

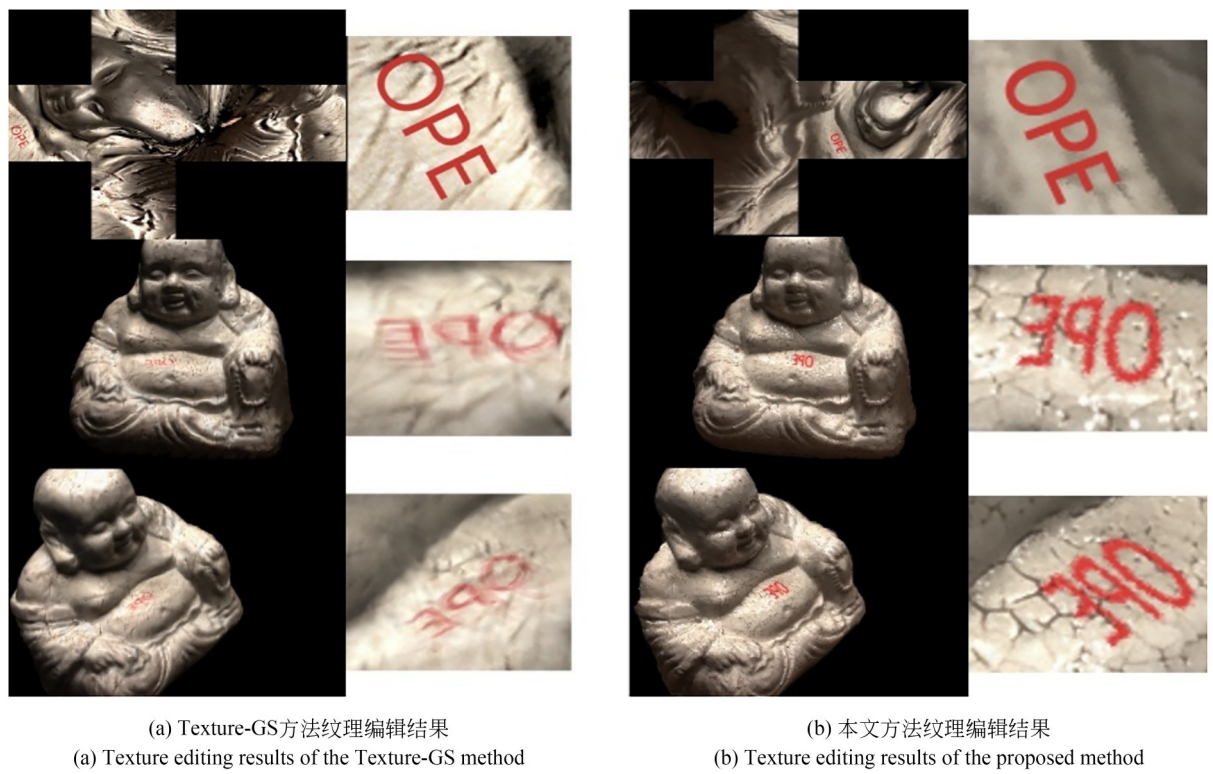


图 5 与 Texture-GS 方法的纹理编辑对比
Fig. 5 Comparison of texture editing with the texture-GS method




图 6 NeRFSyn 数据集中 hotdog 与 chair 场景的纹理编辑结果
Fig. 6 Texture editing results of the hotdog and chair scenes in the NeRFSyn dataset

本方法的理论基础是漫反射时不同视角具有相同的反射能量,需要连续的空间进行学习,而且保证了在 2D 纹理编辑后,再渲染时以漫反射方式进行叠加,所以 NeRF 方法必不可少。镜面反射项在各方向都会有所变化,使用基于 3D 高斯泼溅的方法进行学习,足够密集的高斯基元能够具备较高的渲染精度,并且渲染推理速度高效。纹理编辑阶段,每个新视图渲染耗时主要是导入编辑后的 2D 纹理后,需要计算渲染视图像素光线的中心点区域分组并根据相邻位置权重获取散射纹理颜色,每张视图平均耗时在 1 min 左右。可见本方法在训练阶段耗时较多,但在推理使用阶段可高效可用。

表 1 本方法时效性分析
Tab. 1 Comparison of quantitative metrics on the novel view synthesis test set

	漫反射网络训练 阶段	镜面反射网络 训练阶段	渲染推理阶段	纹理 编辑
DTU 数据集平均耗时	>87 h	1.8 h	0.8 min	0.9 min/视图
NeRF-Syn 数据集平均耗时	>108 h	2.1 h	1.2 min	1.1 min/视图

3. 2. 2 新视角合成

本文的方法还与先进的专注于外观编辑的方法在新视角合成方面进行定量比较。与 NeuTex 及 Texture-GS 方法使用的数据一致,都来自 DTU 的真实 5 个场景数据,在 49 或 64 个视图数据中保留 4 个视图作为测试数据,与公开代码一样使用第 6,13,30,35 个视图进行测试,用其他视图作为训练数据进行训练。评估使用峰值信噪比 PSNR 及学习感知图像相似性 LPIPS 指标。

与几种先进的分离几何和外观的编辑方法进行比较,包括 NeuTex^[8], Neural Gauge

Fields^[9], 3DGS^[6] 及 Texture-GS^[19], 这些算法的定量数据来自 Texture-GS。如表 2 所示,本文方法在 5 个场景测试集上的平均 PSNR 指标(越高越好)都高于其他方法,平均提升 5.6%,在 LPIPS 指标(越低越好)上也仅次于 3DGS 的结果。可见本文方法不仅支持灵活的纹理编辑,在新视角合成方面也具备竞争力。图 6 是模型新视角合成渲染的视图与真实视图的对比,图中上面部分为真实图像,下面部分为新视角合成的图像,可以明显看出非常接近真实数据的情况下,不放大仔细观察难以察觉差异。

表 2 DTU 数据集新视角合成测试集定量指标对比

Tab. 2 Quantitative metric comparison on DTU dataset novel view synthesis test set

	NeuTex	NGF	3DGS	Texture-GS	本文方法
PSNR	30.39	29.44	30.99	30.03	32.03
LPIPS	0.161 3	0.150 6	0.107 9	0.144 0	0.124 6



图 7 真实图像与本方法渲染图像的对比图

Fig. 7 Comparison between the real image and the rendered image by the proposed method

在多个不同特征的 NeRFSyn 数据集上与 NeuTex^[8], Texture-GS^[19] 及 NeuMesh^[24] 方法进行对比。如表 3 所示,本文方法在 PSNR 与 LPIPS 指标上优于 NeuTex,略弱于 Texture-GS 及 NeuMesh。在 SSIM 指标上优于其他方法。可见在颜色丰富形状复杂的数据上本方法细节

噪声仍有待改善,但纹理结构相似性具有优势。其中 NeuMesh 方法使用另外的思路进行外观编辑,直接在视图上编辑而不用考虑 uv 映射的失真,但需要在微调时考虑其他视角下纹理编辑的一致性,新视图越多,需要的微调工作就越多。

表 3 NeRFSyn数据集新视角合成测试集定量指标对比
Tab. 3 Quantitative metric comparison on NeRFSyn dataset novel view synthesis test set

	NeuTex	Texture-GS	NeuMesh	本文的方法
PSNR	25.718	28.97	30.945	28.51
LPIPS	0.109	0.055	0.058	0.067
SSIM	0.914	0.938	0.951	0.960

3.2.3 消融实验

为了分析本方法的几个关键环节的有效性以及算法应用于实际的适用性,进行了消融实验。DTU114数据集的镜面反射项尤为突出,在数据集中其定量评估指标相对其他场景指标较低,以此场景来分析漫反射网络中漫反射模块及球体空间采样的有效性,更能体现本方法的优势。

如表 4 所示,在无漫反射模块时的 PSNR 为 28.43,SSIM 为 0.776,在加入漫反射无球体空间采样时 PSNR 为 28.49,SSIM 为 0.809,在使用这些方法时 PSNR 为 28.91,SSIM 为 0.826。从定量指标上看这些模块都稳步提升了此网络的效果,尤其在定性的渲染图像上更明显地能看到高频的高光项建模更接近真实图像。在分析漫反射网络中漫反射项与高光部分的系数时,使用训练集数据重新渲染后的定量指标进行比较,最终选择 0.5 为最佳效果。

为了验证镜面反射纹理学习模型在不同视角下高光项的提升,在训练集上进行对比,如表 5 所示,在加入镜面反射纹理学习模块后指标有所

表 4 漫反射模块与球体空间采样消融实验
Tab. 4 Diffuse module and sphere space sampling ablation experiments

	PSNR	SSIM
无漫反射模块	28.43	0.776
无球体空间采样	28.49	0.809
本方法	28.91	0.826

参考文献:

[1] 周明全,褚彤,耿国华,等. 结构与纹理融合的三维文物孔洞修复方法[J]. 光学精密工程, 2022(8): 894-907.

提升。虽然从定量指标上来看提升不是非常明显,但从定性的渲染视图上对比,无镜面反射纹理学习模块时反射的高光区域与真实图像比较差异较为明显,但在加入此模块后的渲染视图即使放大后也很难搜寻到图像差异。

表 5 镜面反射纹理学习网络消融实验
Tab. 5 Specular Reflection texture learning network ablation experiments

	PSNR	SSIM
无镜面反射纹理学习网络	31.02	0.823
有镜面反射纹理学习网络	32.13	0.941

4 结 论

本文根据现代计算机图形学对纹理映射灵活编辑的要求,提出了解耦漫反射与镜面反射光的可编辑神经纹理映射的深度学习方法。介绍了基于物理渲染的光反射模型作为理论基础,研究了解耦漫反射与镜面反射光的可编辑神经纹理映射方法,提出了漫反射、镜面反射及纹理映射网络独立学习的方法框架与算法。最后,给出了编辑显式 2D 纹理实现可控的神经网络编辑外观方法。实验结果证明:在 DTU 新视角合成测试集上定量指标的峰值信噪比方面平均提升了 5.6%,感知图像损失平均降低了 18%,在 NeRF-Syn 数据集上的结构相似性也具有优势。定性结果验证了显式编辑纹理再通过神经网络渲染多视角视图后明显具有更高的保真度,满足了显式信息控制隐式网络进行灵活编辑外观的要求。

作者贡献声明:

曾 升:方法提出与实验设计,论文构思和撰写;
武向娟:数据的分析与优化算法的分析;
耿国华:论文的研究方法策划指导与审核。

ZHOU M Q, CHU T, GENG G H, *et al.* Three-dimensional cultural relic hole repair method combining structure and texture[J]. *Opt. Precision Eng.*, 2022(8): 894-907. (in Chinese)
[2] HENZLER P, MITRA N J, RITSCHEL T.

- Learning a neural 3D texture space from 2D exemplars[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 8353-8361.
- [3] THIES J, ZOLLHÖFER M, NIEßNER M. Deferred neural rendering: image synthesis using neural textures [J]. *ACM Transactions on Graphics*, 2019, 38(4): 1-12.
- [4] LIU R, SUN D, CHEN M D, *et al.* Deformable beta splatting[C]. *Proceedings of the Special Interest Group on Computer Graphics and Interactive Techniques Conference Conference Papers. Vancouver BC Canada*. ACM, 2025: 1-11.
- [5] MILDENHALL B, SRINIVASAN P P, TANCIK M, *et al.* NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis[M]. Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 405-421.
- [6] KERBL B, KOPANAS G, LEIMKUEHLER T, *et al.* 3D Gaussian splatting for real-time radiance field rendering[J]. *ACM Transactions on Graphics*, 2023, 42(4): 1-14.
- [7] XIANG F B, XU Z X, HAŠAN M, *et al.* NeuTex: neural texture mapping for volumetric neural rendering [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021, Nashville, TN, USA. IEEE, 2021: 7115-7124.
- [8] SRINIVASAN P P, GARBIN S J, VERBIN D, *et al.* Nuvo: neural UV mapping for unruly 3D representations [C]. *Computer Vision-ECCV 2024*. Cham: Springer, 2025: 18-34.
- [9] ZHAN F N, LIU L J, KORTYLEWSKI A, *et al.* General neural gauge fields[EB/OL]. 2023: *arXiv*: 2305.03462. <https://arxiv.org/abs/2305.03462>
- [10] DAS S, MA K, SHU Z X, *et al.* Learning anIsometric surface parameterization for texture unwrapping[C]. *Computer Vision-ECCV 2022*. Cham: Springer, 2022: 580-597.
- [11] CHEN Z Q, YIN K X, FIDLER S. AUV-net: learning aligned UV maps for texture transfer and synthesis [C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 1455-1464.
- [12] MA L, LI X Y, LIAO J, *et al.* Neural parameterization for dynamic human head editing[J]. *ACM Transactions on Graphics*, 2022, 41(6): 1-15.
- [13] CHAO B, TSENG H Y, PORZI L, *et al.* Textured gaussians for enhanced 3D scene appearance modeling [C]. 2025 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 10-17, 2025, Nashville, TN, USA. IEEE, 2025: 8964-8974.
- [14] YE M Q, DANELLJAN M, YU F, *et al.* Gaussian grouping: segment and edit anything in 3D scenes [C]. *Computer Vision-ECCV 2024*. Cham: Springer, 2025: 162-179.
- [15] HUANG J J, YU H C, ZHANG J J, *et al.* Point'n Move: Interactive scene object manipulation on Gaussian splatting radiance fields[J]. *IET Image Processing*, 2024, 18(12): 3507-3517.
- [16] ZHOU S J, CHANG H R, JIANG S C, *et al.* Feature 3DGS: supercharging 3D gaussian splatting to enable distilled feature fields [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 21676-21685.
- [17] XIE T Y, ZONG Z S, QIU Y X, *et al.* Phys-Gaussian: physics-integrated 3D gaussians for generative dynamics [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 4389-4398.
- [18] ZHANG X, CHEN A P, XIONG J C, *et al.* Neural shell texture splatting: more details and fewer primitives [C]. 2025 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 19-25, 2025, Honolulu, HI, USA. IEEE, 2026: 25229-25238.
- [19] XU T X, HU W B, LAI Y K, *et al.* Texture-GS: Disentangling the Geometry and Texture for 3D Gaussian Splatting Editing[M]. Computer Vision - ECCV 2024. Cham: Springer Nature Switzerland, 2024: 37-53.
- [20] WU J, BIAN J W, LI X H, *et al.* GaussCtrl: multi-view consistent text-driven 3D gaussian splatting editing [C]. *Computer Vision-ECCV 2024*. Cham: Springer, 2025: 55-71.
- [21] ZHUANG J Y, KANG D, CAO Y P, *et al.* TIP-editor: an accurate 3D editor following both text-prompts and image-prompts [J]. *ACM Transac-*

- tions on Graphics, 2024, 43(4): 1-12.
- [22] LIANG Z H, ZHANG Q, FENG Y, *et al.* GS-IR: 3D gaussian splatting for inverse rendering [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 21644-21653.
- [23] HUANG B B, YU Z H, CHEN A P, *et al.* 2D gaussian splatting for geometrically accurate radiance fields[C]. *Special Interest Group on Computer Graphics and Interactive Techniques Conference Conference Papers. Denver CO USA. ACM*, 2024: 1-11.
- [24] YANG B B, BAO C, ZENG J Y, *et al.* NeuMesh: Learning Disentangled Neural Mesh-based Implicit Field for Geometry and Texture Editing[M]. Computer Vision-ECCV 2022. Cham: Springer Nature Switzerland, 2022: 597-614.

通讯作者:



曾 升(1986—),男,宁夏银川人,博士,准聘副教授,2008年于中南大学获得硕士学位,2022年于西北大学获得博士学位,现为宁夏大学信息工程学院教师,主要从事文物数字化、计算机视觉及虚拟现实方面的研究。E-mail: zengsheng@nxu.edu.cn



耿国华(1955—),女,山东莱西人,博士,教授,博士生导师,1988年于西北大学获得硕士学位,2002年于西北大学获得博士学位,现任文化遗产数字化国家地方联合工程研究中心主任,主要从事计算机图形图像处理与可视化、智能信息处理与模式识别等方面的研究。E-mail: ghgeng@nwu.edu.cn

作者简介:



武向娟(1985—),女,宁夏银川人,博士,副教授,2012年于南京信息工程大学获得硕士学位,2022年于西安电子科技大学获得博士学位,现为宁夏大学信息工程学院教师,主要从事计算智能、多目标优化、图像目标识别等方面的研究。E-mail: xjwu@nxu.edu.cn